Metodologija vrjednovanja kvalitete u korištenju aplikacijama Web 2.0

Orehovački, Tihomir

Doctoral thesis / Disertacija

2013

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics Varaždin / Sveučilište u Zagrebu, Fakultet organizacije i informatike Varaždin**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:979764

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-25**

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu

Fakultet organizacije i informatike

Tihomir Orehovački

METODOLOGIJA VRJEDNOVANJA KVALITETE U KORIŠTENJU APLIKACIJAMA WEB 2.0

DOKTORSKI RAD

Varaždin, 2013.

University of Zagreb

Faculty of Organization and Informatics

Tihomir Orehovački

METHODOLOGY FOR EVALUATING THE QUALITY IN USE OF WEB 2.0 APPLICATIONS

DOCTORAL THESIS

Varaždin, 2013.

PODACI O DOKTORSKOM RADU

I. AUTOR

Ime i prezime	Tihomir Orehovački
Datum i mjesto rođenja	24. kolovoza 1982., Koprivnica
Naziv fakulteta i datum diplomiranja na VII/I stupnju	Fakultet organizacije i informatike, 11. veljače 2005.
Sadašnje zaposlenje	Fakultet organizacije i informatike

II. DOKTORSKI RAD

Naslov	Metodologija vrjednovanja kvalitete u korištenju aplikacijama Web 2.0
Broj stranica, slika, tablica, grafikona, priloga, bibliografskih podataka	488 stranica, 57 slika, 131 tablica, 6 grafikona, 7 priloga, 498 bibliografskih podataka
Znanstveno područje i polje iz kojeg je postignut doktorat znanosti	Društvene znanosti, Informacijske i komunikacijske znanosti
Mentori ili voditelji rada	Izv. prof. dr. sc. Dragutin Kermek Prof. dr. sc. Andrina Granić
Fakultet na kojem je obranjen doktorski rad	Fakultet organizacije i informatike
Oznaka i redni broj rada	

III. OCJENA I OBRANA

Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena tema	14. srpnja 2011.
Datum predaje rada	28. lipnja 2013.
Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena pozitivna ocjena rada	10. rujna 2013.
Sastav povjerenstva koje je rad ocijenilo	Prof. dr. sc. Alen Lovrenčić, Izv. prof. dr. sc. Marjan Krašna, Prof. dr. sc. Vesna Dušak, Prof. dr. sc. Andrina Granić, Izv. prof. dr. sc. Dragutin Kermek
Datum obrane doktorskog rada	27. rujna 2013.
Sastav povjerenstva pred kojim je rad obranjen	Prof. dr. sc. Alen Lovrenčić, Izv. prof. dr. sc. Marjan Krašna, Prof. dr. sc. Vesna Dušak, Prof. dr. sc. Andrina Granić, Izv. prof. dr. sc. Dragutin Kermek
Datum promocije	

Sveučilište u Zagrebu

Fakultet organizacije i informatike

Tihomir Orehovački

METODOLOGIJA VRJEDNOVANJA KVALITETE U KORIŠTENJU APLIKACIJAMA WEB 2.0

DOKTORSKI RAD

Mentori:

Izv. prof. dr. sc. Dragutin Kermek
Prof. dr. sc. Andrina Granić

Varaždin, 2013.

University of Zagreb

Faculty of Organization and Informatics

Tihomir Orehovački

METHODOLOGY FOR EVALUATING THE QUALITY IN USE OF WEB 2.0 APPLICATIONS

DOCTORAL THESIS

Supervisors:

Assoc. Prof. Dragutin Kermek, Ph.D.
Prof. Andrina Granić, Ph.D.

Varaždin, 2013.

ZAHVALE

Na početku ovog doktorskog rada želim se zahvaliti svima koji su na izravan ili neizravan način doprinijeli njegovom stvaranju. Od srca se zahvaljujem izv. prof. dr. sc. Dragutinu Kermeku i prof. dr. sc. Andrini Granić što su sa velikim entuzijazmom prihvatili mentorstvo te me profesionalno usmjeravali, poticali i savjetovali tijekom izrade doktorskog rada. Zahvaljujem se i ostalim članovima Povjerenstva (prof. dr. sc. Alenu Lovrenčiću, izv. prof. dr. sc. Marjanu Krašni i prof. dr. sc. Vesni Dušak) što su svojim sugestijama unaprijedili kvalitetu doktorskog rada. Veliko hvala prof. dr. sc. Goranu Bubašu što me motivirao da započnem sa ovim istraživanjem te mi velikodušno pomagao u njegovoj realizaciji. Posebno se zahvaljujem svojim kolegama Snježani Babić, prof. (Veleučilište u Rijeci), doc. dr. sc. Mariju Jadriću (Ekonomski fakultet Sveučilišta u Splitu), Tomislavu Jakopecu, mag. inf. i dr. sc. Aniti Papić (Filozofski fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku), prof. dr. sc. Antoniju Granollersu Saltiveriju (Universitat de Lleida, Španjolska), doc. dr. sc. Alexandri Ruiz Gaoni (Universidad del Quindío, Kolumbija) i prof. dr. sc. Césaru Albertu Collazosu Ordóñezu (Universidad del Cauca, Kolumbija) koji su u ulozi moderatora istraživanje proveli na matičnim visokoškolskim institucijama. Iskreno se zahvaljujem kolegici Andreji Kovačić, prof. na nesebičnoj podršci i pomoći oko prijevoda materijala za provedbu istraživanja na engleski jezik. Također se zahvaljujem svim članovima GRIHO istraživačke grupe na požrtvovnom angažmanu oko prijevoda materijala za provedbu istraživanja na španjolski jezik.

Neizmjerno sam zahvalan svim stručnjacima domene (Ivanu Araru, mag. inf., doc. dr. sc. Tanji Arh, Bojanu Bedraču, prof., Željku Bubičiću, univ. spec. inf., izv. prof. dr. sc. Cristini Cachero Castro, doc. dr. sc. Cinzii Cappiello, prof. dr. sc. Césaru Albertu Collazosu Ordóñezu, doc. dr. sc. Maji Ćukušić, Tihomiru Dmitroviću, pristup. inf., prof. dr. sc. Xavieru Ferréu Grauu, Krunoslavu Funtaku, mag. ing. rač., izv. prof. dr. sc. Robertu Garcíji Gonzálezu, izv. prof. dr. sc. Rosi Maríji Gil Iranzo, dr. sc. Joséu Luisu Gonzálezu Sánchezu, prof. dr. sc. Antoniju Granollersu Saltiveriju, Tomislavu Jakopecu, mag. inf., mr. sc. Cristhy Jiménez Granizo, Josepu Mariji Junoyu Domènechu, pristup. oec., Daliboru Kirchmayeru, mag. inf., mr. sc. Mihaelu Kukecu, mr. sc. Sandiju Ljubiću, mr. sc. Nikoli Maranguniću, mr. sc. Llúciji Masip Ardévol, izv. prof. dr. sc. Maristelli Materi, Srđanu Matijeviću, univ. bacc. inf., mr. sc. Raúlu Miñónu, doc. dr. sc. Ivici Mitroviću, izv. prof. dr. sc. Lourdes Moreno López, mr. sc. Jeleni Nakić, mr. sc. Carolini Navarro, dr. sc. Predragu Oreškom, mr. sc. Nataliji Padilli Zei, mr. sc. Afri Pascual, mr. sc. Matiji Pipanu, mr. sc. Robertu Polillu, Juanu Joséu Rodriguezu Soleru, mag. psih., prof. dr. sc. Cristianu Rusuu, dr. sc. Faustu J. Sainz de Salcesu, prof. dr. sc. Montserrat Sendín Veloso, Matiji Tomaškoviću, mag. inf., izv. prof. dr. sc. Aimiliji Tzanavari i mr. sc. Mariji Lili Villegas Ramírez) na vremenu i trudu kojeg su uložili u kategorizaciju i određivanje relevantnosti čestica, indikatora i atributa kvalitete u korištenju.

Puno hvala svim studentima koji su svoje dragocjeno vrijeme utrošili na provedbu reprezentativnih koraka scenarija interakcije sa Web 2.0 aplikacijama i njihovo vrjednovanje. Hvala prof. dr. sc. Jozi J. Dujmoviću na dugotrajnim raspravama i savjetima vezanim uz primjenu metode logičkog bodovanja preferencija. Zahvaljujem se i prof. dr. sc. Paulu Van Schaiku na nesebičnom prijenosu znanja i iskustva vezanog uz specifičnosti primjene metode modeliranja strukturalnim jednadžbama tehnikom parcijalnih najmanjih kvadrata.

Naročito se zahvaljujem dragim kolegama i prijateljima Nikolini Žajdeli Hrustek, mag. oec., izv. prof. dr. Danijelu Radoševiću i izv. prof. dr. Jasminki Dobša na konstruktivnim diskusijama, primjedbama i prijedlozima te redovitom podsjećanju na moje ciljeve. Puno hvala bratu Mariju te roditeljima Štefici i Dragutinu na svoj podršci i ljubavi koju su mi pružali za vrijeme nastajanja ovog doktorskog rada. Posebno se zahvaljujem najboljem prijatelju Tomislavu Vrbancu na strpljenju, razumijevanju, pomoći i svakodnevnoj motivaciji za rad. Hvala prijateljima Ivanu Vrbancu i Tanji Drvarić što su sudjelovali u vrjednovanju razumljivosti početnog skupa manifestnih varijabli. Naposljetku se zahvaljujem i svima ostalima koji nisu poimence spomenuti, a pomogli su u ostvarenju ovog doktorskog rada. Bez svih vas ovaj doktorski rad vjerojatno nikada ne bi bio napisan, stoga vam još jednom najiskrenije zahvaljujem.

Tihomir Orehovački

INFORMACIJE O MENTORIMA

Izv. prof. dr. sc. Dragutin Kermek je diplomirao, magistrirao i doktorirao na Fakultetu organizacije i informatike u Varaždinu. Nakon diplomiranja zaposlio se u Centru za informatiku na Fakultetu organizacije i informatike kao pripravnik na radnom mjestu organizator-programer. Tijekom nekoliko sljedećih godina obavljao je poslove organizatora-programera, projektanta te samostalnog projektanta. Dana 16. srpnja 1993. godine izabran je u nastavno zvanje asistent na Katedri za teorijske osnove informacijskih sustava Fakulteta organizacije i informatike, a 28. rujna 1999. godine u suradničko zvanje viši asistent na Katedri za računalstvo i tehnologiju. U znanstveno-nastavno zvanje docent izabran je 2002. godine, a u znanstveno-nastavno zvanje izvanredni profesor 2008. godine.

Trenutno sudjeluje kao nositelj u izvođenju nastave na informatičkim preddiplomskim i diplomskim studijima Fakulteta organizacije i informatike na kolegijima "Web dizajn i programiranje", "Napredne Web tehnologije i servisi" i „Uzorci dizajna“ te kao sunositelj na kolegiju „Sustavi za elektroničko učenje“. Autor je jedne knjige, te više od 30 znanstvenih i 25 stručnih radova.

Bio je predsjednik organizacijskog odbora međunarodne konferencije “Information and Intelligent Systems – IIS” za 2003. i 2004. godinu te suurednik zbornika radova spomenutih godina konferencije. Od akademske godine 2002./2003. do 2004./2005. bio je pročelnik Katedre za računalstvo i tehnologiju Fakulteta organizacije i informatike. Član je Predsjedništva Vijeća CARNet korisnika od 2005. godine. Od akademske godine 2005./2006. do 2010/.2011. obnašao je funkciju prodekana za nastavu Fakulteta organizacije i informatike. Član je Programskog odbora konferencije CARNet User Conference (CUC) za godine 2007., 2008., 2009., 2010., 2011. i 2012. Član je Radne skupine za studijske programe Sveučilišta u Zagrebu od 2010. godine. Član je Programskog odbora konferencije Central European Conference on Information and Intelligent Systems (CECIIS) od 2010. godine. Dobitnik je „Srebrne značke informatike“ Hrvatskog informatičkog zbora 2008. godine.

Prof. dr. sc. Andrina Granić je zaposlena kao redoviti profesor na Odjelu za informatiku na Prirodoslovno-matematičkom fakultetu Sveučilišta u Splitu. Diplomirala je i magistrirala na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu, te je na istom fakultetu 2002. godine obranila doktorsku disertaciju iz područja tehničkih znanosti, znanstvenog polja računarstvo. Vanjski je suradnik Fakulteta elektrotehnike, strojarstva i brodogradnje, Ekonomskog fakulteta, Filozofskog fakulteta i Umjetničke akademije Sveučilišta u Splitu te Fakulteta elektrotehnike i računarstva Sveučilišta u Zagrebu.

Znanstveno-istraživačka djelatnost prof. dr. sc. Andrine Granić je u području interakcije čovjeka i računala (engl. Human-Computer Interaction, HCI), području iz kojeg je ujedno uvela nove kolegije na dodiplomskom, diplomskom i doktorskom studiju Sveučilišta u Splitu. Aktivni je istraživač na projektima Ministarstva znanosti, obrazovanja i sporta Republike Hrvatske, te je voditelj znanstvenog projekta kategoriziranog kao projekt visoke izvrsnosti (kategorija A). Također aktivno sudjeluje u realizaciji i vođenju hrvatskih partnera u međunarodnim projektima financiranim od strane Europske komisije iz područja informacijske i komunikacijske tehnologije (ICT).

Autorica je više od 80 znanstvenih radova objavljenih kao poglavlja u knjigama, u časopisima ili zbornicima radova s međunarodnih i domaćih znanstvenih skupova. Član je uređivačkih odbora nekolicine međunarodnih časopisa, te radi kao recenzent za renomirane svjetske časopise, međunarodne i domaće konferencije. Član je programskog, znanstvenog ili organizacijskog odbora velikog broja međunarodnih znanstvenih skupova. Također je angažirana i kao evaluator projekata financiranih od strane Europske komisije u ICT području, te kao evaluator nacionalnih istraživačkih i razvojnih (R&D) projekata nekih europskih zemalja. Član je strukovnog udruženja IEEE Computer Society, KoREMA, te zajednice diplomiranih inženjera Fakulteta elektrotehnike i računarstva u Zagrebu, AMAC-FER.

SAŽETAK

U sklopu ovog doktorskog rada oblikovana je metodologija koja omogućava vrjednovanje svih relevantnih pragmatičnih i hedonističkih atributa kvalitete u korištenju Web 2.0 aplikacijama. Nakon što su manifestne varijable namijenjene vrjednovanju spomenutih atributa identificirane pregledom literature, istima je primjenom metode sortiranja karata utvrđena sadržajna valjanost. Hijerarhijska klaster analiza rezultirala je konačnim skupom od 38 sadržajno valjanih atributa temeljem kojih su oblikovani mjerni instrumenti i konceptualni model. Kako bi se validirala razvijena metodologija provedena su dva eksperimenta. U prvom eksperimentu su korisnici vrjednovali dvije Web 2.0 aplikacije za kolaborativno uređivanje teksta, a u drugom dvije Web 2.0 aplikacije za izradu mentalnih mapa. Učinkovitost i radni učinak korisnika su mjereni primjenom alata Mousotron. Podaci vezani uz djelotvornost korisnika prikupljeni su pomoću obrasca sa reprezentativnim koracima scenarija interakcije sa Web 2.0 aplikacijama. Subjektivno vrjednovanje relevantnih dimenzija kvalitete u korištenju Web 2.0 aplikacijama provedeno je online upitnikom koji se sastojao od 117 čestica. Višedimenzionalni združeni konstrukti modelirani su novorazvijenom hibridnom tehnikom. Metrijske karakteristike konceptualnog modela vrjednovane su PLS-SEM metodom. Analiza vrijednosti parametara mjernih i strukturalnih modela u kontekstu sve četiri vrjednovane Web 2.0 aplikacije pokazala je da konceptualni model udovoljava svim kriterijima valjanosti i pouzdanosti. Na osnovi spomenute analize definirane su referentne vrijednosti koeficijenta determinacije koje mogu poslužiti kao opće pravilo kod identifikacije prediktorske snage egzogenih latentnih varijabli u srodnim istraživanjima. Temeljem konceptualnog modela izrađeno je stablo zahtjeva u kojem su manifestne varijable specificirane kao varijable performansi. Zatim su za sve varijable performansi definirani elementarni kriteriji te im je pomoću metode grupnog procjenjivanja težina utvrđena relativna važnost unutar podsustava preferencija kojem pripadaju. Primjenom metode logičkog bodovanja preferencija izračunate su elementarne preferencije za podsustave varijabli performansi i globalne preferencije za vrjednovane Web 2.0 aplikacije. Vrijednosti navedenih preferencija poslužile su analizi prednosti i nedostataka vrjednovanih Web 2.0 aplikacija te njihovoj komparaciji. Naposljetku su na osnovi svih rezultata empirijskog dijela istraživanja oblikovane smjernice i preporuke koje se u obliku heuristika mogu primijeniti u različitim fazama životnog ciklusa Web 2.0 aplikacija.

Ključne riječi: Web 2.0, metodologija vrjednovanja, kvaliteta u korištenju, sortiranje karata, hijerarhijska klaster analiza, parcijalni najmanji kvadrati, modeliranje višedimenzionalnih formativnih i reflektivnih konstrukata, logičko bodovanje preferencija

EXTENDED ABSTRACT

Web 2.0 is an umbrella term for the second generation of web applications that support different types of interaction among users and enable them to create, share, organize, and integrate various artefacts. Despite the fact that Web 2.0 applications are widely used for personal and business purposes, a comprehensive framework for their evaluation is still not available. With the aim to identify all the relevant pragmatic and hedonic attributes and their relative contribution to the quality in use composite index, as the main outcome of this doctoral thesis a methodology for evaluating the quality in use of Web 2.0 applications was developed. Based on the literature review, a set of 263 manifest variables was generated. By applying the closed card sorting procedure, domain experts assigned the set forth pool of manifest variables to the predetermined quality in use attributes. In the next step, the domain experts employed the open card sorting technique and thus categorized the set of 123 content-valid manifest variables. Drawing on the data collected from the domain experts, hierarchical cluster analysis revealed a finite set of 38 quality in use attributes that were afterwards used as the foundation for the design of metrics, measuring instruments, and the conceptual model.

Two empirical studies constitute the essential part of this doctoral thesis. In the first study, the research subjects were observed during their interactions with two Web 2.0 applications meant for collaborative writing, and in the second, during their interactions with two Web 2.0 applications aimed for mind mapping. During each study, the participants performed representative scenarios of interaction with Web 2.0 applications which had been designed by the author of the doctoral thesis. The objective data were gathered during the interaction with the Web 2.0 applications, while the subjective data were collected afterwards. Users' efficiency (time on task) and workload (number of mouse clicks, mouse movements, mouse scrolls, and keystrokes) were measured by means of the Mousotron tool. The number of scenario steps that were successfully completed with a particular Web 2.0 application was interpreted as an indicator of users' effectiveness. The subjective assessment of Web 2.0 applications was conducted with the use of an online questionnaire which was composed of 117 items related to all the relevant facets of the quality in use.

With the objective to enable the evaluation of higher-order (multidimensional) aggregate constructs, a novel hybrid modelling technique was proposed. The psychometric characteristics of the conceptual model were explored with PLS-SEM method. An analysis of measurement and structural models' parameter estimates in the context of the four evaluated Web 2.0 applications uncovered that the conceptual model met all validity and reliability criteria. Considering results of four structural models estimation, R^2 values of 0.15, 0.34, and 0.46 for endogenous latent

variables can, as a rule of thumb in similar future empirical studies, be interpreted as weak, moderate, or substantial, respectively.

On the basis of the conceptual model structure, a quality in use requirements tree was designed in which each manifest variable was specified as a performance variable. Drawing on the pilot study results, elementary criteria were defined for all performance variables in the context of both types of Web 2.0 applications. The relative importance of each performance variable within the underlying subsystem of preferences was determined with the use of the group weighting method. By employing the logic scoring of preferences method, elementary preferences for each subsystem of performance variables as well as global preferences for all the four Web 2.0 applications were estimated from the quality in use perspective. Furthermore, values of elementary and global preferences were used for the analysis of strengths and weaknesses of the evaluated Web 2.0 applications as well as for their comparison within a group. Finally, based on empirical findings a set of guidelines and recommendations that can be applied in the form of heuristics for the design and evaluation of Web 2.0 applications at various stages of their life cycle was proposed.

Keywords: Web 2.0, evaluation methodology, quality in use, card sorting, hierarchical cluster analysis, partial least squares, modelling higher-order formative and reflective constructs, logic scoring of preferences

SADRŽAJ

SADRŽAJ I
POPIS SLIKA VII
POPIS TABLICA X
POPIS GRAFIKONA XVII
1. UVOD 1
1.1 Definiranje problema istraživanja 2
1.2 Ciljevi i hipoteze istraživanja 5
2. WEB X.Y 6
2.1 Od ideje do implementacije 7
2.2 Globalizacija i komercijalizacija Weba 10
2.3 Web 2.0 15
2.3.1 Uzorci dizajna Weba 2.0 16
2.3.2 Taksonomija Web 2.0 aplikacija 22
2.3.2.1 Wiki sustavi 23
2.3.2.2 Blogovi 24
2.3.2.3 Web 2.0 aplikacije za društveno knjižno označavanje 25
2.3.2.4 Web 2.0 aplikacije za podcasting 26
2.3.2.5 Društvene mreže 27
2.3.2.6 Hibridne Web 2.0 aplikacije 28
2.3.2.7 Virtualni svjetovi 29
2.3.2.8 E-portfolio sustavi 30
2.3.2.9 Repozitoriji artefakata 31
2.3.2.10 Web 2.0 aplikacije za kolaborativnu izradu artefakata 32
2.3.2.11 Web 2.0 aplikacije za komunikaciju 33
2.4 Web danas i sutra 33
3. TEORIJSKI OKVIR 36
3.1 Osnovne dimenzije teorijskog okvira 36
3.1.1 Kvaliteta 36
3.1.2 Upotrebljivost 41
3.1.3 Korisničko iskustvo 45
3.1.4 Kvaliteta u korištenju 47
3.2 Sporedne dimenzije teorijskog okvira 50
3.3 Početni skup atributa kvalitete u korištenju 53

3.3.1 Djelotvornost 54
3.3.2 Dodana vrijednost sadržaja 55
3.3.3 Dosljednost 55
3.3.4 Dostupnost 56
3.3.5 Estetika 57
3.3.6 Familijarnost 58
3.3.7 Interaktivnost 59
3.3.8 Interoperabilnost 60
3.3.9 Jedinstvenost 61
3.3.10 Kompatibilnost 61
3.3.11 Korisnost 62
3.3.12 Lakoća korištenja 64
3.3.13 Lakoća učenja korištenja 66
3.3.14 Lojalnost 67
3.3.15 Minimalna aktivnost 69
3.3.16 Minimalno opterećenje memorije 71
3.3.17 Mogućnost komunikacije 72
3.3.18 Mogućnost kontrole 73
3.3.19 Mogućnost oporavka 74
3.3.20 Mogućnost pretraživanja 75
3.3.21 Mogućnost prilagodbe 76
3.3.22 Mogućnost suradnje 77
3.3.23 Odupiranje promjenama 77
3.3.24 Pamtljivost 78
3.3.25 Potpunost sadržaja 79
3.3.26 Pouzdanost 79
3.3.27 Povratne informacije 80
3.3.28 Pravovremenost sadržaja 81
3.3.29 Pristupačnost 82
3.3.30 Raspoloživost i pružanje pomoći 84
3.3.31 Razigranost 85
3.3.32 Razumljivost 87
3.3.33 Reputacija 88
3.3.34 Sigurnost 88
3.3.35 Skalabilnost 90

3.3.36 Sprječavanje pogrješaka ... 90
3.3.37 Stav prema ponašanju ... 91
3.3.38 Sveobuhvatnost konteksta ... 92
3.3.39 Točnost sadržaja ... 93
3.3.40 Učinkovitost ... 94
3.3.41 Upravljivost ... 95
3.3.42 Utjecaj društva ... 96
3.3.43 Užitak ... 97
3.3.44 Vjerodostojnost sadržaja ... 98
3.3.45 Vrijeme odaziva ... 99
3.3.46 Zadovoljstvo ... 100
4. VRJEDNOVANJE ... 102
4.1.1 Metode pregledavanja ... 104
4.1.1.1 Vrjednovanje prema heuristikama ... 104
4.1.1.2 Kognitivna šetnja ... 108
4.1.1.3 Multidisciplinarna kognitivna šetnja ... 109
4.1.1.4 Perspektivan pregled ... 109
4.1.1.5 Pregled funkcionalnih dijelova ... 110
4.1.1.6 Formalni pregled ... 110
4.1.1.7 Pregledavanje dosljednosti ... 111
4.1.1.8 Usklađenost sa standardima ... 111
4.1.1.9 Usklađenost sa smjernicama ... 112
4.1.2 Metode testiranja ... 112
4.1.2.1 Razmišljanje naglas ... 112
4.1.2.2 Postavljanje pitanja ... 113
4.1.2.3 Konstruktivna interakcija ... 113
4.1.2.4 Izravni prijenos ... 114
4.1.2.5 Odgođeno emitiranje ... 114
4.1.2.6 Stručno podučavanje ... 115
4.1.2.7 Učenje ... 115
4.1.2.8 Mjerenje radnog učinka korisnika ... 116
4.1.2.9 Automatsko zapisivanje postupaka ... 116
4.1.2.10 Analitika web mjesta ... 117
4.1.2.11 Metoda praćenja očiju ... 119
4.1.2.12 Udaljeno testiranje ... 121

4.1.3 Metode ispitivanja ... 121
4.1.3.1 Terensko ispitivanje ... 122
4.1.3.2 Ciljane skupine ... 122
4.1.3.3 Intervjui ... 123
4.1.3.4 Kontekstualno ispitivanje ... 124
4.1.3.5 Upitnici ... 124
4.1.3.6 Vođenje dnevnika ... 127
4.1.3.7 Spremanje izgleda ekrana ... 128
4.1.3.8 Povratne informacije od korisnika ... 128
5. METODOLOGIJA ... 129
5.1 Metoda sortiranje karata ... 130
5.2 Hijerarhijska klaster analiza ... 132
5.3 Modeliranje strukturalnim jednadžbama ... 135
5.3.1 Specifikacija modela ... 138
5.3.2 Vrjednovanje konceptualnog modela ... 144
5.3.2.1 Vrjednovanje vanjskog reflektivnog modela ... 144
5.3.2.2 Vrjednovanje vanjskog formativnog modela ... 147
5.3.2.3 Vrjednovanje unutarnjeg modela ... 151
5.3.2.4 Vrjednovanje višedimenzionalnih konstrukata ... 154
5.4 Logičko bodovanje preferencija ... 156
6. ISTRAŽIVANJE ... 168
6.1 Oblikovanje mjernih instrumenata ... 173
6.1.1 Karakteristike HCI/WE stručnjaka ... 174
6.1.2 Karakteristike WD stručnjaka ... 182
6.1.3 Rezultati primjene metode zatvorenog sortiranja karata ... 195
6.2 Oblikovanje konceptualnog modela ... 217
6.2.1 Karakteristike HCI/WE stručnjaka ... 218
6.2.2 Rezultati primjene metode otvorenog sortiranja karata ... 226
6.2.3 Sadržajna valjanost latentnih varijabli ... 229
6.2.4 Modeliranje ... 239
6.2.5 Postavke algoritama korištenih u analizi konceptualnog modela ... 247
6.2.6 Izrada stabla zahtjeva ... 247
6.2.7 Definiranje kriterijskih funkcija ... 248
6.2.8 Grupno procjenjivanje težina ... 255
6.2.9 Izračun globalne preferencije ... 261

6.2.10 Razina podudaranja u grupnom procjenjivanju težina ... 261
6.3 Prvi eksperiment ... 265
6.3.1 Karakteristike sudionika ... 267
6.3.2 Rezultati analize metrijskih karakteristika konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer ... 274
6.3.3 Rezultati analize metrijskih karakteristika konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App ... 298
6.3.4 Rezultati vrjednovanja kvalitete u korištenju Web 2.0 aplikacija za kolaborativno uređivanje teksta ... 322
6.3.4.1 Prednosti Web 2.0 aplikacije Zoho Writer ... 334
6.3.4.2 Nedostatci Web 2.0 aplikacije Zoho Writer ... 337
6.3.4.3 Prednosti Web 2.0 aplikacije Microsoft Word Web App ... 339
6.3.4.4 Nedostatci Web 2.0 aplikacije Microsoft Word Web App ... 342
6.4 Drugi eksperiment ... 345
6.4.1 Karakteristike sudionika ... 347
6.4.2 Rezultati analize metrijskih karakteristika konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Mindomo ... 354
6.4.3 Rezultati analize metrijskih karakteristika konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping ... 378
6.4.4 Rezultati vrjednovanja kvalitete u korištenju Web 2.0 aplikacija za izradu mentalnih mapa ... 402
6.4.4.1 Prednosti Web 2.0 aplikacije Mindomo ... 413
6.4.4.2 Nedostatci Web 2.0 aplikacije Mindomo ... 415
6.4.4.3 Prednosti Web 2.0 aplikacije Wise Mapping ... 417
6.4.4.4 Nedostatci Web 2.0 aplikacije Wise Mapping ... 420
7. DISKUSIJA ... 423
7.1 Testiranje ciljeva i hipoteza istraživanja ... 423
7.2 Smjernice i preporuke za unaprjeđenje metodike razvoja i vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama ... 436
7.2.1 Endogene smjernice ... 437
7.2.2 Egzogene smjernice ... 439
7.2.3 Endogene preporuke ... 440
7.2.4 Egzogene preporuke ... 441
8. ZAKLJUČAK ... 442
8.1 Znanstveni doprinosi ... 443
8.2 Ograničenja istraživanja ... 449
8.3 Smjernice za buduća istraživanja ... 450

LITERATURA 451
PRILOZI 489

POPIS SLIKA

Slika 2.1 Razvojne faze Weba 7
Slika 2.2 Prva web stranica 8
Slika 2.3 Wikipedia 23
Slika 2.4 inspireUX 24
Slika 2.5 Diigo 25
Slika 2.6 YouTube 27
Slika 2.7 ResearchGate 28
Slika 2.8 Netvibes 29
Slika 2.10 Mahara 31
Slika 2.11 Scribd 31
Slika 2.12 Gliffy 32
Slika 2.13 Anymeeting 33
Slika 4.1 Omjer postotka identificiranih problema upotrebljivosti i potrebnog broja evaluatora 107
Slika 5.1 Primjer PLS-SEM modeliranja puta 140
Slika 5.2 Višedimenzionalan združen konstrukt formativan na prvoj i drugoj razini 143
Slika 5.3 Višedimenzionalan združen konstrukt reflektivan na prvoj razini i formativan na drugoj razini 144
Slika 5.10 Skala preferencija sa intervalom [0, 1] 157
Slika 5.11 Skala preferencija sa intervalom [0, 100%] 157
Slika 5.14 Grafička notacija generalizirane konjunkcije/disjunkcije 158
Slika 5.15. Modeliranje istovremenosti neobaveznih preferencija 159
Slika 5.16 Modeliranje istovremenosti obaveznih preferencija 160
Slika 5.17 Modeliranje nadomjestivosti pomoću logičkih operatora spajanja sa slabim i jakim intenzitetom polarizacije 161
Slika 5.18 Spajanje neobaveznih ulaznih preferencija sa disjunktnim logičkim operatorom srednjeg intenziteta polarizacije 161
Slika 5.19 Grafička notacija dviju varijanti konjunktivne parcijalne apsorpcije 162
Slika 5.20 Primjeri konjunktivne parcijalne apsorpcije 164
Slika 5.21 Grafička notacija dviju varijanti disjunktivne parcijalne apsorpcije 165
Slika 5.22 Primjeri disjunktivne parcijalne apsorpcije 166
Slika 5.23 Dijagram odabira logičkih operatora spajanja 167
Slika 6.1 Početna inačica konceptualnog modela vrjednovanja Web 2.0 aplikacija 168
Slika 6.2 Mousotron izvještaj 171

Slika 6.3 Aplikacija za provedbu metode otvorenog sortiranja karata..... 172

Slika 6.4 Aplikacija za provedbu hijerarhijske klaster analize..... 226

Slika 6.5 Grafički prikaz strukture klastera (dendrogram) 227

Slika 6.6 Konceptualni model vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama..... 246

Slika 6.7 Koraci primjene metode logičkog bodovanja preferencija prilagođeni kontekstu doktorskog rada..... 248

Slika 6.8 Elementarni kriterij za postotak dovršenosti koraka scenarija u kontekstu vrjednovanja izmjerene djelotvornosti korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta..... 249

Slika 6.9 Elementarni kriterij za postotak dovršenosti koraka scenarija u kontekstu vrjednovanja izmjerene djelotvornosti korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa..... 249

Slika 6.10 Elementarni kriterij za broj pritisnutih tipaka na tipkovnici potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta..... 250

Slika 6.11 Elementarni kriterij za broj pritisnutih tipaka na tipkovnici potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa..... 251

Slika 6.12 Elementarni kriterij za udaljenost prijeđenu pomicanjem miša tijekom izvršavanja svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta..... 251

Slika 6.13 Elementarni kriterij za udaljenost prijeđenu pomicanjem miša tijekom izvršavanja svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa..... 251

Slika 6.14 Elementarni kriterij za broj klikova mišem potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta..... 252

Slika 6.15 Elementarni kriterij za broj klikova mišem potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa..... 252

Slika 6.16 Elementarni kriterij za broj pomicanja klizača na mišu potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta 253

Slika 6.17 Elementarni kriterij za broj pomicanja klizača na mišu potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa 253

Slika 6.18 Elementarni kriterij za količinu vremena potrebnog za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerene učinkovitosti korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta..... 253

Slika 6.19 Elementarni kriterij za količinu vremena potrebnog za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerene učinkovitosti korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa 254

Slika 6.20 Elementarni kriterij za vrjednovanje zamijećene kvalitete u korištenju 254

Slika 6.21. Stablo zahtjeva kvalitete u korištenju Web 2.0 aplikacijama 256

Slika 6.21 Radno okruženje Web 2.0 aplikacije Zoho Writer 266

Slika 6.22 Radno okruženje Web 2.0 aplikacije Microsoft Word Web App 266

Slika 6.23 Rezultati analize metrijskih karakteristika unutarnjeg modela u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer 292

Slika 6.24 Rezultati analize metrijskih karakteristika unutarnjeg modela u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App 316

Slika 6.25 Radno okruženje Web 2.0 aplikacije Mindomo 346

Slika 6.26 Radno okruženje Web 2.0 aplikacije Wise Mapping 346

Slika 6.27 Rezultati analize metrijskih karakteristika unutarnjeg modela u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Mindomo 372

Slika 6.28 Rezultati analize metrijskih karakteristika unutarnjeg modela u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping 396

POPIS TABLICA

Tablica 2.1 Pregled najranijih Web preglednika sa grafičkim korisničkim sučeljem 11
Tablica 5.1 Minimalne vrijednosti pokazatelja sadržajne valjanosti u odnosu na broj procjenitelja 131
Tablica 5.2 Skala referentnih vrijednosti za Kappa koeficijent 132
Tablica 5.3 Pravila odlučivanja vezana uz operacionalizaciju latentnih konstrukata 141
Tablica 5.4 Referentne vrijednosti koeficijenta determinacije 151
Tablica 5.5 Generalizirana konjunkcija/disjunkcija 159
Tablica 5.6 Karakteristike konjunktivne parcijalne apsorpcije 163
Tablica 5.7 Nagrade i penali za srednju kvazi-konjunkciju 164
Tablica 5.8 Karakteristike disjunktivne parcijalne apsorpcije 165
Tablica 6.1 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema spolu 174
Tablica 6.2 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema akademskom stupnju 174
Tablica 6.3 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema osnovnom obrazovanju 175
Tablica 6.4 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema zvanju 175
Tablica 6.5 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema zanimanju 175
Tablica 6.6 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema državi iz koje dolaze 176
Tablica 6.7 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema području interesa 176
Tablica 6.8 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema profesionalnom iskustvu 178
Tablica 6.9 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema području ekspertize 179
Tablica 6.10 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema akademskom stupnju 182
Tablica 6.11 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema osnovnom obrazovanju 183
Tablica 6.12 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema profesionalnom iskustvu 186
Tablica 11.13 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema ulogama u timu za razvoj web mjesta u posljednjih pet godina 187

Tablica 6.14 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema ulogama u timu za razvoj web mjesta u posljednje tri godine 188

Tablica 6.15 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema ulogama u timu za razvoj web mjesta u posljednjih godinu dana 189

Tablica 6.16 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema području ekspertize 190

Tablica 6.17 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema iskustvu u primjeni pojedinog razvojnog okruženja i programskog jezika 192

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli 197

Tablica 6.19 Rezultati vrjednovanja konstruktne valjanosti i pouzdanosti provedbe metode zatvorenog sortiranja karata 213

Tablica 6.20 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema spolu 218

Tablica 6.21 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema akademskom stupnju 218

Tablica 6.22 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema osnovnom obrazovanju 219

Tablica 6.23 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema zvanju 219

Tablica 6.24 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema zanimanju 219

Tablica 6.25 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema državi iz koje dolaze 220

Tablica 6.26 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema području interesa 220

Tablica 6.27 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema profesionalnom iskustvu 222

Tablica 6.28 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema području ekspertize 223

Tablica 6.29 Vrijednosti pokazatelja sadržajne valjanosti za konačan skup latentnih varijabli. 229

Tablica 6.30 Konačan skup manifestnih i latentnih varijabli sa naznakom njihove relevantnosti 232

Tablica 6.31 Prilagođene postavke algoritama korištenih u izračunu parametara unutarnjeg i vanjskog modela 247

Tablica 6.32 Razina podudaranja između stručnjaka domene u grupnom procjenjivanju težina 263

Tablica 6.33 Struktura sudionika u prvom eksperimentu prema učestalosti upotrebe web preglednika tijekom izvršavanja koraka scenarija interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta 265

Tablica 6.34 Struktura sudionika u prvom eksperimentu prema spolu 267

Tablica 6.35 Struktura sudionika u prvom eksperimentu prema visokoškolskoj ustanovi koju pohađaju 268

Tablica 6.36 Struktura sudionika u prvom eksperimentu prema godini studija koju pohađaju 268

Tablica 6.37 Struktura sudionika u prvom eksperimentu prema intenzitetu i svrsi korištenja Internetom 271

Tablica 6.38 Struktura sudionika u prvom eksperimentu prema učestalosti i svrsi korištenja Internetom 271

Tablica 6.39 Struktura sudionika u prvom eksperimentu prema učestalosti korištenja Web 2.0 aplikacijama 272

Tablica 6.40 Struktura sudionika u prvom eksperimentu prema samoprocjeni poznavanja rada na računalu te korištenja Internetom i Web 2.0 aplikacijama 273

Tablica 6.41 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 275

Tablica 6.42 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 277

Tablica 6.43 Vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 277

Tablica 6.44 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 278

Tablica 6.45 Apsolutna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 280

Tablica 6.46 Apsolutna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 280

Tablica 6.47 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 281

Tablica 6.48 Relativna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 283

Tablica 6.49 Relativna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 283

Tablica 6.50 Vrijednosti kriterija vrjednovanja pouzdanosti i konvergentne valjanosti reflektivnih latentnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 285

Tablica 6.51 Rezultati analize multikolinearnosti formativnih manifestnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 286

Tablica 6.52 Diskriminacijska valjanost reflektivnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 288

Tablica 6.53 Diskriminacijska valjanost reflektivnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 288

Tablica 6.54 Diskriminacijska valjanost formativnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 289

Tablica 6.55 Diskriminacijska valjanost formativnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 290

Tablica 6.56 Diskriminacijska valjanost formativnih latentnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 290

Tablica 6.57 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 294

Tablica 6.58 Rezultati analize veličine utjecaja i prediktivne valjanosti egzogenih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer 297

Tablica 6.59 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 299

Tablica 6.60 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 301

Tablica 6.61 Vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 301

Tablica 6.62 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 302

Tablica 6.63 Apsolutna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 304

Tablica 6.64 Apsolutna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 304

Tablica 6.65 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 305

Tablica 6.66 Relativna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 307

Tablica 6.67 Relativna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 307

Tablica 6.68 Vrijednosti kriterija vrjednovanja pouzdanosti i konvergentne valjanosti reflektivnih latentnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 309

Tablica 6.69 Rezultati analize multikolinearnosti formativnih manifestnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 310

Tablica 6.70 Diskriminacijska valjanost reflektivnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 312

Tablica 6.71 Diskriminacijska valjanost reflektivnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 312

Tablica 6.72 Diskriminacijska valjanost formativnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 313

Tablica 6.73 Diskriminacijska valjanost formativnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 314

Tablica 6.74 Diskriminacijska valjanost formativnih latentnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 314

Tablica 6.75 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 318

Tablica 6.76 Rezultati analize veličine utjecaja i prediktivne valjanosti egzogenih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App 321

Tablica 6.77 Elementarne i globalne preferencije Web 2.0 aplikacija za kolaborativno uređivanje teksta 326

Tablica 6.78 Struktura sudionika u drugom eksperimentu prema učestalosti upotrebe web preglednika tijekom izvršavanja koraka scenarija interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa 345

Tablica 6.79 Struktura sudionika u drugom eksperimentu prema spolu 347

Tablica 6.80 Struktura sudionika u drugom eksperimentu prema visokoškolskoj ustanovi koju pohađaju 348

Tablica 6.81 Struktura sudionika u drugom eksperimentu prema godini studija koju pohađaju 348

Tablica 6.82 Struktura sudionika u drugom eksperimentu prema intenzitetu i svrsi korištenja Internetom 351

Tablica 6.83 Struktura sudionika u drugom eksperimentu prema učestalosti i svrsi korištenja Internetom 351

Tablica 6.84 Struktura sudionika u drugom eksperimentu prema učestalosti korištenja Web 2.0 aplikacijama 352

Tablica 6.85 Struktura sudionika u drugom eksperimentu prema samoprocjeni poznavanja rada na računalu te korištenja Internetom i Web 2.0 aplikacijama 353

Tablica 6.86 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 355

Tablica 6.87 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 357

Tablica 6.88 Vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 357

Tablica 6.89 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 358

Tablica 6.90 Apsolutna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 360

Tablica 6.91 Apsolutna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 360

Tablica 6.92 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 361

Tablica 6.93 Relativna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 363

Tablica 6.94 Relativna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 363

Tablica 6.95 Vrijednosti kriterija vrjednovanja pouzdanosti i konvergentne valjanosti reflektivnih latentnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 365

Tablica 6.96 Rezultati analize multikolinearnosti formativnih manifestnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 366

Tablica 6.97 Diskriminacijska valjanost reflektivnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 368

Tablica 6.98 Diskriminacijska valjanost reflektivnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 368

Tablica 6.99 Diskriminacijska valjanost formativnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 369

Tablica 6.100 Diskriminacijska valjanost formativnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 370

Tablica 6.101 Diskriminacijska valjanost formativnih latentnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 370

Tablica 6.102 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 374

Tablica 6.103 Rezultati analize veličine utjecaja i prediktivne valjanosti egzogenih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo 377

Tablica 6.104 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 379

Tablica 6.105 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 381

Tablica 6.106 Vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 381

Tablica 6.107 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 382

Tablica 6.108 Apsolutna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 384

Tablica 6.109 Apsolutna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 384

Tablica 6.110 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 385

Tablica 6.111 Relativna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 387

Tablica 6.112 Relativna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 387

Tablica 6.113 Vrijednosti kriterija vrjednovanja pouzdanosti i konvergentne valjanosti reflektivnih latentnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 389

Tablica 6.114 Rezultati analize multikolinearnosti formativnih manifestnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 390

Tablica 6.115 Diskriminacijska valjanost reflektivnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 392

Tablica 6.116 Diskriminacijska valjanost reflektivnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 392

Tablica 6.117 Diskriminacijska valjanost formativnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 393

Tablica 6.118 Diskriminacijska valjanost formativnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping..... 394

Tablica 6.119 Diskriminacijska valjanost formativnih latentnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping 394

Tablica 6.120 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping..... 398

Tablica 6.121 Rezultati analize veličine utjecaja i prediktivne valjanosti egzogenih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping..... 401

Tablica 6.122 Elementarne i globalne preferencije Web 2.0 aplikacija za izradu mentalnih mapa 405

POPIS GRAFIKONA

Grafikon 6.1 Struktura sudionika u prvom eksperimentu prema starosnoj dobi 267

Grafikon 6.2 Struktura sudionika u prvom eksperimentu prema godinama iskustva u interakciji sa računalom 269

Grafikon 6.3 Struktura sudionika u prvom eksperimentu prema godinama iskustva u korištenju Internetom 269

Grafikon 6.4 Struktura sudionika u drugom eksperimentu prema starosnoj dobi 347

Grafikon 6.5 Struktura sudionika u drugom eksperimentu prema godinama iskustva u radu sa računalom 349

Grafikon 6.6 Struktura sudionika u drugom eksperimentu prema godinama iskustva u korištenju Internetom 349

1. UVOD

Pod utjecajem novih društvenih i tehnoloških trendova, u posljednjih je nekoliko godina došlo do promjena u procesu razvoja te načinu korištenja web mjestom (eng. web site). Statične web stranice i sustavi za upravljanje sadržajem (eng. content management systems, CMS) koji su bili namijenjeni pasivnim primateljima kreiranih i objavljenih sadržaja zamijenjeni su dinamičnim, fleksibilnim i interaktivnim web aplikacijama koje omogućuju korisnicima da aktivno sudjeluju u stvaranju repozitorija znanja. Web 2.0 je pojam koji označava novi način razmišljanja te mnogo zreliji medij kojeg karakteriziraju komunikacija, suradnja, dijeljenje, sudjelovanje, otvorenost i povezanost. Web 2.0 je također i model razvoja programskog proizvoda – od njegovog koncepta pa sve do dostavljanja krajnjem korisniku (O'Reilly i Battelle, 2009).

Nakon nešto više od osam godina od predstavljanja temeljnih uzoraka dizajna (O'Reilly, 2005), Web 2.0 aplikacije su implementirane u gotovo sve sfere ljudskog djelovanja, od e-učenja (Downes, 2005) do e-poslovanja (McAfee, 2006). Osnovna načela Web 2.0 paradigme su usmjerenost na korisnika i uprezanje kolektivne inteligencije (O'Reilly, 2005). Prema tome, uspjeh i prihvaćanje Web 2.0 aplikacija ne ovisi samo o implementiranim uzorcima dizajna već i o zadovoljnim i lojalnim korisnicima. Ukoliko Web 2.0 aplikacija ne udovoljava zahtjevima atributa kvalitete u korištenju koji su korisnicima bitni ili ako se upotrebom Web 2.0 aplikacije ne postižu željeni učinci, korisnici neće dvojiti već će potražiti kvalitetniju alternativu. Obzirom da je kontinuirana nadogradnja i korekcija pogrješaka u radu jedan od temeljnih uzoraka dizajna Web 2.0 aplikacija (O'Reilly, 2005), vrjednovanje kvalitete u korištenju tijekom svih faza njihova životnog ciklusa od iznimno je velike važnosti. Stoga će okosnicu ovog doktorskog rada činiti sljedeća istraživačka pitanja:

- Koji subjektivni i objektivni atributi kvalitete u korištenju utječu na zadovoljstvo i lojalnost korisnika Web 2.0 aplikacija?
- Da li su postojeći mjerni instrumenti prikladni za vrjednovanje kvalitete u korištenju Web 2.0 aplikacijama?
- Od kojih se metoda prikupljanja i analize podataka treba sastojati metodologija koja pojednostavljuje i ubrzava identifikaciju problema u korištenju te olakšava komparaciju vrjednovanih Web 2.0 aplikacija?

1.1 Definiranje problema istraživanja

Kvaliteta, kvaliteta u korištenju, upotrebljivost i korisničko iskustvo su ključni čimbenici metodologije vrjednovanja web aplikacija (Lew et al., 2010). Premda se kvaliteta u korištenju često spominje kao sinonim za upotrebljivost (primjerice u ISO 9241-11, 1998; Seffah et al., 2006), novi standard (ISO/IEC, 2011a) namijenjen vrjednovanju kvalitete programskih proizvoda logički je odijelio ova dva koncepta. Upotrebljivost (eng. usability) kao sastavni dio modela kvalitete proizvoda (eng. product quality) omogućava mjerenje pragmatičnih (eng. pragmatic) obilježja web aplikacija pomoću šest različitih atributa: primjerenost prepoznavanja (eng. appropriateness recognisability), lakoća učenja korištenja (eng. learnability), operabilnost (eng. operability), sprječavanje nastanka pogrješaka (eng. user error protection), estetika korisničkog sučelja (eng. user interface aesthetics) i pristupačnost (eng. accessibility). S druge strane, kvaliteta u korištenju (eng. quality in use) je zaseban model koji odražava mjeru prema kojoj programski proizvod može učinkovito (izvorno eng. efficiency), djelotvorno (izvorno eng. effectiveness) i bezopasno (izvorno eng. freedom from risk) zadovoljiti potrebe korisnika u specifičnom kontekstu upotrebe (izvorno eng. context coverage). Korisničko iskustvo (eng. user experience, UX) predstavlja proširenje tradicionalnih modela kvalitete sa hedonističkim atributima (eng. hedonic attributes) poput zabave (eng. fun) i užitka (eng. pleasure) (Hassenzahl i Tractinsky, 2006).

Kvaliteta u korištenju je sačinjena od dva komplementarna koncepta (Bevan, 2009a): upotrebljivosti i korisničkog iskustva. Upotrebljivost je mjera prema kojoj se korištenjem programskog proizvoda točno, potpuno i uz minimalan utrošak resursa postižu zadani ciljevi. Korisničko iskustvo predstavlja mjeru zamijećene kvalitete koja služi vrjednovanju brojnih aspekata zadovoljstva korisnika poput dopadljivosti (eng. likability) odnosno kognitivnog zadovoljstva, povjerenja (eng. trust) odnosno zadovoljstva sa razinom sigurnosti, užitka (eng. pleasure) odnosno emocionalnog zadovoljstva i komforta (eng. comfort) odnosno fizičkog zadovoljstva. U standardu ISO/IEC 25010 (2011) atributu *dopadljivost* promijenjen je naziv u *korisnost* (eng. usefulness). Primjena spomenutih atributa ovisi o vrsti programskog proizvoda koji se vrjednuje kao i kontekstu u kojem se isti upotrebljava.

Literatura koja se bavi istraživanjima u području interakcije čovjeka i računala (eng. Human Computer Interaction, HCI) donosi mnogo različitih modela, metoda i standarda namijenjenih vrjednovanju različitih oblika web mjesta kao što su web stranice, web informacijski sustavi, web portali, sustavi za upravljanje sadržajem i slično. Međutim, istraživanja vezana uz vrjednovanje Web 2.0 aplikacija su još uvijek rijetka. Razlog tome je što postojeći pristupi, namijenjeni vrjednovanju desktop aplikacija i maločas spomenutih vrsta web mjesta, nisu

prikladni za vrjednovanje Web 2.0 aplikacija. Navedeno su potvrdili rezultati nekoliko istraživanja. Hart et al. (2008) su svojim istraživanjem otkrili da Facebook udovoljava samo dvjema od deset Nielsenovih tradicionalnih heuristika (Nielsen, 1994) te je stoga njegova upotrebljivost na vrlo niskoj razini. Nasuprot tome, sa nešto više od milijardu aktivnih korisnika mjesečno (Facebook, 2013a), Facebook je primjer jedne od najuspješnijih Web 2.0 aplikacija. Kao razlog njegove popularnosti i široke prihvaćenosti isti autori navode pozitivno korisničko iskustvo koje se reflektira kroz atribute kvalitete u korištenju poput lakoće korištenja (85% korisnika ga smatra laganim ili vrlo laganim za korištenje), korisnosti (omogućava djelotvornu interakciju sa ostalim korisnicima) i razigranosti (korištenje je zabavno, puno iznenađenja te omogućava samoizražavanje).

Istraživanje u kojem je YouTube vrjednovan prema heuristikama polučilo je slične rezultate (Silva i Dix, 2007). Naime, YouTube je također udovoljio samo dvjema heuristikama; prva se odnosi na vidljivost statusa aplikacije, a druga na kontrolu i slobodu korisnika. Uz usmjerenost na stvaranje i razmjenu sadržaja, spomenute dvije heuristike predstavljaju glavni razlog njegove popularnosti i široke prihvaćenosti među korisnicima (Silva i Dix, 2007). Thompson i Kemp (2009) su svojim istraživanjem pronašle da je usmjerenost na korisničko iskustvo jedan od glavnih razloga uspjeha Web 2.0 aplikacija kao što su Flickr, Wikipedia i YouTube. Osim toga, modificirale su početni skup Nielsenovih tradicionalnih heuristika te ga proširile sa dvije dodatne heuristike. Međutim, valjanost novog skupa heuristika namijenjenog vrjednovanju Web 2.0 aplikacija nije empirijski potvrđena.

U novije se vrijeme nekoliko istraživača bavilo problematikom razvoja sveobuhvatnih modela vrjednovanja Web 2.0 aplikacija. U tom su kontekstu Sassano et al. (2010) predložili proširenje međunarodnog standarda ISO/IEC 25010 (2011b) karakteristikom koja će omogućavati vrjednovanje sljedećih dimenzija kvalitete sadržaja: ispravnost (točnost, vjerodostojnost (mjerodavnost, objektivnost i provjerljivost) i ažurnost), primjerenost (sveobuhvatnost (adekvatnost, cjelovitost, konciznost), dodana vrijednost (do koje je mjere sadržaj nov, koristan i utječe na reakcije korisnika) i dosljednost), pristupačnost i pravna usklađenost. Pang et al. (2010) su temeljem pregleda literature oblikovali model koji bi trebao omogućiti vrjednovanje Web 2.0 aplikacija sa sljedećih pet aspekata: kvaliteta sučelja (neposrednost, kompatibilnost, navigacija, izgled i razmještaj elemenata sučelja), kvaliteta sustava (dostupnost, učinkovitost, pouzdanost i sigurnost), kvaliteta informacija (potpunost, pravovremenost, sveobuhvatnost, vjerodostojnost, varijabilnost prezentiranja, arhitektura i mogućnost pretraživanja), kvaliteta usluge (mogućnost prilagodbe, podrška, raznolikost kanala, vrijeme odaziva, poticaji i kompenzacija) i kvaliteta emocija (uvjerenost, suosjećajnost, prisnost, razigranost i emocije). Ostali su autori svoj rad usmjeravali na oblikovanje modela koji omogućuju vrjednovanje

specifičnih aspekata kvalitete u korištenju kao što su kvaliteta informacija (Almeida et al., 2010) i pristupačnost (Brown et al., 2012) ili određenih vrsta Web 2.0 aplikacija kao što su mashupovi (Cappiello et al., 2011). Međutim, potrebno je napomenuti da velika većina spomenutih modela također nije empirijski validirana.

Dosadašnji su se pristupi vrjednovanju web mjesta sastojali od primjene objektivnih ili subjektivnih metrika vrjednovanja. Međutim, u kontekstu vrjednovanja Web 2.0 aplikacija odvojena upotreba spomenutih vrsta metrika ima svojih nedostataka. Objektivne metrike nisu dovoljno dobar pokazatelj kvalitete u korištenju Web 2.0 aplikacijama iz razloga što su u kontradikciji sa njihovim osnovnim načelom, a to je usmjerenost na korisnike. S druge strane, postoje obilježja Web 2.0 aplikacija koja nije dovoljno vrjednovati isključivo subjektivno iz perspektive korisnika već ih je potrebno izmjeriti specijaliziranim alatima. Hornbæk (2006) navodi dva razloga zbog kojih je preporučljivo kombinirati subjektivne i objektivne metrike:

- dobiva se kompletna predodžba o upotrebljivosti vrjednovanog programskog proizvoda,
- rezultati mjerenja mogu utjecati na poboljšanje korisničkog iskustva i objektivnih performansi.

Centralno mjesto u većini dosadašnjih pristupa vrjednovanju web mjesta su imale tradicionalne metode poput provjeravanja usklađenosti sa heuristikama (sa aspekta stručnjaka) ili prikupljanja podataka upotrebom upitnika (sa aspekta korisnika). Vrlo su rijetko istraživanja uključivala obje skupine spomenutih dionika. Pored toga, uzorak stručnjaka je uglavnom bio sačinjen od istraživača dok web razvojni inženjeri (dizajneri, programeri, arhitekti) nisu bili uključeni u proces vrjednovanja.

Iz navedenog je evidentno da su dosadašnji pristupi vrjednovanju web mjesta dominantno usmjereni na mjerenje pragmatičnih atributa dok je mjerenje hedonističkih atributa stavljeno u drugi plan. Temeljni cilj ovog doktorskog rada je razviti metodologiju koja će proširiti koncept kvalitete u korištenju te ga prilagoditi kontekstu vrjednovanja Web 2.0 aplikacija. Istraživanje će se sastojati od vrjednovanja pragmatičnih i hedonističkih atributa kvalitete u korištenju primjenom subjektivnih i objektivnih mjernih instrumenata. Podaci će se prikupljati pomoću različitih metoda (upitnik, automatsko zapisivanje postupaka, mjerenje radnog učinka korisnika i povratne informacije od korisnika) dok će sudionici istraživanja biti korisnici, istraživači u području web inženjerstva i interakcije čovjeka i računala te web razvojni inženjeri. Pored metodologije, rezultat doktorskog rada će biti i skup smjernica i preporuka za unaprjeđenje metodike razvoja i vrjednovanja Web 2.0 aplikacija.

1.2 Ciljevi i hipoteze istraživanja

Razvoj metodologije vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama će se temeljiti na sljedećim ciljevima istraživanja:

1. Identificirati i kategorizirati atribute kvalitete u korištenju Web 2.0 aplikacijama te razviti instrumente za njihovo mjerenje.
2. Izraditi konceptualni model i ispitati njegovu valjanost i pouzdanost.
3. Razviti metodologiju vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama koja će:

    a) ubrzati proces identifikacije problema tijekom upotrebe Web 2.0 aplikacija,
    b) olakšati analizu i komparaciju vrjednovanih Web 2.0 aplikacija.

Navedeni ciljevi istraživanja su konkretizirani i precizirani pomoću sljedećih hipoteza:

H_1. Konceptualni model vrjednovanja Web 2.0 aplikacija, temeljen na subjektivnim i objektivnim atributima kvalitete u korištenju, je valjan i pouzdan.

H_2. Na temelju konceptualnog modela te analize prednosti i nedostataka postojećih metoda, razvit će se metodologija vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama.

H_3. Metodologija vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama omogućava učinkovitu analizu i komparaciju vrjednovanih Web 2.0 aplikacija.

2. WEB X.Y

Web (kratica za World Wide Web) je nedavno navršio dvadeset godina te je u tom kratkom razdoblju ostavio trag u gotovo svim aspektima ljudskog djelovanja. Od svojih skromnih početaka kao medij namijenjen razmjeni informacija među znanstvenicima, razvio se u moćnu platformu koja podržava brojne oblike interakcije među različitim vrstama korisnika. Web je promijenio način na koji ljudi pretražuju informacije, pohranjuju i razmjenjuju multimedijske sadržaje, komuniciraju i surađuju, povezuju se sa prijateljima i obitelji, kupuju proizvode i usluge, obavljaju poslovne aktivnosti, usvajaju nova znanja, itd. Osim toga, potaknuo je razvoj novih poslovnih modela i strategija zbog kojih su organizacije promijenile način na koji donose odluke, povezuju se i komuniciraju sa dobavljačima i kupcima, surađuju tijekom provedbe projekata i slično.

U posljednjih se nekoliko godina Web počeo eksponencijalno razvijati što je motiviralo istraživače da njegov razvojni ciklus podijele u faze te svakoj dodijele naziv i oznaku. Naziv je sveobuhvatan pojam koji opisuje osnovne karakteristike razvojne faze, njene tehnološke temelje te načine djelovanja i korištenja Webom. S druge strane, pridruživanje generičkih oznaka u formatu X.Y služi logičkoj organizaciji razvojnih faza Weba tijekom njegovog životnog ciklusa.

Murugesan (2010) je razvojni ciklus Weba svrstao u četiri osnovne faze: Web 1.0 ili tradicionalan Web namijenjen prezentiranju informacija, Web 2.0 ili društveni Web usmjeren na povezivanje ljudi, Web 3.0 ili semantički Web orijentiran integraciji podataka te Web 4.0 ili inteligentan Web koji bi trebao omogućiti interakciju između proaktivnih agenata. Weber i Rech (2010) su otišli korak dalje u granulaciji kategorizacije te predstavili osam razvojnih faza Weba, od njegovog nastanka (Web 0.5) pa sve do vizije njegove evolucije (Web 4.0). Razvojne faze Weba ilustrirane su na slici 2.1.

Faze sa generičkom oznakom X.0 predstavljaju suštinsku promjenu u paradigmi Weba. S druge strane, X.5 predstavlja generičku oznaku za međufaze odnosno razdoblja kada web mjesta iz prethodne razvojne faze sazrijevaju dok usporedo nastaju tehnologije koje će obilježiti sljedeću razvojnu fazu. Potrebno je napomenuti da nastanak nove faze ne označava prestanak upotrebe prethodne faze (kao što je to slučaj sa verzijama programskih proizvoda) već sve faze Weba djeluju istovremeno. Naime, svaka je prethodna faza temelj za razvoj i nadogradnju razvojnih faza koje slijede. Primjerice, nastankom društvenih mreža nije došlo do prestanka upotrebe ostalih oblika interakcije među korisnicima kao što su elektronička pošta ili forumi. Isto tako, nastanak Web 2.0 paradigme nije ugrozio web portale već im omogućio da implementacijom novih tehnologija zadrže postojeće i privuku nove korisnike.

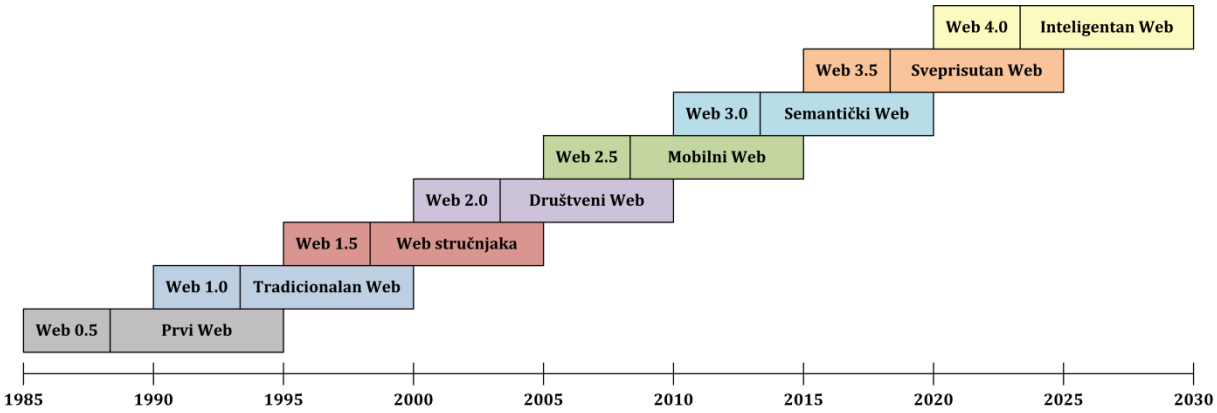

Slika 2.1 Razvojne faze Weba

Izvor: Weber i Rech (2010)

U ovom će poglavlju biti opisane razvojne faze Weba: od koncepta i implementacije, preko globalizacije i komercijalizacije, pa sve do Weba 2.0 i projekcije mogućih smjerova njegova razvoja u desetljećima koja dolaze.

2.1 Od ideje do implementacije

Razdoblje u kojem je Web od ideje o sustavu za upravljanje informacijama postao besplatna i svima dostupna usluga na Internetu te tijekom kojeg su se razvile tehnologije koje i danas čine temeljni dio njegove infrastrukture nosi oznaku Web 0.5.

Ideja o Webu kao sustavu međusobno povezanih hipertekstualnih dokumenata nastala je još 1980. godine u Europskoj organizaciji za nuklearna istraživanja (fra. Conseil Européen pour la Recherche Nucléaire – CERN). Kako bi olakšao praćenje informacija o povezanosti velikog broja dislociranih istraživača i projekata na kojima su oni angažirani, Tim Berners-Lee je razvio jednostavan hipertekstualan sustav za upravljanje informacijama te ga nazvao Enquire (skraćeno od punog naziva Enquire-Within-Upon-Everything). Enquire je bio sačinjen od niza dvosmjerno povezanih čvorova (eng. node) te je zbog toga više sličio wiki sustavu nego web stranici. Svaki čvor je sadržavao naslov, tip i popis dvosmjernih poveznica (Connolly, 2000).

Devet godine kasnije, Berners-Lee je napisao prijedlog razvoja sustava za upravljanje informacijama koji bi istraživačima širom svijeta omogućio decentraliziranu razmjenu podataka (Berners-Lee, 1989). Međutim, uprava CERN-a nije prepoznala potencijal njegovog prijedloga te je stoga Berners-Lee odlučio samostalno implementirati svoju ideju. Koristeći NeXTStep objektno orijentiran operativni sustav na NeXT radnoj stanici, Berners-Lee je tijekom 1990. godine razvio cjelokupnu tehničku infrastrukturu Weba koja je obuhvaćala: HTTP (kratica za

eng. HyperText Transfer Protocol) protokol za razmjenu hipertekstualnih dokumenata između web preglednika i web poslužitelja, web preglednik simboličnog naziva WorldWideWeb (W3) koji je osim grafičkog korisničkog sučelja sadržavao i funkcionalnost izrade web stranica u opisnom jeziku HTML (kratica za eng. HyperText Markup Language), te URI (kratica za eng. Unified Resource Identifier) shemu za dodjeljivanje jedinstvenih identifikatora dokumentima pohranjenih na Webu (Berners-Lee et al., 1994). Osim toga, konfigurirao je web server koji je na adresi *info.cern.ch* prikazivao početnu web stranicu (prikazana na slici 2.2) sa svim informacijama o projektu.

Slika 2.2 Prva web stranica

Obzirom da WorldWideWeb preglednik (čije je naziv kasnije promijenjen u Nexus kako ne bi došlo do poistovjećivanja sa sustavom hipertekstualnih dokumenata) nije bio prenosiv te se njime bilo moguće koristiti jedino na NeXT radnoj stanici, Nicola Pellow je napisala Line Mode Browser (World Wide Web Consortium, 1991) koji je preko naredbenog korisničkog sučelja omogućavao pregledavanje tekstualnih web stranica. Zbog navedene je karakteristike Line Mode Browser bio funkcionalan na većini tadašnjih računala. U studenom 1990. godine, Berners-Lee je uz pomoć Roberta Cailliaua oblikovao formalni prijedlog o razvoju mreže hipertekstualnih dokumenata (Berners-Lee i Cailliau, 1990). Budući da uprava CERN-a i dalje nije bila zainteresirana za financiranje prijedloga, Berners-Lee se okrenuo Internet zajednici te je 6. kolovoza 1991. godine objavio informacije o projektu na *alt.hypertext* interesnoj grupi. Navedenog je datuma Web i službeno postao javno dostupna usluga na Internetu. Mjesec dana kasnije, CERN je posjetio Paul Kunz iz Stanford Linear Accelerator Center (SLAC) nacionalnog laboratorija za energiju u Kaliforniji. Kunz se toliko oduševio konceptom Weba da je isti po povratku prezentirao Louise Addis koja je u to vrijeme vodila knjižnicu u SLAC-u. Na njen se poticaj oformio tim stručnjaka koji je započeo rad na prvom web serveru izvan CERN-a. U

prosincu 1991. godine tim je pod vodstvom Louise Addis objavio prvu web stranicu sa područja Sjedinjenih Američkih Država koja je omogućavala pristup bibliografskoj bazi fizike čestica (Berners-Lee, 1999).

Pored World Wide Weba, u tom su vremenskom razdoblju nastala još dva sustava čiji se rad temeljio na arhitekturi klijent-poslužitelj (eng. client-server). Prvi među njima je bio Wide Area Information Server (WAIS) koji je razvijen 1988. godine u Thinking Machines Inc. Njegova namjena je bila indeksiranje, pretraživanje i dohvaćanje dokumenata pohranjenih na poslužitelju. WAIS je podržavao pretraživanje dokumenata u dvije faze. U prvoj je temeljem mehanizma za ponderiranje indeksiranih riječi i rangiranje dokumenata prema relevantnosti dohvaćao nazive dokumenata koji su se najbolje podudarali sa upitom pretraživanja. Nakon toga je korisnik imao mogućnost da nad dohvaćenim podacima provede novu, suženu pretragu. Međutim, WAIS nije sadržavao navigacijske mehanizme za upravljanje dohvaćenim rezultatima pretraživanja te nije omogućavao direktan pristup do grafičkih datoteka (Berners-Lee et al., 1994). Osim toga, sustav nije podržavao pretraživanje i dohvaćanje dokumenata izvan poslužitelja na kojem su oni bili indeksirani i pohranjeni (Berners-Lee et al., 1992). Premda je njegov potencijal najviše korišten za indeksiranje i pretraživanje dokumenata u knjižnicama, WAIS se zbog svojih karakteristika s pravom može smatrati pretečom modernih tražilica.

Drugi sustav sličan World Wide Webu nastao je u proljeće 1991. godine na Sveučilištu u Minnesoti pod nazivom Gopher. Namijenjen je distribuciji dokumenata koji su hijerarhijski organizirani te prikazani kao elementi izbornika. Takva je struktura ujedno i jedan od najvećih nedostataka Gopher sustava jer je njegova upotreba ograničena na pretraživanje i pregledavanje dokumenata kojima je unaprijed određen tip i format. Premda su u početku Gopher preglednici podržavali dohvaćanje isključivo tekstualnih dokumenata, tek je razvoj HyperGopher preglednika omogućio prikazivanje jednostavnih grafičkih dokumenata. Temeljni dijelovi Gopher sustava su Veronica i Jughead poslužitelji, a služe indeksiranju naziva direktorija i datoteka pohranjenih na Gopher stranicama.

Dvije odluke donesene početkom 1993. godine zauvijek su odredile budućnost Gopher i World Wide Web sustava. Najprije je Sveučilište u Minnesoti odlučilo da će naplaćivati upotrebu njihovih implementacija Gopher poslužitelja (The Minnesota Gopher Team, 1993), da bi samo dva mjeseca nakon toga CERN službeno objavio da će World Wide Web biti besplatan i svima dostupan (Connolly, 2000). Nakon toga je broj korisnika Weba počeo ubrzano rasti te je globalna mreža za razmjenu informacija počela dobivati potpuno nove dimenzije.

2.2 Globalizacija i komercijalizacija Weba

U ovom je razdoblju Web bio orijentiran prezentiranju informacija. Dok su jedino poznavatelji HTML jezika imali mogućnost kreirati web stranice, korisnici su bili pasivni konzumenti sadržaja koji su na njima bili objavljeni. Obzirom da su web stranice bile pisane u HTML jeziku, njihova je interaktivnost bila minimalna. Web stranice su bile statične te je ponekad trebalo čekati i mjesecima kako bi sadržaj na njima bio promijenjen. Zbog svega navedenog ova razvojna faza nosi oznaku Web 1.0 te joj se pridjeljuju različiti nazivi poput Web samo za čitanje, statičan Web, plitak Web i tradicionalan Web.

Nedugo nakon što je koncept Weba objavljen na interesnim zajednicama, broj HTTP servera širom svijeta neprestano se povećavao da bi početkom 1993. godine dosegnuo brojku pedeset (World Wide Web Consortium, 2004). U to je vrijeme jedini dostupni web preglednik sa grafičkim korisničkim sučeljem i dalje bio WorldWideWeb. Međutim, kako je on bio funkcionalan jedino na NeXT radnoj stanici, javila se potreba za web preglednicima sa grafičkim korisničkim sučeljem koji će se moći upotrebljavati na platformama poput Unixa, Macintosha i Microsoft Windowsa. Motivirani idejom o korištenju Webom na osobnim računalima brojni su entuzijasti, mahom iz redova studenata, razvili vlastite web preglednike. Pregled najranijih web preglednika nalazi se u tablici 2.1.

Od navedenih je web preglednika najveću popularnost stekao Mosaic prvenstveno zbog toga što je podržavao rad na tri različite platforme. Osim toga, sadržavao je brojne funkcionalnosti poput podrške za video zapise, zvuk, obrasce, knjižne oznake i datoteke sa podacima o povijesti pretraživanja što ostali web preglednici u to vrijeme nisu imali (Vetter et al., 1994). U ožujku 1994. godine, Marc Andreessen je zajedno sa kolegama koji su bili angažirani na razvoju Mosaic web preglednika te u suradnji sa Jamesom H. Clarkom utemeljio Mosaic Communications. Mjesec dana kasnije, organizacija je promijenila ime u Netscape Communications da bi sredinom prosinca iste godine objavila prvu verziju komercijalnog web preglednika Netscape Navigator. Razvoj brojnih web preglednika rezultirao je neredom u specifikaciji HTML jezika jer je svaki autor u istu dodavao svoje tagove (Raggett et al., 1998). Kako bi riješio navedeni problem, Dan Connolly je zajedno sa kolegama napravio popis najkorištenijih tagova te u koautorstvu sa Timom Berners-Leejem napisao i objavio novu specifikaciju jezika pod nazivom HTML 2.0 (Berners-Lee i Connolly, 1995). Rast popularnosti Weba potaknuo je pružatelje usluga pristupa Internetu (eng. Internet Service Providers, ISPs) da korisnicima ponude raznovrsne pakete koji su osim dial-up priključka na Internet te nekoliko specifičnih programa sadržavali i web preglednik. Prvi takve vrste ponudila je tvrtka Spry pod nazivom „Internet in the Box“ (Goldberg, 1994). Sve navedeno dovelo je do globalizacije Weba.

Tablica 2.1 Pregled najranijih Web preglednika sa grafičkim korisničkim sučeljem

Naziv web preglednika	Autor(i)	Ustanova	Datum objave	Podržane platforme
WorldWideWeb (Nexus)	Tim Berners-Lee	Conseil Européen pour la Recherche Nucléaire (CERN)	prosinac 1990.	NeXTStep OS
Erwise	Kim Nyberg Teemu Rantanen Kati Suominen Kari Sydänmaanlakka	Helsinki University of Technology	travanj 1992.	Unix
ViolaWWW	Pei-Yuan Wei	University of California, Berkeley	travanj 1992.	Unix
Lynx	Lou Montulli Michael Grobe Charles Rezac	University of Kansas	srpanj 1992.	Unix
tkWWW	Joseph Wang	Massachusetts Institute of Technology	srpanj 1992.	Unix
MidasWWW	Tony Johnson	Stanford Linear Accelerator Center	studeni 1992.	Unix
Samba	Nicola Pellow Robert Cailliau	Conseil Européen pour la Recherche Nucléaire (CERN)	siječanj 1993.	Macintosh
Mosaic	Marc Andreessen Eric Bina	National Center for Supercomputing Applications at the University of Illinois	veljača 1993.	Unix
	Aleksandar Totić		rujan 1993.	Macintosh
	Chris Wilson Jon Mittelhauser		rujan 1993.	Microsoft Windows
Cello	Thomas R. Bruce	Cornell Law School	lipanj 1993.	Microsoft Windows
Arena	Dave Raggett	Hewlett-Packard, Bristol	1993.	Unix

Eksponencijalan rast u broju korisnika i raznovrsnih web mjesta potaknuo je Berners-Leeja na razmišljanje o nezavisnom tijelu koje bi se bavilo osiguranjem kontinuiranog razvoja Weba. Stoga je početkom listopada 1994. godine uz potporu Europske komisije (eng. European Commission) i agencije američkog ministarstva obrane za razvoj novih tehnologija DARPA (kratica za eng. Defense Advanced Research Projects Agency) na MIT-u (kratica za eng. Massachusetts Institute of Technology) osnovao World Wide Web konzorcij (eng. World Wide Web Consortium, W3C). Konzorcij se danas sastoji od 375 organizacija iz cijelog svijeta (World Wide Web Consortium, 2012) koje zajedničkim snagama rade na oblikovanju preporuka i standardizaciji tehnološke infrastrukture Weba, a sve s ciljem postizanja usklađenosti i suglasnosti u razvoju web mjesta.

U nadolazećoj su razvojnoj fazi web mjesta od statičnih web stranica prerasla u dinamične i interaktivne web aplikacije namijenjene elektroničkom poslovanju i upravljanju sadržajem. Bilo je to razdoblje Weba 1.5 kada se razvojna paradigma dominantno usmjerena na funkcionalnost web mjesta počela sve više fokusirati na želje i potrebe krajnjih korisnika.

Paralelno sa nastankom novih web preglednika poput Netscape Navigatora i Internet Explorera, razvijali su se i programski jezici koji su omogućavali skriptiranje na jednoj od strana u arhitekturi klijent-poslužitelj. Dinamični HTML (eng. Dynamic HyperText Markup Language, DHTML) je proširenje opisnog jezika HTML sa: a) programskim jezikom koji omogućava skriptiranje na strani klijenta (primjerice JavaScript ili ActiveX), b) prezentacijskim jezikom namijenjenim opisu izgleda i formata pojedinih elemenata web stranice (primjerice stilski jezik Cascading Style Sheets, CSS) i c) objektnim modelom dokumenta (eng. Document Object Model, DOM) koji predstavlja sučelje za programiranje aplikacija (eng. Application Programming Interface, API), a služi definiranju logičke strukture hipertekstualnog dokumenta i načina kojim se njime upravlja te mu se pristupa. Web stranice implementirane pomoću DHTML-a su imale sofisticiraniji dizajn te su bile sačinjene od interaktivnih elemenata sučelja poput padajućih izbornika, animiranog teksta i slika, elemenata navigacije (gumbi) koji mijenjaju izgled kada se mišem prijeđe preko njih i sličnih efekata.

Kao standardno sučelje koje određuje format i sintaksu za prosljeđivanje podataka web poslužiteljima od strane klijenta (eng. Common Gateway Interface, CGI) korištene su skripte najčešće pisane u programskim jezicima Perl i C/C++ (Gundavaram, 1996). Validacija podataka unesenih u obrazac i brojač posjeta su samo neki od primjera kako su CGI skripte bile upotrebljavane. Razvoj opisnog jezika XML (kratica za eng. eXtensible Markup Language) namijenjenog definiranju, prijenosu, validaciji i interpretaciji podataka na Webu te programskih jezika orijentiranih skriptiranju na strani poslužitelja kao što su Perl, PHP (kratica za eng. PHP:

Hypertext Preprocessor), ASP (kratica za eng. Active Server Pages), JSP (kratica za eng. Java Server Pages), Ruby, Python i ColdFusion omogućio je generiranje dinamičnih web aplikacija za upravljanje sadržajem i elektroničko poslovanje.

Kako bi se riješio problem decentraliziranosti web mjesta na kojima su jedino pojedinci sa razvijenim tehničkim vještinama mogli objavljivati sadržaje, sredinom devedesetih godina prošlog stoljeća razvili su se sustavi za upravljanje sadržajem na Webu (eng. Web Content Management Systems, WCMSs). U početku je njihova svrha bila omogućiti krajnjim korisnicima da temeljem unaprijed definiranih predložaka brzo i jednostavno generiraju web stranice te na njih dodaju nove ili modificiraju postojeće sadržaje. Obzirom da je skalabilnost jedna od važnijih prednosti sustava za upravljanjem sadržajem na Webu, u kasnijim su inačicama njihove funkcionalnosti proširene na module za upravljanje verzijama dokumenata, personalizaciju sučelja, asinkronu komunikaciju (forumi), galerije slika i slično. Osim toga, zbog svoje su fleksibilnosti često bili korišteni za izradu web portala i web trgovina.

Ubrzo nakon što je razvoj Weba uzeo maha, poslovne su organizacije prepoznale njegov potencijal za oglašavanje i prodaju proizvoda. Prva među njima je bila online knjižara koju je 1994. godine osnovao Jeff Bezos pod nazivom Cadabra da bi istu samo godinu dana kasnije preimenovao u Amazon.com. Pet godine kasnije, časopis Time je Bezosa proglasio osobom godine zbog uspješnog poslovnog modela i popularizacije online kupovanja (Ramo, 1999). U međuvremenu je kompanija znatno proširila svoj asortiman te se razvila u jednu od najpopularnijih online trgovina u svijetu.

Potaknute uspjehom Amazona i porastom sredstava fondova rizičnog kapitala, brojne su organizacije krajem devedesetih godina prošlog stoljeća odlučile svoje poslovanje temeljiti na Webu. Riječ je o takozvanim *dot-com* kompanijama kojima je bio cilj u što kraćem periodu vremena monopolizirati tržište određene niše te se obogatiti prodajom dionica. Bez obzira na činjenicu što su njihove poduzetničke ideje uglavnom bile moderne i profitabilne, gotovo nijedna kompanija nije imala razrađen dugoročni poslovni plan. Dodavanje prefiksa „e-“ i/ili sufiksa „.com“ u naziv kompanije je bilo percipirano kao pozitivna promjena u poslovanju te je nerijetko nagrađivano porastom cijene dionica (Willis, 2011). Ulagači se više nisu pouzdali u klasične pokazatelje poslovanja već su svoje odluke temeljili na uvjerenjima o tehnološkom napretku. Međutim, takav je oblik poslovanja bio kratkog vijeka. NASDAQ (kratica za eng. National Association of Securities Dealers Automated Quotation) kompozitni indeks sačinjen od dionica dot-com kompanija je 10. ožujka 2000. godine dosegnuo svoju najvišu točku da bi do listopada 2002. godine zabilježio pad od 78% (Augen, 2011). Zbog drastičnog pada cijena dionica, većina dot-com kompanija je preuzeto od strane konkurencije ili su u potpunosti ugašene. Kompanije

koje su uspjele preživjeti krah su i danas vodeće u granama svojeg djelovanja. Osim Amazona, među njih se ubrajaju eBay i Google.

Popularno aukcijsko web mjesto eBay utemeljio je Pierre Omidyar u rujnu 1995. godine pod nazivom AuctionWeb. Prva stvar koja je bila prodana putem tog web mjesta je bio pokvareni laserski pokazivač za kojeg je kolekcionar izdvojio iznos od 14,83 dolara (Peragine i Russell, 2011). Kako je popularnost web mjesta rasla, Omidyar je odlučio zakupiti domenu echobay.com kao skraćeni oblik naziva njegove konzultantske tvrtke Echo Bay Technology Group. Obzirom da je ta domena već bila zauzeta, Omidyar je dodatno skratio naziv te je tako rođen eBay.com koji je predstavljen javnosti u rujnu 1998. godine (Peragine i Russell, 2011). Premda se ponuda eBay-a u početku sastojala samo od kolekcionarskih predmeta, proširenje asortimana dovelo je do značajnog poslovnog rasta kompanije. Kako bi zaštitio svoje klijente od prijevara, eBay je u svibnju 1999. godine kupio Billpoint te ga integrirao kao službeni oblik plaćanja. U ožujku sljedeće godine nastao je PayPal koji je štitio sigurnost kupaca tako da je tijekom provedbe online transakcije od njih zahtijevao unos CAPTCHA (kratica za eng. Completely Automated Public Turing test to tell Computers and Humans Apart) znakova. PayPal je ubrzo postao omiljena metoda plaćanja kojom se koristila većina eBay klijenata. Stoga je eBay u listopadu 2002. godine kupio PayPal koji je u nadolazećim godinama postao sinonim za siguran oblik plaćanja na Webu (McDougall, 2007).

Online trgovine nisu bili jedini način na koji su poslovne organizacije pokušavale doprijeti do potencijalnih kupaca. Usporedo sa razvojem web preglednika, nastajali su i web portali koji su prilikom instalacije web preglednika postavljani kao početno web mjesto. Web portal je specifična vrsta web mjesta koje objedinjava informacije sa različitih izvora te korisnicima nudi široki spektar dodatnih usluga. Postoje dvije vrste web portala: horizontalni i vertikalni portali (Xiao i Dasgupta, 2005). Horizontalni portali su usmjereni prema široj zajednici korisnika. Osim što prezentiraju vijesti i novosti iz različitih interesnih područja, sadrže i usluge poput tražilice, elektroničke pošte, vremenske prognoze, tečajne liste i slično. S druge strane, vertikalni portali pružaju usko specijalizirane informacije i usluge namijenjene specifičnoj skupini korisnika. Dok horizontalni portali nude otvoren pristup svim korisnicima, za pristupanje sadržajima vertikalnog portala je najčešće potrebno imati otvoren korisnički račun.

Google je nastao tijekom 1996. godine kao istraživački projekt dvojice poslijediplomanata sveučilišta Stanford. Kao sastavni dio BackRub tražilice, Larry Page i Sergey Brin su implementirali rekurzivni algoritam PageRank koji je pridruživao ponder svakom hipertekstualnom dokumentu s ciljem mjerenja njegove relativne važnosti. Koristeći razdiobu vjerojatnosti, PageRank je generirao hijerarhiju rezultata pretraživanja prema popularnosti

poveznica (Page et al., 1999). Položaj pojedinog dokumenta u hijerarhiji rezultata pretraživanja bio je određen brojem poveznica koje su na njega upućivale. Nasuprot tome, popularne web tražilice iz tog vremena Yahoo! i Altavista su rezultate pretraživanja rangirale prema učestalosti pojavljivanja traženog pojma u hipertekstualnom dokumentu. Međutim, ispostavilo se je da PageRank algoritam vraća relevantnije rezultate pretraživanja od svih ostalih web tražilica (Brin i Page, 1998).

Tijekom 1997. godine tražilica mijenja naziv u Google koji predstavlja matematički pojam za broj jedan i stotinu nula te na taj način reflektira misiju kompanije - organizirati naizgled beskonačnu količinu informacija na Internetu (Google, 2012). Godinu dana kasnije, PC Magazine je proglasio Google najboljom web tražilicom te ga uvrstio među 100 najboljih web lokacija (Google, 2012). U lipnju 2000. godine, Google objavljuje indeks sa milijardu URL-ova te time postaje i službeno najveća web tražilica na svijetu (Google, 2012). Četiri mjeseca kasnije, Google pokreće samoposlužni program oglasa pod nazivom AdWords koji omogućava svakome da na jednostavan način kreira oglas te ga označi ključnim riječima. Svaki put kada korisnici u tražilicu upišu ključnu riječ koja je oglasu pridodana, oglas će se prikazati pokraj rezultata pretraživanja. Razlog zbog kojeg je ovaj oblik oglašavanja postao uspješan je način naplaćivanja oglasa. Naime, usluga oglašavanja se naplaćuje samo ako netko klikne na oglas (eng. Pay Per Click), dok se samo prikazivanje oglasa ne naplaćuje. AdWords se ubraja među prve web aplikacije koje su svojim obilježjima nagovijestile novu paradigmu Weba u kojoj će korisnici imati puno veću slobodu u kreiranju i objavljivanju sadržaja.

2.3 Web 2.0

Tim Berners-Lee je u svojem prijedlogu o implementaciji World Wide Weba (Berners-Lee i Cailliau, 1990) predvidio da će korisnici u prva tri mjeseca od pokretanja projekta moći pregledavati web stranice dok će im u sljedeća tri biti omogućeno da samostalno kreiraju i objavljuju sadržaje online. Dok je prvi cilj zaživio relativno brzo, na realizaciju drugog su korisnici trebali čekati gotovo cijelo desetljeće.

Početkom 2004. godine stručnjaci domene su uočili da se Web razvio u dinamičnu i robusnu platformu koja podržava nove oblike razvoja i upotrebe web mjesta. U listopadu iste godine predstavnici kompanija O'Reilly i MediaLive International su organizirali konferenciju na kojoj su globalni lideri kao primjeri dobre prakse zainteresiranim dionicima predstavili načine na koje je moguće maksimalno iskoristiti potencijale koje pruža Web kao platforma. Utemeljiteljem koncepta Weba 2.0 se smatra Dale Dougherty iz razloga što je tijekom sastanka koji je prethodio

spomenutoj konferenciji napomenuo kako je krah dot-com kompanija označio početak druge generacije web aplikacija (Musser i O'Reilly, 2007).

Dinamična i interaktivna web mjesta koja korisnicima pružaju slobodu i fleksibilnost u interakciji sa elementima njihova sučelja se nazivaju Web 2.0 aplikacije. U prijašnjim razvojnim fazama Weba, objavljivanje novih i ažuriranje postojećih sadržaja na web mjestu je bilo rezervirano za pojedince koji su posjedovali dostatnu količinu informacijske pismenosti dok su preostali korisnici objavljene sadržaje mogli samo čitati i pregledavati. Nasuprot tome, Web 2.0 aplikacije raspolažu funkcionalnostima koje podržavaju različite oblike interakcije među korisnicima te omogućuju svakome od njih da kreira, objavljuje, razmjenjuje, organizira i integrira raznovrsne artefakte te na taj način aktivno sudjeluje u oblikovanju repozitorija sadržaja. Zbog navedenog se Web druge generacije naziva još i društveni Web.

2.3.1 Uzorci dizajna Weba 2.0

O'Reilly (2005) je definirao osam uzoraka dizajna te na taj način pojasnio koncepte Web 2.0 paradigme. Zatim su Musser i O'Reilly (2007) spomenute uzorke konkretizirali primjerima dobre prakse te na taj način specificirali obilježja Web 2.0 aplikacija. Uzorci dizajna su usmjereni na razvoj i vrjednovanje Web 2.0 aplikacija, izgradnju infrastrukture te oblikovanje i primjenu poslovnog plana. Potrebno je napomenuti da nijedan od spomenutih uzoraka nije nezavisan već se isti međusobno isprepliću i nadopunjuju. Svaki od osam ključnih uzoraka dizajna (Musser i O'Reilly, 2007, str. 13-54) će biti opisan u nastavku ovog potpoglavlja.

Prvi uzorak dizajna druge generacije Weba je **uprezanje kolektivne inteligencije** (izvorno eng. Harnessing Collective Intelligence) koje počiva na arhitekturi sudjelovanja korisnika i mrežnim učincima. Prema prvom od spomenutih koncepata ovog uzorka dizajna, korisnici kroz različite oblike interakcije sa Web 2.0 aplikacijom počam od kreiranja, dijeljenja, organizacije i integracije artefakata preko pretraživanja, kupovine, preuzimanja i ostavljanja povratnih informacija u obliku komentara ili recenzija pa sve do komunikacije i suradnje sa ostalim korisnicima stvaraju dodanu vrijednost Web 2.0 aplikacije. Pored spomenutih eksplicitnih oblika sudjelovanja, potrebno je osigurati da korisnici implicitno dodaju vrijednost Web 2.0 aplikaciji. Primjerice, Amazon na osnovi prikupljenih podataka vezanih uz pretraživanje i kupovinu korisnicima nudi proizvode u obliku personaliziranih preporuka (Musser i O'Reilly, 2007, str. 15). Drugi koncept ovog uzorka dizajna implicira da Web 2.0 aplikacija postaje bolja što je više ljudi upotrebljava. Na primjer, povećanje broja korisnika Web 2.0 aplikacije eBay rezultiralo je pogodnostima za kupce u pogledu raznovrsnijeg asortimana proizvoda i prednostima za prodavatelje u obliku većeg broja ponuditelja (Musser i O'Reilly, 2007, str. 16).

Obzirom da korisnici običavaju prihvatiti početne postavke te ih je mali broj spreman aktivno doprinijeti dobrobiti Web 2.0 aplikacije, potrebno je da mrežni učinci budu implementirani kao zadane postavke. Tako su primjerice fotografije objavljene na Web 2.0 aplikaciji Flickr prema zadanoj postavci javne zbog čega je ista u kratkom roku prikupila veliki broj korisnika (Musser i O'Reilly, 2007, str. 15). Kako bi se osiguralo aktivno sudjelovanje korisnika, potrebno im je omogućiti da primjenom Web 2.0 aplikacije ostvare svoj cilj na učinkovit i jednostavan način. Kao primjer dobre prakse moguće je navesti YouTube koji omogućava nesmetano pretraživanje, pregledavanje i objavljivanje video zapisa ili Diigo koji olakšava pohranu i organizaciju izvora na Webu. Nadalje, potrebno je stvoriti relevantan kontekst upotrebe Web 2.0 aplikacije. Navedeno se odnosi na funkcionalnosti sa kojima Web 2.0 aplikacija raspolaže kao i na njihovu prikladnost. Primjerice, društvene mreže trebaju podržavati različite oblike interakcije među korisnicima, omogućavati pretraživanje, dijeljenje i integraciju artefakata, sadržavati funkcionalnosti koje olakšavaju personalizaciju korisničkih profila i stvaranje interesnih grupa, itd. Jednako tako, potrebno je vjerovati korisnicima te utvrditi što ih potiče na korištenje Web 2.0 aplikacijom. Korisnici su ti koji u Wikipediji imaju kontrolu nad kreiranjem i upravljanjem sadržajem što im stvara osjećaj odgovornosti za njihovu istinitost i vjerodostojnost. S druge strane, u društvenoj mreži Researchgate korisnici dobivaju bodove koji predstavljaju mjerilo njihove znanstvene reputacije te ih motiviraju da budu aktivniji u diskusijama sa ostalim korisnicima kao i da im omoguće pristup cjelovitom tekstu radova koje su objavili. Naposljetku, Web 2.0 aplikacija treba olakšati implementaciju promjena u svom radu kao rezultat korisničkog iskustva. Primjerice, Flickr je originalno zamišljen kao online igra no ubrzo je postalo jasno da su korisnici najviše zainteresirani za njegovu funkcionalnost dijeljenja fotografija (Musser i O'Reilly, 2007, str. 16).

Prema drugom uzorku dizajna, **podaci predstavljaju jezgru kompetitivne prednosti** (izvorno eng. Data Is the Next "Intel Inside") Web 2.0 aplikacije. Navedeno je moguće postići putem različitih strategija. Prema prvoj od njih, potrebno je stvoriti jedinstveni izvor podataka koji je ostalima teško ili skupo razviti. Ovaj oblik strategije primijenio je NAVTEQ te na taj način postao vodeći proizvođač digitalnih kartografskih podataka čije usluge između ostalog upotrebljava i Google Maps (Musser i O'Reilly, 2007, str. 21). Prema sljedećoj strategiji potrebno je vlastite podatke proširiti onima koji nastanu aktivnošću korisnika bilo da je riječ o njihovim artefaktima, komentarima, tagovima ili ocjenama. Pored toga, Web 2.0 aplikacija treba raspolagati kapacitetima koji će potaknuti korisnike da istoj povjere pohranu svojih podataka. Nadalje, Web 2.0 aplikacija treba osigurati zaštitu intelektualnog vlasništva svojih korisnika. Primjenom jednog od modela licence slobodnog softvera (eng. General Public License, GPL) ili kreativnog općeg dobra (eng. Creative Commons, CC) Web 2.0 aplikacija može zaštititi prava vlasnika odnosno autora artefakta te istovremeno omogućiti njihovo dijeljenje i korištenje pod određenim uvjetima (Musser i O'Reilly, 2007, str. 21). Navedeno predstavlja samo jedan od

načina kako Web 2.0 aplikacija treba olakšati ponovnu upotrebu podataka. Tijekom oblikovanja podataka potrebno je slijediti postojeće standarde kao što je primjerice RSS (kratica za eng. Rich Site Summary ili Really Simple Syndication) čime će biti olakšano njihovo pretraživanje, korištenje i distribuiranje. Potrebno je naći „svoje mjesto pod suncem“ u kontekstu podatkovne strategije te iskoristiti prednosti koje ono donosi. Primjerice, deCarta više ne nudi samo usluge procesiranja i renderiranja kartografskih podataka već je potaknuta uspjehom aplikacije Google Maps ponudila vlastito okruženje za razvoj lokacijskih aplikacija (Musser i O'Reilly, 2007, str. 22). Pored izvora podataka, kompetitivna prednost može počivati i na vlastitom indeksu, registru ili formatu podataka. Primjeri dobre prakse su brojni (Musser i O'Reilly, 2007, str. 22), od indeksa blogova (Technorati) i rangova web mjesta (Alexa) preko registra poslovnih profila (LinkedIn) pa sve do formata geoprostornih datoteka (Google Earth). Naposljetku, Web 2.0 aplikacija može usluge upravljanja pristupa podacima (npr. upravljanje infrastrukturom, kapacitet na serveru i slično) prepustiti trećim stranama ili se za navedene usluge i sama specijalizirati.

Web kao platforma namijenjena razvoju inovativnih aplikacija (izvorno eng. Innovation in Assembly) predstavlja treći uzorak dizajna. Kako bi se iskoristile prednosti ovog uzorka dizajna potrebno je trećim stranama omogućiti pristup vlastitom sučelju za razvoj Web 2.0 aplikacija (eng. Application Programming Interface, API). Jednako je tako potrebno razviti infrastrukturu podrške web razvojnim inženjerima koja će se sastojati od dokumentacije, raznovrsnih mehanizama namijenjenih komunikaciji i suradnji, jednostavnih primjera u brojnim programskim jezicima, podrške za različite podatkovne formate i protokole, itd. Spomenutu je infrastrukturu potrebno temeljiti na Web 2.0 aplikacijama koje će ovisno o svojoj namjeni osigurati relevantnu podršku razvojnoj platformi. Musser i O'Reilly (2007) naglašavaju da su otvorenost i visoki stupanj transparentnosti temelj izgradnje povjerenja i lojalnosti korisnika. Isti autori navode da ugradnja poslovnog modela u vlastito sučelje za razvoj Web 2.0 aplikacija rezultira time da se svakom upotrebom istog od trećih strana stječe dobit. Nadalje, digitalne je podatke potrebno oblikovati u male i praktične cjeline te dostavljati u strukturiranim podatkovnim formatima kao što su RSS, Atom, JSON (kratica za eng. JavaScript Object Notation), multimedijski formati i mikroformati čime je olakšano njihovo remiksiranje i integracija u mashupove. Korisnici mogu sadržaje pohranjene u spomenutim formatima pregledavati pomoću widgeta ugrađenih u personalizirane web portale kao što je primjerice Netvibes. Zbog toga sadržaji trebaju biti distribuirani u standardnim formatima kako na strani klijenta, tako i na strani poslužitelja. Konačno, načini na koji treće strane primjenjuju sučelje za razvoj aplikacija, a korisnici remiksiraju podatke, trebaju poslužiti kao inspiracija za unaprjeđenje postojećih i razvoj novih vlastitih proizvoda.

Četvrti uzorak dizajna je usmjeren na **obogaćivanje korisničkog iskustva** (izvorno eng. Rich User Experiences). Navedeno se postiže kombinacijom najboljih elemenata desktop okruženja (interaktivnost, angažman korisnika i performanse na visokoj razini) i web aplikacija (neovisnost o platformi, mogućnost pristupanja od bilo kuda i suradnja)(Musser i O'Reilly, 2007, str. 31). Primjerice, Google Docs omogućuje kolaborativno uređivanje dokumenata na bilo kojem računalu koje ima vezu na Internet preko grafičkog korisničkog sučelja koje je vrlo slično sučelju desktop verzija uredskih paketa. Upotrebljivost i jednostavnost trebaju biti imperativ razvoja Web 2.0 aplikacija te ih se ne smije žrtvovati zbog tehnoloških trendova. Navedeno se prvenstveno odnosi na učinkovitost i lakoću korištenja. Primjer dobre prakse je YouTube čijom je primjenom moguće na vrlo jednostavan način učitavati i reproducirati multimedijske zapise raznovrsnih formata u različitim web preglednicima (Musser i O'Reilly, 2007, str. 31). Osim toga, njegova je komponenta za reprodukciju implementirana u Flashu te je istu shodno tome moguće na vrlo jednostavan način integrirati u wiki stranicu, blog, društvenu mrežnu stranicu i slično. Implementacija tehnologija koje osiguravaju bogato korisničko iskustvo treba biti usklađena sa kontekstom upotrebe Web 2.0 aplikacije. Jednako je tako potrebno integrirati mehanizme koji omogućuju učinkovito interno pretraživanje. Jedan od primjera jest Delicious koji na osnovi web adrese, postojećih tagova korisnika i tagova preostalih korisnika automatski predlaže tagove za web izvor kojeg korisnik namjerava pohraniti (Musser i O'Reilly, 2007, str. 32). Obzirom da pojedine vrste Web 2.0 aplikacija nisu sačinjene od stranica već elemenata grafičkog korisničkog sučelja, sadržajima koji su na njima pohranjeni nije moguće pristupati preko direktne web adrese. Međutim, navedene je sadržaje potrebno učiniti pretraživima kako ljudima (preko knjižnih oznaka) tako i strojevima (preko tražilica, agregatora i slično). Google Maps je doskočio spomenutom problemu na način da generira direktnu poveznicu za svaku geolokaciju koju prikazuje (Musser i O'Reilly, 2007, str. 32). Naposljetku, Web 2.0 aplikacija temeljem prijašnjih interakcija predviđa potrebe korisnika, pamti njihove preference te im se prilagođava. Tijekom učitavanja, Amazon generira, personalizira i optimizira gotovo svaku stranicu što rezultira povećanjem lojalnosti korisnika (Musser i O'Reilly, 2007, str. 33). S druge strane, Gmail na osnovi poslanih i zaprimljenih poruka elektroničke pošte korisnicima predlaže adrese elektroničke pošte bez da su iste prethodno unesene kao kontakti u adresar (Musser i O'Reilly, 2007, str. 33).

Prema petom uzorku dizajna, Web 2.0 aplikacija treba biti **dostupna sa svakog uređaja koji omogućava pristup Internetu** (izvorno eng. Software Above the Level of a Single Device). Web 2.0 aplikacije trebaju biti upotrebljive na svakom uređaju sa vezom na Internet. Navedeno je moguće postići na dva načina. Prvi je da se Web 2.0 aplikacija upotrebljava u web pregledniku koji je na uređaju instaliran, a drugi da se za svaki uređaj razvije posebna aplikacija preko koje se pristupa funkcionalnostima sučelja i sadržajima Web 2.0 aplikacije. Primjerice, Facebook je

moguće učitati i upotrebljavati u web pregledniku na svakom uređaju koji je povezan na Internet. Međutim, jednako su tako dostupne specijalizirane aplikacije za operacijske sustave iOS i Andoid čija primjena unaprjeđuje kvalitetu interakcije kada se Facebook upotrebljava na pametnom telefonu ili tabletu. Nadalje, Web 2.0 aplikacija treba olakšavati razmjenu podataka između različitih uređaja. Tako primjerice Box i iCloud omogućuju pohranu i organizaciju raznovrsnih formata datoteka te njihovu sinkronizaciju između različitih uređaja. Obzirom da uređaji sa vezom na Internet imaju integrirane tehnologije kao što su Bluetooth i GPS, Web 2.0 aplikacija može iskoristiti prednosti dostupnih lokacijskih podataka. Na primjer, Instagram sadrži funkcionalnost geoprostornog označavanja (eng. geotagging) učitanih fotografija. Pored toga, Web 2.0 aplikacija može u kombinaciji sa prednostima mobilnog uređaja predstavljati izvor korisnih informacija. Upotrebom aplikacije Foursquare korisnici mogu na vrlo jednostavan način dobiti informacije o sadržajima blizu lokacije na kojoj se trenutno nalaze. Konačno, korisnici mogu upotrebom Web 2.0 aplikacija na mobilnim uređajima kreirati raznovrsne artefakte poput mentalnih mapa (Mindomo) ili audio podcastova (Mobile Podcaster) te ih objaviti na društvenim mrežnim stranicama.

Redovito dodavanje novih mogućnosti kao posljedica korisničkog iskustva (izvorno eng. Perpetual Beta) je šesti uzorak dizajna. Kontinuirano poboljšanje je osnovno obilježje razvojnog procesa Web 2.0 aplikacija. Primjena agilnih i iterativnih metodologija omogućava da se temeljem povratnih informacija od korisnika inkrementalno implementiraju nove funkcionalnosti i ispravci programskih pogrješaka. Kako bi se olakšalo upravljanje verzijama Web 2.0 aplikacije, potrebno je automatizirati testiranje te primjenjivati stroge procese izgradnje i implementacije. Primjerice, nova verzija Web 2.0 aplikacije eBay se izdaje u prosjeku svaka dva tjedna (Musser i O'Reilly, 2007, str. 40). Središnje mjesto u vrjednovanju Web 2.0 aplikacije i njenih značajki imaju korisnici. Vrjednovanje se treba sastojati od provedbe eksperimenta u kontroliranim uvjetima tijekom kojeg će se pomoću specijalizirane aplikacije prikupljati podaci o aktivnostima korisnika za vrijeme njihove interakcije sa Web 2.0 aplikacijom. Jedan od primjera takvih eksperimenata su A/B testovi koja Amazon provodi svakodnevno, a sastoje se od toga da se manjem uzorku korisnika predstave alternativne funkcionalnosti sučelja čime se vrjednuju različiti aspekti upotrebljivosti i korisničkog iskustva (Musser i O'Reilly, 2007, str. 41). Pored novih značajki, rezultat iterativnog razvoja trebaju biti i novi proizvodi. Odličan primjer je Google koji je započeo kao tražilica da bi danas u ponudi imao cijelu lepezu proizvoda. Ključ kompetitivne prednosti počiva na sljedećim operativnim strategijama (Musser i O'Reilly, 2007, str. 42): primjena hardverskih komponenti koje osiguravaju visoku razinu dostupnosti i tolerancije na pogrješke, primjena programskih proizvoda otvorenog koda koji osiguravaju visoki stupanj podrške zajednicama i resursima, prikladno nadgledanje i upravljanje sustavom, planiranje i kadrovska politika kao prioriteti,

ugradnja znanja stečenog iskustvom u značajke Web 2.0 aplikacije, stabilnost i skalabilnost. Iz navedenog proizlazi da se razvojni tim treba baviti poslovima implementacije, upravljanja podacima, vrjednovanja i upravljanja povratnim informacijama od korisnika. Kako bi se iskoristile prednosti agilnih metodologija i kratkih razvojnih ciklusa, Web 2.0 aplikacije je potrebno implementirati u dinamičnim programskim jezicima kao što su PHP, Python i Ruby ili razvojnim okruženjima poput Ruby on Rails i Django (Musser i O'Reilly, 2007, str. 42).

Sedmi uzorak se bavi **iskorištavanjem povoljnih prilika specifičnih segmenata tržišta** (izvorno eng. Leveraging the Long Tail). Odnos ponude i potražnje proizvoda na tržištu se prikazuje statističkom distribucijom koja nosi naziv dugi rep (eng. The Long Tail) gdje je „glava“ krivulje sačinjena od ograničenog broja najpopularnijih proizvoda dok se „rep“ sastoji od širokog spektra niša od kojih svaka nudi brojne tržišne prilike. U eri Weba 2.0, spomenuti fenomen omogućava osvajanje novih mikro tržišta, olakšava distribuciju sadržaja široj publici te utječe na povećanje ponude. Navedeno se postiže demokratizacijom produkcije, smanjenjem troškova te novim načinima povezivanja ponude i potražnje (Musser i O'Reilly, 2007, str. 45). Demokratizacija produkcije predstavlja razvoj Web 2.0 aplikacija koje korisnici upotrebljavaju u svrhu generiranja raznovrsnih artefakata kao što su blogovi, wiki stranice, podcastovi i slično. Uštede je moguće postići na različite načine. Primjerice, troškovi proizvodnje se mogu smanjiti komisionom prodajom (npr. komisionar (Apple) isplaćuje iznos komitentu (autoru) tek nakon što je multimedijski zapis kupljen i preuzet pomoću aplikacije iTunes), troškove skladištenja je moguće minimizirati prodajom na zahtjev (primjeri dobre prakse su Amazon i Lulu), troškovi marketinga se mogu ublažiti integracijom funkcionalnosti sinkrone i asinkrone komunikacije koje olakšavaju promociju usmenom predajom između korisnika dok se troškovi podrške mogu zadržati na prihvatljivoj razini ukoliko se korisnicima prepusti kontrola nad upravljanjem korisničkim računom (Musser i O'Reilly, 2007, str. 46-47). Naposljetku, upravljanje odnosom ponude i potražnje se bazira na filozofiji mudrosti svjetine (eng. wisdom of crowds), a provodi se primjenom algoritamskih tehnika pretraživanja i filtriranja repozitorija podataka nastalog aktivnim sudjelovanjem korisnika. Primjerice, Web 2.0 aplikacija može na osnovi recenzija korisnika ili njihovih prijašnjih aktivnosti generirati personalizirane preporuke i sadržaje. U tom je kontekstu potrebno stvoriti povjerenje između korisnika, ali i povjerenje u kvalitetu podataka i sustava. Navedeno se postiže implementacijom raznovrsnih mehanizama poput sustava za međusobno ocjenjivanje korisnika (npr. sustav reputacije kojim raspolaže eBay), CAPTCHA verifikacijske tehnike koja štiti podatke od neautoriziranih korisnika (primjenjuje se primjerice kod izrade Google korisničkog računa), moderatora ili urednika koji provjerava točnost i vjerodostojnost objavljenih sadržaja (npr. Wikipedia) i slično (Musser i O'Reilly, 2007, str. 46-47).

Posljednji uzorak dizajna se odnosi na **lagane modele i isplativu skalabilnost** (izvorno eng. Lightweight Models and Cost-Effective Scalability). Obzirom da je Web 2.0 paradigma pogonjena mrežnim učincima, svaki aspekt razvoja aplikacije i poslovanja treba biti osmišljen na način da omogući skroman početak, a da promjene u opsegu djelovanja Web 2.0 aplikacije budu uvjetovane i razmjerne zahtjevima tržišta. Navedene strategije osiguravaju rani i ubrzani rast (sa aspekta ponude) te veću fleksibilnost u promjeni opsega djelovanja (sa aspekta potražnje). Web 2.0 epohu također karakterizira i udruživanje odnosno nadovezivanje poslovnih modela koje se manifestira implementacijom odsječka JavaScript programskog koda povezanog sa transakcijskim sustavom Web 2.0 aplikacije u programski kod web mjesta (npr. bloga ili portala). Na ovaj način web mjesto ostvaruje prihod prikazivanjem kontekstualno relevantnih oglasa (npr. Google AdSense) ili posredovanjem u provedbi transakcije online kupnje (npr. Amazon) dok Web 2.0 aplikacija postaje vidljivija i dostupnija široj interesnoj zajednici (Musser i O'Reilly, 2007, str. 50). Sve operativne aspekte djelovanja Web 2.0 aplikacije koji istoj ne predstavljaju strateške funkcije (npr. održavanje infrastrukture, upravljanje kapacitetom i slično) je potrebno povjeriti specijaliziranim trećim stranama. S druge strane, operativni aspekti djelovanja koji su Web 2.0 aplikaciji od strateške važnosti te shodno tome predstavljaju njenu ekspertizu je potrebno ponuditi i osigurati trećim stranama. Kako bi se mogle iskoristiti prednosti koje se sobom nose uzorci dizajna čije su strategije usmjerene na mrežne učinke, specifične segmente tržišta, upravljanje podacima i razvoj temeljen na platformi, potrebno je oblikovati skalabilne i slojevite modele prihoda koji će u početku rezultirati povećanjem dostupnosti Web 2.0 aplikacije, a u konačnici prihvaćanjem od strane šire zajednice korisnika te razvojem repozitorija sadržaja (Musser i O'Reilly, 2007, str. 52). Naposljetku, skalabilne Web 2.0 aplikacije se temelje na jednostavnoj tehnološkoj infrastrukturi i dizajnu, sadrže funkcionalnosti koje korisnicima pružaju kontrolu nad interakcijom te raspolažu kapacitetima koji osiguravaju nesmetan rast (Musser i O'Reilly, 2007, str. 53).

2.3.2 Taksonomija Web 2.0 aplikacija

U literaturi postoji nekoliko taksonomija koje olakšavaju izbor i primjenu Web 2.0 aplikacija u kontekstu obrazovanja (Anderson, 2007; Orehovački et al., 2012b) i poslovanja (Levy, 2009; Orehovački et al., 2008). Na osnovi spomenutih specifičnih taksonomija, u nastavku ovog potpoglavlja biti će predstavljena generalna taksonomija Web 2.0 pri čemu će unutar svake skupine biti navedeni najpoznatiji predstavnici iste. Potrebno je naglasiti da taksonomija opisana u ovom potpoglavlju nije sveobuhvatna već se sastoji od skupina Web 2.0 aplikacija koje imaju široku primjenu. Jednako je tako potrebno napomenuti da se pod pojmom artefakt u

okviru ovog doktorskog rada podrazumijeva svako virtualno djelo koje nastane upotrebom Web 2.0 aplikacija (tekst, multimedijski zapis, mentalna mapa, dijagram, itd.).

2.3.2.1 Wiki sustavi

Pojam *wiki* na havajskom jeziku znači *brzo* što implicira da korisnici mogu u vrlo kratkom vremenskom razdoblju kreirati jednu ili veći broj međusobno povezanih wiki stranica. Prvi wiki sustav razvio je Ward Cunningham tijekom 1994. godine sa ciljem da olakša razmjenu ideja među programerima. Godinu dana kasnije, Cunningham je objavio prvu wiki stranicu pod nazivom WikiWikiWeb koja je bila sačinjena samo od tekstualnih sadržaja. Danas wiki sustavi kao što su MediaWiki ili Wikispaces omogućuju objavu raznovrsnih multimedijskih sadržaja. Najpopularniji i najuspješniji wiki projekt je online enciklopedija Wikipedia (prikazana na slici 2.3) čiji se sadržaji svakodnevno ažuriraju kao rezultat kolektivne inteligencije njenih korisnika.

Slika 2.3 Wikipedia

Svaki wiki sustav predstavlja bazu informacija koja nastaje aktivnim sudjelovanjem korisnika te se povećava sa svakim novim unosom sadržaja. Kako bi se olakšalo praćenje ažuriranja te spriječila zloupotreba, svaki se unos evidentira zasebno. Postoje tri osnovne primjene wiki sustava (Orehovački et al., 2012b):

- wiki kao sredstvo za dokumentiranje svih aktivnosti na projektu gdje svaka wiki stranica predstavljati zaseban izvještaj,

- wiki kao repozitorij znanja sačinjen od artefakata koje su korisnici kreirali primjenom ostalih desktop, web ili mobilnih aplikacija te potom integrirali u wiki stranice ili ih sa njima povezali i
- wiki kao platforma za provedbu različitih oblika asinkrone suradnje između interesnih strana (npr. studenata, studenata i nastavnika, zaposlenika, zaposlenika i klijenata i sl.).

2.3.2.2 Blogovi

Web mjesto koje korisnicima omogućuje objavljivanje sadržaja kronološkim redoslijedom u formatu osobnog dnevnika nosi naziv blog. Osnovno obilježje bloga je dvosmjerna komunikacija između autora koji sa svakom objavom sadržaja prenosi svoje ideje i razmišljanja te čitatelja koji spomenute objave komentiraju čime aktivno doprinose kvaliteti sadržaja od kojih je blog sačinjen. Svaku objavu je moguće označiti ključnim riječima odnosno tagovima što olakšava njihovo pretraživanje te omogućuje njihovu kategorizaciju prema srodnim temama. Zajednica blogova odnosno njihovih autora i čitatelja nosi naziv blogosfera. Prema načinu objavljivanja sadržaja blogove je moguće svrstati u tri skupine. Prva skupina je sačinjena od blogova na kojima sadržaje objavljuje veći broj autora od kojih je svaki stručnjak u određenom području. Upotrebom ove skupine blogova korisnici mogu diseminirati rezultate projekta, podijeliti svoje znanje i iskustvo te kroz asinkronu komunikaciju povećati svoju vidljivost unutar određene interesne zajednice. Primjeri dobre prakse su blogovi UsabilityPost i inspireUX (na slici 2.4).

Slika 2.4 inspireUX

U drugu skupinu se ubrajaju blogovi koje u većini slučajeva uređuju pojedinci. Primjenom servisa kao što je WordPress korisnici mogu oblikovati personalizirano web mjesto određene tematike. Posljednja skupina su mikroblogovi koji korisnicima nude mogućnost distribucije kratkih tekstualnih poruka prema skupini korisnika koji su se na iste pretplatili. Korisnici mogu poruke čitati i objavljivati slanjem SMS poruka sa mobilnog telefona, primjenom aplikacija za izravnu razmjenu poruka te pomoću specijaliziranih aplikacija kao što je Twitter. Obzirom da su prenosivost i neposrednost osnovna obilježja mikroblogova, isti se mogu upotrebljavati za objavljivanje novosti u području te komunikaciju između članova projektnog tima.

2.3.2.3 Web 2.0 aplikacije za društveno knjižno označavanje

Proces sačinjen od aktivnosti pretraživanja, kategorizacije, pohrane i razmjene poveznica usmjerenih prema raznovrsnim artefaktima objavljenim na Webu (npr. dokumenti, multimedijske datoteke, slike, web mjesta i slično) nosi naziv društveno knjižno označavanje (eng. social bookmarking). Kategorizacija se provodi označavanjem spomenutih poveznica pomoću proizvoljno odabranih ključnih riječi odnosno tagova koji iste jednoznačno opisuju. Zbir svih tagova pomoću kojih su korisnici kolaborativno označili pojedinu poveznicu nosi naziv folksonomija.

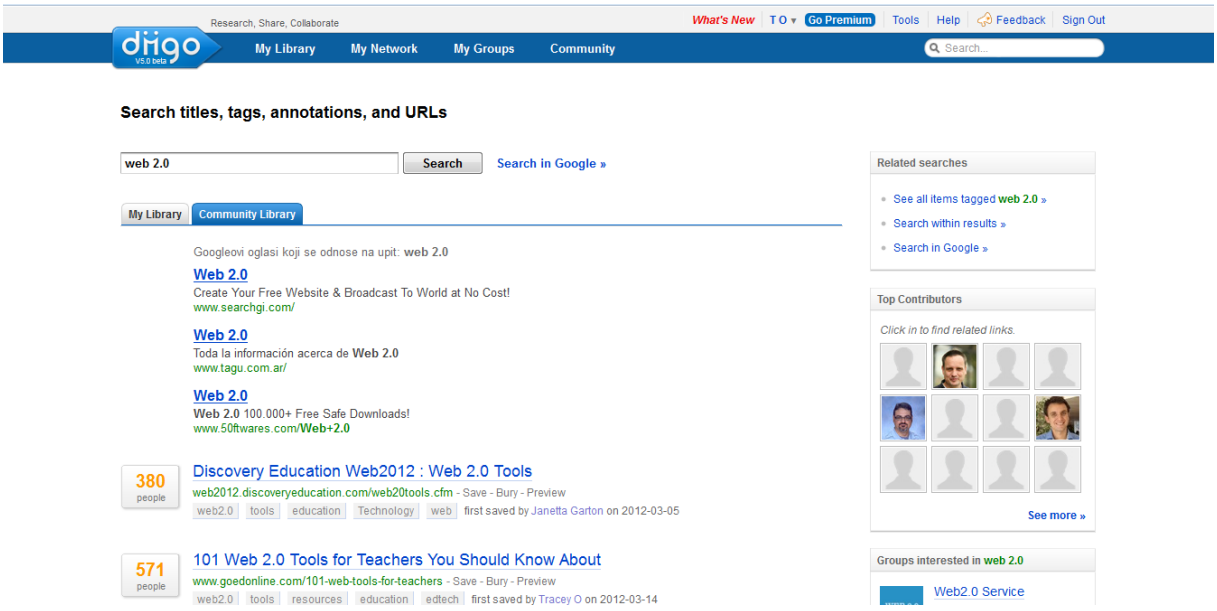

Slika 2.5 Diigo

Oblak tagova je navigacijski mehanizam koji kroz vizualizaciju tagova od kojih je određena folksonomija sačinjena olakšava njeno pretraživanje. Veličina fonta kojom je pojedini tag prikazan u oblaku predstavlja indikator učestalosti njegove upotrebe u kontekstu označavanja poveznica. Primjenom aplikacija kao što su Delicious ili Diigo (na slici 2.5) korisnici mogu kreirati javne i privatne knjižne oznake. Nadalje, spomenute aplikacije prikazuju tko je i kada kreirao pojedinu knjižnu oznaku te koliko je korisnika označilo i pohranilo istovjetnu poveznicu. Naposljetku, upotrebom spomenutih aplikacija moguće je saznati koliko korisnika je upotrijebilo pojedini tag za označavanje poveznica te pregledati sve poveznice koje su sa istim tagom označene. Osnovna prednost ove skupine Web 2.0 aplikacija je što se pohranjenim knjižnim oznakama može pristupati sa svakog uređaja koji ima vezu na Internet. Pored toga, aplikacije za društveno knjižno označavanje mogu poslužiti kao platforma za povezivanje korisnika te stvaranje interesnih zajednica.

2.3.2.4 Web 2.0 aplikacije za podcasting

Proces izrade multimedijskih zapisa i njihove distribucije pomoću RSS podatkovnog formata naziva se podcasting. Iz navedenog je evidentno da postoje dvije skupine Web 2.0 aplikacija namijenjenih podcastingu. Prva od njih služi izradi multimedijskih zapisa odnosno podcastova te je ovisno o vrsti multimedijskog zapisa dekomponirana na tri podskupine: audio podcasting, video podcasting i screencasting. Primjenom Web 2.0 aplikacija kao što je AudioPal korisnicima je omogućeno kreiranje audio zapisa pomoću mikrofona ili mobilnog uređaja te pretvaranjem teksta u zvuk. Upotrebom Web 2.0 aplikacija kao što je Masher korisnici mogu kombinirati fotografije sa audio i video isječcima te na taj način izraditi kreativne video zapise. Web 2.0 aplikacije kao što je Screencast-O-Matic služe snimanju zaslona što korisnicima omogućava izradu tutorijala. YouTube (na slici 2.6) i Vimeo su predstavnici druge skupine Web 2.0 aplikacija namijenjenih podcastingu koje služe reprodukciji i distribuciji multimedijskih zapisa. Njihova prednost je u tome što korisnici mogu pristupiti sadržajima koji su na njima pohranjeni sa bilo kojeg uređaja kojeg je moguće spojiti na Internet. Pored toga, ova skupina aplikacija omogućuje korisnicima da preuzmu multimedijske zapise te ih reproduciraju kada, gdje, koliko puta i na uređaju kojem žele. Ekvivalent čitačima RSS izvora su podcast klijenti odnosno podcatcheri kao što je Podfy koji provjeravaju i automatski preuzimaju multimedijske sadržaje sa web lokacija na koje su se korisnici pretplatili.

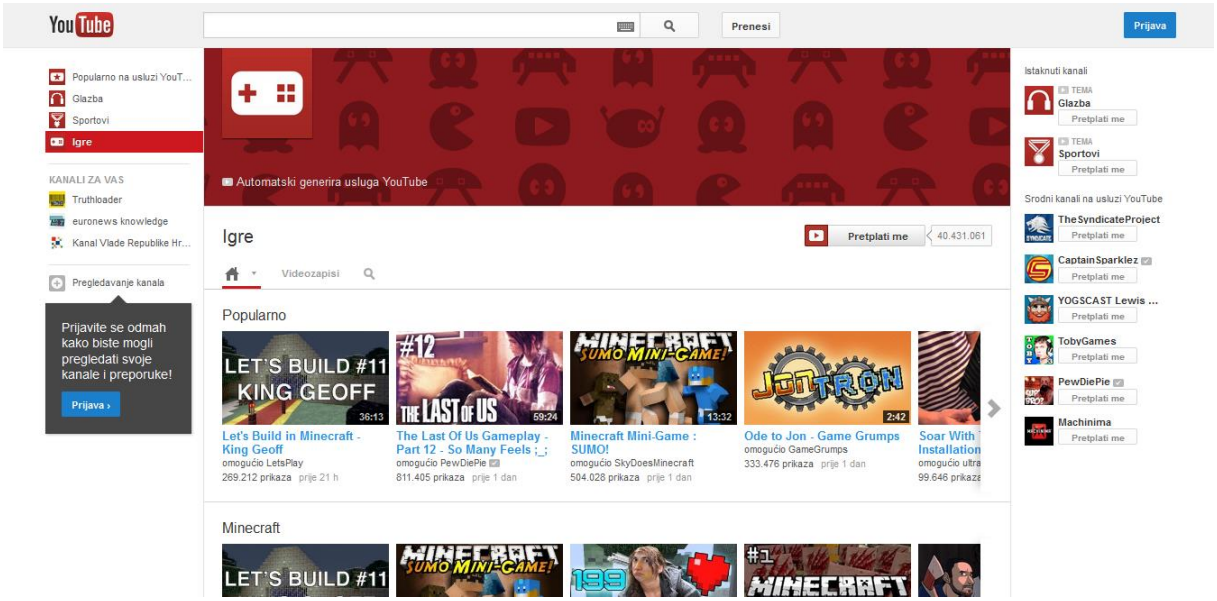

Slika 2.6 YouTube

2.3.2.5 Društvene mreže

Web 2.0 aplikacije koje pojedincima omogućuju provedbu velikog broja različitih online aktivnosti počam od izrade i personalizacije osobne stranice preko povezivanja, komunikacije i suradnje sa korisnicima sličnih interesa pa sve do razmjene raznovrsnih artefakata nazivaju se društvene mreže. Prva društvena mreža koja je u kratkom vremenskom razdoblju premašila brojku od milijun aktivnih korisnika je bio Friendster (Rivlin, 2006). Spomenutu društvenu mrežu utemeljio je Jonathan Abrams 2002. godine. Friendster je bio vlasnik titule najpopularnije društvene mreže sve do travnja 2004. godine kada ga je sa tog mjesta smijenio MySpace. Iste godine u veljači Mark Zuckerberg je sa kolegama razvio društvenu mrežu namijenjenu studentima sa Harvardskog sveučilišta pod nazivom Facebook. Mjesec dana kasnije, Facebook su implementirala dodatna tri američka sveučilišta: Stanford, Columbia i Yale (Facebook, 2013b). U rujnu 2005. godine objavljena je verzija Facebooka namijenjena srednjoškolcima da bi samo godinu dana nakon toga Facebook postao javno dostupna društvena mreža. Sa nešto više od milijardu aktivnih korisnika na mjesečnoj razini Facebook (2013a) danas predstavlja sinonim za društveno umrežavanje.

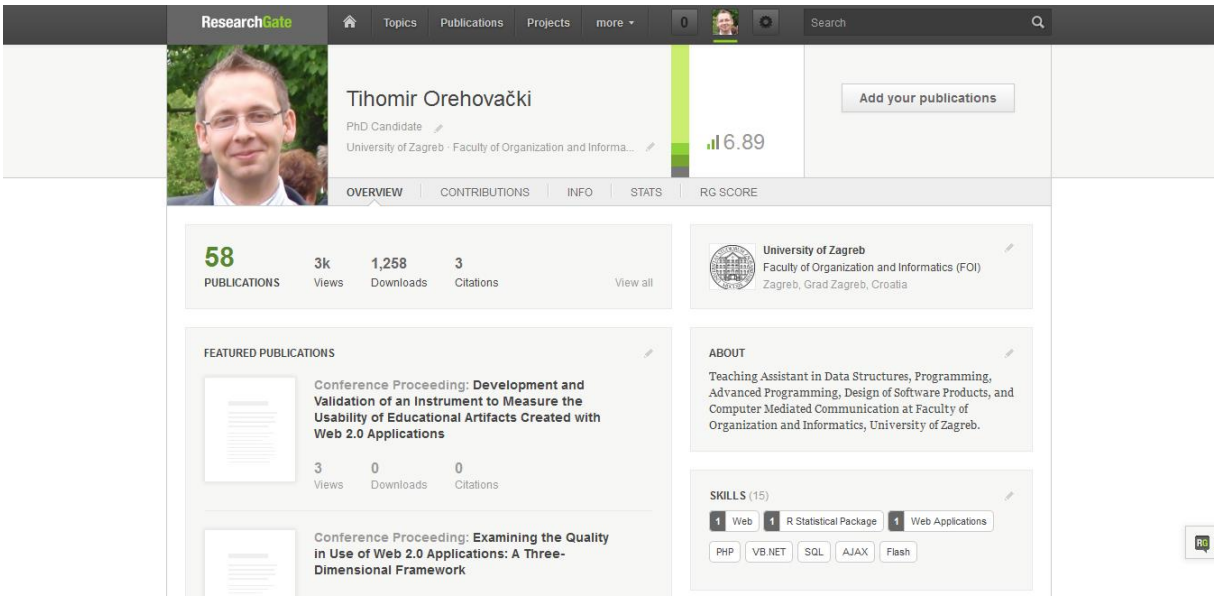

Slika 2.7 ResearchGate

Orehovački et al. (2012b) navode da postoje tri skupine društvenih mreža. Prva skupina su opće društvene mreže u koje se ubrajaju Facebook i Google+. Osnovni motivi upotrebe ove skupine društvenih mreža su vezani uz izražavanje osobnog identiteta, diseminaciju sadržaja te različite oblike interakcije sa kontaktima (Pempek et al., 2009). Sljedeću skupinu tvore društvene mreže kao što su LinkedIn i ResearchGate (na slici 2.7) koje su namijenjene povezivanju znanstvenika i stručnjaka, razmjeni znanja i iskustava, izradi osobnih portfelja te diseminaciji projektnih rezultata. Posljednja skupina društvenih mreža je sačinjena od platformi kao što su Ning i SocialGo koje služe razvoju vlastitih izoliranih i specijaliziranih interesnih zajednica.

2.3.2.6 Hibridne Web 2.0 aplikacije

Postoje dvije skupine hibridnih Web 2.0 aplikacija: mashupovi i personalizirani web portali. Mashupovi su situacijske (eng. situational) Web 2.0 aplikacije koje nastaju integracijom lako dostupnih komponenti kao što su RSS/Atom izvori (eng. feeds), widgeti, web servisi i sadržaji koje pružaju heterogeni izvori te na taj način oblikuju novi kontekst upotrebe. Primjer dobre prakse je Web 2.0 aplikacija WeatherSpark koja kombiniranjem informacija sa četiri različita web mjesta (Google Maps, Weather.gov, met.no i World Weather Online) obogaćuje iskustvo praćenja vremenske prognoze za bilo koju lokaciju u svijetu.

Web 2.0 aplikacije koje omogućuju korisnicima da na jednom mjestu primaju informacije o ažuriranim ili novododanim sadržajima sa različitih web izvora koji su predmet njihova interesa nazivaju se personalizirani web portali. Ova skupina Web 2.0 aplikacija prvenstveno obavlja

funkciju čitača sadržaja koji su objavljeni u RSS ili Atom podatkovnom formatu. Primjenom Web 2.0 aplikacija kao što su MyYahoo ili Netvibes (na slici 2.8) korisnici mogu integrirati veliki broj raznovrsnih RSS izvora te u isto vrijeme pratiti statuse na društvenoj mreži, objavu novih članaka na wiki sustavu ili blogu, stanje na burzovnom tržištu, vremensku prognozu, itd. Jednako tako, korisnici mogu upotrebom Web 2.0 aplikacija kao što je Feedity kreirati vlastite RSS izvore te na taj način obavještavati sve zainteresirane o promjenama u osobnom repozitoriju artefakata.

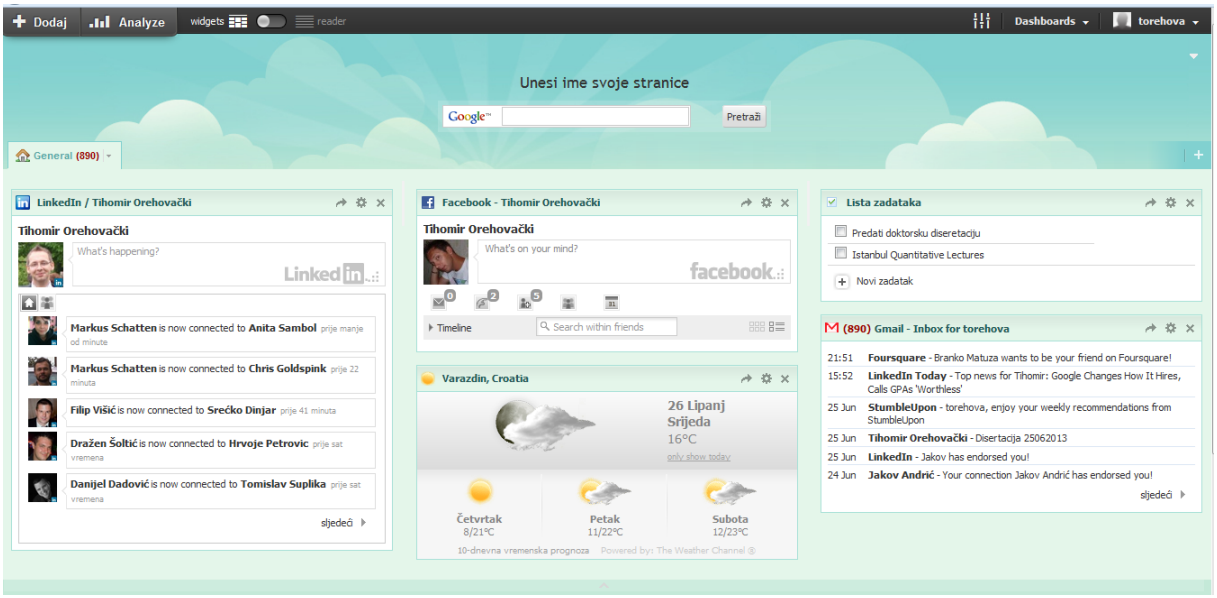

Slika 2.8 Netvibes

2.3.2.7 Virtualni svjetovi

Simulirano 3D okruženje u kojem pojedinci mogu putem svog avatara provoditi svakodnevne aktivnosti kao što su edukacija, poslovanje, druženje i zabava naziva se virtualni svijet. Sa preko 30 milijuna registriranih korisnika i više od 12 tisuća posjeta dnevno, Second Life (na slici 2.9) je najpopularniji virtualni svijet (Voyager, 2013). Okruženje spomenutog virtualnog svijeta je sačinjeno od mnoštva otoka koje avatari mogu istraživati hodanjem, letenjem ili teleportiranjem. Interakcija među avatarima se odvija na javnim i privatnim mjestima koja odražavaju lokacije iz stvarnog svijeta (npr. trgovački centri, muzeji, fakulteti i slično) ili na mjestima koje su kreirali korisnici.

Avatari međusobno mogu komunicirati razmjenom istovremenih poruka ili audio čavrljanjem. Svaki artefakt kojeg je kreirao avatar je vlasništvo korisnika koji ga može prodati. Zbog navedenih su obilježja korisnici dosad upotrebljavali Second Life na brojne načine. Primjerice, umjetnici su postavili izložbe, glazbenici održali koncerte, pojedini organi državne uprave su

otvorili svoje virtualne ambasade, sveučilišta su izradila svoje virtualne kampuse, nastavnici su održali predavanja svojim studentima dok su znanstvenici održali predavanja na konferencijama (Educause Learning Initiative, 2008).

Slika 2.9 Second Life

Izvor: Newswise (2009)

2.3.2.8 E-portfolio sustavi

Personalizirano web mjesto na kojem korisnici mogu pohraniti digitalne artefakte koji odražavaju njihovo znanje, vještine i iskustvo naziva se e-portfolio. Riječ je o specifičnoj skupini Web 2.0 aplikacija iz razloga što iste raspolažu funkcionalnostima i obilježjima koja su karakteristična za neke od dosad spomenutih vrsta Web 2.0 aplikacija. Primjerice, Mahara (na slici 2.10) omogućuje integraciju artefakata što je temeljna karakteristika wiki sustava, sadrži funkcionalnost kreiranja blogova te podržava kreiranje interesnih zajednica što je odlika društvenih mreža. Pored spomenutih mogućnosti, ova skupina Web 2.0 aplikacija omogućava izradu planova te olakšava organizaciju, upravljanje i dijeljenje artefakata pohranjenih u repozitoriju.

Slika 2.10 Mahara

2.3.2.9 Repozitoriji artefakata

Ova skupina Web 2.0 aplikacija je namijenjena pohrani, upravljanju i diseminaciji kreiranih artefakata. Ovisno o vrsti artefakata, repozitorije je moguće svrstati u dvije skupine. Web 2.0 aplikacije kao što je Scribd (na slici 2.11) raspolažu funkcionalnostima primjenom kojih korisnici mogu pretraživati, čitati, učitavati i dijeliti knjige, časopise, članke, prezentacije, pravilnike, zakone, propise te kreirati vlastite kolekcije dokumenata.

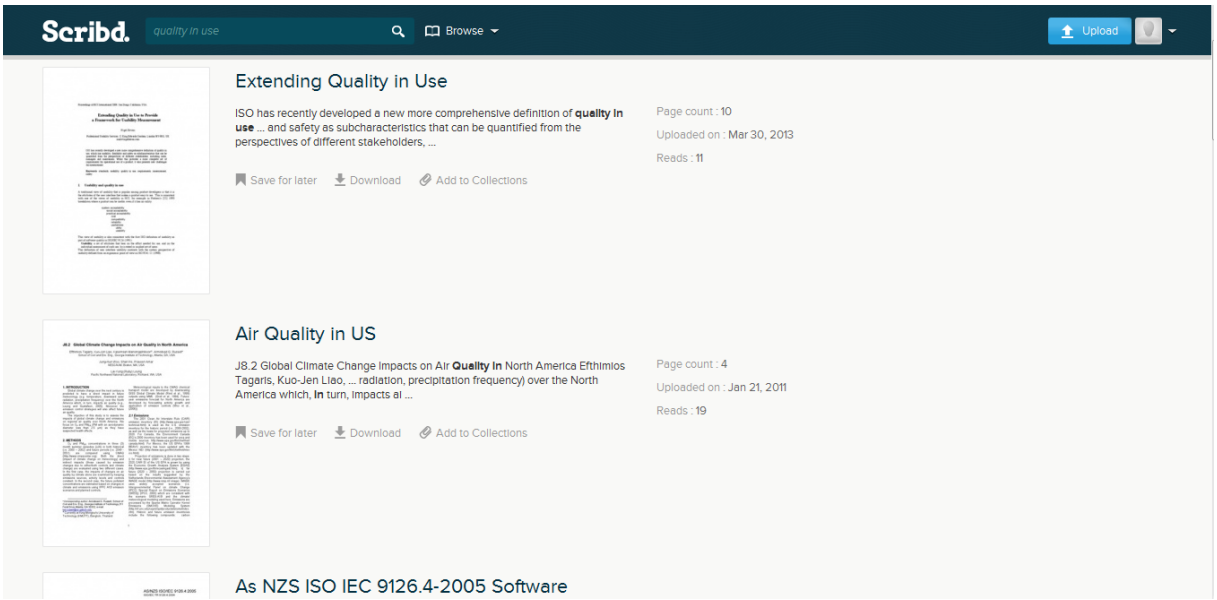

Slika 2.11 Scribd

S druge strane, Web 2.0 aplikacije kao što je Flickr omogućuju učitavanje, organizaciju, označavanje, razmjenu i pretraživanje fotografija. Iz navedenog je evidentno da repozitoriji artefakata predstavljaju vrijedan izvor resursa koji se mogu upotrebljavati u različite svrhe.

2.3.2.10 Web 2.0 aplikacije za kolaborativnu izradu artefakata

Ovu vrstu Web 2.0 aplikacija moguće je podijeliti na uredske pakete i aplikacije za upravljanje znanjem. Uredski paketi kao što su Google Docs i Zoho omogućuju uređivanje teksta, izradu proračunskih tablica, prezentacija i obrazaca te shodno tome predstavljaju alternativu desktop verzijama komercijalnih programskih proizvoda iste namjene. Međutim, za razliku od njih Web 2.0 inačice uredskih paketa podržavaju sinkroni rad na istom artefaktu. Skupina Web 2.0 aplikacija za upravljanje znanjem je namijenjena raščlambi i logičkoj organizaciji informacija. Glavni predstavnici ove skupine su Web 2.0 aplikacije za izradu mentalnih mapa i Web 2.0 aplikacije za izradu dijagrama.

Mentalne mape su shematski prikazi znanja koji olakšavaju razumijevanje kompleksnih problema te pospješuju pamćenje informacija. Iste se mogu kreirati pomoću Web 2.0 aplikacija kao što je Mindmeister. Dijagrami su grafičke ilustracije koje demonstriraju povezanost između dijelova cjelina te na taj način olakšavaju rješavanje problema. Primjer Web 2.0 aplikacije za izradu dijagrama je Gliffy (na slici 2.12). Potrebno je napomenuti da sve Web 2.0 aplikacije namijenjene kolaborativnoj izradi artefakata podržavaju razmjenu datoteka sa ostalim desktop, web i mobilnim aplikacijama iste ili slične namjene.

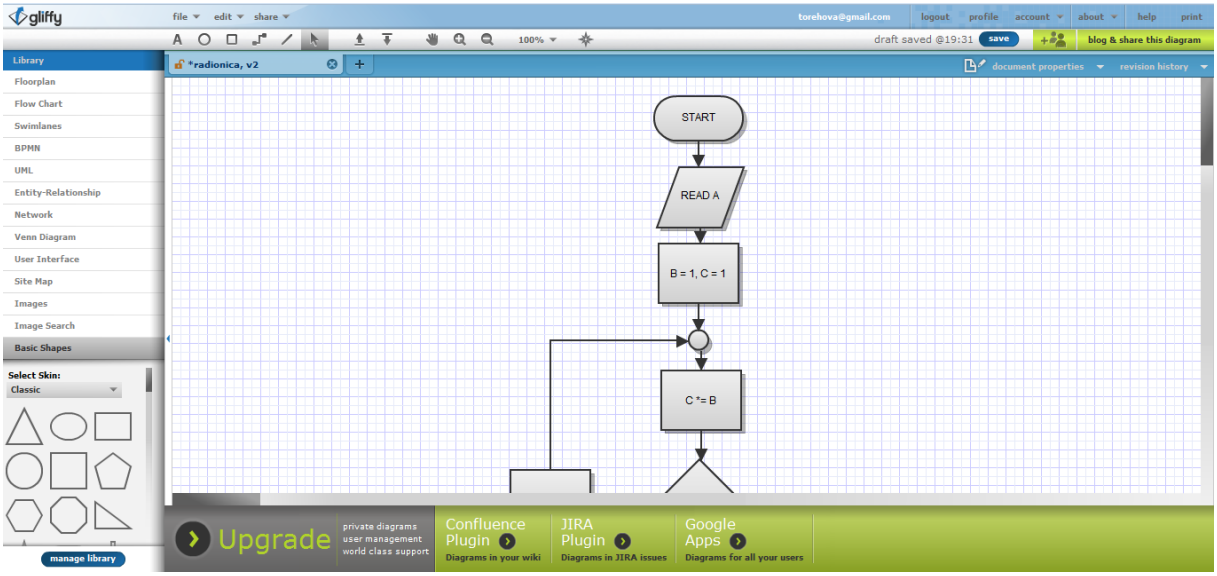

Slika 2.12 Gliffy

2.3.2.11 Web 2.0 aplikacije za komunikaciju

Web 2.0 aplikacije koje su specijalizirane za komunikaciju među korisnicima moguće je svrstati u dvije osnovne skupine. Prva od njih je sačinjena od Web 2.0 aplikacija kao što je Ebuddy koje služe izravnoj razmjeni poruka (eng. instant messaging). Za razliku od desktop verzija ove skupine aplikacija, njihove Web 2.0 inačice omogućuju korisnicima da preko jednog sučelja komuniciraju sa kontaktima koji upotrebljavaju različite klijente za izravnu razmjenu poruka (npr. MSN, Yahoo, Google Talk, Facebook, AIM, Hyves, ICQ, itd.). U drugu skupinu se ubrajaju Web 2.0 aplikacije kao što je Anymeeting (na slici 2.13) koje su namijenjene održavanju web konferencija te organizaciji i upravljanju sastancima. Pored navedenog, ova skupina Web 2.0 aplikacija podržava snimanje i pohranu održanih sastanaka te učitavanje i razmjenu dokumenata.

Slika 2.13 Anymeeting

2.4 Web danas i sutra

Aktualne strategije razvoja i upotrebe web mjesta nose oznaku Web 2.5 te se nazivaju mobilni Web (Weber i Rech, 2010). Premda su računala i dalje dominantan uređaj posredstvom kojeg korisnici pristupaju Internetu, broj mobilnih uređaja na kojima isti upotrebljavaju web aplikacije se svakodnevno povećava (Deloitte, 2013). Zbog navedenog mobilni Web u prvi plan stavlja

dostupnost, upotrebljivost i pristupačnost Web 2.0 aplikacija na svim uređajima koje je moguće spojiti na Internet.

Semantički Web ili Web 3.0 omogućava korisnicima da primjenom tehnologija kao što su RDF, SPARQL, OWL i SKOS kreiraju podatkovne repozitorije, oblikuju ontologije te kreiraju pravila za upravljanje podacima (World Wide Web Consortium, 2013). Svrha ove razvojne faze je olakšati automatsko procesiranje i integraciju podataka dostupnih na Webu. RDF (kratica za eng. Resource Description Framework) je jezik pomoću kojeg se predstavljaju informacije odnosno metapodaci o resursima na Webu. Primjena RDF-a se sastoji od utvrđivanja jedinstvenog identifikatora resursa (eng. Uniform Resource Identifier, URI) te opisa njegovih svojstava i vrijednosti koje svojstva mogu poprimiti. Rezultat primjene RDF-a je tvrdnja odnosno graf kojim se ilustriraju odnosi između resursa (subjekta), obilježja resursa (predikata) te vrijednosti obilježja (objekta). Svojstva i klase RDF resursa su opisani u rječniku koji se naziva RDF Shema. Logički jezik koji u stogu semantičkog Weba (World Wide Web Consortium, 2013) predstavlja nadogradnju RDF Sheme te je shodno tome namijenjen definiranju i instanciranju ontologija se naziva OWL (kratica za eng. Web Ontology Language).

Ontologija je formaliziran rječnik sačinjen od definicija koncepata i veza (takozvanih izraza) pomoću kojih se opisuje određeno područje. OWL ontologija služi opisivanju semantike klasa (npr. relacije između klasa, kardinalitet, enumeracije, itd.) i svojstava (npr. simetrija) koji se upotrebljavaju u web dokumentima. U situacijama kada su izrazi koji se upotrebljavaju u različitim podatkovnim skupovima višeznačni, ontologije olakšavaju njihovu integraciju te shodno tome predstavljaju temelj za razvoj širokog spektra inteligentnih web aplikacija. SPARQL je naziv za upitni jezik i protokol namijenjen dohvaćanju informacija pohranjenih u RDF datotekama. SKOS (kratica za eng. Simple Knowledge Organization System) je RDF rječnik koji služi predstavljanju polu-formalnih oblika organizacije znanja kao što su taksonomije ili folksonomije, njihovoj razmjeni između različitih programskih proizvoda, povezivanju sa ostalim podacima na Webu, objavljivanju na Webu te integraciji u ostale oblike konceptualnih shema. Iz navedenog proizlazi da Web 3.0 predstavlja okruženje u kojem web aplikacije rezoniraju na osnovi veza među podacima.

Weber i Rech (2010) predviđaju da će epohu sveprisutnog Weba obilježiti autonomni agenti u koje će biti implementirane sofisticirane semantičke tehnologije poput elementarne razine umjetne inteligencije zbog čega će isti tijekom svog rada u obzir uzimati osobni kontekst korisnika te na taj način umanjiti jaz između stvarnog i virtualnog svijeta. Kao primjere, Weber i Rech (2010) navode servise za procesiranje prirodnog govora i 3D virtualne društvene mreže.

Murugesan (2010) smatra da će se tijekom ere Weba 4.0 pojaviti inteligentni proaktivni agenti sposobni za interakciju sa ostalim agentima i korisnicima. Od preostalih predviđanja za razdoblje inteligentnog Weba potrebno je izdvojiti scenarij u kojem će ljudi pomoću senzora na motoričkoj kori mozga sa snagom misli moći upravljati avatarima u virtualnim svjetovima, implantate i umjetne udove koji će biti povezani na Internet te obavještavati članove obitelji i njegovatelje o zdravstvenom stanju pacijenta te operativni sustav u kojem će svi uređaji koje je moguće spojiti na Internet tvoriti jedan paralelan svijet (Weber i Rech, 2010).

3. TEORIJSKI OKVIR

Kako bi se identificirali atributi koji mjere relevantne aspekte kvalitete u korištenju Web 2.0 aplikacijama, provedena je analiza literature koja se sastojala od modela, tehnika, standarda, metoda, metodologija, metrika i mjernih instrumenata namijenjenih vrjednovanju različitih vrsta web mjesta počam od web stranica, preko web portala i web informacijskih sustava pa sve do Web 2.0 aplikacija. Rezultati analize literature su pokazali da su web mjesta dosad vrjednovana sa aspekta kvalitete, upotrebljivosti, korisničkog iskustva i kvalitete u korištenju. Shodno tome će spomenuti aspekti biti operacionalizirani kao temeljne dimenzije teorijskog okvira vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama. Nadalje, analizom literature utvrđeno je kako su istraživači u sklopu teorije razložne akcije, teorije planiranog ponašanja, modela prihvaćanja tehnologije, modela uspjeha informacijskog sustava i teorije potvrđivanja očekivanja izučavali konstrukte koji značajno doprinose zadovoljstvu i lojalnosti korisnika. Zbog toga će spomenute teorije i modeli biti razmatrani kao sporedne dimenzije teorijskog okvira vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama. U nastavku poglavlja će najprije biti opisane osnovne i sporedne dimenzije teorijskog okvira nakon čega slijedi pregled identificiranih atributa za koje se temeljem spomenutih dimenzija pretpostavlja da imaju utjecaj na kvalitetu u korištenju u kontekstu Web 2.0 aplikacija.

3.1 Osnovne dimenzije teorijskog okvira

U literaturi postoji mnoštvo definicija pojmova kvaliteta, upotrebljivost, korisničko iskustvo i kvaliteta u korištenju koje se uglavnom razlikuju prema objektu i kontekstu vrjednovanja. Shodno tome, istraživači i standardizacijska tijela oko njih teško postižu konsenzus (Abran et al., 2003). U nastavku slijedi opis najrelevantnijih poimanja spomenutih koncepata.

3.1.1 Kvaliteta

IEEE (1990, str. 60) je definirao kvalitetu kao (1) mjeru do koje sustav, komponenta ili proces udovoljava određenim zahtjevima te kao (2) razinu do koje sustav, komponenta ili proces udovoljava potrebama i očekivanjima korisnika. U standardu kojeg je ponudila ista organizacija, osiguranje kvalitete je definirano kao (1) skup planiranih i sistematiziranih aktivnosti koje su potrebne za osiguranje dostatne razine povjerenja da programski proizvod udovoljava definiranim tehničkim zahtjevima te kao (2) skup aktivnosti namijenjenih vrjednovanju procesa razvoja programskih proizvoda (IEEE, 1990, str. 60). U međunarodnom standardu ISO 8402

(1994), kvaliteta je definirana kao sveukupnost karakteristika proizvoda koje se odnose na njegovu sposobnost da udovolji navedenim i podrazumijevanim potrebama. Garvin (1984) navodi pet različitih pristupa definiranju pojma kvalitete:

- Transcendentan pristup (eng. transcendent approach) se odnosi na filozofsko poimanje kvalitete kao sinonima za prirođenu izvrsnost koju nije moguće precizno definirati, ali je intuitivno razumljivo što ona predstavlja. Kvaliteta je jednostavno svojstvo kojeg nije moguće analizirati, već ga se sa iskustvom nauči prepoznati.
- Pristup temeljen na proizvodu (eng. product-based approach) definira kvalitetu kao temeljnu karakteristiku proizvoda koju je moguće objektivno vrjednovati. Kvaliteta precizno odražava prisutnost ili odsutnost mjerljivih atributa te na taj način omogućava komparaciju i rangiranje proizvoda.
- Pristup temeljen na korisnicima (eng. user-based approach) predstavlja subjektivni pogled na kvalitetu usredotočen na želje i potrebe korisnika. Kvaliteta predstavlja kombinaciju atributa proizvoda koji u najvećoj mjeri doprinose zadovoljstvu korisnika.
- Pristup temeljen na proizvodnji (eng. manufacturing-based approach) promatra kvalitetu kao razinu do koje proizvod udovoljava unaprijed definiranim specifikacijama. Svako odstupanje od specifikacija smanjuje kvalitetu proizvoda te istovremeno povećava troškove njegove modifikacije.
- Pristup temeljen na vrijednosti (eng. value-based approach) definira kvalitetu u kontekstu troškova i cijena. Kvalitetan proizvod je onaj koji pruža radni učinak uz prihvatljivu cijenu ili udovoljava specifikacijama uz prihvatljive troškove.

U trećem mjesecu 2011. godine, međunarodna organizacija za standardizaciju (eng. International Organization for Standardization, ISO) i međunarodna elektrotehnička komisija (eng. International Electrotechnical Commission, IEC) zajedničkim su snagama objavile standard ISO/IEC 25010 (2011a) koji opisuje modele vrjednovanja kvalitete sustava i programskih proizvoda. Ovaj je standard član porodice SQuaRE (kratica za eng. Software Product Quality Requirements and Evaluation) namijenjene specifikaciji zahtjeva za kvalitetom te vrjednovanju iste u kontekstu programskih proizvoda. Serija standarda SQuaRE se sastoji od sljedećih pet dijelova (ISO/IEC, 2011b):

- ISO/IEC 2501n (modeli kvalitete) – standardi koji opisuju modele vrjednovanja kvalitete računalnih sustava i programskih proizvoda, kvalitete u korištenju i kvalitete podataka.
- ISO/IEC 2502n (mjerenje kvalitete) – standardi koji sadrže model mjerenja kvalitete programskih proizvoda, matematičke definicije metrika kvalitete te praktične smjernice za njihovu primjenu.

- ISO/IEC 2503n (specifikacija zahtjeva za kvalitetom) – standardi koji temeljem prethodno navedena dva dijela olakšavaju specifikaciju zahtjeva za kvalitetom programskog proizvoda prije njegova razvoja ili vrjednovanja.
- ISO/IEC 2504n (vrjednovanje kvalitete) – standardi koji obuhvaćaju zahtjeve, preporuke i smjernice za vrjednovanje kvalitete programskih proizvoda.
- ISO/IEC 25050 – 25099 (SQuaRE proširenja) – standardi koji sadrže zahtjeve za kvalitetom komercijalnih programskih proizvoda (eng. Commercial Off-The-Shelf, COTS) te CIF (kratica za eng. Common Industry Formats) formate za izvještaje upotrebljivosti.

Iz navedenog je evidentno da ISO/IEC 2501n zamjenjuje skup standarda ISO/IEC 9126 (1991), dok će ISO/IEC 2504n naslijediti seriju standarda ISO/IEC 14598. Prema međunarodnom standardu ISO/IEC 25010 (2011a), kvaliteta programskog proizvoda predstavlja razinu do koje programski proizvod udovoljava navedenim i podrazumijevanim potrebama kada se upotrebljava u okviru specificiranih uvjeta. Model kvalitete proizvoda predstavljen u spomenutom standardu je revidirana verzija modela vanjske i unutarnje kvalitete iz standarda ISO/IEC 9126-1 (2001) i kao takav predstavlja njegovu zamjenu. Sačinjen je od 31 atributa svrstanih u osam kategorija (ISO/IEC, 2011a):

- Funkcionalna prikladnost (eng. functional suitability) je stupanj do kojeg programski proizvod raspolaže funkcijama koje udovoljavaju utvrđenim i podrazumijevanim potrebama kada se upotrebljavaju pod specificiranim uvjetima.
    - Funkcionalna cjelovitost (eng. functional completeness) je razina do koje skup funkcija pokriva sve specificirane zadatke i ciljeve korisnika.
    - Funkcionalna točnost (eng. functional correctness) je stupanj do kojeg programski proizvod pruža točne rezultate sa potrebnim stupnjem preciznosti.
    - Funkcionalna primjerenost (eng. functional appropriateness) je razina do koje funkcije olakšavaju postizanje specificiranih zadataka i ciljeva.
- Radna učinkovitost (eng. performance efficiency) je radni učinak razmjeran količini resursa utrošenih pod utvrđenim uvjetima.
    - Ponašanje u vremenu (eng. time behaviour) je stupanj do kojeg vremena odaziva i obrade kao i stopa propusnosti programskog proizvoda tijekom izvršavanja njegovih funkcija udovoljavaju zahtjevima.
    - Utrošak resursa (eng. resource utilisation) je razina do koje količina i vrsta resursa koje programski proizvod utroši prilikom izvršavanja svojih funkcija udovoljava zahtjevima.

    - Kapacitet (eng. capacity) je stupanj do kojeg maksimalna ograničenja parametara sustava udovoljavaju zahtjevima.
- Kompatibilnost (eng. compatibility) je razina do koje programski proizvod može razmjenjivati informacije sa ostalim programskim proizvodima, sustavima ili komponentama, i/ili izvršavati zahtijevane funkcije, dok dijeli isto hardversko ili softversko okruženje sa ostalim programskim proizvodima.
    - Suživot (eng. co-existence) je stupanj do kojeg programski proizvod može izvršavati zahtijevane funkcije dok dijeli isto hardversko ili softversko okruženje sa ostalim programskim proizvodima, bez štetnog utjecaja na bilo koji drugi programski proizvod.
    - Interoperabilnost (eng. interoperability) je razina do koje dva ili više sustava, proizvoda ili komponente mogu razmjenjivati informacije i upotrebljavati informacije koje su razmijenjene.
- Upotrebljivost (eng. usability) je stupanj do kojeg određeni korisnici mogu upotrebljavati proizvod ili sustav kako bi učinkovito, djelotvorno i na vlastito zadovoljstvo postigli određene ciljeve u određenom kontekstu upotrebe.
    - Prepoznatljivost primjerenosti (eng. appropriateness recognisability) je razina do koje korisnici mogu prepoznati da li je programski proizvod primjeren njihovim potrebama.
    - Lakoća učenja korištenja (eng. learnability) je stupanj do kojeg određeni korisnici mogu upotrebljavati programski proizvod kako bi postigli određene ciljeve vezane uz učenje korištenja programskim proizvodom na djelotvoran i učinkovit način, bez rizika i sa zadovoljstvom, u određenom kontekstu upotrebe.
    - Operabilnost (eng. operability) je razina do koje programski proizvod raspolaže svojstvima koja ga čine jednostavnim za upravljanje i kontroliranje.
    - Zaštita korisnika od pogrješaka (eng. user error protection) je stupanj do kojeg programski proizvod štiti korisnike od toga da počine pogrješke.
    - Estetika korisničkog sučelja (eng. user interface aesthetics) je razina do koje sučelje omogućuje korisniku ugodnu i zadovoljavajujuću interakciju.
    - Pristupačnost (eng. accessibility) je stupanj do kojeg programski proizvod mogu upotrebljavati ljudi sa najširim rasponom osobina i mogućnosti kako bi postigli određene ciljeve u određenom kontekstu korištenja.
- Pouzdanost (eng. reliability) je razina do koje programski proizvod izvršava određene funkcije pod određenim uvjetima u određenom vremenskom razdoblju.

- Zrelost (eng. maturity) je stupanj do kojeg programski proizvod udovoljava potrebi za pouzdanošću u uvjetima normalnog rada.
- Dostupnost (eng. availability) je razina do koje je sustav, proizvod ili komponenta operativan i dostupan kada ga je potrebno upotrebljavati.
- Tolerancija pogrješaka (eng. fault tolerance) je stupanj do kojeg programski proizvod funkcionira kako je i zamišljeno bez obzira na prisutnost hardverskih ili softverskih pogrješaka.
- Mogućnost oporavka (eng. recoverability) je razina do koje, u slučaju prekida ili pogrješke, programski proizvod može oporaviti podatke koji su direktno pogođeni te ponovno uspostaviti željeno stanje.

- Sigurnost (eng. security) je stupanj do kojeg programski proizvod štiti informacije i podatke tako da razina do koje im mogu pristupati osobe, ostali programski proizvodi ili sustavi bude primjerena tipovima i razinama njihovih ovlasti.
  - Povjerljivost (eng. confidentiality) je razina do koje programski proizvod osigurava da su podaci dostupni samo onima sa ovlaštenim pristupom.
  - Integritet (eng. integrity) je stupanj do kojeg programski proizvod ili komponenta sprječava neovlašteni pristup do podataka ili njihovu modifikaciju.
  - Neporecivost (eng. non-repudiation) je razina do koje se može dokazati da su se akcije ili događaji dogodili tako da ih kasnije nije moguće poreći.
  - Odgovornost (eng. accountability) je stupanj do kojeg je moguće jedinstveno pratiti aktivnosti svakog pojedinog entiteta.
  - Autentičnost (eng. authenticity) je razina do koje se može dokazati da je identitet subjekta ili resursa upravo taj za kojeg se tvrdi da jest.
- Mogućnost održavanja (eng. maintainability) je stupanj učinkovitosti i djelotvornosti sa kojim namjeravani održavatelji mogu modificirati programski proizvod.
  - Modularnost (eng. modularity) je razina do koje je programski proizvod sačinjen od diskretnih komponenti na način da promjena jedne komponente ima minimalan utjecaj na preostale komponente.
  - Mogućnost ponovne upotrebe (eng. reusability) je stupanj do kojeg se programski sustav može upotrebljavati u više od jednog sustava ili za izgradnju drugih programskih proizvoda.
  - Mogućnost analize (eng. analysability) je mjera učinkovitosti i djelotvornosti sa kojom je moguće:
    - procijeniti razinu do koje će se namjeravane promjene u jednom ili većem broju dijelova programskog proizvoda odraziti na programski proizvod,

        - utvrditi nedostatke ili uzroke pogrješaka u radu programskog proizvoda,
        - identificirati dijelove programskog proizvoda koje je potrebno promijeniti.
    - Mogućnost izmjene (eng. modifiability) je stupanj do kojeg je moguće učinkovito i djelotvorno izmijeniti programski proizvod bez da se uzrokuju pogrješke ili smanji postojeća kvaliteta programskog proizvoda.
    - Mogućnost testiranja (eng. testability) je razina do koje je moguće izraditi testne kriterije za programski proizvod te provesti testove kako bi se utvrdilo da li su ti kriteriji zadovoljeni.
- Prenosivost (eng. portability) je stupanj djelotvornosti i učinkovitosti do kojeg je moguće prenijeti programski proizvod iz hardverskog, softverskog ili drugog radnog okruženja ili okruženja upotrebe u drugo okruženje.
    - Prilagodljivost (eng. adaptability) je razina do koje je programski proizvod moguće djelotvorno i učinkovito prilagoditi različitim:
        - razvojnim hardverskim, softverskim ili ostalim radnim okruženjima,
        - okruženjima upotrebe.
    - Mogućnost instalacije (eng. installability) je stupanj djelotvornosti i učinkovitosti sa kojom je moguće programski proizvod instalirati u i/ili ukloniti iz određenog okruženja.
    - Zamjenjivost (eng. replaceability) je razina do koje programski proizvod može zamijeniti drugi specificirani programski proizvod jednake namjene u istom okruženju.

Bertoa et al. (2006) napominju kako su modeli kvalitete definirani međunarodnim standardima generičke naravi zbog čega ih je vrlo teško primijeniti u specifičnoj domeni vrjednovanja. Zbog toga će u okviru ovog doktorskog rada koncept kvalitete biti sagledan kroz pristup temeljen na proizvodu i pristup temeljen na korisnicima (Garvin, 1984). Pored toga, oblikovat će se novi model koji će omogućiti vrjednovanje svih relevantnih aspekata kvalitete u kontekstu Web 2.0 aplikacija.

3.1.2 Upotrebljivost

Offutt (2002) navodi da je upotrebljivost jedan od najvažnijih atributa kvalitete web aplikacija. Zbog navedenog je upotrebljivost sveprisutan koncept kako u polju interakcije čovjeka i računala tako i u polju web inženjerstva. Pojam *upotrebljivost* (eng. usability) proizlazi iz izraza *prilagođen korisniku* (eng. user friendly) koji se koristi kako bi se opisalo svojstvo sustava da

uspostavi dijalog između korisnika i računala kojeg je jednostavno razumjeti te da bude korisniku početniku lagan za korištenje (Parker, 2002). Međutim, s vremenom je izraz *prilagođen korisniku* stekao veliki broj kritika koje su bile upućene na račun brojnih nejasnih i subjektivnih konotacija (Bevan et al., 1991) od kojih je potrebno istaknuti da se računalni sustavi „nepotrebno poistovjećuju sa čovjekom" te sugeriraju „da je jedan atribut dovoljan za opisivanje svih potreba korisnika" (Nielsen, 1993, str. 23). Kako bi se uklonili nedostatci izraza *prilagođen korisniku*, osmišljen je pojam *upotrebljivost*.

Analizom pojma *lakoća korištenja* (eng. ease of use; Miller, 1971) i razvojem mjera za njegovo vrjednovanje (Bennett, 1979) napravljeni su prvi koraci prema definiciji upotrebljivosti. U tom kontekstu Gould i Lewis (1985, str. 300) naglašavaju kako „svaki sustav koji je dizajniran da se ljudi njime koriste treba biti lako naučiti i zapamtiti upotrebljavati, treba biti koristan, sadržavati funkcije koje su ljudima potrebne u njihovom poslu te treba biti jednostavan i ugodan za upotrebu". Shackel (1984) je opisao upotrebljivost kao mjeru do koje ciljani korisnici upotrebom informacijskog sustava mogu djelotvorno izvršavati zadatke. Obzirom da je spomenuta definicija bila suviše općenita te usmjerena na samo jedan aspekt upotrebljivosti, Shackel (1991) je operacionalizirao i kvantificirao koncept te ponudio novu definiciju prema kojoj upotrebljivost predstavlja „sposobnost da određena skupina korisnika, uz određeni trening i podršku, upotrebom sustava jednostavno i djelotvorno dovrši određeni niz zadataka unutar određenog skupa scenarija". Potrebno je napomenuti da ova definicija jasno razlikuje vrjednovanje subjektivnih i objektivnih aspekata upotrebljivosti. Jednostavnost je subjektivna mjera percepcije lakoće korištenja dok djelotvornost predstavlja objektivnu mjeru radnog učinka korisnika.

Najčešće korištene i citirane definicije pojma *upotrebljivost* inicijalno su predložene u različitim međunarodnim standardima koje su razvile i objavile međunarodna organizacija za standardizaciju i međunarodna elektrotehnička komisija. U jedanaestom je dijelu međunarodnog standarda ISO 9241 (1998) upotrebljivost definirana kao „mjera do koje se upotrebom programskog proizvoda u specifičnom kontekstu korištenja ciljevi mogu postići učinkovito, djelotvorno i na zadovoljstvo korisnika". Prva verzija međunarodnog standarda ISO/IEC 9126 (1991) definirala je upotrebljivost kao „skup atributa koji se odnose na napor koji je skupini utvrđenih ili podrazumijevanih korisnika potreban za upotrebu ili za individualno vrjednovanje takve upotrebe". Revidirana verzija standarda (ISO/IEC 9126-1, 2001) ponudila je nešto drugačiju definiciju prema kojoj upotrebljivost označava „sposobnost programskog proizvoda da bude razumljiv, prikladan za učenje, operabilan i privlačan korisniku, kada se upotrebljava u određenim uvjetima". Van Welie et al. (1999) ističu da je definicija koncepta upotrebljivosti u standardu ISO 9241-11 (1998) suviše kratka, nejasna i plitka. Istovremeno,

riječ je o najcitiranijoj definiciji ovog koncepta u kontekstu vrjednovanja što potvrđuje činjenica da je upravo posljednja inačica standarda namijenjenog mjerenju kvalitete programskih proizvoda (ISO/IEC, 2011a) preuzela definiciju upotrebljivosti iz standarda ISO 9241-11 (1998).

Quesenbery (2001) je kritizirao definiciju upotrebljivosti iz standarda ISO 9241-11 (1998) kao nedovoljno konkretnom za primjenu tijekom razvoja programskih proizvoda te shodno tome predložio njeno proširenje pod akronimom 5E prema kojem svaki sustav treba biti djelotvoran (eng. effective), učinkovit (eng. efficient), zanimljiv (eng. engaging), tolerantan na pogrješke (eng. error tolerant) te treba biti lako naučiti koristiti se njime (eng. easy to learn). Dumas i Redish (1999, str. 4) smatraju da upotrebljivost predstavlja „mjeru do koje korisnici mogu primjenom programskog proizvoda brzo i lako izvršiti zadatke“.

Osim ISO/IEC, još su dvije međunarodne organizacije ponudile svoje poimanje koncepta upotrebljivosti. Članovi međunarodne strukovne udruge IEEE (kratica za eng. Institute of Electrical and Electronics Engineers) su definirali upotrebljivost kao „jednostavnost sa kojom korisnici mogu naučiti upravljati sustavom, pripremiti ulazne i protumačiti izlazne vrijednosti sustava“ (IEEE, 1990, str. 80). Članovi organizacije UPA (kratica za eng. Usability Professionals' Association) smatraju da „upotrebljivost tijekom cjelokupnog razvojnog procesa treba biti usredotočena na povratne informacije od korisnika s ciljem razvoja programskog proizvoda koji će udovoljiti potrebama korisnika te smanjenja troškova razvoja“ (UPA, 2013).

Steve Krug (2005, str. 5) smatra da razviti upotrebljiv programski proizvod znači „pobrinuti se da programski proizvod radi dobro kako bi ga prosječna ili ispodprosječna osoba u smislu vještina i iskustva mogla bez frustracija namjenski upotrebljavati“.

U nastojanju da što detaljnije definira koncept, Hertzum (2010) je predstavio šest različitih aspekata (eng. images) upotrebljivosti:

- Univerzalna upotrebljivost (eng. universal usability) je aspekt prema kojem je programski proizvod upotrebljiv širokom krugu ljudi, neovisno o razlikama među pojedincima (prema dobi, spolu, obrazovanju, učestalosti korištenja, uvjetima i načinu korištenja, stilu života i vrijednostima), razlikama u predznanju korištenja sličnim programskim proizvodima te tehnološkoj infrastrukturi. Ovaj aspekt upotrebljivosti je vrlo važan za sustave opće namjene među koje se ubraja i Web. Autor predlaže da se ovaj aspekt vrjednuje prema smjernicama i heuristikama upotrebljivosti te pomoću automatiziranih alata.
- Situacijska upotrebljivost (eng. situational usability) je aspekt koji tijekom vrjednovanja u obzir uzima raznovrsne varijable poput vrste zadataka koje je potrebno izvršiti,

obilježja i namjenu programskog proizvoda, vještine potrebne za korištenje te kontekst upotrebe. Ovaj se aspekt ne bavi vrjednovanjem programskog proizvoda *per se*, već kvalitetom u korištenju programskim proizvodom. Prema tome, krajnji cilj upotrebljivosti je zadovoljstvo procesom korištenja. Razmišljanje naglas, prototipiranje i analiza zadataka su metode namijenjene vrjednovanju situacijske upotrebljivosti.

- Zamijećena upotrebljivost (eng. perceived usability) je aspekt usmjeren na korisnika, a bavi se vrjednovanjem impresija stečenih tijekom interakcije sa programskim proizvodom. Riječ je o vrlo važnom aspektu iz razloga što značajno utječe na radni učinak korisnika te na proces donošenja odluka vezan uz nastavak i učestalost korištenja programskim proizvodom. Među važnije odrednice ovog aspekta upotrebljivosti ubrajaju se korisnost, kvaliteta informacija, poznavanje programskog proizvoda te količina truda kojeg je potrebno uložiti u učenje korištenja programskim proizvodom. Ovaj se aspekt upotrebljivosti uglavnom vrjednuje standardiziranim upitnicima ili tehnikom mjerenja promjera zjenica kako bi se utvrdila razina radnog opterećenja.
- Hedonistička upotrebljivost (eng. hedonic usability) je aspekt namijenjen vrjednovanju emocija koje nastaju kao posljedica korištenja programskim proizvodom. Za razliku od preostalih aspekata koji su usmjereni na programski proizvod i/ili proces korištenja, hedonistička upotrebljivost se bavi temeljnim ljudskim potrebama poput uzbuđenosti, ugode, sreće i zadovoljstva. Ljepota, estetika i dizajn korisničkog sučelja su glavne odrednice ovog aspekta upotrebljivosti. Obzirom da je srodna zamijećenoj upotrebljivosti, hedonistička upotrebljivost također ima vrlo važnu ulogu u prihvaćanju i redovitom korištenju programskim proizvodom. Podaci o hedonističkoj upotrebljivosti mogu se prikupiti različitim metodama poput intervjua, kodiranja izraza lica, psiholoških reakcija kože ili upitnika sa bipolarnim skalama semantičkog diferencijala.
- Organizacijska upotrebljivost (eng. organizational usability) se bavi mjerenjem učinkovitosti integracije programskog proizvoda u strukturu organizacije. Ovaj je aspekt upotrebljivosti posebice važan za programske proizvode namijenjene suradnji većeg broja ljudi. Implementacijom programskog proizvoda na razini organizacije često dolazi do promjena u obujmu i vrsti posla, količini odgovornosti i strukturi ljudskih resursa. Logička posljedica takvog scenarija je da zaposlenici ne žele prihvatiti programski proizvod, čak ni kada je korištenje njime obavezno. Stoga o organizacijskoj upotrebljivosti programskog proizvoda treba voditi računa u svim fazama njegovog životnog ciklusa. Organizacijska se upotrebljivost vrjednuje metodom terenskog intervjua, etnografskim promatranjima, uključivanjem korisnika u razvojni proces te metodom razmišljanja naglas.

- Kulturalna upotrebljivost (eng. cultural usability) je aspekt koji tijekom vrjednovanja u obzir uzima kulturalne razlike među pojedincima. Navedeno se prvenstveno odnosi na pojedina obilježja sučelja web mjesta kao što su boje, znakovi, jezik, razmještaj navigacijskih mehanizama i slično. Riječ je o vrlo važnom aspektu jer različite kulture pridaju drugačiji značaj pojedinim atributima upotrebljivosti. Potrebno je napomenuti da je ovaj aspekt potrebno sagledati vrlo detaljno te osim međukulturalnih razmotriti i unutarkulturalne razlike. Konačno, odabir metode vrjednovanja kao i dodjeljivanje pojedinih uloga tijekom provedbe metode značajno ovisi o kulturalnim karakteristikama sudionika.

Primjena navedenih aspekata se sastoji od (Hertzum, 2010): a) otkrivanja tijekom kojeg je potrebno programski proizvod sagledati sa što je moguće više različitih aspekata kako bi se utvrdila njegova upotrebljivost, b) integracije tijekom koje se utvrđuje dominantan aspekt upotrebljivosti te aspekti koji ga u kontekstu vrjednovanog programskog proizvoda nadopunjuju i c) povremenog izazova promjene dominantnog aspekta upotrebljivosti s ciljem utvrđivanja njegovih slabosti te projekcije posljedica promjene. Potrebno je napomenuti da spomenuti aspekti, premda međusobno povezani, ne tvore jedinstveni koncept upotrebljivosti.

Uzimajući u obzir sve razmotrene definicije upotrebljivosti, ista će u sklopu ovog doktorskog rada biti sagledana, a time i vrjednovana, kroz dimenzije univerzalne, situacijske i zamijećene upotrebljivosti koje je predložio Hertzum (2010). Dimenzije hedonističke upotrebljivosti će također biti vrjednovane, ali u kontekstu korisničkog iskustva.

3.1.3 Korisničko iskustvo

Uspjeh web mjesta ne ovisi samo o tome do koje razine isto zadovoljava pragmatične dimenzije kvalitete, upotrebljivosti i kvalitete u korištenju koje su vezane uz ostvarenje specifičnih ciljeva već i o mjeri do koje udovoljava hedonističkim aspektima korisničkog iskustva (eng. User eXperience, UX) koji se odnose na emotivne reakcije korisnika (Hassenzahl i Tractinsky, 2006; Norman, 2004). Premda je pojam korisničkog iskustva predstavljen krajem osamdesetih godina prošlog stoljeća (Norman, 1988), u literaturi još uvijek ne postoji sveobuhvatna i općeprihvaćena definicija ovog koncepta. Razlog tome je što je korisničko iskustvo dinamičan i subjektivan koncept koji nastaje kao posljedica interakcije sa programskim proizvodom te ovisi o kontekstu i subjektivnim percepcijama pojedinaca (Law et al., 2009). Ukoliko se u obzir uzme vremensko razdoblje tijekom kojeg se korisničko iskustvo manifestira, isto je moguće sagledati sa sljedeća četiri aspekta (Roto et al., 2011):

- Očekivano (eng. anticipated) korisničko iskustvo koje se temelji na prijašnjim iskustvima sa sličnim programskim proizvodima, prezentacijama, izlaganjima, tuđem mišljenju, itd.
- Trenutačno (eng. momentary) korisničko iskustvo koje se odnosi na emocionalne promjene tijekom interakcije sa programskim proizvodom.
- Epizodno (eng. episodic) korisničko iskustvo koje je vezano uz procjenu specifične interakcije sa programskim proizvodom.
- Zbirno (eng. cumulative) korisničko iskustvo koje predstavlja sagledavanje programskog proizvoda kao cjeline nakon što ga je korisnik upotrebljavao dulje vrijeme.

Na osnovi pregleda literature, Bargas-Avila i Hornbæk (2011) su identificirali sljedećih deset dimenzija korisničkog iskustva: generičko korisničko iskustvo, emocije, užitak i zabava, estetika, hedonistička kvaliteta, tijek i uključenost, motivacija, ushit, frustracije te vrijednost i spontanost. Iz spomenutog je moguće zaključiti da je korisničko iskustvo usko povezano sa zadovoljstvom i lojalnošću korisnika (Tobias i Spiegel, 2009).

Istraživači se prema načinu definiranja pojma korisničkog iskustva generalno dijele u dvije skupine: jedni ga smatraju sinonimom za upotrebljivost i dizajn usmjeren na korisnike (npr. Alben, 1996; Tullis i Albert, 2008), a drugi zasebnim konceptom (npr. Hassenzahl i Tractinsky, 2006; Law i Van Schaik, 2010).

Pod pojmom iskustvo, Alben (1996) podrazumijeva različite aspekte upotrebe interaktivnog proizvoda. Kvalitetno iskustvo je ono koje je uspješno, zanimljivo i korisniku dragocjeno (Alben, 1996). Kvaliteta korisničkog iskustva je pod utjecajem dvije skupine kriterija (Alben, 1996):

- Kriteriji razvoja programskog proizvoda:
    - mjera do koje razvojni tim razumije potrebe korisnika i kontekst upotrebe te na koji se način to odražava na programski proizvod,
    - mjera do koje je razvojni proces dobro osmišljen i proveden.
- Kriteriji interakcije sa programskim proizvodom:
    - namjena i doprinosi programskog proizvoda,
    - mjera do koje je programski proizvod lako upotrebljavati te se lako naučiti koristiti njime,
    - mjera do koje je programski proizvod učinkovit i praktičan u rješavanju problema na odgovarajući način,
    - mjera do koje je upotreba programskog proizvoda estetski ugodno i čulno zadovoljavajuće iskustvo,
    - mjera do koje je programski proizvod moguće prilagoditi specifičnim potrebama pojedinaca i grupe ili nadograditi sa novim funkcionalnostima,

- mjera do koje programski proizvod daje podršku cjelokupnom kontekstu upotrebe (npr. preko službe za korisnike).

Hassenzahl i Tractinsky (2006) su definirali korisničko iskustvo kao „posljedicu unutarnjeg stanja korisnika (predispozicije, očekivanja, potrebe, motivacije, raspoloženje, itd.), karakteristika dizajniranog sustava (npr. složenost, svrha, upotrebljivost, funkcionalnost, itd.) i konteksta (ili okruženja) u okviru kojeg se interakcija manifestira (npr. organizacijska/društvena okolina, smislenost aktivnosti, dobrovoljnost korištenja, itd.)“. Prema standardu ISO 9241-210, korisničko iskustvo „su percepcije i reakcije korisnika koje nastaju kao posljedica upotrebe i/ili očekivane upotrebe proizvoda, sustava ili usluge“ (ISO, 2010). Mäkelä i Fulton Suri (2001) smatraju da korisničko iskustvo predstavlja rezultat motivirane akcije u određenom kontekstu. Članovi udruženja UPA (2013b) su definirali korisničko iskustvo kao „zbir svih aspekata koje korisnik zamjećuje tijekom interakcije sa programskim proizvodom“. Iz navedenog proizlazi da se ova definicija odnosi na elemente sučelja koje korisnik percipira osjetilima vida (razmještaj elemenata, čitljivost teksta, estetika dizajna) i sluha (zvuk). Desmet i Hekkert (2007) smatraju da korisničko iskustvo predstavlja mjeru sveukupnog dojma kojeg je interakcija sa programskim proizvodom ostavila na korisnika počam od ugode za korisnikova osjetila (aspekt estetike), preko značenja koje korisnici pridaju proizvodu (aspekt smislenosti) sve do osjećaja koje je interakcija izazvala (aspekt emocija). Hassenzahl (2008) je definirao korisničko iskustvo kao trenutan osjećaj prosudbe o kvaliteti (npr. dobra ili loša) interakcije sa programskim proizvodom. Jednako tako, korisničko iskustvo predstavlja mjeru do koje su korisnici zadovoljni kada upotrebljavaju programski proizvod (BitPipe, 2013) i uspješni u izvršavanju zadataka primjenom elemenata njegova sučelja (Goto, 2004).

Kao temeljne odrednice korisničkog iskustva pojedini izvori (Kuniavsky, 2010; Nyman, 2005; Sutcliffe, 2009; Sward i MacArthur, 2007; Usability First, 2013; UXmatters, 2013) navode lakoću učenja korištenja, korisnost, upotrebljivost, dostupnost, atraktivnost i pouzdanost programskog proizvoda, zamijećen užitak interakcije sa elementima njegova sučelja, učinkovitost, djelotvornost i produktivnost korisnika. S druge strane, Colbert (2005) naglašava da je korisničko iskustvo neizostavan aspekt kvalitete u korištenju.

3.1.4 Kvaliteta u korištenju

Prema međunarodnom standardu ISO/IEC 9126-1 (2001), kvaliteta u korištenju omogućava korisniku da sagleda kvalitetu programskog proizvoda sa aspekta konteksta i okruženja u kojem ga upotrebljava. Za razliku od kvalitete i upotrebljivosti koje se bave vrjednovanjem karakteristika programskog proizvoda, kvaliteta u korištenju je usmjerena na mjerenje razine do

koje korisnik može primjenom programskog proizvoda izvršiti specifične zadatke. Zbog toga je isti standard definirao kvalitetu u korištenju kao mjeru do koje korisnik može primjenom programskog proizvoda djelotvorno i produktivno te na bezopasan i njemu prihvatljiv način ostvariti svoje ciljeve. Iz navedenog je evidentno da je kvaliteta u korištenju u standardu ISO/IEC 9126-1 (2001) dekomponirana na sljedeće četiri potkarakteristike:

- Djelotvornost (eng. effectiveness) je mjera do koje programski proizvod omogućuje korisnicima da točno i u cijelosti ostvare određene ciljeve u određenom kontekstu korištenja.
- Produktivnost (eng. productivity) je stupanj do kojeg programski proizvod omogućuje korisnicima da utroše primjerenu količinu resursa (vrijeme potrebno za dovršetak zadatka, napor kojeg korisnici trebaju uložiti, materijalni troškovi ili troškovi upotrebe) u odnosu na djelotvornost ostvarenu u određenom kontekstu korištenja.
- Zaštićenost (eng. safety) je razina do koje programski proizvod može osigurati prihvatljivu razinu zaštite od rizika koji bi mogli naštetiti ljudima, poslu, programskoj opremi, imovini ili okruženju u određenom kontekstu korištenja.
- Zadovoljstvo (eng. satisfaction) je mjera do koje programski proizvod udovoljava korisnicima u određenom kontekstu korištenja.

U standardu ISO/IEC 25010 (2011a) je došlo do značajnih izmjena modela kvalitete u korištenju predloženog standardom ISO/IEC 9126-1 (2001). Naime, jedino je potkarakteristika *djelotvornost* ostala nepromijenjena. Potkarakteristika *produktivnost* je zamijenjena sa potkarakteristikom *učinkovitost* koja je preuzeta iz standarda ISO 9241-11 (1998). Potkarakteristika *zadovoljstvo* je dekomponirana na četiri atributa te joj je proširena definicija. Naposljetku, potkarakteristika *zaštićenost* je preoblikovana u potkarakteristiku *zaštita od rizika* koja se sastoji od tri atributa. Pored toga, dodana je nova karakteristika pod nazivom *sveobuhvatnost konteksta* koja je dalje dekomponirana na dvije potkarakteristike. Naposljetku, fokus modela kvalitete u korištenju je proširen na cjelokupni sustav interakcije čovjeka i računala gdje ulogu predmeta vrjednovanja imaju računalni sustavi i programski proizvodi. Uzimajući u obzir sve navedeno, model kvalitete u korištenju je u standardu ISO/IEC 25010 (2011) organiziran na sljedeći način:

- Djelotvornost (eng. effectiveness) je mjera do koje korisnici mogu točno i u potpunosti ostvariti određene ciljeve.
- Učinkovitost (eng. efficiency) predstavlja količinu utrošenih resursa u odnosu na točnost i potpunost sa kojom korisnici ostvaruju određene ciljeve.

- Zadovoljstvo (eng. satisfaction) je stupanj do kojeg su zadovoljene potrebe korisnika kada se programski proizvod upotrebljava u određenom kontekstu korištenja.
    - Korisnost (eng. usefulness) je razina do koje je korisnik zadovoljan sa zamijećenim ostvarenjem pragmatičnih ciljeva, uključujući rezultate i posljedice korištenja.
    - Povjerenje (eng. trust) je stupanj do kojeg korisnik ili ostali dionici vjeruju da će se programski proizvod ponašati onako kako je zamišljeno.
    - Užitak (eng. pleasure) je razina do koje korisniku ispunjenje osobnih potreba (npr. nova znanja i vještine, diseminacija vlastitog identiteta, izazivanje ugodnih sjećanja) stvara osjećaj ugode.
    - Udobnost (eng. comfort) je stupanj do kojeg je korisnik zadovoljan sa fizičkom udobnošću.
- Zaštita od rizika (eng. freedom from risk) je razina do koje proizvod ili sustav ublažava potencijalni rizik za ekonomski status, ljudski život, zdravlje ili okoliš.
    - Smanjenje ekonomskog rizika (eng. economic risk mitigation) je stupanj do kojeg programski proizvod ublažava potencijalni rizik za financijski status, učinkovite operacije, komercijalno vlasništvo, ugled i ostale resurse u namjeravanom kontekstu korištenja.
    - Smanjenje zdravstvenih i sigurnosnih rizika (eng. health and safety risk mitigation) je razina do koje programski proizvod ublažava potencijalni rizik za ljude u namjeravanom kontekstu korištenja.
    - Smanjenje rizika za okolinu (eng. environmental risk mitigation) je stupanj do kojeg programski proizvod ublažava potencijalni rizik za imovinu ili okolinu u namjeravanom kontekstu korištenja.
- Sveobuhvatnost konteksta (eng. context coverage) je razina do koje je moguće učinkovito, djelotvorno, bez rizika i na zadovoljstvo korisnika upotrebljavati programski proizvod u unaprijed specificiranim kontekstima korištenja kao i izvan njih.
    - Cjelovitost konteksta (eng. context completeness) je stupanj do kojeg je moguće učinkovito, djelotvorno, bez rizika i na zadovoljstvo korisnika upotrebljavati programski proizvod u svim specificiranim kontekstima korištenja.
    - Fleksibilnost (eng. flexibility) je razina do koje je moguće učinkovito, djelotvorno, bez rizika i na zadovoljstvo korisnika upotrebljavati programski proizvod izvan unaprijed specificiranih konteksta korištenja.

Premda kvaliteta u korištenju predstavlja puno širi koncept od upotrebljivosti (Covella i Olsina, 2006), ista je sačinjena od ograničenog skupa atributa koji nisu dostatni za vrjednovanje

kompleksnih programskih proizvoda, a time ni cjelokupnog sustava interakcije čovjeka i računala kao što je naznačeno u recentnom modelu namijenjenom vrjednovanju kvalitete i kvalitete u korištenju programskim proizvodom (ISO/IEC, 2011a). Zbog toga su u kontekstu Web 2.0 aplikacija pojedini istraživači predložili proširenje definicije ovog koncepta ili su model kvalitete u korištenju dopunili dodatnim atributima i metrikama. Tako su primjerice Lew et al. (2010) kvalitetu u korištenju proširili karakteristikom aktualnog korisničkog iskustva (eng. actual user experience) koja je dalje dekomponirana na aktualnu upotrebljivost (eng. actual usability), zadovoljstvo korištenjem (eng. satisfaction in use) i zaštićenost (eng. safety). Aktualna upotrebljivost je prema istim autorima sačinjena od učinkovitosti u korištenju (eng. efficiency in use), djelotvornosti u korištenju (eng. effectiveness in use), lakoće učenja korištenja (eng. learnability in use) i pristupačnosti u korištenju (eng. accessibility in use). S druge strane, Orehovački (2011b) navodi da je kvaliteta u korištenju Web 2.0 aplikacijama sačinjena od dva različita no ujedno i komplementarna koncepta: upotrebljivosti i korisničkog iskustva. Dok vrjednovanje upotrebljivosti obuhvaća primjenu subjektivnih i objektivnih instrumenata u mjerenju pragmatičnih atributa kvalitete u korištenju, vrjednovanje korisničkog iskustva se sastoji od subjektivnog mjerenja hedonističkih aspekata kvalitete u korištenju.

U kontekstu ovog doktorskog rada, kvaliteta u korištenju je definirana kao **mjera do koje pragmatični aspekti Web 2.0 aplikacije i hedonističke dimenzije interakcije sa elementima njena sučelja u određenom kontekstu upotrebe udovoljavaju određenim zahtjevima korisnika**. Zbog toga će u sklopu ovog doktorskog rada koncept kvalitete u korištenju koji je predložen standardom ISO/IEC (2011b) biti proširen atributima namijenjenim vrjednovanju korisničkog iskustva, upotrebljivosti i kvalitete web mjesta kao i atributima koji prema teorijama prihvaćanja tehnologije, teoriji potvrđivanja očekivanja i modelu uspjeha informacijskog sustava značajno doprinose zadovoljstvu i lojalnosti korisnika.

3.2 Sporedne dimenzije teorijskog okvira

Pod ostalim dimenzijama teorijskog okvira se podrazumijevaju teorije i modeli koji su se bavili proučavanjem utjecaja raznovrsnih prediktora na zadovoljstvo i lojalnost korisnika. U nastavku će svaka od spomenutih dimenzija biti ukratko opisana dok će njihove temeljne pretpostavke biti detaljnije razmotrene u sklopu identificiranih atributa kvalitete u korištenju koji su bili predmet njihova istraživanja.

Teorija razložne akcije (eng. Theory of Reasoned Action, TRA; Fishbein i Ajzen, 1975; Ajzen i Fishbein, 1980) je jedan od temeljnih modela društvene psihologije namijenjen predikciji i pojašnjenju voljnih ponašanja. Prema temeljnim pretpostavkama teorije, ponašajna namjera

pojedinca ovisi o njegovom ili njenom stavu prema ponašanju i mišljenju njemu ili njoj bitnih ljudi o provedbi ponašanja dok stvarno ponašanje pojedinca direktno ovisi o njegovoj ili njenoj ponašajnoj namjeri.

Proširenje teorije razložne akcije konstruktom zamijećene ponašajne kontrole (eng. perceived behavior control) naziva se teorija planiranog ponašanja (eng. Theory of Planned Behavior, TPB). Ova teorija polazi od pretpostavke da donošenje odluke vezane uz realizaciju ponašanja ne ovisi samo o ponašajnim uvjerenjima i očekivanjima značajnih drugih osoba, već i kontroli nad ponašanjem (Ajzen, 1985; Ajzen, 1991). Relativna važnost navedenih konstrukata ovisi i razlikuje se ovisno o kontekstu ponašanja.

Prilagodbom teorije razložne akcije kontekstu informacijskih sustava, nastao je model prihvaćanja tehnologije (eng. Technology Acceptance Model, TAM). Prema temeljnoj pretpostavci ovog modela (Davis, 1989; Davis et al., 1989), zamijećena korisnost (eng. perceived usefulness) i zamijećena lakoća korištenja (eng. perceived ease of use) su glavne odrednice prihvaćanja informacijskog sustava. Naime, oba konstrukta pozitivno utječu na formiranje stavova vezanih uz korištenje što se dalje reflektira na namjeru korištenja i stvarno korištenje sustavom. Venkatesh i Davis (2000) su inicijalnu inačicu modela prihvaćanja tehnologije proširili prediktorima zamijećene korisnosti te ga nazvali TAM2 model. Iste je godine Venkatesh (2000) početnu verziju modela proširio prediktorima zamijećene lakoće korištenja. Naposljetku, integracijom prediktora zamijećene korisnosti i zamijećene lakoće korištenja Venkatesh i Bala (2008) su oblikovali TAM3 model.

Opća teorija prihvaćanja i korištenja tehnologijom (eng. Unified Theory of Acceptance and Use of Technology, UTAUT) nastala je kao rezultat longitudinalnog istraživanja tijekom kojeg su Venkatesh et al. (2003) na osnovi podataka prikupljenih od četiri organizacije uspoređivali metrijske kvalitete osam relevantnih modela te njihovom analizom identificirali sedam prediktora ponašajne namjere odnosno korištenja sustavom. Obzirom da su prethodna istraživanja pokazala da računalna samoučinkovitost, računalna anksioznost i stav prema korištenju često nemaju značajan utjecaj na ponašajnu namjeru ili korištenje sustavom, autori su odlučili da spomenuta tri prediktora neće biti sastavni dio UTAUT modela. Zbog toga je u finalnoj verziji UTAUT modela pretpostavljeno da očekivani radni učinak, očekivani napor i utjecaj društva imaju značajan utjecaj na ponašajnu namjeru dok ponašajna namjera i olakšavajući uvjeti značajno doprinose stvarnom korištenju sustavom. Pored spomenutih prediktora, u model su uvrštena i četiri moderatora: dob, spol, iskustvo i dobrovoljnost korištenja. U recentnom proširenju opće teorije prihvaćanja i korištenja tehnologijom koja se u literaturi spominje pod akronimom UTAUT2 (Venkatesh et al., 2012), pretpostavljeno je da na ponašajnu namjeru pored

očekivanog radnog učinka, očekivanog napora i utjecaja društva imaju još i olakšavajući uvjeti, hedonistička motivacija, navika te zamijećeni odnos koristi i troškova koje nastaju kao posljedica korištenja sustavom. Osim toga, u UTAUT2 modelu je pretpostavljeno da na korištenje sustavom pored ponašajne namjere i olakšavajućih uvjeta direktan utjecaj ima i navika. Naposljetku, od četiri moderatora koja su konceptualizirana u prvoj inačici UTAUT modela, u njegovoj proširenoj verziji su zadržana samo tri (dob, spol i iskustvo) dok je dobrovoljnost korištenja izostavljena iz UTAUT2 modela.

Na osnovi komunikacijske teorije koju su razvili Shannon i Weaver (1949), njene prilagodbe kontekstu informacijskih sustava (Mason, 1978), te analize empirijskih istraživanja iz područja upravljanja informacijskim sustavom, DeLone i McLean (1992) su predložili taksonomiju i model uspjeha informacijskog sustava. Taksonomija je služila kao okvir za kategorizaciju mjera identificiranih pregledom literature u šest međusobno povezanih konstrukata (DeLone i McLean, 1992): kvaliteta sustava, kvaliteta informacija, korištenje, zadovoljstvo korisnika, individualan učinak i organizacijski učinak. Spomenuti je model bio sačinjen od nekoliko pretpostavki (DeLone i McLean, 1992, str. 83-87). Prema prvoj i drugoj pretpostavci, kvaliteta sustava i kvaliteta informacija su prediktori korištenja i zadovoljstva korisnika. Treća pretpostavka implicira da korištenje i zadovoljstvo korisnika mogu međusobno pozitivno i/ili negativno utjecati jedan na drugog. Prema četvrtoj pretpostavci korištenje i zadovoljstvo korisnika direktno utječu na individualan učinak. Posljednja pretpostavka implicira da je individualan učinak prediktor organizacijskog učinka.

Model uspjeha informacijskog sustava često je bio predmet kritike iz nekoliko razloga. Najveća zamjerka odnosila se na činjenicu da dimenzija kvalitete usluge nije bila uvrštena u model (Pitt et al., 1995). Naime, riječ je o konstruktu koji je izuzetno važan u kontekstu transakcijskih informacijskih sustava i za čije su vrjednovanje u vrijeme razvoja modela postojali mjerni instrumenti (npr. SERVQUAL, Parasuraman et al., 1988; Parasuraman et al., 1991). Ostale kritike su uglavnom bile na račun toga što dimenzijom korištenja nije eksplicitno navedeno na koju se vrstu korištenja sustava misli (dok je primjerice kod modela prihvaćanja tehnologija to navedeno; Seddon, 1997) kao i na to da na uspjeh informacijskog sustava osim individualnog i organizacijskog učinka utječu još učinci radnih grupa (Myers et al., 1998), učinci korisnika (Brynjolfsson, 1996) te industrijski (Clemons et al., 1993) i društveni (Seddon, 1997) učinci.

Kao odgovor na navedene kritike, autori su deset godina od predstavljanja modela objavili njegovu nadopunjenu verziju. Novi model uspjeha informacijskog sustava, u odnosu na njegovu inicijalnu verziju, sadrži sljedeće nadopune i proširenja (DeLone i McLean, 2003):

- Kvaliteta usluge je uz kvalitetu sustava i kvalitetu informacija postala prediktor korištenja i zadovoljstva korisnika.
- Konceptualizacija međuodnosa konstrukata korištenje i zadovoljstvo korisnika je detaljnije pojašnjena. Korištenje je prediktor zadovoljstva korisnika na način da pozitivno iskustvo korištenja utječe na povećanje zadovoljstva korisnika. Istovremeno, rast zadovoljstva korisnika ima pozitivan utjecaj na povećanje namjere korištenja te posljedično rezultira ponovnom upotrebom sustava.
- Umjesto da se svaka vrsta učinka vrjednuje zasebno, autori su predložili njihovo objedinjavanje pod nazivom neto korist (eng. net benefits). Riječ je o konstruktu kojim se mjere učinci svih dionika uključenih u korištenje informacijskim sustavom.
- Model je obogaćen povratnim vezama preko kojih neto korist utječe na korištenje i zadovoljstvo korisnika.

Teorija potvrđivanja očekivanja (eng. Expectation-Confirmation Theory, ECT; Oliver, 1980) služi modeliranju zadovoljstva korisnika i njegovih ponašajnih namjera nakon interakcije sa programskim proizvodom. Proces tijekom kojeg korisnik oblikuje svoju ponašajnu namjeru vezanu uz nastavak korištenja odnosno lojalnost se sastoji od nekoliko koraka (Oliver, 1980). U prvom koraku korisnik oblikuje početna očekivanja vezana uz programski proizvod. Nakon toga korisnik upotrebljava programski proizvod određeno vremensko razdoblje te stvara percepciju o njegovim performansama. U sljedećem koraku korisnik vrjednuje zamijećene performanse sa aspekta oformljenih očekivanja te na taj način utvrđuje mjeru do koje su njegova očekivanja potvrđena. Na osnovi razine do koje su performanse programskog proizvoda potvrdile njegova očekivanja, korisnik formira stupanj zadovoljstva programskim proizvodom. Ukoliko je korisnik u dostatnoj mjeri zadovoljan programskim proizvodom, nastaviti će se koristiti njime dok ga u protivnom neće htjeti ponovno upotrebljavati.

3.3 Početni skup atributa kvalitete u korištenju

Kako bi se stvorilo teorijsko uporište za oblikovanje konceptualnog modela i razvoj mjernih instrumenata, iz maločas opisanih osnovnih i sporednih dimenzija izdvojeno je 46 konstrukata koji tvore početni skup atributa kvalitete u korištenju Web 2.0 aplikacijama. Obzirom da gotovo nijedan od identificiranih atributa nije moguće svrstati u samo jednu od spomenutih dimenzija, svaki će atribut kvalitete u korištenju Web 2.0 aplikacijama u nastavku biti opisan zasebno.

3.3.1 Djelotvornost

Koncept djelotvornosti (eng. effectiveness) je u kontekstu vrjednovanja programskih proizvoda među prvima spomenuo Shackel (1984) kada je predložio svoju definiciju upotrebljivosti. Međunarodni standard ISO 9241 (1998) je uvrstio djelotvornost među tri osnovne odrednice upotrebljivosti programskog proizvoda. Nasuprot tome, ISO/IEC 9126-1 (2001), Seffah et al. (2006) i ISO/IEC 25010 (2011a) su konceptualizirali djelotvornost kao atribut kvalitete u korištenju pomoću kojeg se utvrđuje mjera do koje programski proizvod omogućuje korisnicima da točno i u cijelosti ostvare određene ciljeve u specificiranom kontekstu korištenja. Quesenbery (2001) napominje da je sustav djelotvoran ako pomoću jasnih i razumljivih elemenata sučelja, materijala pomoći i navigacijskih mehanizama omogući korisnicima da izvrše zadatke točno i u potpunosti.

Djelotvornost korisnika je moguće vrjednovati objektivnim i subjektivnim metrikama. Međunarodnim standardom 9126-4 (2004) predložene su četiri objektivne metrike. Prva od njih predstavlja udio zadataka koje je korisnik uspio točno dovršiti, druga se iskazuje postotkom dovršenosti zadatka, treća predstavlja broj pogrješaka koje je korisnik počinio dok se četvrtom metrikom utvrđuje koliko je puta korisnik tijekom izvršavanja zadataka konzultirao sadržaje pomoći. Prilikom oblikovanja kompozitnog indeksa upotrebljivosti, Sauro i Kindlund (2005) su mjerili djelotvornost metrikama dovršenosti zadataka i količine pogrješaka dok su Oztekin et al. (2009) u istu svrhu upotrijebili jedino metriku dovršenosti zadataka. U suprotnosti sa navedenim, zamijećenu djelotvornost korisnika je moguće vrjednovati česticama koje su navedene u upitnicima kao što su UMUX (kratica za eng. The Usability Metric for User Experience; Finstad, 2010), AMUSE (kratica za eng. Appraisal and Measurement of User Satisfaction; Doerr et al., 2007), HED/UT (kratica za eng. Hedonic Utility Scale; Voss et al., 2003), PSUQ (kratica za eng. The Post-Study System Usability Questionnaire Items; Lewis, 2002) i USE (kratica za eng. Usefulness, Satisfaction, and Ease of Use; Lund, 2001). Potrebno je napomenuti da je koncept djelotvornosti u velikom broju istraživanja vrjednovan sa aspekta korisnosti programskih proizvoda (npr. Chang et al., 2009; Chiu et al., 2009; Davis et al, 1989; Hsu i Chiu, 2004; Sánchez-Franco, 2006; Van Schaik i Ling, 2011; Venkatesh i Bala, 2008). Iz svega navedeno je evidentno da se djelotvornost korisnika u kontekstu interakcije sa Web 2.0 aplikacijama može vrjednovati pomoću sljedećih pet čestica i jednog indikatora, respektivno:

DTV1. Upotrebom Web 2.0 aplikacije povećava se produktivnost korisnika u izvršavanju zadataka.
DTV2. Upotrebom Web 2.0 aplikacije povećava se djelotvornost korisnika u izvršavanju zadataka.

DTV3. Upotrebom Web 2.0 aplikacije, zadatke je moguće izvršiti točno i u potpunosti.
DTV4. Sučelje Web 2.0 aplikacije sadrži sve funkcionalnosti potrebne za izvršavanje zadataka.
DTV5. Sučelje Web 2.0 aplikacije sadrži veliki broj različitih funkcionalnosti.
DTV6. Postotak dovršenosti predefiniranih koraka scenarija interakcije sa Web 2.0 aplikacijom.

3.3.2 Dodana vrijednost sadržaja

Atribut pomoću kojeg se utvrđuje razina do koje je sadržaj koristan te pruža pogodnosti onima koji ga upotrebljavaju nosi naziv dodana vrijednost sadržaja (eng. content value-added; Olsina et al., 2009; Orehovački et al., 2013; Wang i Strong, 1996). Dosad je nekoliko istraživača vrjednovalo dimenzije ovog atributa sa aspekta relevantnosti (npr. Barnes i Vidgen, 2003; De Wulf et al., 2006; Lee et al., 2002; McKinney et al., 2002; Muylle et al., 2004) i korisnosti (npr. Aladwani i Palvia, 2002; Cheung i Lee, 2005; Hong i Kim, 2004; Poelmans et al., 2008) informacija. Za potrebe vrjednovanja svih relevantnih aspekata ovog atributa u kontekstu sadržaja kojeg korisnici generiraju tijekom interakcije sa Web 2.0 aplikacijom oblikovano je sljedećih pet čestica:

DVS1. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je koristan.
DVS2. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je upotrebljiv.
DVS3. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je pristupačan.
DVS4. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je usklađen sa ciljevima korisnika.
DVS5. Sadržaj koji nastane upotrebom Web 2.0 aplikacije utječe na donošenje odluka kod korisnika.

3.3.3 Dosljednost

Dix et al. (2004) su definirali dosljednost (eng. consistency) kao dimenziju lakoće učenja korištenja primjenom koje se provjerava da li su nazivlje, izgled i način upotrebe elemenata sučelja uniformni u svim dijelovima aplikacije. Prema Seffah et al. (2006), dosljednost se ubraja među 26 relevantnih kriterija vrjednovanja upotrebljivosti, a služi mjerenju razine ujednačenosti među elementima korisničkog sučelja i smislenosti metafora koje oni pružaju korisnicima. U modelu kojeg su razvili Alonso-Ríos et al. (2010) dosljednost predstavlja dimenziju familijarnosti (izvorno eng. knowability), a primjenjuje se kako bi se utvrdilo do koje su mjere elementi, struktura i način funkcioniranja programskog proizvoda ujednačeni i usklađeni. Kako bi se osigurala dosljednost korisničkog sučelja, tijekom dizajna njegovih elemenata potrebno je slijediti uvriježene standarde platforme (Nielsen, 1994).

U instrumentu pod nazivom PUTQ (kratica za eng. Purdue Usability Testing Questionnaire) kojeg su razvili Lin et al. (1997) dosljednost je jedan od osam atributa pomoću kojih se vrjednuje upotrebljivost računalnih sustava sa grafičkim korisničkim sučeljem. Ozok i Salvendy (2001) su oblikovali instrument namijenjen vrjednovanju dosljednosti web sučelja te ga nazvali ICTQ (kratica za eng. Interface Consistency Testing Questionnaire). ICTQ predstavlja kombinaciju prethodne verzije upitnika kojeg su autori objavili pod nazivom PCTQ (kratica za eng. Purdue Consistency Testing Questionnaire; Ozok i Salvendy, 2000) i njegovog proširenja ILCTQ (kratica za eng. Interface Language Consistency Testing Questionnaire) namijenjenog vrjednovanju jezične dosljednosti. Konačna verzija upitnika obuhvaća 94 čestice koje preko skale od sedam stupnjeva omogućuju vrjednovanje sljedećih aspekata web sučelja: struktura teksta (eng. text structure), opće značajke teksta (eng. general text features), prikaz informacija (eng. information representation), leksičke kategorije (eng. lexical categories), značenje (eng. meaning), znanje korisnika (eng. user knowledge), atributi komunikacije (eng. communicational attributes) i fizički atributi (eng. physical attributes). Aspekte ovog atributa je u kontekstu Web 2.0 aplikacija moguće vrjednovati pomoću sljedećih pet čestica:

DSD1. Izvršavanje jednakih aktivnosti dovodi do jednakih rezultata u svim dijelovima Web 2.0 aplikacije.
DSD2. Funkcionalnosti sučelja su jednako razmještene u svim dijelovima Web 2.0 aplikacije.
DSD3. Dizajn sučelja je jednak u svim dijelovima Web 2.0 aplikacije.
DSD4. Način i mjesto prikazivanja poruka i informiranja korisnika su jednaki u svim dijelovima Web 2.0 aplikacije.
DSD5. U svim dijelovima Web 2.0 aplikacije se primjenjuje jednaka terminologija.

3.3.4 Dostupnost

Atribut kojim se mjeri razina do koje je programski proizvod pristupačan i funkcionalan svaki put kada je korisnicima to potrebno nosi naziv dostupnost (eng. availability; ISO/IEC, 2011a). Iz navedenog proizlazi da je dostupnost mjera za količinu vremena u kojem je programski proizvod upotrebljiv (Calero et al., 2005) te shodno tome predstavlja splet obilježja potkarakteristika kojima se mjeri učestalost pojavljivanja pogrješaka, tolerancija pogrješaka i mogućnost oporavka od pogrješaka (ISO/IEC, 2001). Dostupnost u značajnoj mjeri utječe na upotrebljivost (Tarafdar i Zhang, 2005) i reputaciju (Pang et al. 2010) web mjesta zbog čega isto treba biti u potpunosti funkcionalno svaki dan u godini, 24 sata na dan (24/7/365; Basu, 2003). Jednako je tako potrebno da razdoblje nedostupnosti u slučajevima održavanja ili nadogradnje bude što je moguće kraće te da sa rasporedom provedbe spomenutih procedura korisnici budu unaprijed

upoznati (Orehovački et al., 2013). Razinu dostupnosti web mjesta moguće je prema standardu ISO/IEC 9126-2 (2003a) utvrditi pomoću dvije objektivne metrike. Opća dostupnost web mjesta se izračunava kao omjer količine vremenskog razdoblja u kojem je web mjesto funkcionalno i sume količine spomenutog vremenskog razdoblja i količine vremena potrebnog da web mjesto ponovno postane funkcionalno. Radna dostupnost predstavlja proporciju uspješnog i ukupnog broja pristupanja web mjestu u određenom vremenskom razdoblju. Uspješno pristupanje implicira dostupnost i funkcionalnost web mjesta u trenutku pristupanja. Pored navedenih objektivnih metrika, pojedini su autori (npr. Aladwani i Palvia, 2002; Shin, 2007) dimenzije dostupnosti vrjednovali primjenom upitnika. Kako bi se utvrdila razina dostupnosti Web 2.0 aplikacija, oblikovano je sljedećih šest čestica:

DST1. Web 2.0 aplikacija je dostupna svaki put kada je korisniku to potrebno.
DST2. Da bi se isprobale funkcionalnosti sa kojima raspolaže Web 2.0 aplikacija, nije potrebno kreirati korisnički račun.
DST3. Sve funkcionalnosti koje su potrebne za izvršavanje zadataka pomoću Web 2.0 aplikacije su omogućene.
DST4. Web 2.0 aplikaciju je jednostavno pronaći preko web tražilice.
DST5. Web 2.0 aplikacija omogućava prijavu sa postojećim (npr. Google, Facebook, Yahoo, ili OpenID) korisničkim računom.
DST6. Web 2.0 aplikacija sadrži funkcionalnost upotrebe u offline načinu rada.

3.3.5 Estetika

Prema recentnom standardu namijenjenom vrjednovanju kvalitete programskih proizvoda (ISO/IEC, 2011a), estetika (eng. aesthetics) je atribut upotrebljivosti pomoću kojeg se utvrđuje do koje mjere dizajn sučelja programskog proizvoda utječe na povećanje razine ugode i zadovoljstva kod korisnika. Nadalje, estetika je zajedno sa minimalističkim dizajnom uvrštena u skup temeljnih Nielsenovih heuristika (Nielsen, 1994) namijenjenih vrjednovanju upotrebljivosti dizajna korisničkog sučelja. Spomenuta heuristika stavlja naglasak na razmještaj elemenata korisničkog sučelja kao uporište njegove preglednosti (Neil, 2009).

U kontekstu interakcije sa web mjestom postoje dvije vrste estetike (Lavie i Tractinsky, 2004). Dok je klasična estetika usmjerena na vrjednovanje jasnoće i simetričnosti, izražajna estetika služi mjerenju originalnosti i sofisticiranosti dizajna sučelja web mjesta. Sonderegger i Sauer (2010) navode da je koncept estetike moguće sagledati sa objektivnog i subjektivnog aspekta. Usklađenost boja na korisničkom sučelju predstavlja objektivni podražaj (Postrel, 2004), a razina do koje korisnici smatraju da je dizajn sučelja ugodan za oči implicira subjektivnu reakciju

na spomenuti podražaj (Van der Heijden, 2003). Brojni istraživači (npr. Basu, 2003; Brady i Phillips, 2003; Becker i Mottay, 2001) ističu da su boje koje prevladavaju na korisničkom sučelju ključan čimbenik u vrjednovanju estetike web mjesta. Rezultati dosadašnjih istraživanja su pokazali da estetika ima značajan utjecaj na zamijećenu upotrebljivost elemenata sučelja (Tractinsky et al. 2000), stvara osjećaj ugode tijekom interakcije (Tractinsky i Hassenzahl, 2005) te doprinosi zadovoljstvu (Schenkman i Jönsson, 2000) i lojalnosti (Hall i Hanna, 2004) korisnika. Zbog toga je za potrebe vrjednovanja estetike korisničkog sučelja Web 2.0 aplikacija oblikovano sljedećih pet čestica:

EST1. Dizajn sučelja Web 2.0 aplikacije je vizualno privlačan.
EST2. Boje koje prevladavaju na sučelju Web 2.0 aplikacije su prikladno usklađene.
EST3. Boje koje prevladavaju na sučelju Web 2.0 aplikacije su ugodne za oči.
EST4. Web 2.0 aplikacija ima atraktivno sučelje.
EST5. Web 2.0 aplikacija lijepo izgleda.

3.3.6 Familijarnost

Prema Dix et al. (2004), familijarnost (eng. familiarity) je dimenzija lakoće učenja korištenja pomoću koje se utvrđuje do koje mjere vizualni izgled elemenata sučelja insinuira njihovu funkcionalnost te je shodno tome postojeće znanje i iskustvo korisnika dostatno za učinkovitu interakciju sa aplikacijom. Seffah et al. (2006) su definirali familijarnost kao mjeru do koje su elementi sučelja i interakcija sa programskim proizvodom poznati korisniku. Ukoliko je korisnicima terminologija i struktura web mjesta od prije poznata, istima će biti jasnije što predstavljaju pojedini elementi sučelja, lakše će se snalaziti tijekom interakcije sa web mjestom te će trebati uložiti manje napora u pogledu broja klikova mišem kako bi ostvarili svoj cilj (Galletta et al., 2006). Familijarnost ima vrlo važnu ulogu u oblikovanju povjerenja u web mjesto (Gefen, 2000; Gefen i Straub, 2004). Nedovoljna razina familijarnosti ima za posljedicu povećanje stupnja zamijećenog rizika u transakcije koje se izvršavaju putem Interneta (Black et al., 2002). Ako su korisnici upoznati sa elementima korisničkog sučelja, biti će im lakše upotrebljavati web mjesto (Lederer et al., 2000) i snalaziti se tijekom korištenja njime (Edwards i Hardman, 1999) jer znaju što mogu očekivati od interakcije. Naposljetku, familijarnost korisničkog sučelja značajno doprinosi lojalnosti korisnika (Casaló et al., 2008; Flavián et al., 2006) iz razloga što smanjuje vjerojatnost da će korisnici biti voljni potražiti alternativno web mjesto. Familijarnost Web 2.0 aplikacije je moguće vrjednovati pomoću sljedećih pet čestica:

FML1. Raspored elemenata na korisničkom sučelju Web 2.0 aplikacije je sličan rasporedu u aplikacijama kojima se redovito koristim.

FML2. Način izvršavanja zadataka pomoću Web 2.0 aplikacije se bitno ne razlikuje od načina izvršavanja zadataka pomoću aplikacija kojima se svakodnevno koristim.
FML3. Web 2.0 aplikacija upotrebljava jednake nazive za funkcionalnosti sučelja kao i aplikacije kojima se inače koristim.
FML4. Web 2.0 aplikacija upotrebljava slične ikone za pokretanje pojedinih funkcionalnosti kao i aplikacije kojima se svakodnevno koristim.
FML5. Sučelje Web 2.0 aplikacije sadrži iste funkcionalnosti kao i aplikacije kojima se redovito koristim.

3.3.7 Interaktivnost

Musser i O'Reilly (2007) navode da je interaktivnost (eng. interactivity) jedna od temeljnih karakteristika Web 2.0 aplikacija. Interaktivnost je višedimenzionalan koncept za kojeg u literaturi postoji mnoštvo definicija. Prema velikom broju autora (npr. Lee i Kozar, 2012; Song i Zinkhan, 2008; Teoh et al., 2009; Yoo i Donthu, 2001), interaktivnost predstavlja mjeru do koje web mjesto raspolaže funkcionalnostima sinkrone i asinkrone komunikacije. Ostale definicije interaktivnosti u prvi plan stavljaju dostupnost i djelotvornost funkcionalnosti podrške korisnicima (npr. Srinivasan et al., 2002), personalizaciju web mjesta (npr. Palmer, 2002b) te kontrolu korisnika u pristupanju sadržajima (npr. Cyr et al., 2009). Orehovački (2010) je definirao interaktivnost kao mjeru do koje Web 2.0 aplikacija stvara osjećaj korištenja desktop aplikacijom te sadrži funkcionalnosti koje olakšavaju različite oblike interakcije među korisnicima. Pojedini su autori ponudili definiciju ovog atributa kroz identifikaciju njegovih dimenzija. Primjerice, Dholakia et al. (2000) smatraju da je interaktivnost web mjesta sačinjena od šest dimenzija: kontrole, vremena odaziva, interakcije u realnom vremena, povezanosti, personalizacije i razigranosti. Vrlo slično, Lee (2005) navodi da su kontrola korisnika, vrijeme odaziva, personalizacija i mogućnost povezivanja temeljne odrednice interaktivnosti. Dosadašnja istraživanja su pokazala da interaktivnost ima značajan utjecaj na učinkovitost, djelotvornost, užitak i povjerenje korisnika (Cyr et al., 2009) te uspjeh web mjesta (Palmer, 2002b).

Obzirom da komunikacija i suradnja predstavljaju specifične oblike interakcije među korisnicima, njihova se operacionalizacija preklapa sa poimanjem koncepta interaktivnosti. Zbog toga su u sklopu ovog doktorskog rada interaktivnost, mogućnost komunikacije i mogućnost suradnje specificirani kao zasebni atributi kvalitete u korištenju. Osim toga, definicija koju je ponudio Orehovački (2010) je modificirana te sada glasi: interaktivnost predstavlja mjeru do koje Web 2.0 aplikacija stvara osjećaj korištenja desktop aplikacijom te sadrži funkcionalnosti

koje olakšavaju upravljanje artefaktima. Shodno tome je oblikovano sljedećih šesnaest čestica namijenjenih vrjednovanju različitih aspekata interaktivnosti Web 2.0 aplikacija:

ITR1. Web 2.0 aplikacija sadrži funkcionalnost generiranja direktne poveznice za svaki kreirani artefakt.
ITR2. Web 2.0 aplikacija sadrži funkcionalnost za dodjelu razina vidljivosti kreiranom artefaktu.
ITR3. Web 2.0 aplikacija sadrži funkcionalnost za dodjeljivanje dozvola nad kreiranim artefaktom.
ITR4. Web 2.0 aplikacija sadrži funkcionalnost označavanja kreiranih artefakata pomoću ključnih riječi (tagova).
ITR5. Web 2.0 aplikacija sadrži funkcionalnost automatske pohrane artefakata (autosave).
ITR6. Web 2.0 aplikacija sadrži funkcionalnost objave kreiranih artefakata na društvenim mrežama.
ITR7. Web 2.0 aplikacija sadrži funkcionalnost slanja obavijesti o promjenama nad artefaktom (RSS kanal, e-mail, poruka na društvenoj mreži).
ITR8. Web 2.0 aplikacija sadrži funkcionalnost kreiranja RSS kanala.
ITR9. Web 2.0 aplikacija sadrži funkcionalnost prikaza sadržaja sa više različitih izvora.
ITR10. Web 2.0 aplikacija sadrži funkcionalnost pretplate na sadržaje od interesa.
ITR11. Sučelje Web 2.0 aplikacije sadrži funkcionalnost ispisa kreiranog artefakta na pisač.
ITR12. Web 2.0 aplikacija pohranjuje informacije o autoru artefakta te datumu njegova nastanka ili modifikacije.
ITR13. Web 2.0 aplikacija sadrži statistiku o učestalosti pristupanja i pregledavanja kreiranih artefakata.
ITR14. Web 2.0 aplikacija sadrži detaljan pregled svih kreiranih artefakata (naziv, veličina, autor, datum kreiranja, datum modifikacije i sl.).
ITR15. Web 2.0 aplikacija omogućava učitavanje vlastitih multimedijskih artefakata (slika, ikona, videozapisa).
ITR16. Web 2.0 aplikacija prikazuje popis artefakata koji su zadnji mijenjani.

3.3.8 Interoperabilnost

Prema međunarodnom standardu ISO/IEC 9126-1 (2001) interoperabilnost (eng. interoperability) je potkarakteristika funkcionalnosti pomoću koje se provjerava do koje mjere programski proizvod raspolaže mehanizmima koji podržavaju različite oblike interakcije sa jednim ili većim brojem ostalih programskih proizvoda ili sustava. Interoperabilnost se može vrjednovati dvjema objektivnim metrikama koje su predložene standardom ISO/IEC 9126-3

(2003b). Prva se odnosi na razmjenjivost podataka (eng. data exchangeability), a predstavlja omjer broja podatkovnih formata koji su ispravno implementirani i broja podatkovnih formata koje je potrebno razmjenjivati kao što je naznačeno u specifikaciji. Druga metrika je vezana uz dosljednu implementaciju protokola korisničkog sučelja, a mjeri se proporcijom broja protokola korisničkog sučelja koji su ispravno implementirani i broja protokola korisničkog sučelja koji prema specifikaciji trebaju biti implementirani. Kako bi se omogućilo vrjednovanje interoperabilnosti Web 2.0 aplikacija, oblikovane su sljedeće tri čestice:

INT1. Prilikom prenošenja artefakta (preuzimanje i umetanje) između Web 2.0 aplikacije i aplikacija kojima se svakodnevno koristim, ne dolazi do promjena u strukturi artefakta.
INT2. Prilikom prenošenja artefakta (kopiranje i lijepljenje) između Web 2.0 aplikacije i aplikacija kojima se svakodnevno koristim, ne dolazi do promjena u strukturi artefakta.
INT3. Artefakte koji nastanu upotrebom Web 2.0 aplikacije moguće je pohraniti u formatima datoteka koji su mi potrebni.

3.3.9 Jedinstvenost

Jedinstvenost (eng. uniqueness) je atribut pomoću kojeg se utvrđuje do koje se razine web mjesto koje je objekt vrjednovanja razlikuje od ostalih web mjesta (Tian et al., 2001). Moustakis et al. (2004) predlažu primjenu ovog atributa u vrjednovanju aspekata strukture i dizajna web mjesta. U mjernom instrumentu WebQual (Loiacono et al., 2007) jedinstvenost predstavlja dimenziju inovativnosti web mjesta. Nemzow (1999) napominje da pomanjkanje jedinstvenosti web mjesta ima za posljedicu nisku razinu lojalnosti korisnika. Kako bi se utvrdilo da li Web 2.0 aplikacija raspolaže značajkama koje istu jednoznačno određuju, oblikovane su sljedeće tri čestice:

JDN1. Web 2.0 aplikacija ima ono nešto po čemu se razlikuje od drugih aplikacija.
JDN2. Web 2.0 aplikacija je jedinstvena.
JDN3. Web 2.0 aplikacija se ističe u skupini aplikacija sa istom namjenom.

3.3.10 Kompatibilnost

Pang et al. (2010) su definirali kompatibilnost (eng. compatibility) kao mjeru do koje su Web 2.0 aplikacije pristupačne i upotrebljive u različitim okruženjima kao što su operativni sustavi i web preglednici. Kao nadopuna ovoj definiciji, Orehovački et al. (2013) navode da kompatibilnost predstavlja razinu do koje je Web 2.0 aplikacija funkcionalna na različitim uređajima koji imaju vezu na Internet. Međutim, u međunarodnom se standardu ISO/IEC 25010 (2011a) poimanje

kompatibilnosti značajno razlikuje od spomenutih definicija dok je istima najviše slična konceptualizacija prenosivosti programskog proizvoda. Naime, u standardu ISO/IEC 25010 (2011a) kompatibilnost je zasebna karakteristika kvalitete pomoću koje se provjerava do koje mjere programski proizvod podržava razmjenu podataka sa ostalim programskim proizvodima, sustavima ili komponentama u istom okruženju. U navedenom je standardu kompatibilnost sačinjena od dvije potkarakteristike: suživota i interoperabilnosti. S druge strane, prenosivost (eng. portability) označava mjeru do koje je programski proizvod moguće učinkovito i djelotvorno prenijeti iz jednog radnog okruženja u drugo. Prenosivost je dalje dekomponirana na prilagodljivost, mogućnost instalacije i zamjenjivost (ISO/IEC, 2011a).

Svaku je od spomenutih potkarakteristika moguće vrjednovati skupom objektivnih metrika koje su specificirane standardima ISO/IEC 9126-2 (2003a) i ISO/IEC 9126-3 (2003b). Osim toga, pojedini su istraživači (Ajzen, 1991; Taylor i Todd 1995a, 1995b; Venkatesh i Bala, 2008) predložili subjektivno vrjednovanje aspekata ovog atributa pomoću samo jedne čestice. Kako bi se omogućilo mjerenje razine kompatibilnosti Web 2.0 aplikacija, oblikovano je sljedećih pet čestica:

KMP1. Način korištenja Web 2.0 aplikacijom se ne razlikuje među web preglednicima.
KMP2. Dostupnost elemenata sučelja Web 2.0 aplikacije se ne razlikuje među web preglednicima.
KMP3. Način korištenja Web 2.0 aplikacijom te dostupnost elemenata njena sučelja se ne razlikuje među uređajima koje je moguće spojiti na Internet.
KMP4. Artefakt koji nastane upotrebom Web 2.0 aplikacije je kompatibilan sa aplikacijama koje korisnik svakodnevno upotrebljava.
KMP5. Web 2.0 aplikacija se može upotrebljavati na svakom uređaju koji ima vezu na Internet.

3.3.11 Korisnost

Definicija koncepta korisnosti (eng. usefulness) programskog proizvoda je u literaturi sagledana sa aspekata upotrebljivosti (Grudin, 1992; Hertzum, 2010; ISO/IEC, 2011a; Nielsen, 1993; Seffah et al., 2006) i prihvaćanja tehnologije (Davis, 1989). Prema Nielsenu (1993, str. 24), korisnost predstavlja „mjeru do koje korisnik upotrebom programskog proizvoda može postići zadane ciljeve“. Grudin (1992) je podijelio korisnost na dva dijela: a) korist (eng. utility) kao mjeru do koje programski sustav izvršava svoju funkcionalnost i b) upotrebljivost (eng. usability) kao mjeru do koje je moguće kvalitetno koristiti se raspoloživim funkcionalnostima programskog proizvoda. Seffah et al. (2006) su uvrstili korisnost u deset temeljnih kategorija upotrebljivosti te je definirali kao mjeru do koje programski proizvod sa svojim obilježjima i funkcionalnostima

omogućuje korisnicima da riješe stvarne probleme na prihvatljiv način. Naposljetku, Hertzum (2010) smatra da je korisnost jedna od temeljnih odrednica zamijećene upotrebljivosti (eng. perceived usability).

Zamijećena korisnost (eng. perceived usefulness) je stupanj do kojeg osoba vjeruje da će korištenje određenog sustava unaprijediti njegov ili njen radni učinak (Davis, 1989, str. 320). U TAM2 modelu (Venkatesh i Davis, 2000) se prediktori zamijećene korisnosti dijele na procese društvenog utjecaja (eng. social influence processes) te na kognitivno instrumentalne procese (eng cognitive instrumental processes). Subjektivna norma (eng. subjective norm) i imidž (eng. image) se ubrajaju u procese društvenog utjecaja. Skupina kognitivno instrumentalnih procesa osim zamijećene lakoće korištenja preuzete iz originalnog TAM modela sadrži još dodatna tri konstrukta: primjerenost poslu (eng. job relevance), kvalitetu izlaznih rezultata (eng. output quality) i demonstrabilnost rezultata (eng. result demonstrability). Osim navedenog, u model su uvrštene dvije moderatorske varijable: iskustvo (eng. experience) i dobrovoljnost (eng. voluntariness). Dobrovoljnost je mjera do koje pojedinci percipiraju korištenje sustavom kao neobavezno (Agarwal i Prasad, 1997).

Prema pretpostavkama kognitivno instrumentalnih procesa u TAM2 modelu, odluka o korisnosti sustava donosi se kroz dvije faze: tijekom faze kompatibilnosti testira se primjerenost sustava poslu (eng. job relevance) dok se u fazi profitabilnosti vrjednuje kvaliteta izlaznih rezultata (eng. output quality) nastalih upotrebom sustava (Beach i Mitchell, 1998; Venkatesh i Davis, 2000). Svrha faze kompatibilnosti je utvrditi količinu poslovnih zadataka koje je upotrebom sustava moguće dovršiti. Svaki sustav koji ne udovoljava minimumu unaprijed definiranih poslovnih zahtjeva korisnika je izuzet iz daljnjeg vrjednovanja. Tijekom faze profitabilnosti uspoređuje se kvaliteta izlaznih rezultata sustava koji su udovoljili zahtjevima faze kompatibilnosti te se odabire najbolja alternativa. Iz navedenog je evidentno da rezultati korištenja sustavom igraju vrlo važnu ulogu u donošenju odluke o korisnosti sustava. Stoga je potrebno da rezultati budu prikazani na način da je iz njih jasno vidljivo (eng. results demonstrability) na koji način korištenje sustavom doprinosi povećanju radne učinkovitosti pojedinca. Posljedni kognitivno instrumentalni proces je zamijećena lakoća korištenja čija je konceptualizacija veze prema zamijećenoj korisnosti preuzeta iz originalnog TAM modela (Davis, 1989; Davis et al., 1989). Analizom podataka prikupljenih kroz četiri longitudinalne studije utvrđeno je da spomenuti prediktori objašnjavaju između 40% i 60% varijance u zamijećenoj korisnosti (Venkatesh i Davis, 2000).

Pored spomenutih prediktora, konstrukti kao što su užitak (npr. Ha i Stoel, 2009; Liaw, 2002), kvaliteta sustava, kvaliteta usluge i kvaliteta informacija (npr. Ahn et al., 2007) i mogućnost

oporavka (npr. Drennan et al., 2005) imaju značajan utjecaj na zamijećenu korisnost u online okruženju. S druge strane, rezultati dosadašnjih istraživanja impliciraju da zamijećena korisnost značajno doprinosi lojalnosti korisnika (npr. Bhattacherjee, 2001a; Cyr et al., 2007). Ako se u obzir uzme sve maločas razmotreno, korisnost Web 2.0 aplikacija se može vrjednovati pomoću sljedeće četiri čestice:

KRS1. Korištenje Web 2.0 aplikacijom utječe na povećanje kvalitete artefakata.
KRS2. Upotrebom Web 2.0 aplikacije povećavaju se performanse korisnika u izvršavanju zadataka.
KRS3. Web 2.0 aplikacija je korisna za izvršavanje zadataka.
KRS4. Web 2.0 aplikacija je prikladna za izvršavanje zadataka.

3.3.12 Lakoća korištenja

Prema Agarwal i Venkatesh (2002), lakoća korištenja (eng. ease of use) se odnosi na količinu napora koja je potrebna za korištenje web mjestom. Spomenuti su autori dekomponirali lakoću korištenja na tri potkategorije: strukturu (eng. structure) koja je usmjerena na organizaciju web mjesta, svrhu (eng. goals) koja je vezana uz jasne i razumljive ciljeve te povratne informacije (eng. feedback) koje predstavljaju mjeru do koje web mjesto obavještava korisnika o statusu u svom radu. Davis (1989) je definirao zamijećenu lakoću korištenja (eng. perceived ease of use) kao mjeru do koje osoba vjeruje da će korištenje određenim sustavom biti oslobođeno napora. Nadovezujući se na njegov rad, Venkatesh (2000) je predstavio prediktore zamijećene lakoće korištenja. Navedeni su prediktori svrstani u dvije skupine: sidrišta (eng. anchors) i prilagodbe (eng. adjustements). U situacijama kada pojedinci nemaju iskustva u interakciji sa novim (specifičnim) sustavom, odluku o zamijećenoj lakoći korištenja donose na osnovi sidrišta odnosno općih uvjerenja vezanih uz korištenje računalnim sustavima (Venkatesh, 2000). U skupinu sidrišta se ubrajaju kontrola, intrinzična motivacija (računalna razigranost) i emocije (računalna anksioznost).

Kontrola je u sklopu teorije planiranog ponašanja (Ajzen, 1985; Ajzen, 1991) tretirana kao jednodimenzionalan konstrukt. Međutim, kako su prethodna istraživanja pokazala da pojedinci različito percipiraju unutarnju i vanjsku kontrolu, Venkatesh (2000) se odlučio za njenu dvodimenzionalnu konceptualizaciju. Dok unutarnja kontrola ili samoučinkovitost (eng. self-efficacy) predstavlja percepciju vlastitih mogućnosti (npr. znanje i vještine) vezanih uz korištenje sustavom, vanjska kontrola implicira percepciju tehnoloških i resursnih olakšavajućih uvjeta (eng. facilitating conditions) poput primjerice dostupnosti službe za korisnike. Pretpostavka je da će pojedinci prije stečenog iskustva u interakciji sa specifičnim sustavom

percepciju o lakoći korištenja temeljiti na uvjerenjima o vlastitim sposobnostima vezanim uz korištenje i poznavanje računalnih sustava te dostupnosti tehnološke infrastrukture i resursa (Venkatesh, 2000).

Računalna razigranost (eng. computer playfulness) ili intrinzična motivacija je zamijećena količina ugode i zadovoljstva koja nastaje kao posljedica korištenja sustavom (Vallerand, 1997). Pojedinci koji su prirodno znatiželjni i spontani u interakciji sa računalnim sustavima će jedva dočekati da isprobaju specifičan sustav (Venkatesh, 2000). Sama činjenica da je riječ o nečem novom i neistraženom će kod pojedinaca sa visokom razinom računalne razigranosti pozitivno utjecati na njihovu percepciju lakoće korištenja. Detaljnije informacije o atributu kojim se vrjednuje razigranost nalaze se u nastavku ovog poglavlja.

Računalna anksioznost (eng. computer anxiety) je osjećaj neugode ili straha od korištenja računalom (Simonson et al. 1987). Obzirom da je riječ o emocionalnoj reakciji koja negativno utječe na zamijećenu lakoću korištenja, pojedinci koji pate od računalne anksioznosti će imati poteškoća u interakciji sa specifičnim sustavom. Čak i nakon što steknu iskustvo u interakciji sa specifičnim sustavom, pojedinci i dalje imaju tendenciju percepciju lakoće korištenja temeljiti na računalnoj anksioznosti i uvjerenjima u vlastite sposobnosti upotrebe računala (Venkatesh, 2000). Kako bi se fokus percepcije što je moguće više približio kontekstu specifičnog sustava, predlaže se vrjednovanje objektivne upotrebljivosti. Riječ je konstruktu prilagodbe namijenjenom mjerenju količine napora potrebnog za dovršetak određenog zadatka. Kombinacijom objektivne upotrebljivosti i općih uvjerenja dobiva se puno preciznija predodžba o zamijećenoj lakoći korištenja specifičnim sustavom.

Venkatesh (2000) smatra da će se stjecanjem iskustva percepcija vanjske kontrole odnosno olakšavajućih uvjeta prilagoditi kontekstu specifičnog sustava na način da će pojedinci promijeniti fokus sa organizacijskog okruženja na okruženje specifičnog sustava. Nadalje, povećanjem iskustva u korištenju specifičnim sustavom, aspekti računalne razigranosti poput izazovnosti i noviteta počinju gubiti na značaju. Nasuprot tome, obilježja sustava koja kod korisnika tijekom i nakon interakcije stvaraju osjećaj ugode (eng. perceived enjoyment) će s vremenom imati sve veći utjecaj na zamijećenu lakoću korištenja specifičnim sustavom. Rezultati istraživanja kojeg je proveo Venkatesh (2000) su pokazali da spomenuti prediktori objašnjavaju 60% varijance u zamijećenoj lakoći korištenja.

Dosadašnja istraživanja su pokazala da u kontekstu Weba, atributi kao što su upravljivost i razumljivost (npr. Brown, 2002), užitak (npr. Yi i Hwang, 2003), kvaliteta sustava, kvaliteta usluge i kvaliteta informacija (npr. Ahn et al., 2007) i atraktivnost (npr. Van der Heijden, 2003) značajno doprinose lakoći korištenja web mjestom. S druge strane, prethodna su istraživanja

potvrdila da lakoća korištenja ima značajan utjecaj na korisnost i stav prema korištenju (npr. Moon i Kim, 2001), namjeru korištenja i razigranost (npr. Ahn et al., 2007), užitak (npr. Van Schaik i Ling, 2011), itd. Uzimajući u obzir sve navedeno, lakoća korištenja Web 2.0 aplikacijama se može vrjednovati pomoću sljedećih pet čestica:

LAK1. Lako je izvršavati zadatke pomoću Web 2.0 aplikacije.
LAK2. Web 2.0 aplikacija je jednostavna za upotrebu.
LAK3. Jednostavno je raditi sa Web 2.0 aplikacijom.
LAK4. Jednostavno je upravljati kreiranim artefaktima.
LAK5. Da bi se izvršio zadatak pomoću Web 2.0 aplikacije, nije potrebno konzultirati sadržaje pomoći.

3.3.13 Lakoća učenja korištenja

Premda poimanje lakoće učenja korištenja (eng. learnability) ovisi o vrsti programskog proizvoda koji se vrjednuje kao i specifičnostima zadataka koji se njegovom primjenom izvršavaju (Lew et al., 2010), istraživači su prilikom definiranja ovog koncepta stavljali naglasak na karakteristike grupe kojoj korisnik pripada te količinu vremena potrebnu za učenje. Brzina sa kojom će pojedinci naučiti koristiti se programskim proizvodom ovisi o tome da li isti pripadaju skupini početnih ili naprednih korisnika ukoliko se u obzir uzme razina njihovog predznanja u interakciji sa računalima, razina njihovog iskustva u korištenju sučeljem, kvaliteta njihovog poznavanja domene te iskustvo u upotrebi sličnih programskih proizvoda (Grossman et al., 2009). Prema Shackelu (1991), lakoća učenja korištenja služi mjerenju količine vremena koja je korisnicima početnicima potrebna da uz trening i podršku nauče koristiti se sustavom kao i količine vremena koja je povremenim korisnicima potrebna da nauče koristiti se sustavom svaki put kad ga upotrebljavaju. Svaki sustav treba pomoću materijala pomoći (npr. tutorijali, upute za upotrebu pojedinih funkcionalnosti i sl.) te dosljednih i predvidljivih elemenata sučelja pomoći korisnicima početnicima da što lakše postanu vješti u interakciji sa sustavom, a istovremeno potaknuti iskusne korisnike na istraživanje primjene preostalih funkcionalnosti sučelja (Quesenbery, 2001). Preece (2001) napominje da ovaj atribut upotrebljivosti značajno doprinosi uspjehu online zajednice dok Liu i Arnett (2000) navode da je lakoća učenja korištenja direktno povezana sa zadovoljstvom korisnika.

Lakoću učenja korištenja je moguće vrjednovati objektivno i subjektivno. Ukoliko se objektivne metrike sagledaju sa aspekta količine vremena potrebnog za učenje, iste je moguće svrstati u skupinu početnog ili produženog učenja (Grossman et al., 2009). Početno učenje se odnosi na mjerenje količine vremena potrebnog za stjecanje vještine korištenja programskim proizvodom.

U ovu skupinu se ubrajaju metrike kao što su lakoća učenja korištenja funkcionalnosti sučelja ili lakoća učenja izvršavanja zadataka (ISO/IEC, 2003a). Metrikama produženog učenja se mjeri stupanj promjene u produktivnosti korisnika kroz vrijeme. Prema Lew et al. (2009), ovoj skupini pripadaju objektivne metrike poput brzine učenja (povećanje razine iskustva u korištenju programskim proizvodom treba rezultirati smanjenjem količine vremena potrebnog za dovršetak istovjetnog zadatka) te odstupanje u količini vremena potrebnog za dovršetak (niska razina standardne devijacije između skupina korisnika implicira da korisnici početnici mogu podjednako brzo naučiti koristiti se programskim proizvodom kao i napredni korisnici što je indikator da je lakoća učenja korištenja programskim proizvodom na visokoj razini). Aspekti ovog atributa su dosad subjektivno vrjednovani primjenom upitnika kao što su WAMMI (kratica za eng. Website Analysis and MeasureMent Inventory; Kirakowski et al., 1998), SUS (kratica za eng. System Usability Scale; Brooke, 1996) i PUTQ (kratica za eng. Purdue Usability Testing Questionnaire; Lin et al., 1997). Lakoća učenja korištenja Web 2.0 aplikacijama će biti vrjednovana pomoću sljedeće tri čestice:

LUK1. Jednostavno je postati vješt/a u korištenju Web 2.0 aplikacijom.
LUK2. Lako je naučiti izvršavati zadatke pomoću Web 2.0 aplikacije.
LUK3. Funkcionalnosti sučelja Web 2.0 aplikacije moguće je brzo naučiti upotrebljavati.

3.3.14 Lojalnost

Ključni čimbenik uspjeha web mjesta su lojalni korisnici (Reichheld i Schefter, 2000; Orehovački, 2010). Obzirom da se u literaturi uz koncept lojalnosti (eng. loyalty) korisnika vežu brojni alternativni nazivi kao što su ponašajna namjera (eng. behavioral intention) i namjera nastavljanja (eng. continuance intention), isti je moguće sagledati sa aspekta teorije razložne akcije, teorije planiranog ponašanja, modela prihvaćanja tehnologije, opće teorije prihvaćanja i korištenja tehnologijom i teorije potvrđivanja očekivanja. Prema teoriji razložne akcije (eng. Theory of Reasoned Action, TRA; Fishbein i Ajzen, 1975; Ajzen i Fishbein, 1980) na ponašajnu namjeru utječu stav prema ponašanju (eng. attitude towards behavior) i subjektivna norma (eng. subjective norm). Ponašajna namjera je intenzitet namjere prema provedbi ponašanja (Fishbein i Ajzen, 1975, str. 288). Što je intenzitet namjere jači, veća je vjerojatnost da će doći do provedbe ponašanja. Teorija planiranog ponašanja (eng. Theory of Planned Behavior, TPB) polazi od pretpostavke da donošenje odluke vezane uz realizaciju ponašanja ne ovisi samo o ponašajnim uvjerenjima i očekivanjima značajnih drugih osoba, već i kontroli nad ponašanjem (Ajzen, 1985; Ajzen, 1991). Relativna važnost navedenih konstrukata ovisi i razlikuje se ovisno o kontekstu ponašanja. Zamijećena ponašajna kontrola (eng. perceived behavior control) je mjera

do koje pojedinac smatra da će provedba određenog ponašanja biti jednostavna odnosno teška (Ajzen, 1991). Njen intenzitet ovisi o kontrolnim uvjerenjima odnosno količini resursa i mogućnosti sa kojima pojedinac smatra da raspolaže, kao i očekivanim preprekama u provedbi ponašanja. Prema glavnoj pretpostavci teorije planiranog ponašanja (Ajzen, 1985; Ajzen, 1991), zamijećena ponašajna kontrola i ponašajna namjera su prediktori stvarnog ponašanja. Kao opravdanje za modeliranje takvih odnosa, Ajzen (1991) navodi dva razloga: prvi je vezan uz činjenicu da zamijećena ponašajna kontrola povećava uspješnost provedbe ponašanja, a drugi što se ovisno o točnosti percepcije ista može upotrijebiti kao zamjena za mjeru stvarne kontrole.

Prema jednoj od temeljnih pretpostavki modela prihvaćanja tehnologije (eng. Technology Acceptance Model, TAM; Davis, 1989; Davis et al., 1989) zamijećena lakoća korištenja i zamijećena korisnost imaju pozitivan utjecaj na formiranje stavova vezanih uz korištenje što se dalje reflektira na namjeru korištenja i stvarno korištenje sustavom. Razlog modeliranog direktnog utjecaja zamijećene korisnosti na ponašajnu namjeru temeljen je na činjenici da ljudi imaju tendenciju koristiti se sustavom ukoliko smatraju da će takvo ponašanje unaprijediti njihov radni učinak. Rezultati istraživanja koje su proveli Venkatesh i Davis (2000) te Venkatesh i Bala (2008) impliciraju da spomenuti prediktori objašnjavaju između 34% i 53% varijance u ponašajnoj namjeri korištenja. Premda su istraživači dominantno upotrebljavali TAM model kako bi objasnili prihvaćanje specifične tehnologije, isti je dosad primjenjivan i u proučavanju ponašanja korisnika nakon što su oni prihvatili tehnologiju odnosno istraživanju njihove namjere nastavljanja korištenja (Gefen et al., 2003; Karahanna et al., 1999; Taylor & Todd, 1995a).

Prema općoj teoriji prihvaćanja i korištenja tehnologijom (eng. Unified Theory of Acceptance and Use of Technology, UTAUT, Venkatesh et al., 2003), temeljni prediktori ponašajne namjere odnosno korištenja sustavom su očekivani radni učinak, očekivani napor, utjecaj društva i olakšavajući uvjeti. Pored spomenutih prediktora, u model su uvrštena i četiri moderatora: dob, spol, iskustvo i dobrovoljnost korištenja. Rezultati istraživanja su pokazali da spomenuti prediktori objašnjavaju 70% varijance u ponašajnoj namjeri (Venkatesh et al., 2003). Naposljetku, prema teoriji potvrđivanja očekivanja (Oliver, 1980), zadovoljstvo korisnika je temeljna odrednica ponašajne namjere odnosno nastavljanja korištenja.

Spomenute su teorije potakle istraživače na oblikovanje modela koji će objasniti ponašanje korisnika vezano uz nastavak korištenja tehnologijom. Tako je Bhattacherjee (2001b) razvio model nastavljanja korištenja informacijskim sustavom (eng. Post-Acceptance Model of Information System Continuance) prema kojem namjeru nastavljanja korištenja objašnjavaju zadovoljstvo korisnika i zamijećena korisnost. Liao et al. (2009) su oblikovali teoriju nastavljanja

korištenja (eng. Technology Continuance Theory, TCT) u kojoj ulogu prediktora nastavljanja korištenja imaju stav, zadovoljstvo i zamijećena korisnost. Prema Barnesu (2011), namjera nastavljanja korištenja virtualnih svjetova ovisi o pragmatičnim atributima prihvaćanja poput zamijećene korisnosti te hedonističkim atributima prihvaćanja kao što su navika i užitak. U kontekstu Web 2.0 aplikacija, lojalnost korisnika se može vrjednovati pomoću sljedećih pet čestica:

LOJ1. Web 2.0 aplikaciju namjeravam nastaviti upotrebljavati.
LOJ2. Svakome bih preporučio/preporučila ovu Web 2.0 aplikaciju.
LOJ3. Web 2.0 aplikaciju ubuduće planiram često upotrebljavati.
LOJ4. Web 2.0 aplikaciju namjeravam redovito upotrebljavati.
LOJ5. Web 2.0 aplikaciju namjeravam upotrebljavati u slobodno vrijeme.

3.3.15 Minimalna aktivnost

Prema Seffah et al. (2006), minimalna aktivnost (eng. minimal activity) je mjera do koje korisnik upotrebom programskog proizvoda može izvršiti zadatak u minimalnom broju koraka. Minimalna aktivnost korisnika tijekom izvršavanja zadataka značajno doprinosi povećanju njegove učinkovitosti i zadovoljstva (Lin et al., 1997). Orehovački et al. (2012a, 2013) su definirali minimalnu aktivnost kao količinu fizičke aktivnosti potrebne za dovršetak određenog zadatka. Shodno tome se ovaj atribut može još nazvati i fizički napor (eng. physical effort) odnosno ručni napor (eng. manual effort).

Prema Mueller et al. (2008), ručni napor predstavlja ponderiranu sumu broja klikova mišem, broja pritisnutih tipaka na tipkovnici i broja piksela na razini miša koje korisnik prijeđe kada pomiče miš od točke (x_0, y_0) do točke (x_1, y_1). Prema istim je autorima ovu objektivnu metriku moguće sagledati sa dinamičkog i statičkog aspekta. Promatrajući ručni napor sa dinamičkog aspekta, isti upotrebljava kontinuirane funkcije koje su kvantizirane pretvaranjem integrala u sume. Ukoliko zadatak započinje u vremenskoj jedinici t_0 tada se dinamički ručni napor u vremenskoj jedinici t izračunava na sljedeći način (Mueller et al., 2008):

$$E(t) = \frac{1}{t - t_0} \int_{t_0}^{t} \big(w_1 \times pik(t) + w_2 \times klk(t) + w_3 \times tpk(t) + w_4 \times p(t)\big) dt \tag{3.1}$$

gdje $pik(t)$, $klk(t)$ i $tpk(t)$ predstavljaju broj piksela, broj klikova mišem i broj pritisnutih tipaka na tipkovnici u vremenskom intervalu $t - t_0$, respektivno. Pored toga, $p(t)$ je penal koji

označava broj izmjena rada sa tipkovnicom i mišem u spomenutom vremenskom intervalu. Iz navedenog je evidentno da $E(t)$ predstavlja monotono rastuću funkciju (Mueller et al., 2008).

Ukoliko se ručni napor promotri sa statičkog aspekta, tada isti predstavlja količinu napora koja je akumulirana u jedinici vremena kada je zadatak dovršen zbog čega je, prema Mueller et al. (2008), moguće ignorirati oblik krivulje $E(t)$. Pod pretpostavkom da su vremena početka jednaka za sve objektivne metrike, statički ručni napor u vremenskoj jedinici dovršetka zadatka t_c izračunava na sljedeći način (Mueller et al., 2008):

$$E(t) = \frac{1}{t_c - t_0}\left(w_1 \times pik(t) + w_2 \times klk(t) + w_3 \times tpk(t) + w_4 \times p(t)\right) \tag{3.2}$$

Nadovezujući se na njihov rad, Orehovački et al. (2012a, 2013) su definirali sljedećih pet objektivnih metrika namijenjenih mjerenju aktivnosti korisnika odnosno njihovog fizičkog napora tijekom izvršavanja zadataka: udaljenost, broj klikova mišem, broj duplih klikova mišem, broj pomicanja klizača na mišu i broj pritisnutih tipaka na tipkovnici. Udaljenost je izražena količinom milimetara koje korisnici prijeđu kada pomiču miš tijekom izvršavanja zadatka. Broj klikova mišem predstavlja sumu klikova lijevom, desnom i srednjom tipkom na mišu koje korisnici naprave za vrijeme izvršavanja zadatka. Broj duplih klikova mišem predstavlja sumu duplih klikova lijevom tipkom miša tijekom izvršavanja zadatka. Broj pomicanja klizača na mišu je ukupan broj pomicanja klizača potreban za dovršetak zadatka. Broj pritisnutih tipaka na tipkovnici je ukupan broj svih tipaka na tipkovnici koje je korisnik pritisnuo tijekom izvršavanja zadatka. Isti su autori dokazali da je primjenom spomenutih metrika moguće utvrditi značajne razlike među vrjednovanim Web 2.0 aplikacijama. Pored objektivnih metrika, minimalnu aktivnost je moguće vrjednovati i subjektivno. Primjerice, korisnici mogu preko skale koju su razvili Hart i Staveland (1988) naznačiti u kolikoj je mjeri zadatak bio fizički zahtjevan. Pored toga, PUTQ (kratica za eng. Purdue Usability Testing Questionnaire; Lin et al., 1997) upitnik sadrži trinaest čestica pomoću kojih je moguće utvrditi broj koraka potrebnih za dovršavanje zadatka. Kako bi se omogućilo subjektivno i objektivno vrjednovanje fizičkog napora korisnika tijekom interakcije sa Web 2.0 aplikacijama, oblikovano je sljedećih šest čestica i četiri indikatora, respektivno:

MAK1. Korištenje Web 2.0 aplikacijom ne iziskuje mnogo motoričkih aktivnosti pomoću tipkovnice i miša.
MAK2. Izvršavanje zadataka pomoću Web 2.0 aplikacije ne iziskuje mnogo korištenja mišem.
MAK3. Izvršavanje zadataka pomoću Web 2.0 aplikacije ne iziskuje mnogo korištenja tipkovnicom.

MAK4. Tijekom korištenja Web 2.0 aplikacijom, nije potrebno često izmjenjivati rad sa tipkovnicom i mišem.
MAK5. Nakon korištenja Web 2.0 aplikacijom, korisnik ne osjeća umor u očima.
MAK6. Nakon izvršavanja zadataka pomoću Web 2.0 aplikacije, korisnik ne osjeća umor u prstima, zglobovima i mišićima ruku.
MAK7. Broj pritisnutih tipaka na tipkovnici.
MAK8. Broj klikova mišem.
MAK9. Broj pomicanja klizača na mišu.
MAK10. Udaljenost prijeđena pomicanjem miša.

3.3.16 Minimalno opterećenje memorije

Orehovački et al. (2012a, 2013) su definirali minimalno opterećenje memorije (eng. minimal memory load) odnosno mentalni napor (eng. mental effort) kao količinu mentalnih i perceptivnih aktivnosti potrebnih za dovršetak zadatka. Prema Seffah et al. (2006), minimalno opterećenje memorije je atribut kojim se mjeri količina informacija koju korisnik treba zapamtiti kako bi izvršio određeni zadatak. Lin et al. (1997) naglašava da minimalno opterećenje memorije ima značajan utjecaj na povećanje radnog učinka korisnika te na smanjenje količine vremena koje je korisnicima potrebno da se nauče koristiti programskim proizvodom. Opterećenje memorije korisnika je moguće svesti na minimalnu mjeru dobrom organizacijom elemenata sučelja i kvalitetnim navigacijskim mehanizmima (Nielsen, 1993).

Razinu opterećenja memorije korisnika za vrijeme izvršavanja zadataka moguće je izmjeriti objektivno i subjektivno. Objektivno mjerenje se najčešće provodi primjenom metode praćenja očiju (eng. eye tracking). U tom su kontekstu Mueller et al. (2008) predložili sljedeće tri objektivne metrike: prosječno trajanje fiksacije (eng. average fixation duration) izraženo u milisekundama, prosječan promjer zjenica (eng. average pupil diameter) izražen u milimetrima i prosječna amplituda trzaja oka (eng. average saccade amplitude) izražena u stupnjevima. Mentalni napor također upotrebljava kontinuirane funkcije koje su kvantizirane pretvaranjem integrala u sume. Ukoliko zadatak započinje u vremenskoj jedinici t_0, količina mentalnog napora u vremenskoj jedinici t se izračunava na sljedeći način (Mueller et al., 2008):

$$E(t) = \frac{1}{t - t_0} \int_{t_0}^{t} \left(w_1 \times ptf(t) + w_2 \times ppz(t) + w_3 \times \frac{1}{pato(t)} \right) dt \tag{3.3}$$

gdje je $ptf(t)$ prosječno trajanje fiksacije, $ppz(t)$ označava prosječan promjer zjenica dok $pato(t)$ predstavlja prosječnu amplitudu trzaja oka u vremenskom intervalu $t - t_0$. Subjektivno vrjednovanje opterećenja memorije korisnika se sastoji od primjene upitnika. Primjerice, upotrebom instrumenta NASA-TLX (kratica za eng. NASA Task Load Index; Hart i Staveland, 1988) korisnici mogu preko bipolarne skale od dvadeset stupnjeva odrediti razinu do koje su tijekom izvršavanja zadataka poduzimali pojedine mentalne i perceptivne aktivnosti (npr. razmišljanje, odlučivanje, pamćenje, pregledavanje, pretraživanje i slično). Nadalje, SWAT (kratica za eng. Subjective Workload Assessment Technique; Reid i Nygren, 1988) tehnika omogućava korisnicima da preko skale od tri stupnja (vrlo malo, umjereno i opsežno) odrede razinu opterećenja memorije u pogledu količine koncentracije potrebne za dovršetak zadatka. Naposljetku, upitnik PUTQ (kratica za eng. Purdue Usability Testing Questionnaire; Lin et al., 1997) sadrži petnaest čestica pomoću kojih je moguće utvrditi mjeru do koje je tijekom izvršavanja zadataka potrebno poduzimati aktivnosti koje opterećuju memoriju korisnika. Potrebno je napomenuti da su pojedini istraživači čestice namijenjene subjektivnom mjerenju opterećenja memorije upotrebljavali u svrhu vrjednovanja zamijećene lakoće korištenja (npr. Moon i Kim, 2001; Ahn et al., 2007; Venkatesh i Bala, 2008) ili lakoće učenja korištenja (npr. Zhang i Von Dran, 2000). Uzimajući u obzir sve navedeno, razinu opterećenja memorije tijekom i nakon interakcije sa Web 2.0 aplikacijom moguće je utvrditi pomoću sljedećih šest čestica:

MOM1. Korištenje Web 2.0 aplikacijom ne zahtijeva puno mentalnih i perceptivnih aktivnosti.
MOM2. Korištenje Web 2.0 aplikacijom ne zahtijeva puno razmišljanja i odlučivanja.
MOM3. Korištenje Web 2.0 aplikacijom ne zahtijeva puno pamćenja.
MOM4. Korištenje Web 2.0 aplikacijom ne zahtijeva puno pregledavanja i pretraživanja.
MOM5. Korisnik se nakon korištenja Web 2.0 aplikacijom ne osjeća iscrpljeno.
MOM6. Korisnik se nakon korištenja Web 2.0 aplikacijom osjeća opušteno.

3.3.17 Mogućnost komunikacije

U današnje je vrijeme Web najčešće korišten medij za komunikaciju među ljudima (De Sarkar, 2012). Razlog tome je što postoji veliki broj različitih Web 2.0 aplikacija koje su specijalizirane za komunikaciju ili su u njih implementirani mehanizmi koji podržavaju i olakšavaju komunikaciju (Orehovački et al., 2012b). Postoje dva osnovna oblika komunikacije putem web mjesta: sinkrona i asinkrona. Sinkrona komunikacija predstavlja interakciju u stvarnom vremenu što implicira da korisnike dijeli lokacija na kojoj se nalaze dok se razmjena poruka odvija bez vremenskog odmaka. Web 2.0 aplikacije koje podržavaju sinkronu komunikaciju uglavnom imaju integrirane module za istovremeno slanje poruka odnosno čavrljanje te

raspolažu funkcionalnostima za audio ili video konferenciju. Asinkrona komunikacija je interakcija sa vremenskim odmakom što znači da korisnike pored lokacije na kojoj se isti nalaze dijeli i vremensko razdoblje u kojem sastavljaju i šalju poruke. Osim foruma i poruka elektroničke pošte koji predstavljaju naslijeđe prethodnih razvojnih faza Weba, drugu generaciju web aplikacija karakteriziraju novi oblici asinkrone komunikacije poput slanja internih poruka, ostavljanja komentara te 'lajkanja' objavljenih sadržaja. Osim toga, društvene mreže se ubrajaju u skupinu Web 2.0 aplikacija kojima je funkcionalnost sinkrone komunikacije između korisnika jedno od glavnih obilježja (Orehovački et al., 2012b).

Kao jednu od temeljnih odrednica vrjednovanja kvalitete Web 2.0 aplikacija Pang et al. (2010) navode intimnost odnosno mjeru do koje korisnici kroz aktivnu komunikaciju stvaraju bliske odnose sa ostalim korisnicima Web 2.0 aplikacije. Istraživači su dosad dimenzije ovog atributa vrjednovali sa aspekta interaktivnosti (npr. Palmer, 2002b; Oztekin et al., 2010), atraktivnosti sučelja za komunikaciju (npr. Hong i Kim, 2004) te samoizražavanja i reciprociteta (Väänänen-Vainio-Mattila et al., 2010). Kako bi se utvrdila razina do koje Web 2.0 aplikacija podržava komunikaciju (eng. communicativity) između svojih korisnika, oblikovane su sljedeće četiri čestice:

MKM1. Web 2.0 aplikacija sadrži funkcionalnost sinkrone komunikacije sa ostalim korisnicima.
MKM2. Web 2.0 aplikacija sadrži funkcionalnost asinkrone komunikacije sa ostalim korisnicima.
MKM3. Web 2.0 aplikacija omogućava komunikaciju među korisnicima.
MKM4. Web 2.0 aplikacija omogućava razmjenu znanja i iskustva među korisnicima.

3.3.18 Mogućnost kontrole

U međunarodnom standardu ISO 9241-110 (2006), mogućnost kontrole (eng. controllability) je uvrštena među sedam temeljnih heuristika namijenjenih dizajnu i vrjednovanju interakcije čovjeka i računala. Prema spomenutom standardu, korisniku treba biti omogućeno da pokrene i kontrolira smjer i tempo interakcije sa sustavom sve do ostvarenja svog cilja. Iz navedenog proizlazi da web mjesto ne smije ni na koji način određivati kako će ga korisnik upotrebljavati već treba raspolagati mehanizmima koji će korisniku olakšati kontrolu nad pokretanjem, zaustavljanjem, nastavljanjem i poništavanjem dijaloga. Dix et al. (2004) navode da kontrolu nad interakcijom treba preuzeti sustav jedino u slučajevima kada korisnik želi poduzeti destruktivne aktivnosti. U modelu kojeg su oblikovali Seffah et al. (2006) ovaj atribut predstavlja mjeru do koje korisnik ima osjećaj da je programski proizvod pod njegovom kontrolom. Dosad je mogućnost kontrole vrjednovana pomoću dvije čestice u sklopu upitnika pod nazivom WAMMI (kratica za eng. Web Analysis and MeasureMent Inventory) kojeg su oblikovali Kirakowski et al.

(1998). U kontekstu Web 2.0 aplikacija mogućnost kontrole će se vrjednovati pomoću sljedeće tri čestice:

MOK1. Jednostavno je postići da Web 2.0 aplikacija radi što korisnik želi.
MOK2. Redoslijed upotrebe funkcionalnosti sučelja Web 2.0 aplikacije u potpunosti ovisi o korisniku.
MOK3. Korisnik ima potpunu slobodu u izvršavanju zadataka pomoću Web 2.0 aplikacije.

3.3.19 Mogućnost oporavka

Dix et al. (2004) su definirali mogućnost oporavka (eng. recoverability) kao potkarakteristiku robusnosti programskog proizvoda primjenom koje se mjeri razina do koje korisnik može poduzeti korektivne akcije kako bi poništio postupak koji je doveo do nepoželjnog stanja. Natt (2004) navodi dvije vrste oporavka web mjesta: oporavak prema naprijed i oporavak prema natrag. Oporavak prema naprijed (eng. forward recoverability) je usmjeren na popravljanje nastalih pogrješaka dok se oporavak prema natrag (eng. backward recoverability) bavi poništavanjem pogrješaka odnosno vraćanjem u prethodno stanje (Natt, 2004).

Dimenzije ovog atributa je moguće vrjednovati objektivno i subjektivno. Objektivne metrike eksterne kvalitete koje su predložene standardom ISO/IEC 9126-2 (2003a) služe mjerenju prosječnog vremena u kojem programski proizvod nije bio dostupan zbog pogrješke ili prekida u radu (izvorno eng. mean down time), prosječnog vremena koje je programskom proizvodu potrebno da se oporavi od pogrješke ili prekida u radu (izvorno eng. mean recovery time) i količine vremena koje je programskom proizvodu potrebno da se ponovno pokrene nakon oporavka (izvorno eng. restartability). Preostale tri metrike koje se nalaze u spomenutom standardu (ISO/IEC, 2003a) su namijenjene utvrđivanju razine dostupnosti programskog proizvoda u određenom vremenskom razdoblju (eng. availability), stupnja do kojeg se programski proizvod može vratiti u prethodno stanje (eng. restorability) te razine djelotvornosti vraćanja u prethodno stanje (eng. restore effectiveness). Nasuprot navedenom, razinu zamijećene mogućnosti oporavka programskog proizvoda moguće je vrjednovati upitnicima kao što su PSUQ (kratica za eng. The Post-Study System Usability Questionnaire Items; Lewis, 2002) ili USE (kratica za eng. Usefulness, Satisfaction, and Ease of Use; Lund, 2001). Pored toga, Hashim i Sultan (2009) su vrjednovali mogućnost oporavka sa aspekta učinkovitosti, a Poelmans et al. (2008) u kontekstu kvalitete sustava. Međutim, potrebno je naglasiti da su ovaj atribut navedeni autori vrjednovali pomoću samo jedne čestice. Zbog toga su za potrebe vrjednovanja mogućnosti oporavka Web 2.0 aplikacija oblikovane sljedeće četiri čestice:

MOP1. Ukoliko tijekom korištenja Web 2.0 aplikacijom dođe do pogrješke ili prekida u radu, nakon ponovnog učitavanja, ista će prikazati oporavljenu verziju artefakta.
MOP2. Ukoliko tijekom izvršavanja zadataka dođe do pogrješke ili prekida u radu Web 2.0 aplikacije, ne izgubi se sav posao koji se do tada napravio.
MOP3. Ukoliko tijekom korištenja Web 2.0 aplikacijom dođe do pogrješke ili prekida u radu, potrebno je ugasiti web preglednik i ponovno učitati Web 2.0 aplikaciju.
MOP4. Web 2.0 aplikacija se može brzo oporaviti od pogrješke ili prekida u radu.

3.3.20 Mogućnost pretraživanja

Atribut pomoću kojeg se utvrđuje do koje mjere mehanizam internog pretraživanja prikazuje točne i relevantne rezultate nosi naziv mogućnost pretraživanja (eng. searchability, search capability; Pang et al., 2010). Brojni autori (Abels et al., 1999; Flanders i Peters, 2002; Johnson, 2003, Krug, 2005; Lynch i Horton, 2008; Nielsen, 2000) navode da implementacija mehanizama pretraživanja predstavlja vrlo važan koncept dizajna web mjesta. Cappel i Huang (2007) smatraju da će korisnici kojima je interno pretraživanje preferirani oblik navigacije zasigurno prestati upotrebljavati web mjesto ukoliko isto ne sadrži funkcionalnost internog pretraživanja. Iz navedenog proizlazi da integracija mehanizama pretraživanja doprinosi upotrebljivosti (Schlosser, 2003) i kvaliteti (Madu i Madu, 2002) web mjesta. Dimenzije ovog atributa su dosad pretežno vrjednovane subjektivno primjenom upitnika (npr. Aladwani i Palvia, 2002; Chiu et al., 2009; Shneiderman, 1998). Pored navedenog, González et al. (2009) su za potrebe vrjednovanja aspekata ovog atributa razvili tri heuristike pomoću kojih se provjerava da li početna stranica sadrži tekstualni okvir za interno pretraživanje, da li je pokraj tekstualnog okvira jasno naznačeno da se radi o internoj tražilici te da li je u tekstualni okvir moguće upisati između 25 i 30 vidljivih znakova koji predstavljaju upit pretraživanja. Kako bi se utvrdila razina do koje Web 2.0 aplikacije podržavaju interno pretraživanje, oblikovano je sljedećih pet čestica:

MPT1. Interna tražilica nudi različite mogućnosti pretraživanja kreiranih artefakata.
MPT2. Rezultati pretraživanja interne tražilice su točni i precizni.
MPT3. Rezultati pretraživanja interne tražilice su relevantni.
MPT4. Interna tražilica je učinkovita.
MPT5. Za svaki uneseni upit, interna tražilica automatski generira rezultate pretraživanja.

3.3.21 Mogućnost prilagodbe

Prema Dix et al. (2004), mogućnost prilagodbe (eng. customizability) predstavlja mjeru do koje sustav omogućava personalizaciju elemenata sučelja te podržava njihovu automatsku prilagodbu karakteristikama korisnika ili specifičnostima zadatka. U modelu Quint2 koji predstavlja prilagodbu standarda ISO/IEC 9126 (1991) kontekstu Weba, Paulussen et al. (1996) su definirali mogućnost prilagodbe kao atribut upotrebljivosti pomoću kojeg se utvrđuje da li web programski proizvod raspolaže sa funkcionalnostima koje korisniku omogućuju njegovu prilagodbu kako bi se smanjio napor potreban za njegovu upotrebu te povećalo zadovoljstvo korisnika. Seffah et al. (2006) su ovaj atribut uvrstili u svoj model upotrebljivosti pod nazivom fleksibilnost (eng. flexibility) te ga definirali kao razinu do koje je sučelje programskog proizvoda moguće prilagoditi željama i potrebama korisnika. Alonso-Ríos et al. (2010) su ga pod jednakim nazivom pridružili atributu operabilnost i proširili njegovu definiciju tako da isti osim aspekata mogućnosti prilagodbe mjeri i dimenzije mogućnosti kontrole. Prema Pang et al. (2010), mogućnost prilagodbe predstavlja relevantnu dimenziju kvalitete usluge Web 2.0 aplikacije. Alben (1996) navodi da razina do koje je programski proizvod moguće prilagoditi specifičnim potrebama pojedinaca i grupe utječe na kvalitetu korisničkog iskustva. Kako bi se utvrdilo da li Web 2.0 aplikacija raspolaže sa funkcionalnostima prilagodbe elemenata sučelja, definirano je sljedećih jedanaest čestica:

MPR1. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe radnog prostora.
MPR2. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe jezika prikaza.
MPR3. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe prikaza formata datuma i vremena.
MPR4. Web 2.0 aplikacija sadrži funkcionalnosti koje omogućuju personalizaciju elemenata sučelja.
MPR5. Web 2.0 aplikaciju je moguće prilagoditi željama i potrebama korisnika.
MPR6. Web 2.0 aplikaciju je moguće prilagoditi karakteristikama zadatka.
MPR7. Web 2.0 aplikaciju je moguće prilagoditi kulturnim i lokalnim specifičnostima korisnika.
MPR8. Radni prostor Web 2.0 aplikacije moguće je postaviti na puni ekran.
MPR9. Web 2.0 aplikacija sadrži funkcionalnost organizacije zasebnih zadataka u kartice.
MPR10. Na sučelju Web 2.0 aplikacije postoji funkcionalnost kojom je moguće odrediti količinu detalja koji se prikazuju za pojedini artefakt.
MPR11. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe načina prikazivanja kreiranih artefakata.

3.3.22 Mogućnost suradnje

Ključan čimbenik uspjeha u web okruženju jest implementacija funkcionalnosti koje omogućuju suradnju (eng. collaborativity) među korisnicima (Kamel Boulos i Wheeler, 2007). Postoje dva oblika suradnje: kooperacija i kolaboracija. Dok je kooperacija hijerarhijski proces raspodjele posla u kojem svaki pojedinac zasebno djeluje te je odgovoran za aktivnosti koje provodi, kolaboracija predstavlja heterarhijski koordinirani skup aktivnosti tijekom kojih sudionici zajedničkim snagama rješavaju određeni problem (Roschelle i Teasley, 1995). Iz navedenog je evidentno da je kolaboracija jedno od temeljnih obilježja Web 2.0 aplikacija (Musser i O'Reilly, 2007). Suradnja kao i komunikacija može biti sinkrona i asinkrona. Pod sinkronom suradnjom se podrazumijeva istovremeni zajednički rad na određenom artefaktu. U skupinu Web 2.0 aplikacija koje podržavaju sinkronu suradnju se ubrajaju aplikacije za uređivanje teksta, izradu mentalnih mapa, izradu dijagrama i slično. Asinkrona suradnja predstavlja zajednički rad na određenom artefaktu gdje sudionici provode aktivnosti sa odmakom vremena. Jedinstveni primjer asinkrone suradnje jest uređivanje wiki stranice. Obzirom da aspekti ovog atributa dosad nisu vrjednovani u kontekstu kvalitete u korištenju, za potrebe ovog doktorskog rada oblikovano je šest čestica pomoću kojih je moguće izmjeriti razinu do koje Web 2.0 aplikacija podržava suradnju između korisnika:

MSU1. Web 2.0 aplikacija sadrži funkcionalnost dodjele pristupa kreiranom artefaktu preko liste kontakata.
MSU2. Web 2.0 aplikacija sadrži funkcionalnost dodjele pristupa kreiranom artefaktu preko direktne poveznice.
MSU3. Web 2.0 aplikacija omogućava suradnju u izradi artefakata.
MSU4. Web 2.0 aplikacija podržava timski rad.
MSU5. Web 2.0 aplikacija podržava rad većeg broja korisnika na izradi artefakta.
MSU6. Web 2.0 aplikacija omogućava razmjenu artefakata među korisnicima.

3.3.23 Odupiranje promjenama

Prema Nov i Ye (2007), odupiranje promjenama (eng. resistance to changes) je kritični čimbenik prihvaćanja tehnologije iz razloga što se negativno odražava na zamijećenu lakoću korištenja. Venkatesh et al. (2000) navode da je odupiranje novim tehnologijama jedan od glavnih uzroka propadanja projekata implementacije informacijsko komunikacijske tehnologije. Jiang et al. (2000) smatraju da je koncept odupiranja promjenama moguće sagledati sa tri različite perspektive. Prema prvoj, ulogu uzroka odupiranja promjenama imaju različite karakteristike

korisnika poput dobi, spola, vrijednosti i uvjerenja. Druga perspektiva se odnosi na specifičnosti programskog proizvoda kao što su dizajn sučelja, radni učinak, pouzdanost, upotrebljivost i slično. Posljednja perspektiva se odnosi na posljedice interakcije između korisnika i programskog proizvoda poput primjerice gubitka kontrole, ovlasti ili statusa u društvu. Oreg (2003) je razvio skalu od 17 čestica koja omogućuje vrjednovanje koncepta odupiranja promjenama sa aspekta preferiranja rutine nad promjenama, negativnih emocionalnih reakcija (npr. stres) na promjene, tolerantnosti na vremensko razdoblje prilagodbe na promjenu te kognitivne krutosti odnosno fleksibilnosti u promjeni stavova. Kako bi se utvrdila razina do koje su korisnici spremni prihvatiti promjene u kontekstu web tehnologija u koje se ubrajaju i Web 2.0 aplikacije, oblikovane su sljedeće četiri čestice:

ODP1. Zainteresiran/a sam za nove web tehnologije.
ODP2. Volim čitati, gledati i slušati o novim web tehnologijama.
ODP3. Volim isprobati nove web tehnologije.
ODP4. Sklon/a sam promijeniti aplikacije koje koristim za svakodnevne online aktivnosti (web preglednik, mail klijent i sl.).

3.3.24 Pamtljivost

Alonso-Ríos et al. (2010) su svrstali pamtljivost (eng. memorability) u skupinu atributa namijenjenih vrjednovanju familijarnosti (izvorno eng. knowability) te je definirali kao svojstvo programskog proizvoda koje omogućava korisniku da zapamti njegove elemente, strukturu i funkcioniranje. Prema definicijama koje su ponudili Constantine i Lockwood (1999), Hix i Hartson (1993), Shneiderman (1998) te Wixon i Wilson (1997), pamtljivost predstavlja mjeru do koje je jednostavno prisjetiti se kako se programski proizvod upotrebljava. Nielsen (1993) napominje da način korištenja programskim proizvodom treba biti lako pamtljiv te time omogućiti korisniku da se i nakon duljeg vremena nekorištenja može lagano prisjetiti gdje se nalaze i kako se upotrebljavaju pojedine funkcionalnosti sučelja. Aspekti pamtljivosti su dosad uglavnom mjereni u sklopu atributa namijenjenih vrjednovanju lakoće učenja korištenja (npr. Lund, 2001; Zhang i Von Dran, 2000) ili lakoće korištenja (npr. Moon i Kim, 2001). Pamtljivost Web 2.0 aplikacija će se vrjednovati sa sljedeće tri čestice:

PMT1. Jednostavno je zapamtiti kako se upotrebljava Web 2.0 aplikacija.
PMT2. Lako je zapamtiti gdje se nalaze pojedine funkcionalnosti sučelja Web 2.0 aplikacije.
PMT3. Biti će jednostavno prisjetiti se gdje se nalaze i kako se upotrebljavaju funkcionalnosti sučelja, čak i ako se Web 2.0 aplikacija ne bude dulje vrijeme upotrebljavala.

3.3.25 Potpunost sadržaja

Orehovački et al. (2013) navode da potpunost sadržaja (eng. content coverage) predstavlja mjeru do koje je sadržaj cjelovit, pregledan i prikladno prikazan. Olsina et al. (2009) su definirali ovaj atribut kao razinu do koje su informacije koncizne, prikladne i dostatne za ostvarivanje ciljeva korisnika. Prema međunarodnom standardu namijenjenom vrjednovanju kvalitete podataka (ISO/IEC, 2008), potpunost sadržaja se odnosi na mjeru do koje svojstvena obilježja podataka pokrivaju sve instance entiteta kojeg predstavljaju u određenom kontekstu upotrebe. Ukoliko se ovaj atribut promotri sa aspekta mashupova, isti predstavlja sposobnost komponente da generira sve očekivane podatkovne vrijednosti (Cappiello et al., 2010). Wang i Strong (1996) su konceptualizirali ovaj atribut kao dostatnu dubinu, širinu i opseg podataka potrebnih za izvršavanje zadataka. Batini et al. (2009) su specificirali potpunost sadržaja kao stupanj do kojeg je podatkovna kolekcija sačinjena od podataka koji opisuju odgovarajući skup objekata iz stvarnog svijeta. Naposljetku, Pang et al. (2010) su definirali ovaj atribut kao razinu do kojeg web mjesto raspolaže sa širokim spektrom informacija koje su korisnicima relevantne za postizanje ciljeva i donošenje odluka.

Istraživanja su pokazala da je potpunost sadržaja moguće vrjednovati objektivnim metrikama kao što je omjer broja nepotpunih podatkovnih jedinica i ukupnog broja podatkovnih jedinica u skupu podataka (Helfert i Foley, 2009), omjer količine podataka koje komponenta generira i očekivane količine podataka koja će biti generirana (Cappiello et al., 2010) te omjer broja dostavljenih podataka i broja podataka za koje se očekivalo da će biti dostavljeni (Batini et al., 2009). Pored navedenog, pojedini su istraživači (npr. Ahn et al., 2007; Aladwani i Palvia, 2002; Lee et al., 2002; Muylle et al., 2004) dimenzije ovog atributa vrjednovali primjenom upitnika. Za potrebe vrjednovanja potpunosti sadržaja nastalog za vrijeme interakcije sa Web 2.0 aplikacijom, oblikovane su sljedeće četiri čestice:

PTS1. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je potpun.
PTS2. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je pregledan.
PTS3. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je prikladno prikazan.
PTS4. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je jezgrovit.

3.3.26 Pouzdanost

Pouzdanost (eng. reliability) se ubraja među najvažnije atribute kvalitete web aplikacije (Offutt, 2002). U međunarodnom standardu ISO/IEC 9126-1 (2001) pouzdanost je definirana kao karakteristika kvalitete programskog proizvoda kojom se vrjednuje njegova sposobnost da

zadrži određenu razinu funkcionalnosti kada se upotrebljava pod određenim uvjetima. Isti je standard dekomponirao pouzdanost na četiri potkarakteristike: zrelost (eng. maturity), toleranciju pogrješaka (eng. fault tolerance), mogućnost oporavka (recoverability) i udovoljavanje propisima vezanih uz pouzdanost (eng. reliability compliance). Deset godina kasnije, međunarodni standard ISO/IEC 25010 (2011a) je konceptualizirao pouzdanost kao mjeru do koje sustav, proizvod ili komponenta izvršava određenu funkcionalnost pod određenim uvjetima tijekom određenog vremenskog razdoblja. Pored toga, iz strukture ovog atributa je uklonjena potkarakteristika koja se odnosi na udovoljavanje propisima te je u istu uvrštena potkarakteristika pomoću koje se vrjednuju aspekti dostupnosti. Ukoliko se ovaj atribut promotri u kontekstu Weba, isti se odnosi na mjeru do koje web mjesto ispravno i dosljedno obavlja svoju funkcionalnost bez bilo kakvih pogrješaka ili prekida u radu (Lee i Kozar, 2006; Moraga et al., 2004; Pang et al., 2010).

U praksi se pouzdanost vrjednuje objektivnim i subjektivnim metrikama. Međutim, pouzdanost nije moguće izmjeriti direktno već se njeni aspekti vrjednuju objektivnim metrikama (ISO/IEC, 2003a, 2003b) koje su namijenjene mjerenju potkarakteristika od kojih je pouzdanost, prema standardu ISO/IEC 9126-1 (2001), sačinjena. Obzirom da su spomenute potkarakteristike pouzdanosti u kontekstu ovog doktorskog rada konceptualizirane kao zasebni atributi, objektivne metrike će za svaku od njih biti navedene u pripadajućem potpoglavlju. S druge strane, pouzdanost je dosad vrjednovana subjektivno sa aspekta kvalitete sustava (npr. Chen i Cheng, 2009; Webb i Webb, 2004) i robusnosti web mjesta (npr. Hong i Kim, 2004) te kao zaseban konstrukt (npr. De Wulf et al., 2006; Madsen i Gregor, 2000). Kako bi se utvrdila razina zamijećene pouzdanosti Web 2.0 aplikacija, oblikovano je sljedećih pet čestica:

PZD1. Tijekom korištenja Web 2.0 aplikacijom, nije dolazilo do prekida u radu.
PZD2. Tijekom izvršavanja zadataka pomoću Web 2.0 aplikacije, pogrješke se nisu javljale.
PZD3. Web 2.0 aplikacija je pouzdana.
PZD4. Web 2.0 aplikacija je stabilna.
PZD5. Web 2.0 aplikacija nema softverskih pogrješaka (bugova).

3.3.27 Povratne informacije

Prema prvoj od ukupno deset heuristika namijenjenih vrjednovanju upotrebljivosti dizajna korisničkog sustava koje je predložio Nielsen (1994), programski proizvod treba u redovitim vremenskim razdobljima putem prikladnih povratnih informacija (eng. feedback) obavještavati korisnika o promjenama u svom statusu i radu. Seffah et al. (2006) navode da se ovim atributom mjeri razina do koje programski proizvod suvislo reagira na postupke korisnika te im pruža

smislene povratne informacije kada dođe do pogrješke. Korisnici će biti uspješniji u izvršenju zadataka ukoliko temeljem povratnih informacija mogu procijeniti interno stanje programskog proizvoda (Dix et al., 2004). Rezultati istraživanja koje je provela Nah (2004) impliciraju da su korisnici spremni dulje čekati na odaziv web mjesta ukoliko isto prikazuje konstruktivne povratne informacije. Prema tome, ukoliko izvršavanje određene aktivnosti traje dulje nego što bi korisnici mogli očekivati, potrebno ih je o tome obavijestiti putem prikladne poruke ili indikatora napretka (Safavi, 2009).

Istraživači su dosad dimenzije ovog atributa u većini slučajeva vrjednovali pomoću jedne čestice sa aspekta učinkovitosti (npr. Hashim i Sultan, 2009), kvalitete sustava (npr. Poelmans et al., 2008) i upotrebljivosti (npr. Lewis, 1995; Lewis, 2002; Lin et al., 1997). Upotrebljivost povratnih informacija koje pružaju Web 2.0 aplikacije moguće je vrjednovati pomoću sljedećih osam čestica:

PIN1. Web 2.0 aplikacija obavještava korisnika kada će pojedina aktivnost biti izvršena.
PIN2. Nakon provedbe određene aktivnosti nad artefaktom (npr. pohrana), Web 2.0 aplikacija prikazuje prikladnu povratnu poruku.
PIN3. Poruke koje prikazuje Web 2.0 aplikacija su jasne.
PIN4. Poruke koje prikazuje Web 2.0 aplikacija su precizne.
PIN5. Poruke koje prikazuje Web 2.0 aplikacija su korisne.
PIN6. Ukoliko tijekom izvršavanja zadataka dođe do pogrješke ili prekida u radu, Web 2.0 aplikacija o tome pravovremeno obavještava korisnika.
PIN7. Web 2.0 aplikacija prikazuje status dovršenosti zadatka.
PIN8. Web 2.0 aplikacija nudi mogućnost kontaktiranja službe za korisnike.

3.3.28 Pravovremenost sadržaja

Atribut pomoću kojeg se mjeri razina do koje je životni vijek podataka prikladan za izvršavanje zadataka u određenom kontekstu upotrebe nosi naziv pravovremenost sadržaja (eng. content timeliness, currentness; Wang i Strong, 1996; ISO/IEC, 2008). Orehovački et al. (2013) naglašavaju da konceptualizacija i vrjednovanje ovog atributa ovisi o vrsti Web 2.0 aplikacije. U kontekstu Web 2.0 aplikacija namijenjenih prikazu ili dostavljanju sadržaja sa različitih izvora (kao što su primjerice mashupovi ili podcatcheri) ovaj atribut označava razinu do koje je sadržaj nov, aktualan i ažuran dok u slučaju Web 2.0 aplikacija koje služe kreiranju artefakata (poput aplikacija za kolaborativno uređivanje teksta ili izradu mentalnih mapa) pravovremenost sadržaja se odnosi na stupanj do kojeg je generirane artefakte moguće dopuniti, modificirati i

ažurirati (Orehovački et al., 2013). Pojedini su autori (npr. Cappiello et al., 2010; Olsina et al., 2009) specificirali ovaj atribut kao mjeru ažurnosti sadržaja.

Bovee et al. (2003) smatraju da je pravovremenost sadržaja dvodimenzionalan konstrukt koji se sastoji od aktualnosti odnosno mjere životnog vijeka (eng. age) podatka u pogledu datuma kada je kreiran ili posljednji put ažuriran te promjenjivosti (eng. volatility) koja odražava frekventnost promjene vrijednosti obilježja entiteta odnosno implicira prosječni vremenski period valjanosti podataka u određenom kontekstu upotrebe. Nadovezujući se na njihov rad, Cappiello et al., (2010) su predložili proporciju aktualnosti i promjenjivosti kao metriku za objektivno vrjednovanje pravovremenosti sadržaja. Za istu su namjenu u formi objektivne metrike Helfert i Foley (2009) predložili razliku između vremena kada je sadržaj trebao biti kreiran ili ažuriran te vremena kada sadržaj zapravo jest kreiran odnosno ažuriran. Pored toga, brojni su autori (npr. Abdinnour-Helm et al., 2005; Ahn et al., 2007; Aladwani i Palvia, 2002; Barnes i Vidgen, 2003; Chen i Cheng, 2009; De Wulf et al., 2006; Lee et al., 2002; McKinney et al., 2002; Oztekin et al., 2009) aspekte ovog atributa vrjednovali subjektivno primjenom upitnika. Uzimajući u obzir sve navedeno, pravovremenost sadržaja je u kontekstu Web 2.0 aplikacija namijenjenih kreiranju i upravljanju artefaktima moguće vrjednovati pomoću sljedeće tri čestice:

PVS1. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je moguće nadopuniti.
PVS2. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je moguće ažurirati.
PVS3. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je moguće mijenjati.

3.3.29 Pristupačnost

Atribut pomoću kojeg se utvrđuje do koje je mjere programski proizvod upotrebljiv ljudima sa širokim rasponom karakteristika i sposobnosti nosi naziv pristupačnost (eng. accessibility; ISO/IEC, 2011a; Seffah et al., 2006). Programski proizvodi trebaju biti pristupačni svim skupinama korisnika pri čemu je posebnu pozornost potrebno posvetiti ljudima oštećena vida i sluha te ljudima sa ostalim fizičkim i kognitivnim oštećenjima (Al-Badi i Mayhew, 2010; Alonso-Ríos et al., 2010; Becker i Berkemeyer, 2002). Iz navedenog proizlazi da je pristupačnost moguće vrjednovati sa nekoliko različitih aspekata. U sklopu prvog aspekta se provjerava do koje mjere dob korisnika doprinosi poteškoćama u korištenju programskim proizvodom. Drugi aspekt se bavi utvrđivanjem razine do koje ljudi sa različitim oblicima fizičkog oštećenja mogu samostalno ili primjenom pomoćnih tehnologija upotrebljavati programski proizvod. Treći aspekt je usmjeren na identifikaciju mjere do koje su u programski proizvod implementirane funkcionalnosti koje ga čine univerzalno pristupačnim.

U slučajevima kada u eksperiment nije moguće uključiti predstavnike reprezentativnih skupina korisnika, vrjednovanje pristupačnosti web mjesta se sastoji od provjere usklađenosti sa smjernicama (Tullis i Albert, 2008). Primjena spomenute metode pregledavanja se najčešće temelji na drugoj inačici skupa smjernica pristupačnosti sadržaja na Webu (eng. Web Content Accessibility Guidelines 2.0, WCAG 2.0; World Wide Web Consortium, 2008). Spomenute su smjernice svrstane u četiri temeljne kategorije prema kojima: a) informacije i elementi korisničkog sučelja trebaju biti prezentirani na način da ih korisnici mogu spoznati pomoću različitih osjetila, b) korisnicima treba biti omogućeno upravljanje elementima sučelja i navigacijskim mehanizmima, c) informacije i funkcionalnosti elemenata sučelja trebaju korisnicima biti razumljive, d) sadržaj treba biti dovoljno robustan da ga raznovrsne pomoćne tehnologije mogu pouzdano interpretirati. Razinu pristupačnosti web mjesta moguće je utvrditi na osnovi sljedećih dvanaest smjernica (World Wide Web Consortium, 2008):

- Za svaki sadržaj koji nije tekstualan treba postojati tekstualna alternativa koju korisnici mogu upotrebljavati u njima pristupačnim formatima poput glasa, simbola, pojednostavljenog jezika, Brailleovog pisma, teksta sa velikim fontom i slično.
- Za audio zapise je potrebno osigurati video alternativu, a za video zapise audio alternativu.
- Kreirati sadržaj koji je moguće prezentirati na pojednostavljeni način bez gubitka informacija ili strukture.
- Olakšati percepciju prezentiranih sadržaja upotrebom čitljivih fontova, tekstom dostatne veličine, funkcionalnostima prilagodbe (npr. veličina teksta) i kontrole (npr. reprodukcija audio zapisa) te mehanizmima označavanja i naglašavanja koji predstavljaju alternativu bojama i kontrastu.
- Omogućiti pokretanje i upravljanje funkcionalnostima web mjesta preko sučelja tipkovnice.
- Implementirati funkcionalnosti koje će korisnicima osigurati dovoljno vremena da pročitaju ili upotrijebe sadržaj.
- Izbjegavati uzorke dizajna koji mogu korisnicima uzrokovati napadaje (npr. više od tri bljeska u sekundi mogu dovesti do epileptičnog napadaja).
- Integrirati mehanizme koji će korisnicima olakšati upravljanje elementima sučelja te pronalaženje sadržaja.
- Osigurati čitljivost i razumljivost prezentiranih sadržaja (npr. mehanizmi koji olakšavaju identifikaciju nepoznatih riječi, skraćenica, izgovora i slično).
- Osigurati predvidljivost u korištenju web mjestom primjenom dosljednog nazivlja i navigacijskih mehanizama u svim dijelovima web mjesta.

- Pomoći korisnicima u izbjegavanju i ispravljanju pogrješaka (kroz implementaciju mehanizama za identifikaciju i sprječavanje pogrješaka, dostupnost sadržaja pomoći koji se prikazuju ovisno o kontekstu upotrebe i slično).
- Osigurati kompatibilnost sa aktualnim i budućim korisničkim agentima i pomoćnim tehnologijama (kroz dosljednu primjenu početnih i završnih tagova te ugnježđivanje dijelova programskog koda čime je olakšana njihova raščlamba i interpretacija od strane pomoćnih tehnologija).

Stupanj usklađenosti sa maločas spomenutim smjernicama moguće je utvrditi primjenom velikog broja automatiziranih alata među kojima je potrebno izdvojiti Wave i AChecker. Obzirom da su dijelovi pojedinih smjernica već obuhvaćeni ostalim atributima kvalitete u korištenju, vrjednovanje relevantnih aspekata pristupačnosti u kontekstu Web 2.0 aplikacija moguće je provesti pomoću sljedećih osam čestica:

PST1. Web 2.0 aplikacija sadrži popis tipkovničkih kratica za pokretanje često korištenih elemenata sučelja.
PST2. Kada se miš zaustavi na pojedinom elementu sučelja Web 2.0 aplikacije, prikazuje se oznaka koja opisuje njegovu funkcionalnost.
PST4. Tekst koji opisuje funkcionalnost pojedinih elemenata sučelja Web 2.0 aplikacije je dovoljno velik za čitanje.
PST5. Da bi se izvršio zadatak pomoću Web 2.0 aplikacije, dovoljno je upotrebljavati samo tipkovnicu.
PST6. Objekti koji se nalaze na sučelju Web 2.0 aplikacije su dovoljno veliki.
PST7. Osobe koje imaju neki oblik invaliditeta će moći upotrebljavati Web 2.0 aplikaciju.
PST8. Web 2.0 aplikacija je pristupačna sa svakog uređaja koji ima vezu na Internet.

3.3.30 Raspoloživost i pružanje pomoći

Karakteristike programskog proizvoda koje se odnose na dostupnost uputa vezanih uz njegovu upotrebu nose naziv raspoloživost i pružanje pomoći (eng. helpfulness; Calero et al., 2005; Paulussen et al., 1996). Visoka razina kvalitete sadržaja pomoći sa kojima raspolaže programski proizvod utječe na povećanje učinkovitost korisnika u učenju korištenja programskim proizvodom te rezultira smanjenjem opterećenja memorije korisnika tijekom interakcije sa programskim proizvodom (Lin et al., 1997). Podrška korisnicima u obliku raznovrsnih sadržaja pomoći značajno doprinosi povećanju razumljivosti web mjesta (Pang et al., 2010). Prema Alonso-Ríos et al. (2010), ovaj atribut služi utvrđivanju mjere do koje programski proizvod korisnicima pruža odgovarajuće i različite oblike pomoći (npr. opisi, smjernice, primjeri i slično)

kada se isti ne mogu snaći ili prisjetiti kako se programski proizvod upotrebljava. U modelu kojeg su predložili Seffah et al. (2006) raspoloživost i pružanje pomoći je sastavni dio kriterija kojim se vrjednuje upotrebljivost smjernica za korisnike.

Nielsen (1994) navodi da svaki programski proizvod mora sadržavati sadržaje pomoći korisnicima koji su dostatne duljine, kontekstualno povezani sa zadacima koje je primjenom programskog proizvoda moguće izvršavati, sadrže listu koraka koje je potrebno poduzeti kako bi se riješio problem te su jednostavni za pretraživanje. Nadovezujući se na njegov rad, González et al. (2009) su razvili šest potheuristika vezanih uz dostupnost, pretraživost, kontekstualnu osjetljivost, strukturiranost i prikladnost sadržaja pomoći korisnicima. Dosad su dimenzije ovog atributa uglavnom vrjednovane primjenom jedne čestice u sklopu upitnika kao što su PUTQ (kratica za eng. Purdue Usability Testing Questionnaire; Lin et al., 1997), WAMMI (kratica za eng. Website Analysis and MeasureMent Inventory; Kirakowski et al., 1998), EUCS (kratica za eng. End-User Computing Satisfaction; Abdinnour-Helm et al., 2005), PSUQ (kratica za eng. The Post-Study System Usability Questionnaire Items; Lewis, 2002), ASQ (kratica za eng. After Scenario Questionnaire; Lewis, 1995), HED/UT (kratica za eng. Hedonic Utility Scale; Voss et al., 2003) i AMUSE (kratica za eng. Appraisal and Measurement of User Satisfaction; Doerr et al., 2007). Kako bi se utvrdilo do koje su mjere sadržaji pomoći sa kojima raspolaže Web 2.0 aplikacija dostupni i korisni, oblikovano je sljedećih sedam čestica:

RIP1. Web 2.0 aplikacija sadrži različite oblike pomoći korisnicima.
RIP2. Pomoć korisnicima je dostupna sa bilo kojeg dijela Web 2.0 aplikacije.
RIP3. Različiti oblici pomoći korisnicima su dostupni sa bilo kojeg dijela Web 2.0 aplikacije.
RIP4. U situaciji kad korisnik ne zna upotrebljavati neku funkcionalnost sučelja Web 2.0 aplikacije, rješenje problema moguće je pronaći u materijalima pomoći.
RIP5. Sadržaji online pomoći Web 2.0 aplikacije su jasni.
RIP6. U sadržajima online pomoći moguće je jednostavno i brzo pronaći kako se upotrebljava pojedina funkcionalnost Web 2.0 aplikacije.
RIP7. Sadržaji online pomoći Web 2.0 aplikacije su pregledni.

3.3.31 Razigranost

Istraživanja koja su se bavila vrjednovanjem razigranosti (eng. playfulness) moguće je svrstati u dvije skupine. Prema prvoj skupini, razigranost je relevantan aspekt unutarnje motiviranosti pojedinca koji egzistira neovisno o situaciji u kojoj se on ili ona nalazi. Webster i Martocchio (1992) su definirali razigranost kao kognitivnu osobinu spontanog, inventivnog i maštovitog korištenja računalom. Studija koju su proveli Atkinson i Kydd (1997) je pokazala da razigranost

pojedinca ima značajan utjecaj na učestalost korištenja Webom. Pored toga, Martocchio i Webster (1992) su otkrili da korisnici sa izraženijom crtom razigranosti imaju visoku razinu radne učinkovitosti u rješavanju zadataka interakcije sa računalom. U drugoj su skupini istraživači proučavali razigranost kao stanje pojedinca koje je osjetljivo na kontekst interakcije. Navedeno implicira da je razigranost važna dimenzija korisničkog iskustva. Većina istraživanja iz ove skupine je svoj rad temeljila na teoriji tijeka (eng. theory of flow; Csikszentimihalyi, 1975) prema kojoj tijek odražava razinu uzbuđenja koje pojedinci osjećaju kada djeluju sa potpunim angažmanom. Malone (1981) je napomenuo da razigranost potiče kognitivnu radoznalost pojedinca. Nadovezujući se na njihov rad, Moon i Kim (2001) su u kontekstu korištenja Webom definirali zamijećenu razigranost kao mjeru do koje pojedinac percipira da je njegova pažnja usmjerena na interakciju, osjeća znatiželju tijekom interakcije te smatra da je interakcija zanimljiva. Iz navedenog je moguće razaznati tri dimenzije razigranosti: koncentraciju odnosno mjeru do koje je pažnja korisnika usmjerena na aktivnost koju obavlja, znatiželju koja nastaje kao logička posljedica podražaja nastalih tijekom interakcije te ugodu koju korisnik osjeća za vrijeme interakcije.

Dosadašnja istraživanja su potvrdila da zamijećena razigranost ima pozitivan utjecaj na stav prema korištenju i ponašajnu namjeru vezanu uz korištenje (Ahn et al., 2007; Moon i Kim, 2001), zadovoljstvo (Eighmey, 1997) i lojalnost korisnika (Lin et al., 2005) te je shodno tome značajan prediktor uspjeha web mjesta (Liu i Arnett, 2000). Obzirom da će u sklopu ovog doktorskog rada aspekti užitka biti mjereni zasebnim atributom kvalitete u korištenju, razigranost korisnika će u kontekstu korištenja Web 2.0 aplikacijama biti vrjednovana dimenzijama zamijećene koncentracije i znatiželje. Na osnovi maločas razmotrenih istraživanja generirano je sljedećih šest čestica namijenjenih vrjednovanju razigranosti korisnika tijekom interakcije sa Web 2.0 aplikacijama:

RZG1. Korištenje Web 2.0 aplikacijom uspješno zadržava moju pažnju dulje vrijeme.
RZG2. Tijekom korištenja Web 2.0 aplikacijom, u potpunosti sam koncentriran(a) na izvršavanje zadataka.
RZG3. Kada upotrebljavam Web 2.0 aplikaciju, ne primjećujem što se oko mene događa.
RZG4. Korištenje Web 2.0 aplikacijom me u potpunosti zaokuplja.
RZG5. Korištenje Web 2.0 aplikacijom potiče moju kreativnost.
RZG6. Korištenje Web 2.0 aplikacijom potiče moju stvaralačku maštu.

3.3.32 Razumljivost

U prvoj verziji međunarodnog standarda ISO/IEC 9126 (1991), razumljivost (eng. understandability) je specificirana kao atribut upotrebljivosti namijenjen vrjednovanju karakteristika programskog proizvoda koje se odnose na napor korisnika potreban za prepoznavanje logičkog koncepta i njegove primjenjivosti. Deset godina kasnije, u revidiranoj verziji (ISO/IEC, 2001) spomenutog standarda ovaj je atribut upotrebljivosti definiran kao sposobnost programskog proizvoda da korisniku omogući razumijevanje njegove primjerenosti i načina upotrebe za pojedine zadatke i u određenim uvjetima korištenja. Recentna inačica međunarodnog standardna namijenjenog vrjednovanju kvalitete programskog proizvoda (ISO/IEC, 2011a) promijenila je naziv ovom atributu u prepoznatljivost primjerenosti (eng. appropriateness recognisability).

Prema Garrido et al. (2011), razumljivost predstavlja atribut upotrebljivosti kojim se vrjednuje organizacija i razmještaj sadržaja u web aplikaciji. Slijedeći ergonomske kriterije za vrjednovanje korisničkih sučelja koje su predložili Bastien i Scapin (1993), Fernandez et al. (2009) su u kontekstu web aplikacija dekomponirali razumljivost na sljedećih pet potkarakteristika:

- Optička jasnoća teksta i slika koja se odnosi na veličinu fonta, kontrast i poziciju teksta, itd.
- Čitljivost koja je vezana uz gustoću i povezanost prezentiranih informacija.
- Familijarnost kao mjera do koje korisnici prepoznaju elemente sučelja te im je interakcija sa njima prirodna.
- Smanjenje radnog opterećenja odnosno kognitivnog napora korisnika.
- Usmjeravanje korisnika koje obuhvaća kvalitetu poruka, trenutačne povratne informacije i upravljivost.

Razumljivost web mjesta se postiže pružanjem relevantnih i usmjerenih informacija te u značajnoj mjeri doprinosi lakoći korištenja web mjestom (Selim, 2003). Uzimajući u obzir navedeno, oblikovane su sljedeće četiri čestice namijenjene vrjednovanju razumljivosti Web 2.0 aplikacija:

RZM1. Kada korisnik odabere i pokrene pojedine elemente sučelja Web 2.0 aplikacije, dobije što je i očekivao.
RZM2. Funkcionalnost elemenata sučelja Web 2.0 aplikacije je razumljiva.
RZM3. Izgled ikona koje se nalaze na sučelju Web 2.0 aplikacije je usklađen sa njihovom namjenom.

RZM4. Naziv funkcionalnih elemenata sučelja Web 2.0 aplikacije odgovara kontekstu njihove upotrebe.

3.3.33 Reputacija

U literaturi je koncept reputacije (eng. image) velikim dijelom razmatran sa aspekta teorije difuzije inovacija (Moore i Benbasat, 1991) i teorije prihvaćanja tehnologije (Venkatesh i Davis, 2000) prema kojima isti predstavlja mjeru do koje korisnici percipiraju da će upotreba tehnologije utjecati na povećanje njihovog ugleda u društvu. Međutim, u sklopu ovog doktorskog rada će reputacija biti konceptualizirana kao splet obilježja web mjesta koja odražavaju razinu njegove popularnosti. Naime, Shamdasani et al. (2001) navode da su korisnici spremniji prihvatiti web mjesto koje ima visoku razinu reputacije od web mjesta koja se još nisu u dostatnoj mjeri etablirala. Pored toga, Markus (1994) je otkrio da će pojedinci kod odabira tehnologije uvijek dati prednost onoj koja ima veći broj aktivnih korisnika. Naposljetku, istraživanja su pokazala da reputacija web mjesta ima značajan utjecaj na njegovu kvalitetu (Lee i Kozar, 2006) i lojalnost korisnika (Caruana i Ewing, 2010). Kako bi se utvrdilo koji aspekti reputacije vrjednovanih Web 2.0 aplikacija utječu na ponašajnu namjeru korisnika vezanu uz njihovu upotrebu, oblikovane su sljedeće četiri čestice:

RPT1. Da bi upotrebljavao/upotrebljavala Web 2.0 aplikaciju, važno mi je da ona ima veliki broj aktivnih korisnika.
RPT2. Da bi upotrebljavao/upotrebljavala Web 2.0 aplikaciju, važno mi je da je istu razvila ugledna kompanija.
RPT3. Da bi upotrebljavao/upotrebljavala Web 2.0 aplikaciju, važno mi je da ista ima dobar portfolio.
RPT4. Na moju odluku o korištenju određenim Web 2.0 aplikacijama utječe njihova popularnost.

3.3.34 Sigurnost

Prema međunarodnom standardu ISO/IEC 9126-1 (2001), sigurnost (eng. security) je potkarakteristika karakteristike funkcionalnost (eng. functionality), a služi utvrđivanju razine do koje programski proizvod raspolaže mehanizmima koji omogućuju zaštitu informacija i podataka na način da ih neautorizirani korisnici i sustavi ne mogu pročitati ni modificirati, a autorizirani korisnici ne mogu zanijekati da su im pristupali. U međunarodnom standardu ISO/IEC 25010 (2011a) sigurnost je izdvojena kao zasebna karakteristika kvalitete programskog proizvoda.

Pang et al. (2010) napominju da web mjesto treba biti zaštićeno od raznovrsnih napada i prijetnji iz vanjskog svijeta te očuvati privatnost i tajnost pohranjenih podataka. Sigurnosni propusti u implementaciji web mjesta mogu rezultirati visokim troškovima popravljanja štete, pravnim posljedicama, gubitkom prihoda i povjerenja korisnika (Offutt, 2002). Jedan od načina kako se može utvrditi da li programski proizvod u dostatnoj mjeri štiti podatke od neautoriziranog pristupa i korištenja jest primjena objektivnih metrika koje su predložene međunarodnim standardom ISO/IEC 9126-3 (2003b). Prva metrika se odnosi na provjeru pristupanja programskom proizvodu te shodno tome predstavlja omjer broja evidentiranih pristupa i broja pristupa navedenih u specifikaciji. Druga metrika je vezana uz kontrolu pristupa odnosno proporciju broja ispravno implementiranih mehanizama kontrole i broja mehanizama kontrole koji su naznačeni u specifikaciji. Treća metrika se odnosi na zaštitu podataka od oštećenja što implicira da ista predstavlja omjer broja implementiranih instanci namijenjenih zaštiti podataka od oštećenja i broja identificiranih instanci koje su sposobne oštetiti ili uništiti podatke. Posljednja metrika je vezana uz kriptografsku zaštitu podataka odnosno proporciju broja instanci podataka koje su šifrirane i broja instanci podataka koje trebaju biti šifrirane. Drugi način na koji je moguće vrjednovati sigurnost jest primjena upitnika (npr. Aladwani i Palvia, 2002; Hashim i Sultan, 2009; Hong i Kim, 2004; Tate et al., 2007) ili razvoj vlastitog skupa objektivnih metrika (npr. Gledec, 2005; Olsina i Rossi, 2002). Za potrebe ovog doktorskog rada oblikovano je sljedećih dvanaest čestica pomoću kojih je moguće utvrditi do koje mjere Web 2.0 aplikacija štiti kreirane i pohranjene artefakte od neautoriziranog pristupa i korištenja:

SGR1. Obrazac za izradu korisničkog računa sadrži indikator jačine lozinke.
SGR2. Tijekom izrade korisničkog računa potrebno je unijeti previše osobnih podataka.
SGR3. Tijekom popunjavanja obrasca za registraciju novog korisnika potrebno je unijeti CAPTCHA znakove.
SGR4. Tijekom izrade korisničkog računa potrebno je definirati sigurnosno pitanje i odgovor.
SGR5. Tijekom izrade korisničkog računa, potrebno je potvrditi prethodno unesenu lozinku.
SGR6. Tijekom izrade korisničkog računa, potrebno je unijeti lozinku koja sadrži minimalan broj znakova.
SGR7. Tijekom izrade korisničkog računa potrebno je unijeti lozinku koja sadrži posebne znakove (!@#$%^*()~`{}[]|\&_).
SGR8. Kod svakog učitavanja Web 2.0 aplikacije u web preglednik, potrebno je unijeti korisničko ime i lozinku.
SGR9. Web 2.0 aplikacija sadrži funkcionalnost pamćenja korisničkog imena i lozinke.
SGR10. Artefakti koji nastanu upotrebom Web 2.0 aplikacije su zaštićeni od neautoriziranih korisnika.
SGR11. Web 2.0 aplikacija sadrži funkcionalnost oporavka korisničkog računa.

SGR12. Web 2.0 aplikacija sadrži uvjete korištenja i politiku privatnosti.

3.3.35 Skalabilnost

Shea (2000) je definirao skalabilnost (eng. scalability) kao sposobnost web aplikacije da podržava istovremeni rad većeg broja korisnika i/ili istovremeno izvršavanje većeg broja transakcija, a da pri tome zadrži prihvatljivo vrijeme odaziva. Prema Moraga et al. (2004), skalabilnost predstavlja metriku odaziva kojom se utvrđuje da li je web portal sposoban prilagoditi se povećanju radnog opterećenja u pogledu dodatnih korisnika, količine prometa ili složenosti transakcija. Rababah i Masoud (2010) su svrstali ovaj atribut u kategoriju konceptualne pouzdanosti te ga definirali kao spremnost web mjesta da udovolji zahtjevima u pogledu povećanja broja korisnika i upotrebe. Pang et al. (2010) su konceptualizirali skalabilnost kao dimenziju učinkovitosti prema kojoj Web 2.0 aplikacija treba podržavati neočekivano veliku količinu prometa podacima. U međunarodnom su standardu ISO/IEC 25010 (2011a) pojedini aspekti ovog atributa specificirani u sklopu potkarakteristike kapacitet (eng. capacity) koja predstavlja mjeru do koje maksimalna ograničenja programskog proizvoda udovoljavaju zahtjevima. Navedeno se odnosi na broj datoteka koje je moguće pohraniti, broj korisnika koji mogu u isto vrijeme upotrebljavati programski proizvod, komunikacijsku i transakcijsku propusnost, veličinu baze podataka, itd. Uzimajući u obzir sve spomenuto, skalabilnost Web 2.0 aplikacija je moguće vrjednovati pomoću sljedeće četiri čestice:

SLB1. Web 2.0 aplikacija omogućava pohranu velike količine artefakata.
SLB2. Web 2.0 aplikacija omogućava istovremeni rad velikog broja korisnika.
SLB3. Web 2.0 aplikacija omogućava istovremeni rad na većem broju zadataka.
SLB4. Web 2.0 aplikacija omogućava izvršavanje složenih zadataka.

3.3.36 Sprječavanje pogrješaka

Atribut pod nazivom sprječavanje pogrješaka (eng. error prevention) služi mjerenju razine do koje programski proizvod štiti korisnike od toga da počine pogrješke (Constantine i Lockwood, 1999; ISO/IEC, 2011a). Preece (2001) navodi da je količina pogrješaka koje su korisnici počinili tijekom interakcije sa elementima sučelja jedan od pet aspekata upotrebljivosti koji imaju značajan utjecaj na uspjeh web mjesta. Veliki broj pogrješaka u radu smanjuje učinkovitost, a u konačnici i cjelokupni radni učinak korisnika (Shneiderman, 1998). Zbog navedenog Nielsen (1993, 1994) i Quesenbery (2001) smatraju da programski proizvodi trebaju biti tolerantni na pogrješke odnosno sadržavati mehanizme u koje će biti implementirane iznimke za sve

nepredviđene scenarije korištenja te na taj način spriječiti nastanak pogrješaka (primjerice poruke upozorenja kod izvršavanja operacija koje nije moguće poništiti i sl.) i pomoći korisnicima tijekom procesa oporavka ukoliko do pogrješaka ipak dođe (npr. mogućnost povratka u prethodno stanje, konstruktivne poruke o pogrješkama i sl.). Aspekti ovog atributa su dosad pretežno vrjednovani subjektivno primjenom upitnika. Primjerice, Gediga et al. (1999) su u tu svrhu oblikovali zaseban skup čestica, dok su De Wulf et al. (2006) razinu do koje web mjesto sprječava nastanak pogrješaka mjerili u sklopu atributa namijenjenom vrjednovanju pouzdanosti. Kako bi se utvrdilo do koje mjere Web 2.0 aplikacije raspolažu mehanizmima koji štite korisnike od nastanka pogrješaka u radu, oblikovane su sljedeće četiri čestice:

SPO1. Ukoliko tijekom izvršavanja zadataka korisnik napravi pogrješku, istu je moguće brzo i jednostavno ispraviti.
SPO2. Web 2.0 aplikacija sadrži funkcionalnost za praćenje promjena nad artefaktom.
SPO3. Web 2.0 aplikacija omogućuje korisniku da poništi i ponovi promjene na artefaktu.
SPO4. Prije provedbe bilo kakve destruktivne operacije, Web 2.0 aplikacija traži potvrdu od korisnika.

3.3.37 Stav prema ponašanju

Temelji ovog atributa počivaju na teoriji razložne akcije, teoriji planiranog ponašanja i modelu prihvaćanja tehnologije. Prema teoriji razložne akcije (eng. Theory of Reasoned Action, TRA; Fishbein i Ajzen, 1975; Ajzen i Fishbein, 1980), stav prema ponašanju odražava pozitivne ili negativne osjećaje prema provedbi ponašanja. Na formiranje stava prema ponašanju utječu čvrsta uvjerenja o posljedicama provedbe ponašanja i procjene tih posljedica. Nadalje, prema pretpostavci teorije planiranog ponašanja (eng. Theory of Planned Behavior, TPB; Ajzen, 1985; Ajzen, 1991) oblikovanje stava prema ponašanju ovisi o očekivanjima značajnih drugih osoba te kontroli nad ponašanjem. Konačno, u modelu prihvaćanja tehnologije (eng. eng. Technology Acceptance Model, TAM; Davis, 1989; Davis et al., 1989) stav prema ponašanju je određen sa dva različita i međusobno povezana konstrukta: zamijećenom lakoćom korištenja i zamijećenom korisnosti. Davis et al. (1989) navode da modeliranja stava prema ponašanju na spomenut način donosi sljedeće prednosti: a) olakšava identifikaciju relativne važnosti pojedine percepcije na formiranje stava ponašanja, b) pomaže u praćenju utjecaja vanjskih varijabli (primjerice obilježja sustava i karakteristika pojedinca) na oblikovanje ponašanja, c) olakšava identifikaciju razloga neprihvaćanja sustava i d) omogućuje usmjeravanje korektivnih akcija sa ciljem povećanja prihvaćanja sustava.

U kontekstu vrjednovanja upotrebljivosti, stav prema ponašanju je uvjetovan zadovoljstvom koje se manifestira prihvatljivom razinom umora, nelagode, razočarenja i uloženog napora (Shackel, 1991). Pod ponašanjem se u online okruženju podrazumijeva korištenje web mjestom. Motivirani prednostima modeliranja stava prema ponašanju koje su naveli Davis et al. (1989), pojedini su istraživači potvrdili da zamijećena lakoća korištenja i zamijećena korisnost (Castañeda et al., 2007; Shin, 2008) te zamijećen užitak (Hassanein i Head, 2007; Van der Heijden, 2003) imaju značajan utjecaj na formiranje stava prema korištenju web mjestom. Isti su autori potvrdili da stav prema korištenju ima značajan utjecaj na ponašajnu namjeru odnosno lojalnost korisnika. Uzimajući u obzir razmotreno, stav prema korištenju Web 2.0 aplikacijom je moguće vrjednovati pomoću sljedećih pet čestica:

STP1. Korištenje Web 2.0 aplikacijom je dobra ideja.
STP2. Korištenje Web 2.0 aplikacijom je mudra ideja.
STP3. Sviđa mi se ideja o korištenju Web 2.0 aplikacijom.
STP4. Imam pozitivan stav prema korištenju Web 2.0 aplikacijom.
STP5. Veselim se zadacima zbog kojih ću trebati upotrebljavati Web 2.0 aplikaciju.

3.3.38 Sveobuhvatnost konteksta

Prema recentnom međunarodnom standardu namijenjenom vrjednovanju kvalitete programskih proizvoda, (ISO/IEC, 2011a), atribut kojim se vrjednuje sveobuhvatnost konteksta (eng. context coverage) zajedno sa djelotvornošću, učinkovitošću, zadovoljstvom i slobodom od rizika predstavlja temeljnu odrednicu kvalitete u korištenju. Isti je standard definirao ovaj atribut kao stupanj do kojeg je moguće učinkovito, djelotvorno, bez rizika i na zadovoljstvo korisnika upotrebljavati programski u unaprijed specificiranim kontekstima korištenja kao i izvan njih. Pored toga, sveobuhvatnost konteksta je u standardu ISO/IEC 25010 (2011a) dekomponirana na cjelovitost konteksta (eng. context completeness) i fleksibilnost (eng. flexibility). Dok se cjelovitost konteksta odnosi na mogućnost upotrebe programskog proizvoda u svim specificiranim kontekstima korištenja, fleksibilnost predstavlja mjeru do koje je moguće koristiti se programskim proizvodom izvan definiranih konteksta upotrebe. Cjelovitost konteksta je moguće vrjednovati sa aspekta karakteristika korisnika (do koje mjere različite skupine korisnika (npr. početni i napredni korisnici) mogu primjenom programskog proizvoda ostvariti svoje ciljeve u namjeravanom kontekstu korištenja) te sa aspekta specifičnosti programskog proizvoda (do koje je mjere programski proizvod moguće upotrebljavati u svim namjeravanim kontekstima korištenja (npr. rad na zaslonima različitih dimenzija ili rad u okruženjima koje se razlikuju prema stupnju povezanosti na Internet)). S druge strane,

fleksibilnost se odnosi na mogućnost prilagodbe programskog proizvoda različitim skupinama korisnika te vrstama zadataka i okruženja. Iz navedenog je evidentno da se definicija ovog atributa u standardu ISO/IEC 25010 (2011a) konceptualno preklapa sa ostalim atributima kvalitete u korištenju kao što su mogućnost prilagodbe i kompatibilnost. Zbog toga će se u sklopu ovog doktorskog rada dimenzije sveobuhvatnosti konteksta korištenja Web 2.0 aplikacijama vrjednovati pomoću sljedeće tri čestice:

SVK1. Web 2.0 aplikacija omogućava izradu raznovrsnih artefakata.
SVK2. Web 2.0 aplikaciju je moguće upotrebljavati i izvan konteksta za koji je originalno namijenjena.
SVK3. Web 2.0 aplikacija ima široku mogućnost primjene.

3.3.39 Točnost sadržaja

Prema Olsina et al. (2009), točnost sadržaja (eng. content correctness) predstavlja mjeru do koje je sadržaj pouzdan odnosno ne sadrži pogrješke. U međunarodnom standardu koji je usmjeren na vrjednovanje kvalitete podataka (ISO/IEC, 2008), točnost se odnosi na razinu do koje svojstvene karakteristike podataka točno predstavljaju obilježja određenog koncepta ili događaja u specifičnom kontekstu upotrebe. U slučaju mashupova (Cappiello et al., 2010), ovaj atribut predstavlja stupanj do kojeg podaci točno i dosljedno predstavljaju kontekst iz stvarnog svijeta. Redman (1996) je definirao točnost sadržaja kao mjeru sličnosti između vrijednosti podatka i neke druge vrijednosti koja se smatra točnom. Orehovački et al. (2013) navode da ovaj atribut predstavlja razinu do koje je sadržaj ispravan, bez pogrješaka i valjan.

Batini et al. (2009) napominju da postoje dvije vrste točnosti sadržaja: sintaksna i semantička. Vrjednovanje sintaksne točnosti se sastoji od utvrđivanja razine podudaranja između vrijednosti sadržaja i vrijednosti koje su sadržane u određenoj domeni definiranja (npr. provjeravanje pravopisa). S druge strane, vrjednovanje semantičke točnosti obuhvaća identifikaciju stupnja podudaranja između vrijednosti sadržaja i njegove vrijednosti u stvarnom svijetu (npr. da li značenje sadržaja odgovara kontekstu u kojem se isti upotrebljava). Točnost sadržaja moguće je vrjednovati objektivnim i subjektivnim metrikama. Od objektivnih metrika, pojedini autori predlažu omjer broja podatkovnih jedinica koje sadrže pogrješke i ukupnog broja podatkovnih jedinica (Batini et al., 2009; Helfert i Foley, 2009) te izračun vjerojatnosti da podaci sadrže pogrješke (Cappiello et al., 2010). Zamijećenu razinu točnosti sadržaja istraživači su dosad vrjednovali u sklopu zasebnog konstrukta sa više čestica (npr. Lee et al., 2002; Muylle et al. 2004) ili pomoću jedne čestice sa aspekta kvalitete informacija (npr. Ahn et al., 2007; Aladwani i Palvia, 2002; Barnes i Vidgen, 2003; Chen i Cheng, 2009; Cheung i Lee, 2005), relevantnosti

informacija (npr. McKinney et al., 2002) te korisnosti sadržaja (npr. Hong i Kim, 2004). Uzimajući u obzir sve navedeno, razinu točnosti sadržaja nastalih tijekom interakcije sa Web 2.0 aplikacijom moguće je vrjednovati pomoću sljedećih šest čestica:

TNS1. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je točan.
TNS2. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je bez pogrješaka.
TNS3. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je jasan i razumljiv.
TNS4. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je valjan.
TNS5. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je precizan.
TNS6. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je ispravan.

3.3.40 Učinkovitost

Prema međunarodnom standardu ISO 9241-11 (1998), učinkovitost (eng. efficiency) se ubraja u tri temeljne odrednice upotrebljivosti programskog proizvoda. U literaturi je moguće pronaći mnoštvo definicija ovog koncepta od kojih svaka pokriva jedan od komplementarnih aspekata upotrebljivosti. Primjerice, Nielsen (1993) je definirao učinkovitost kao mjeru do koje programski proizvod omogućava korisniku postizanje maksimalnog učinka uz minimalan utrošak resursa. Seffah et al. (2006) su konceptualizirali učinkovitost kao sposobnost programskog proizvoda da omogući korisniku da utroši primjerenu količinu resursa kako bi postigao djelotvornost u određenom kontekstu upotrebe. Prema Alonso-Ríos et al. (2010), učinkovitost predstavlja sposobnost sustava da bude ekonomičan u omjeru izlaznih rezultata i uloženih resursa. Pod resursima se ovdje podrazumijeva količina uloženog fizičkog i mentalnog napora, te troškovi ljudskih potencijala, programskog proizvoda, tehnološke infrastrukture i potrošnog materijala. Parasuraman et al. (2005) su definirali učinkovitost kao lakoću i brzinu kojom se može pristupati web mjestu te se njime koristiti. U namjeri da ovaj koncept približe kontekstu kvalitete u korištenju, Lew et al. (2010) su ga operacionalizirali kao učinkovitost u korištenju (eng. efficiency in use). Naposljetku, Constantine i Lockwood (1999) su definirali učinkovitost u korištenju kao mjeru do koje upotreba programskog proizvoda povećava produktivnost korisnika.

Učinkovitost je moguće vrjednovati primjenom objektivnih i subjektivnih instrumenata. Prema standardu ISO/IEC 9126-3 (2003b), objektivne metrike odnosno indikatore namijenjene vrjednovanju učinkovitosti moguće je podijeliti u tri skupine. Prvom skupinom metrika se vrjednuje ponašanje sustava u vremenu. U ovu skupinu se ubrajaju metrike pomoću kojih se utvrđuje koliko je vremena potrebno sustavu da dovrši određeni zadatak, koliko zadataka sustav može izvršiti u jedinici vremena te koliko je vremena potrebno sustavu da dovrši skup srodnih

zadataka. Druga skupina metrika se odnosi na resurse koje je potrebno uložiti u funkcioniranje sustava. Ovom skupinom metrika se utvrđuje koliko je potrebno upotrebljavati ulazno-izlazne jedinice da bi se dovršio zadatak, učestalost poruka vezanih uz upotrebu ulazno-izlaznih jedinica u linijama koda koje se odnose na pozive sustava, veličina memorije koju će programski proizvod zauzeti kako bi dovršio zadatak, učestalost poruka vezanih uz upotrebu memorije te količina upotrebe resursa prijenosa. Posljednja se skupina veže uz metriku usklađenosti primjenom koje se provjerava do koje razine učinkovitost sustava udovoljava standardima i propisima.

Metrike koje se odnose na ponašanje u vremenu moguće je prilagoditi kontekstu korištenja te ih primijeniti u vrjednovanju upotrebljivosti korisnika. Primjerice, Sauro i Kindlund (2005) te Oztekin et al. (2009) su u izgradnji kompozitnog indeksa upotrebljivosti učinkovitost mjerili količinom vremena koja je korisnicima bila potrebna za dovršetak zadataka. Nasuprot navedenom, zamijećena učinkovitost je vrjednovana česticama upitnika kao što su primjerice WAMMI (kratica za eng. Website Analysis and MeasureMent Inventory; Kirakowski et al., 1998) ili UMUX (Finstad, 2010). Iz navedenog proizlazi da je učinkovitost korisnika tijekom interakcije sa Web 2.0 aplikacijom moguće mjeriti pomoću sljedeće četiri čestice i jednog indikatora, respektivno:

UNK1. Upotrebom Web 2.0 aplikacije, zadatke je moguće brzo izvršiti.
UNK2. Da bi se izvršio zadatak pomoću Web 2.0 aplikacije, potrebno je poduzeti mali broj koraka.
UNK3. Upotrebom Web 2.0 aplikacije povećava se učinkovitost u izvršavanju zadataka.
UNK4. Izvršavanjem zadataka pomoću Web 2.0 aplikacije, dobiva se na uštedi vremena.
UNK5. Količina vremena potrebna za dovršetak predefiniranih koraka scenarija interakcije sa Web 2.0 aplikacijom.

3.3.41 Upravljivost

Lee i Kozar (2012) su definirali upravljivost (eng. navigability) kao sposobnost web mjesta da korisnicima omogući alternativne oblike interakcije i različite tehnike navigacije. Seffah et al. (2006) navode da upravljivost predstavlja kriterij upotrebljivosti pomoću kojeg se mjeri razina do koje se korisnik može na učinkovit način kretati kroz programski proizvod. Kvalitetna navigacijska struktura olakšava pristup sadržajima web aplikacije (Garrido et al., 2011). Ukoliko je web mjesto upravljivo, ono smanjuje dezorijentaciju korisnika (Shneiderman, 1998). U kontekstu web mjesta, Ahuja i Webster (2001) su definirali dezorijentaciju kao osjećaj kojeg doživi korisnik kada ne zna gdje se nalazi i kako da dođe do željene lokacije. Isti su autori otkrili

da su dezorijentiranost i lakoća korištenja dva različita koncepta te su shodno tome oblikovali skalu za vrjednovanje dezorijentiranosti. Visoka razina dezorijentiranosti se ubraja među najčešće uzroke nezadovoljstva korisnika web mjestom (Brinck et al., 2002), ima značajan utjecaj na smanjenje produktivnosti korisnika te se negativno odražava na prihvaćanje web mjesta (Van Schaik i Ling, 2005). Nasuprot tome, visoka razina upravljivosti doprinosi učinkovitosti, zadovoljstvu i lojalnosti korisnika (Lee i Kozar, 2009; Lin, 2010) te uspjehu web mjesta (Nielsen, 2000; Palmer, 2002b). Upravljivost web mjestom se postiže logičkom organizacijom elemenata sučelja koja uključuje strukturiranje poveznica (Farkas i Farkas, 2000), kategorizaciju elemenata u izbornicima i primjenu oblaka tagova (Kalbach i Gustafson, 2007) te dosljedan dizajn (Hasan i Abuelrub, 2011). Za potrebe vrjednovanja upravljivosti Web 2.0 aplikacijama generirano je sljedećih dvanaest čestica:

UPR1. Web 2.0 aplikacija sadrži različite navigacijske mehanizme (npr. tražilica, izbornik i sl.).
UPR2. Korisnik može sa bilo kojeg dijela Web 2.0 aplikacije pristupiti svim funkcionalnostima sučelja koje su mu potrebne za izvršavanje zadataka.
UPR3. Korisnik može brzo i jednostavno pronaći funkcionalnosti sučelja Web 2.0 aplikacije koje su mu potrebne za izvršavanje zadataka.
UPR4. Elementi sučelja Web 2.0 aplikacije su tako raspoređeni da se oni koji imaju srodnu funkcionalnost nalaze jedni pored drugih.
UPR5. Broj elemenata u izborniku i podizbornicima je optimalan.
UPR6. Elementi sučelja Web 2.0 aplikacije su intuitivni za upotrebu.
UPR7. Web 2.0 aplikacija sadrži oblak tagova.
UPR8. Web 2.0 aplikacija sadrži funkcionalnost koja prikazuje trenutnu poziciju u radnom prostoru.
UPR9. Web 2.0 aplikacija sadrži mapu web mjesta.
UPR10. Radni prostor Web 2.0 aplikacije stane u jedan ekran (nije potrebno koristiti klizače).
UPR11. Navigacija između pojedinih dijelova Web 2.0 aplikacije moguća je upotrebom funkcijskih tipki *sljedeći* i *prethodan* u web pregledniku.
UPR12. Navigacija između pojedinih dijelova Web 2.0 aplikacije moguća je upotrebom funkcijskih tipki *sljedeći* i *prethodan* koje se nalaze na njenom sučelju.

3.3.42 Utjecaj društva

Koncept utjecaja društva (eng. social influence) ima svoje korijene u teoriji razložne akcije, teoriji prihvaćanja tehnologije te općoj teoriji prihvaćanja i korištenja tehnologijom. U teoriji razložne akcije, ovaj atribut nosi naziv subjektivna norma (eng. subjective norm), a predstavlja

percepciju pojedinca o mišljenju značajnih drugih osoba vezano uz provedbu njegovog ili njenog ponašanja (Fishbein i Ajzen, 1975, str. 302). Prema spomenutoj teoriji, subjektivna norma je rezultat međuodnosa zamijećenih očekivanja relevantnih osoba i motivacije pojedinca da spomenutim očekivanjima udovolji (Fishbein i Ajzen, 1975). U drugoj inačici modela prihvaćanja tehnologije (TAM2; Venkatesh i Davis, 2000) subjektivna norma je konceptualizirana kao zaseban konstrukt uz kojeg su vezane tri pretpostavke. Prva je da će subjektivna norma imati direktan utjecaj na namjeru korištenja. Kao i kod teorije razložne akcije, riječ je o procesu udovoljavanja (eng. compliance) mišljenju relevantnih osoba (Kelman, 1958). Međutim, takva će veza biti značajna samo u slučaju kada je korištenje sustavom percipirano kao obavezno dok u slučaju percepcije dobrovoljnog korištenja utjecaj neće biti značajan. Druga pretpostavka odnosi se na utjecaj subjektivne norme na namjeru korištenja preko zamijećene korisnosti. Riječ je o procesu internalizacije (eng. internalization) prema kojem će pojedinac mišljenje relevantne osobe ugraditi u vlastitu strukturu uvjerenja te posljedično oblikovati ponašajnu namjeru (Kelman, 1958). Treća pretpostavka vezana je uz proces identifikacije (eng. identification) gdje osoba pod utjecajem mišljenja relevantne osobe ima tendenciju oblikovati ponašajnu namjeru iz razloga što smatra da će korištenjem sustava poboljšati vlastiti društveni status i radnu učinkovitost (Kelman, 1958). Procesi internalizacije i identifikacije se javljaju neovisno o tome da li je korištenje sustavom percipirano kao obavezno ili dobrovoljno. Potrebno je napomenuti da će početni utjecaj subjektivne norme nakon nekog vremena provedenog u interakciji sa sustavom biti zamijenjen stečenim iskustvom. S druge strane, iskustvo nema utjecaja na proces identifikacije već on isključivo ovisi o uvjerenjima društvene zajednice. Naposljetku, prema općoj teoriji prihvaćanja i korištenja tehnologijom (Venkatesh et al., 2003) utjecaj društva značajno doprinosi ponašajnoj namjeri. Aspekte ovog atributa je u kontekstu Web 2.0 aplikacija moguće vrjednovati pomoću sljedeće tri čestice:

UDR1. Na moju odluku o korištenju Web 2.0 aplikacijom utječu ljudi čije mišljenje mi je važno.
UDR2. Na moju odluku o korištenju Web 2.0 aplikacijom utječu informacije iz raznih medija (Internet, stručni časopisi).
UDR3. Na moju odluku o korištenju Web 2.0 aplikacijom utječe činjenica da istu upotrebljavaju moji prijatelji i kolege.

3.3.43 Užitak

Kim et al. (2007) su definirali užitak (eng. pleasure) kao stupanj do kojeg se korisnik tijekom upotrebe tehnologije osjeća dobro ili sretno. Prema modelu kvalitete u korištenju koji je predložen međunarodnim standardom ISO/IEC 25010 (2011a), užitak predstavlja mjeru do koje

ispunjavanje osobnih ciljeva (npr. stjecanje novih vještina, komuniciranje i sl.) primjenom programskog proizvoda korisniku stvara osjećaj ugode. Blythe i Hassenzahl (2003) navode da užitak predstavlja mjeru zaokupljenosti sa zadatkom koji se izvršava. Iz navedenog proizlazi da je užitak usko povezan sa atributom kojim se vrjednuje razigranost korisnika. Kada se izuzmu posljedice vezane uz radni učinak korisnika koje proizlaze iz korištenja sustavom, zamijećeno uživanje (eng. perceived enjoyment) predstavlja mjeru do koje sama aktivnost upotrebe sustava korisniku stvara osjećaj ugode (Venkatesh, 2000). U kontekstu Weba, užitak označava razinu ugode koju korisnik osjeća kada posjeti web mjesto (De Wulf et al., 2006). Rezultati prijašnjih istraživanja su pokazali da estetika elemenata sučelja značajno doprinosi zamijećenom užitku tijekom interakcije sa web mjestom (Schenkman i Jönsson, 2000; Van der Heijden, 2003). Pored toga, dosadašnja su istraživanja potvrdila da užitak ima pozitivan utjecaj na lakoću korištenja (Venkatesh i Bala, 2008), zadovoljstvo korisnika (De Wulf, 2006) i ponašajnu namjeru vezanu uz korištenje (Xu et al., 2012) što rezultira prihvaćanjem web mjesta (Sánchez-Franco i Roldán, 2005). Uzimajući u obzir sve navedeno, razina do koje interakcija sa Web 2.0 aplikacijom korisnicima stvara osjećaj ugode može se mjeriti pomoću sljedećih pet čestica:

UTK1. Korištenje Web 2.0 aplikacijom je zabavno.
UTK2. Korištenje Web 2.0 aplikacijom je zanimljivo.
UTK3. Tijekom upotrebe Web 2.0 aplikacije, korisnik se dobro osjeća.
UTK4. Ugodno je upotrebljavati Web 2.0 aplikaciju.
UTK5. Sviđa mi se način izvršavanja zadataka pomoću funkcionalnosti sučelja Web 2.0 aplikacije.

3.3.44 Vjerodostojnost sadržaja

Olsina et al. (2009) su definirali vjerodostojnost sadržaja (emg. content credibility) kao mjeru do koje a) je autora sadržaja moguće provjeriti, b) izvor sadržaja ima dobru reputaciju i c) su činjenice iznesene u sadržaju objektivne. Orehovački et al. (2013) navode da ovaj atribut predstavlja razinu do koje je sadržaj nepristran, pouzdan i provjerljiv. Wang i Strong (1996) su svaki od tri aspekta vjerodostojnosti sadržaja koje su spomenuli Olsina et al. (2009) i Orehovački et al. (2013) specificirali kao zaseban atribut: objektivnost (eng. objectivity) predstavlja mjeru do koje je sadržaj nepristran, sljedivost (eng. traceability) označava razinu do koje su podaci dobro dokumentirani, provjerljivi te ih je lako povezati sa izvorom dok reputacija (eng. reputation) predstavlja stupanj do kojeg se na osnovi izvora podataka istima može vjerovati. U standardu ISO/IEC 25012 (2008), vjerodostojnost sadržaja je specificirana kao skup svojstvenih obilježja podataka koje korisnici smatraju istinitima i vjerojatnima u određenom kontekstu upotrebe. Naposljetku, Pang et al. (2010) su vjerodostojnost sadržaja konceptualizirali kao

dimenziju atributa kojim se mjeri razina povjerenja u sadržaj (eng. trustworthiness). Obzirom da su aspekti ovog atributa dosad u praksi vrjednovani isključivo subjektivno (npr. Alkhattabi et al., 2011; Barnes i Vidgen, 2003; Cheung i Lee, 2005; De Wulf et al., 2006; Lee et al., 2002), oblikovano je sljedećih šest čestica pomoću kojih je moguće utvrditi vjerodostojnost sadržaja nastalog korištenjem Web 2.0 aplikacijom:

VDS1. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je istinit.
VDS2. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je vjerodostojan.
VDS3. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je pouzdan.
VDS4. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je objektivan.
VDS5. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je relevantan.
VDS6. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je provjerljiv.

3.3.45 Vrijeme odaziva

Prema Dix et al. (2004), vrijeme odaziva (eng. responsiveness, response time) predstavlja količinu vremena koje je potrebna aplikaciji da reagira na zahtjeve i postupke korisnika. Isti su autori također naglasili kako se vrijeme odaziva za provedbu sličnih aktivnosti ne bi smjelo značajno razlikovati te da u slučajevima kada aplikacija ne može odmah obraditi zahtjev treba određenim oblikom povratne informacije korisniku dati do znanja da je isti zaprimljen. Wixom i Todd (2005) su konceptualizirali ovaj atribut pod nazivom pravovremenost (eng. timeliness) te ga definirali kao promptnu reakciju web mjesta na zahtjeve i aktivnosti korisnika. U međunarodnom standardu ISO/IEC 25010 (2011a) ovaj atribut predstavlja aspekt potkarakteristike kojom se ispituje kako se programski proizvod ponaša u vremenu (eng. time behaviour).

Vrijeme odaziva je ključni čimbenik uspjeha web mjesta (Palmer, 2002b; Lin, 2010). Korisnici imaju vrlo nizak prag tolerancije vezano uz vrijeme odaziva web mjesta. Rezultati istraživanja kojeg su proveli Galletta et al. (2004) impliciraju da su korisnici voljni tolerirati vrijeme odaziva od četiri sekunde ukoliko je riječ o nepoznatom web mjestu te da su isti spremni čekati osam sekundi ako se radi o web mjestu kojeg su već upotrebljavali. Ukoliko je vrijeme učitavanja web mjesta dulje od onog koje je korisnicima prihvatljivo, isti neće dvojiti već će potražiti alternativno web mjesto (Weinberg, 2000). Naime, Palmer (2002a) navodi da vrijeme odaziva veće od deset sekundi značajno povećava vjerojatnost da će korisnici prestati čekati na učitavanje web mjesta. Pored toga, Cox i Dale (2002) naglašavaju da će 70% korisnika napustiti web mjesto u slučaju kada vrijeme odaziva prijeđe granicu od dvanaest sekundi. Osim što se vrijeme odaziva može mjeriti objektivno, isto je moguće vrjednovati subjektivno. Istraživači su

dosad vrjednovali zamijećeno vrijeme odaziva sa aspekta kvalitete (npr. Ahn et al., 2007; Aladwani i Palvia, 2002; Cheung i Lee, 2005; Poelmans et al., 2008) i upotrebljivosti (npr. Abdinnour-Helm et al., 2005; Kirakowski et al., 1998; Tate et al., 2007; Thompson i Kemp; 2009) web mjesta. Ukoliko se u obzir uzme sve navedeno, vrijeme odaziva Web 2.0 aplikacije je moguće subjektivno vrjednovati pomoću sljedećih pet čestica:

VOD1. Početna stranica Web 2.0 aplikacije se brzo učitava u web pregledniku.
VOD2. Radni prostor Web 2.0 aplikacije i elementi sučelja se brzo učitavaju u web pregledniku.
VOD3. Nije potrebno dugo čekati da se pokrenu i izvrše odabrane funkcionalnosti sučelja Web 2.0 aplikacije.
VOD4. Vrijeme odaziva Web 2.0 aplikacije je prihvatljivo.
VOD5. Tijekom izvršavanja zadatka nije dolazilo do zastoja u radu Web 2.0 aplikacije.

3.3.46 Zadovoljstvo

Krajnji cilj vrjednovanja upotrebljivosti je utvrditi razinu zadovoljstva (eng. satisfaction) korisnika (Hertzum, 2010). Ovisno o kontekstu vrjednovanja, u literaturi je moguće pronaći raznovrsne definicije ovog koncepta. Primjerice, u standardu ISO 9241-11 (1998) zadovoljstvo je definirano kao mjera udobnosti i prihvatljivosti korištenja programskim proizvodom. Prema Nielsenu (1993), zadovoljstvo predstavlja jedan od pet temeljnih atributa upotrebljivosti, a služi utvrđivanju stupnja do kojeg je sustav ugodan za korištenje. Pored toga, zadovoljstvo je kao temeljni atribut uvršten u modele namijenjene vrjednovanju upotrebljivosti koje su, između ostalih, predložili Constantine i Lockwood (1999), Preece (2001), Seffah et al. (2006) i Oztekin et al. (2009). U međunarodnom standardu ISO/IEC 9126-1 (2001), zadovoljstvo je uvršteno među četiri temeljne odrednice kvalitete u korištenju i definirano kao mjera do koje programski proizvod udovoljava korisnicima u specificiranom kontekstu korištenja. Recentni standard namijenjen vrjednovanju kvalitete programskih proizvoda (ISO/IEC, 2011a) dekomponirao je zadovoljstvo na korisnost, povjerenje, užitak i udobnost te na taj način proširio njegovu definiciju. Alonso-Ríos et al. (2010) su operacionalizirali zadovoljstvo kao sposobnost sustava da kod korisnika izazove osjećaje ugode (eng. pleasure) i interesa (eng. interest). Dok se interes odnosi na pobuđivanje pažnje i znatiželje kod korisnika, ugoda nastaje kao osjetilna reakciju na estetiku (eng. aesthetics) programskog proizvoda.

Razmatrajući ovaj atribut sa aspekta teorije potvrđivanja očekivanja (eng. Expectation-Confirmation Theory, ECT; Oliver, 1980), zadovoljstvo se oblikuje temeljem očekivanja korisnika i razine na kojoj su ta očekivanja potvrđena. Rezultati istraživanja koje su proveli Bhattacherjee (2001b) te Lee i Kwon (2011) pokazali su da zamijećena korisnost također značajno doprinosi

zadovoljstvu korisnika. Zadovoljstvo je zauzelo centralno mjesto i u modelu uspjeha informacijskog sustava kojeg su predložili DeLone i McLean (1992). U nadopunjenoj verziji spomenutog modela (DeLone i McLean, 2003), prediktori zadovoljstva su kvaliteta sustava, kvaliteta usluge, kvaliteta informacija, neto korist i korištenje. Kvaliteta sustava namijenjena je vrjednovanju poželjnih obilježja informacijskog sustava poput prilagodljivosti, dostupnosti, pouzdanosti, vremena odaziva i upotrebljivosti. Konstruktom kvalitete informacija vrjednuju se točnost, smislenost i pravovremenost informacija nastalih upotrebom informacijskog sustava. Kvaliteta usluge služi vrjednovanju cjelokupne podrške koju organizacija pruža korisniku tijekom i nakon interakcije sa informacijskim sustavom. Konstrukt korištenje obuhvaća mjere namijenjene vrjednovanju različitih aspekata interakcije sa sustavom poput primjerice navigacije. Neto korist je konstrukt kojim se mjere učinci svih interesnih strana uključenih u korištenje informacijskim sustavom. Pod interesnom se stranom podrazumijevaju subjekti na koje upotreba informacijskog sustava ima utjecaj počam od kupaca, dobavljača, zaposlenika i organizacije preko tržišta i industrije pa sve do gospodarstva pa čak i društva. Dosadašnja istraživanja su pokazala da u kontekstu Weba spomenuti konstrukti imaju značajan utjecaj na zadovoljstvo korisnika (npr. DeLone i McLean, 2004; Lin i Lee, 2006). Kako bi se utvrdilo do koje su mjere različiti aspekti interakcije sa Web 2.0 aplikacijom udovoljili korisnicima oblikovane su sljedeće četiri čestice:

ZDV1. Web 2.0 aplikacija je ispunila moja očekivanja.
ZDV2. Zadovoljan/zadovoljna sam korištenjem Web 2.0 aplikacijom.
ZDV3. Zadovoljan/zadovoljna sam sa načinom izvršavanja zadataka pomoću elemenata sučelja Web 2.0 aplikacije.
ZDV4. Web 2.0 aplikacija me se dojmila.

4. VRJEDNOVANJE

Vrjednovanje je sistematski proces mjerenja vrijednosti i značaja pojedinih obilježja web aplikacije (Gena i Weibelzahl, 2007). Osim što služi identifikaciji specifičnih problema upotrebljivosti tijekom interakcije, vrjednovanje je također namijenjeno i testiranju dostupnosti funkcionalnosti sučelja te mjerenju korisničkog iskustva (Dix et al., 2004). Brojni autori (npr. Dix et al., 2004; Gena i Weibelzahl, 2007; Rosson i Carroll, 2002) naglašavaju da vrjednovanje nikako ne smije biti isključivo rezervirano za kraj razvojnog procesa već se provoditi kontinuirano kroz sve faze životnog ciklusa web aplikacije. Shodno tome moguće je razlikovati dvije vrste vrjednovanja: formativno i sumativno.

Formativno vrjednovanje je iterativan proces koji se proteže kroz sve faze razvoja web aplikacije. Cilj mu je pravovremeno identificirati potencijalne probleme upotrebljivosti te poduzeti korektivne akcije. Posljedica neprovođenja formativnog vrjednovanja su problemi upotrebljivosti koji se manifestiraju na razini prototipa ili finalnog proizvoda. U takvim je slučajevima potrebno uložiti dodatan napor i resurse u njihovo uklanjanje. Kako do spomenutog scenarija ne bi došlo, sa formativnim je vrjednovanjem potrebno započeti u ranim fazama razvoja. Sumativno vrjednovanje se provodi na kraju ili tijekom kontrolnih točaka razvojnog ciklusa web aplikacije. Njegova je svrha utvrditi mjeru do koje web aplikacija udovoljava zahtjevima i potrebama korisnika. Osim toga, može poslužiti komparaciji konkurentnih web aplikacija.

Centralno mjesto u procesu razvoja i vrjednovanja web aplikacija pripada korisnicima. Uključivanje korisnika u formativno vrjednovanje pomaže boljem razumijevanju njihovih očekivanja vezanih uz upotrebljivost web aplikacije. S druge strane, sudjelovanje korisnika u sumativnom vrjednovanju omogućava prikupljanje podataka o njihovim dojmovima, stavovima, osjećajima i ponašajnim namjerama proizašlim iz interakcije sa web aplikacijom.

Dizajn i implementacija upotrebljivih Web 2.0 aplikacija je izazovan proces iz razloga što njihove karakteristike (O'Reilly, 2006) narušavaju osnovne principe upotrebljivosti (Hart et al., 2008; Silva i Dix, 2007). S druge strane, upotrebljivost je jedna od temeljnih odlika uspješnih web aplikacija (Gena i Weibelzahl, 2007; Offutt, 2002; Orehovački, 2010). Pod uspjehom se u kontekstu upotrebljivosti web aplikacije podrazumijeva stupanj do kojeg ona svojim obilježjima udovoljava zahtjevima korisnika te im omogućava da izvrše željene zadatke.

Kako bi se olakšalo vrjednovanje upotrebljivosti, razvijen je veliki broj metoda. Međutim, njihove se taksonomije značajno razlikuju među autorima. Generalno ih je moguće podijeliti u dvije osnovne skupine: analitičke i empirijske metode (Fernandez et al., 2011; Rosson i Carroll, 2002).

Primjenom analitičkih metoda, stručnjaci u području vrjednovanja upotrebljivosti procjenjuju usklađenost web aplikacije sa skupom smjernica. S druge strane, empirijske metode služe prikupljanju podataka od krajnjih korisnika bilo promatranjem njihove interakcije sa web aplikacijom ili direktnim ispitivanjem. Nielsen (1993) također predlaže podjelu metoda u dvije skupine: direktne koje omogućuju objektivno vrjednovanje korisničkog sučelja te indirektne primjenom kojih se upotrebljivost vrjednuje subjektivno na način da se korisnicima postavljaju pitanja. Melody i Hearst (2001) su klasificirale 128 metoda (od kojih je njih 58 prikladno za vrjednovanje web sučelja) u pet kategorija: testiranje, pregledavanje, ispitivanje, analitičko modeliranje i simulacija.

Nadovezujući se na njihov rad, Fernandez et al. (2011) su proveli iscrpno istraživanje o upotrebi metoda u kontekstu vrjednovanja web mjesta te otkrili da istraživači najčešće primjenjuju metode testiranja, pregledavanja i ispitivanja dok se metode analitičkog modeliranja i simulacije koriste znatno rjeđe. Gena i Weibelzahl (2007) su klasificirali metode prema fazi životnog ciklusa web aplikacije u kojoj se metoda najčešće primjenjuje (faza zahtjeva, faza početnog vrjednovanja i faza završnog vrjednovanja) i načinu prikupljanja podataka (prikupljanje korisničkog mišljenja i promatranje korisnika). Konačno, Seffah i Metzker (2009) su svrstali metode u sedam kategorija: ispitivanje, pregledavanje, testiranje, prototipiranje, kognitivno modeliranje, analiza korisničkih zahtjeva te analitičke i prediktivne metode. Pored navedenog, svakako je potrebno spomenuti da se metode mogu još kategorizirati temeljem vrste prikupljenih podataka (kvantitativne i kvalitativne metode) kao i na osnovi strukture procesa vrjednovanja (formalne i neformalne metode).

U posljednjih je nekoliko godina koncept korisničkog iskustva zauzeo središnje mjesto u procesu dizajna i razvoja programskih proizvoda. Potaknuti navedenom činjenicom, istraživači su oblikovali raznovrsne metode namijenjene vrjednovanju relevantnih dimenzija korisničkog iskustva. Kao rezultat višegodišnjeg istraživanja, Vermeeren et al. (2010) su identificirali 96 metoda te ih kategorizirali prema životnom ciklusu programskog proizvoda i vremenu trajanja korisničkog iskustva. S druge strane, Scapin et al. (2012) su klasificirali postojeće metode prema dimenzijama korisničkog iskustva čijem su vrjednovanju iste namijenjene te vrsti mjernih instrumenta primjenom kojih se prikupljanju podaci. Međutim, postoje dva glavna razloga zbog kojih metode vrjednovanja korisničkog iskustva u sklopu ovog poglavlja neće biti zasebno razmatrane. Prvi od njih jest da se većina identificiranih metoda već dugi niz godina primjenjuje za potrebe vrjednovanja upotrebljivosti te će shodno tome ionako biti spomenute u kontekstu metoda pregledavanja, testiranja ili ispitivanja. Naime, prema rezultatima istraživanja kojeg su proveli Bargas-Avila i Hornbæk (2011) primjena većine metoda vrjednovanja korisničkog iskustva se sastoji od prikupljanja podataka pomoću upitnika, intervjua, ciljanih skupina,

opreme za udaljeno testiranje, bilježenjem verbaliziranih misli korisnika, itd. Drugi razlog je što su pojedine metode specijalizirane za vrjednovanje samo jednog aspekta korisničkog iskustva te ih shodno tome nije moguće primijeniti u vrjednovanju identificiranih atributa kvalitete u korištenju. S druge strane, Hassenzahl (2003) smatra da su upitnici najpouzdaniji instrument mjerenja razine do koje su ostvareni hedonistički ciljevi. Pored toga, Bevan (2009b) naglašava da ne postoji suštinska razlika u načinima vrjednovanja upotrebljivosti i korisničkog iskustva. Zbog toga će u nastavku biti opisane samo one metode koje je moguće primijeniti u kontekstu vrjednovanja pragmatičnih i hedonističkih atributa kvalitete u korištenju Web 2.0 aplikacijama. Potrebno je napomenuti kako se sva razmatranja vezana uz metode vrjednovanja web aplikacija temelje na taksonomijama koje su predložili Nielsen (1993), Dix et al. (2004) te Ivory i Hearst (2001) osim na mjestima gdje je to eksplicitno drugačije naznačeno.

4.1.1 Metode pregledavanja

Metode pregledavanja (eng. inspection methods) se ubrajaju u skupinu analitičkih metoda pomoću kojih evaluatori (stručnjaci) provjeravaju usklađenost web aplikacija sa općepoznatim i prihvaćenim standardima i načelima upotrebljivosti. Navedeno se ne odnosi samo na propise međunarodnog ili nacionalnog karaktera već i na smjernice koje su temeljem dugogodišnjeg praktičnog iskustva predložili stručnjaci domene. Rezultati vrjednovanja dobiveni primjenom metoda iz ove skupine prvenstveno ovise o stručnosti i procjeni evaluatora. Metode se međusobno razlikuju prema tome da li evaluatori vrjednovanje provode zasebno ili u grupi kroz diskusiju.

4.1.1.1 Vrjednovanje prema heuristikama

Heuristika je drugi naziv za smjernicu namijenjenu razvoju novih i vrjednovanju postojećih elemenata sučelja web aplikacije. Metoda vrjednovanja prema heuristikama (eng. heuristic evaluation; Molich i Nielsen, 1990), se ubraja među najkorištenije metode pregledavanja. Cilj metode je identificirati što je moguće veći broj problema upotrebljivosti kako bi se oni tijekom sljedeće iteracije dizajna uklonili (Nielsen, 1993).

Vrjednovanje se provodi na način da manji broj evaluatora analizira do koje mjere elementi sučelja web aplikacije udovoljavaju unaprijed definiranom skupu heuristika. U većini slučajeva je riječ o deset heuristika koje je predložio Nielsen (1994, 2005). Potrebno je napomenuti da su navedene heuristike općenite te ih je prije primjene potrebno prilagoditi vrsti programskih proizvoda koji se vrjednuju kao i kontekstu njihove upotrebe. Prilagodba može uključivati

modifikaciju i/ili dekompoziciju postojećeg skupa heuristika kao i njegovu nadopunu. Isto tako, evaluator ima potpunu slobodu da tijekom vrjednovanja proširi početni skup heuristika ako to smatra svrsishodnim. U nastavku slijedi popis Nielsenovih heuristika prilagođenih kontekstu web aplikacija (Nielsen, 2005; Neil, 2009):

- **Vidljivost statusa sustava**. Web aplikacija treba putem prikladnih povratnih informacija pravovremeno obavještavati korisnika o tome što se događa. Primjerice, prikaz indikatora napretka kod učitavanja stranice, indikatora jačine lozinke kod kreiranja korisničkog računa ili poruke o dovršetku određene aktivnosti (npr. pohrana promjene nad podacima i sl.).
- **Usklađenost između sustava i stvarnog svijeta**. Nazivlje i grafički izgled elemenata sučelja trebaju biti razumljivi korisnicima. Osim toga, trebaju bi raspoređeni i pojavljivati se na prirodan i logičan način.
- **Kontrola i sloboda korisnika**. Web aplikacija mora omogućiti korisniku da na učinkovit način napusti određeni dijalog ili poništi neželjenu aktivnost. Navedeno se odnosi na dostupnost funkcionalnosti poništi (eng. undo), ponovi (eng. redo), povijest promjena (eng. revision history) i slično. Pored toga, navigacijski mehanizmi trebaju korisniku olakšati snalaženje tijekom korištenja web aplikacijom.
- **Dosljednost i standardi**. Potrebno je slijediti konvencije platforme na način da se primjenjuju slični ili jednaki nazivi, ikone te raspored elemenata sučelja kao i kod srodnih aplikacija koje korisnici upotrebljavaju već neko vrijeme. Isto tako, izgled i raspored elemenata sučelja moraju biti dosljedni u svim dijelovima aplikacije.
- **Sprječavanje pogrješaka**. Web aplikacija treba sadržavati mehanizme koji sprječavaju nastanak pogrješaka. Primjerice, onemogućavanje funkcionalnosti koje ne odgovaraju kontekstu upotrebe, primjena provjere pravopisa koja automatski predlaže ispravke, traženje potvrde od korisnika prije provedbe destruktivne aktivnosti i slično.
- **Prepoznavanje umjesto prisjećanja**. Upotreba web aplikacije treba zahtijevati minimalnu količinu mentalnog napora. Elementi sučelja trebaju biti vidljivi i dostupni korisnicima kada im je to potrebno. Osim toga, korisnici ne bi trebali pamtiti informacije od jednog dijela dijaloga do drugog. Primjerice, web aplikacija za obradu teksta uz naziv pojedinog fonta nudi i njegov prikaz što korisniku olakšava formatiranje teksta.
- **Fleksibilnost i učinkovitost korištenja**. Web aplikacija treba sadržavati popis kratica (kombinacija tipaka na tipkovnici za često korištene aktivnosti poput kopiranja, pohrane i slično) koji povećavaju radnu učinkovitost korisnika. Također treba omogućiti prilagodbu i prikaz često korištenih akcija. Primjerice, web aplikacija za tablične proračune prikazuje mjere centralne tendencije za odabran skup ćelija sa vrijednostima.

- **Estetika i minimalistički dizajn**. Sučelje treba sadržavati samo one funkcionalnosti koje odgovaraju ili su potrebne tijekom određenog konteksta korištenja. Svaki dodatan element sučelja smanjuje vidljivost važnih i potrebnih funkcionalnosti. Vizualni izgled treba poštivati načela kontrasta, ponavljanja, poravnanja i udaljenosti.
- **Pomoć korisnicima kod prepoznavanja, dijagnoze i oporavka od pogrješaka**. Poruke vezane uz pogrješke trebaju biti sročene na način da razumljivo i precizno objasne problem te predlože konstruktivan način njegovog rješavanja. Primjerice, slanje informacije o nastalim pogrješkama razvojnom timu ili službi za korisnike.
- **Pomoć i dokumentacija**. Premda je bolje da se web aplikacija može upotrebljavati bez konzultiranja materijala pomoći, isti trebaju biti vidljivi i dostupni. Materijali pomoći trebaju biti koncizni, jednostavni za pretraživanje te sadržavati konkretne primjere za rješavanje specifičnih problema. Sastavni dio pomoći mogu biti često postavljana pitanja, forumi za diskusiju te video tutorijali za korisnike početnike.

Svaki evaluator prolazi kroz interakciju sa web aplikacijom najmanje dvaput. Tijekom prvog prolaza evaluator se upoznaje sa web aplikacijom i rasporedom funkcionalnosti njena sučelja što mu omogućuje da za vrijeme drugog prolaza bude bolje usredotočen na vrjednovanje prema heuristikama. Potrebno je naglasiti da evaluatori zasebno vrjednuju web aplikaciju čime se osigurava nezavisnost i nepristranost prikupljenih podataka. Rezultat primjene ove metode je popis problema upotrebljivosti odnosno narušenih heuristika. Svakom identificiranom problemu evaluator treba odrediti jačinu preko sljedeće skale (Nielsen, 1993):

- 0 – nije problem upotrebljivosti,
- 1 – kozmetički problem koji se rješava na kraju,
- 2 – manji problem sa niskim prioritetom rješavanja,
- 3 – značajan problem sa visokim prioritetom rješavanja,
- 4 – katastrofalan problem kojeg je potrebno riješiti što prije.

Nakon što evaluatori dovrše vrjednovanje, njihovi se popisi spajaju u jednu cjelinu. U sljedećem se koraku izračunava srednja vrijednost jačine svakog identificiranog problema upotrebljivosti koja služi kao indikator za određivanje prioriteta njegovog rješavanja tijekom faze redizajna. Obzirom da jedan evaluator može otkriti samo 35% ukupnih problema upotrebljivosti i da evaluatori imaju tendenciju pronaći različite probleme upotrebljivosti, skupina evaluatora treba biti što je moguće veća i heterogenija (Nielsen, 1993). Kao što je prikazano na slici 4.1, da bi postotak identificiranih problema bio prihvatljiv, poželjno je da u vrjednovanju sudjeluje barem petero evaluatora no nikako ne manje od troje. Međutim, neki istraživači smatraju da petero

evaluatora nije ni približno dovoljno da bi se otkrili svi relevantni problemi upotrebljivosti (Spool i Schroeder, 2001).

Osnovna prednost vrjednovanja prema heuristikama je u njenoj učinkovitosti i ekonomičnosti. Naime, metoda je sastavni dio inženjeringa diskontne upotrebljivosti (eng. discount usability engineering; Nielsen, 1989) što znači da je njenom primjenom moguće u kratkom vremenskom razdoblju i uz relativno mali broj evaluatora otkriti značajnu količinu problema upotrebljivosti. Ono što je najvažnije je da se sve to može postići bez uključivanja krajnjih korisnika. Osim toga, postoje tri različita načina na koje se metoda može primijeniti (Nielsen, 1993). Prvi se odnosi na vrjednovanje nacrta ili makete buduće web aplikacije. Drugi je da evaluatori tijekom vrjednovanja prolaze kroz unaprijed pripremljene korake scenarija za koje se vjeruje da bi ih korisnici izvršavali tijekom interakcije sa web aplikacijom. Prema posljednjem načinu vrjednovanja evaluator ne izvršava zadatke pomoću web aplikacije već samo pregledava elemente njenog sučelja. Zbog navedenih je karakteristika metoda primjenjiva u svim fazama životnog ciklusa web aplikacije. Obzirom da se primjenom metode može pravovremeno identificirati i ukloniti značajan broj problema upotrebljivosti, vrjednovanje prema heuristikama često prethodi ili se primjenjuje u kombinaciju sa metodama u koje su uključeni korisnici poput razmišljanja naglas ili terenskog ispitivanja.

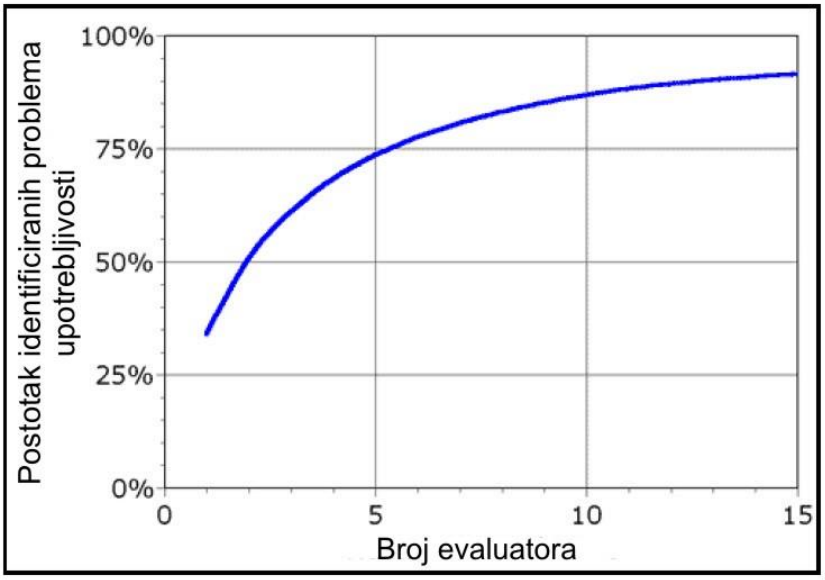

Slika 4.1 Omjer postotka identificiranih problema upotrebljivosti i potrebnog broja evaluatora
Izvor: Nielsen (1992)

Najveći nedostatak metode je što kvaliteta rezultata ovisi o znanju i vještinama evaluatora. Naime, Nielsen (1992) je svojim istraživanjem otkrio da dvostruki stručnjaci (istovremeno posjeduju ekspertizu domene i ekspertizu vrjednovanja upotrebljivosti) imaju 1,5 puta veću

učinkovitost u otkrivanju problema upotrebljivosti od jednostrukih stručnjaka (imaju samo ekspertizu u vrjednovanju upotrebljivosti) te čak 2,7 puta veću učinkovitost od evaluatora početnika (bez navedenih ekspertiza, ali posjeduju osnovnu računalnu pismenost). Prema tome, ukoliko se vrjednovanjem prema heuristikama žele dobiti optimalni rezultati, u njemu trebaju sudjelovati dvostruki stručnjaci. Drugi nedostatak je vezan uz to što evaluatori mogu biti pristrani te na taj način podcijeniti ili precijeniti značaj i jačinu pojedinih problema upotrebljivosti. Treći problem je vezan uz činjenicu da evaluatori nisu nužno ciljani korisnici web aplikacije što znači da ne mogu sa potpunom sigurnošću odrediti kako će pojedini problem biti zamijećen sa njihove strane. Konačno, recentna su istraživanja pokazala da metoda nije prikladna za vrjednovanje Web 2.0 aplikacija (Hart et al., 2008; Silva i Dix, 2007; Thompson i Kemp, 2009).

4.1.1.2 Kognitivna šetnja

Primjena metode kognitivne šetnje (eng. cognitive walkthrough; Polson et al., 1992; Wharton et al., 1994) se sastoji od toga da evaluatori prolaze kroz unaprijed definiran skup koraka scenarija te simuliraju ponašanje korisnika tijekom rješavanja zadataka. Cilj metode je utvrditi stupanj razumljivosti elemenata sučelja te lakoću učenja korištenja web aplikacijom. Preduvjeti za provedbu metode su sljedeći (Wharton et al., 1994):

- detaljna specifikacija ili maketa web aplikacije odnosno njen prototip ili implementacija (ovisno o razvojnoj fazi tijekom koje se metoda primjenjuje),
- popis reprezentativnih zadataka koje korisnik upotrebom funkcionalnosti sučelja web aplikacije treba biti u mogućnosti dovršiti,
- lista aktivnosti koje korisnik treba poduzeti da bi izvršio pojedini zadatak te
- potrebna vrsta i količina predznanja, vještine i ostale karakteristike potencijalnih korisnika web aplikacije.

Uzimajući u obzir spomenute preduvjete, evaluatori za vrijeme kognitivne šetnje temeljito analiziraju svaku pojedinu aktivnost te kroz interpretaciju mogućih postupaka korisnika pokušavaju konstruirati pozitivan ili negativan ishod scenarija. Pri tome odgovaraju na sljedeća pitanja (prilagođeno prema Wharton et al., 1994):

- Da li će korisnik odabrati ispravan način izvršavanja zadatka?
- Da li će korisnik primijetiti funkcionalnosti sučelja potrebne za izvršavanje zadatka?
- Da li će korisnik shvatiti koje ga funkcionalnosti sučelja vode prema dovršenju zadatka?

- Da li će korisnik po odabiru ispravnih funkcionalnosti sučelja razumjeti povratne informacije web aplikacije?

Svaki negativni odgovor na navedena pitanja je indikator problema upotrebljivosti. Rezultat primjene metode je opis, učestalost i značaj svakog identificiranog problema upotrebljivosti. Od glavnih nedostataka metode potrebno je izdvojiti sporost provedbe i izoliranost krajnjih korisnika (Plantak Vukovac i Orehovački, 2010).

4.1.1.3 Multidisciplinarna kognitivna šetnja

Metoda multidisciplinarne kognitivne šetnje (eng. pluralistic walkthrough; Bias, 1991) se primjenjuje u slučajevima kada dvostruki stručnjaci nisu dostupni za sudjelovanje u vrjednovanju. Kao nadomjestak za njihovu stručnost i učinkovitost u otkrivanja problema, u vrjednovanju pored jednostrukih stručnjaka sudjeluju i predstavnici uzorka reprezentativnih korisnika i razvojnih programera. Metoda se sastoji od dva dijela. U prvom svaki od evalautora zasebno vrjednuje web aplikaciju. Nakon toga slijedi diskusija tijekom koje predstavnici sve tri skupine evaluatora još jednom prolaze kroz elemente sučelja web aplikacije te komentiraju potencijalne probleme upotrebljivosti. Kako stručnjaci ne bi dominirali diskusijom, Bias (1991) predlaže da korisnici budu ti koji će u svakoj iteraciji diskusije prvi iznijeti svoje mišljenje.

Prednost metode leži u činjenici da se podaci o upotrebljivosti web aplikacije mogu prikupiti u ranim fazama njena razvoja. Osim toga, korisnici mogu razvojnim programerima postavljati pitanja na način kako bi tijekom interakcije sa web aplikacijom rješavali zadatke ili konzultirali materijale online pomoći što može poslužiti kao indikator za implementaciju određenih funkcionalnosti sučelja te kao pomoć u razvoju materijala pomoći korisnicima.

4.1.1.4 Perspektivan pregled

Metoda perspektivnog pregleda (eng. perspective-based inspection) polazi od pretpostavke da postojeće metode pregledavanja nisu dovoljno učinkovite u identifikaciji problema upotrebljivosti. Stoga Zhang et al. (1998) predlažu da se tijekom procesa vrjednovanja svaki evaluator usredotoči samo na one probleme koji su obuhvaćeni jednom od tri različite perspektive upotrebljivosti. Sastavni dio svake perspektive je lista pitanja odnosno potencijalnih problema upotrebljivosti te procedura provedbe vrjednovanja. Prema perspektivi korisnika početnika (eng. novice user), evaluator procjenjuje koliko uspješno korisnik koji po prvi put upotrebljava web aplikaciju može izvršiti željene aktivnosti. Navedeno se odnosi na lakoću

učenja, pronalaženje funkcionalnosti sučelja, razumljivost rezultata provedbe pojedinih aktivnosti i povratnih informacija koje prikazuje web aplikacija i slično.

U kontekstu perspektive iskusnog korisnika (eng. expert user) vrjednuje se učinkovitost, fleksibilnost i dosljednost u izvršavanju zadataka te vizualni izgled i organizacija elemenata sučelja. Vezano uz perspektivu upravljanja pogrješkama (eng. error handling), evaluator na osnovi klasifikacije pogrješaka procjenjuje izglednost nastanka korisničkih pogrješaka i prekida u radu web aplikacije. Nakon toga evaluator provjerava učestalost nastanka pojedinih pogrješaka, razumljivost poruka vezanih uz pogrješke, načine oporavka od pogrješaka i slično. Rezultati istraživanja su otkrili da se kombinacijom spomenutih perspektiva može otkriti 30% više problema upotrebljivosti nego primjenom klasičnog vrjednovanja prema heuristikama (Zhang et al., 1999).

4.1.1.5 Pregled funkcionalnih dijelova

Svrha metode pregleda funkcionalnih dijelova (eng. feature inspection; Nielsen i Mack, 1994) jest identifikacija problema upotrebljivosti koji se mogu manifestirati tijekom izvršavanja zadataka pomoću pojedinih elemenata sučelja web aplikacije. Metoda se primjenjuje na način da evaluator prema unaprijed definiranim koracima scenarija interakcije analizira različite aspekte upotrebljivosti (dostupnost, korisnost, pristupačnost, razumljivost, lakoću pronalaženja i sl.) svih funkcionalnosti sučelja potrebnih za njihovu provedbu. Ulogu evaluatora imaju članovi razvojnog tima zaduženi za izradu dokumentacije i materijala pomoći korisnicima.

4.1.1.6 Formalni pregled

Metoda formalnog pregleda (eng. formal usability inspection; Kahn i Prail, 1994) predstavlja prilagodbu tehnike pregleda programskih proizvoda kontekstu vrjednovanja upotrebljivosti. Cilj metode je povećati učinkovitost u otkrivanju problema upotrebljivosti tijekom ranijih razvojnih faza web aplikacije. Provedba metode započinje okupljanjem tima sačinjenog od četiri do osam predstavnika interesnih strana (dizajneri, razvojni programeri, osiguranje kvalitete, tehnička podrška, dokumentacija i slično). Svaki član tima obavlja barem jednu od sljedećih uloga:

- Moderator je osoba koja vodi sastanak, distribuira dokumentaciju, prikuplja rezultate vrjednovanja te upravlja procesom korekcije odnosno uklanjanja problema upotrebljivosti.

- Vlasnik je dizajner vrjednovane web aplikacije zadužen za ispravljanje problema upotrebljivosti.
- Zapisničar vodi evidenciju o identificiranim problemima upotrebljivosti tijekom formalnog sastanka.
- Evaluatori su preostali članovi tima koji vrjednuju web aplikaciju te potom za vrijeme formalnog sastanka izvještavaju o identificiranim problemima upotrebljivosti. Moderator i vlasnik se također mogu naći u ulozi evaluatora.

U sljedećem se koraku članovima tima distribuira dokumentacija vezana uz vrjednovanje web aplikacije (detaljna specifikacija ili maketa, profili korisnika, lista reprezentativnih zadataka, popis heuristika te formular za evidenciju problema upotrebljivosti). Nakon toga svaki od članova tima zasebno provodi vrjednovanje prema heuristikama. Po završetku vrjednovanja, članovi tima se formalno sastaju gdje svaki od njih komentira pojedini korak ili zadatak scenarija te navodi identificirane probleme upotrebljivosti. Ukoliko se svi članovi tima slože oko pojedinog problema upotrebljivosti, zapisničar ga i službeno evidentira kao takvog. Svim evidentiranim problemima se određuje prioritet te se isti dodjeljuju odgovornim osobama (vlasnicima) na rješavanje. Iz svega navedenog je evidentno da metoda nije ništa drugo već formalan oblik vrjednovanja prema heuristikama.

4.1.1.7 Pregledavanje dosljednosti

Pregledavanje dosljednosti (eng. consistency inspection; Wixon et al., 1994) se primjenjuje u slučajevima kada svaki tim razvija samo jedan dio web aplikacije koji će se kasnije integrirati u jednu cjelinu. Primjerice, u razvoju web sustava za upravljanje dokumentima, svaki tim može biti zadužen za razvoj funkcionalnosti i sučelja samo jedne aplikacije (npr. Zoho Docs). Cilj primjene metode je ujednačiti dizajn i raspored elemenata sučelja kroz sve dijelove web aplikacije. U provedbi metode sudjeluju predstavnici svih razvojnih timova. Primjena metode započinje analizom sučelja zasebnih dijelova web aplikacije koju provodi stručnjak u području vrjednovanja upotrebljivosti. Rezultat analize će biti popis razlika među pojedinim sučeljima. U sljedećem se koraku sastaju predstavnici razvojnih timova kako bi na osnovi rezultata analize donijeli odluku o uniformnom dizajnu.

4.1.1.8 Usklađenost sa standardima

Svrha metode je osigurati da web aplikacija bude usklađena sa standardima ili njihovim dijelovima koji se odnose na upotrebljivost (npr. ISO/IEC 25010, 2011). Primjena metode se

sastoji od toga da stručnjak u području upotrebljivosti koji je istovremeno vrlo dobar poznavatelj ciljanog standarda provjerava do koje mjere web aplikacija udovoljava pojedinim aspektima upotrebljivosti koji su standardom propisani.

4.1.1.9 Usklađenost sa smjernicama

Namjena metode je provjeriti do koje su se mjere dizajneri i programeri tijekom razvoja web aplikacije pridržavali temeljnih principa upotrebljivosti koji su sastavni dio relevantnih smjernica. Premda se postojeće smjernice mogu upotrebljavati u obliku u kojem su objavljene, većina ih je jako detaljna te ih je potrebno prilagoditi vrsti programskog proizvoda koji se vrjednuje. Kako bi se olakšala procjena usklađenosti sa smjernicama upotrebljivosti i pristupačnosti, Vanderdonckt i Beierekdar (2005) predlažu automatizaciju procesa vrjednovanja kroz statičku analizu HTML koda web mjesta. Iz mnoštva primjera smjernica svakako je potrebno izdvojiti principe dizajna usmjerenog na korisnika (Norman, 1988) kao i osam zlatnih pravila dizajna sučelja (Shneiderman, 1998). U kontekstu vrjednovanja web mjesta, Travis (2009) je predložio 247 smjernica koje obuhvaćaju upotrebljivost početne stranice, izvršavanje zadataka, arhitekturu navigacije i informacija, formulare i unos podataka, povjerenje i vjerodostojnost, kvalitetu sadržaja, izgled i dizajn stranice, pretraživanje, materijale pomoći, povratne informacije i toleranciju pogrješaka.

4.1.2 Metode testiranja

Metode testiranja pripadaju skupini empirijskih metoda vrjednovanja. Njihovom primjenom se dobivaju direktni podaci o problemima upotrebljivosti koji nastanu tijekom interakcije korisnika sa web aplikacijom. Testiranje se sastoji od toga da korisnik upotrebom funkcionalnosti sučelja web aplikacije izvršava skup unaprijed definiranih zadataka dok evaluator ili specijalizirani programski proizvod bilježi rezultate vrjednovanja. Metode iz ove skupine se međusobno razlikuju prema ponašanju korisnika za vrijeme testiranja (primjerice rade u tišini, razmišljaju naglas, postavljaju pitanja, itd.).

4.1.2.1 Razmišljanje naglas

Razmišljanje naglas (eng. think-aloud protocol; Lewis, 1982) se ubraja među najkorisnije metode testiranja (Nielsen, 1993). Sastoji se od toga da korisnici tijekom interakcije sa web aplikacijom verbaliziraju svoje misli te na taj način interpretiraju svaki element sučelja kojeg su upotrebljavali. Zbog toga se ova metoda još naziva i istovremeno razmišljanje naglas (eng.

concurrent think-aloud). Postoje dvije osnovne varijante ove metode: kritički odgovor (eng. critical response) i periodički izvještaj (eng. periodic report). Razlika među njima je u tome što kod kritičkog odgovora korisnik razmišlja naglas za vrijeme izvršavanja predefiniranih zadataka dok u slučaju periodičkog izvještaja korisnik tijekom unaprijed određenih vremenskih intervala objašnjava naglas svoj status interakcije sa web aplikacijom. Periodički izvještaj se upotrebljava u situacijama kada je potrebno izvršiti složene zadatke zbog čega je provedba protokola kritičkog odgovora otežana. Primjena ove metode omogućava evaluatoru da shvati mentalni model korisnika te mu olakšava identifikaciju problema upotrebljivosti.

Prednost metode je da se od malog uzorka korisnika može prikupiti velika količina kvalitativnih podataka. Međutim, kod njihove interpretacije valja biti oprezan jer korisnici imaju sklonost određenim aspektima interakcije pridodati veći značaj nego što on zaista jest. Primjerice, korisnik može prokomentirati da web aplikacija ne sadrži određenu funkcionalnost sučelja, no stvarna je situacija da korisnik zapravo nije pristupio izvršavanju zadatka na ispravan način. Stoga je protokol razmišljanja naglas preporučljivo kombinirati sa ostalim metodama vrjednovanja (primjerice metodom praćenja očiju ili automatskim zapisivanjem postupaka) kako bi se uz komentare korisnika prikupili podaci i o načinu rješavanja zadataka. Od nedostataka je svakako potrebno izdvojiti činjenicu da je protokol većini korisnika neprirodan zbog čega isti trebaju uložiti dodatnu količinu koncentracije i truda u njegovu provedbu. Navedeno rezultira značajnim smanjenjem radne učinkovitosti korisnika te se stoga protokol ne može primijeniti u kombinaciji sa metodom mjerenja radnog učinka korisnika.

4.1.2.2 Postavljanje pitanja

Kako bi se uklonio osjećaj neprirodne verbalizacije misli, kao alternativa protokolu razmišljanja naglas predložena je metoda postavljanja pitanja (eng. question-asking protocol; Nielsen, 1993). Tijekom primjene metode, evaluator postavlja pitanja čime potiče korisnika da izrazi svoje mišljenje vezano uz elemente sučelja web aplikacije ili način izvršavanja zadatka. Na ovaj način evaluator dobiva kompletniju sliku o kvaliteti interakcije korisnika sa web aplikacijom što mu olakšava identifikaciju problema upotrebljivosti. Međutim, metoda se zbog načina provedbe također ne može kombinirati sa metodom mjerenja radnog učinka korisnika.

4.1.2.3 Konstruktivna interakcija

Metoda konstruktivne interakcije (eng. construcitve interaction; O'Malley et al., 1984) ili učenja zajedničkim otkrivanjem (eng. codiscovery learning; Kennedy, 1989) se sastoji od toga da

evaluator promatra ponašanje i postupke dvoje korisnika koji upotrebom pojedinih funkcionalnosti sučelja kroz razgovor i suradnju pokušavaju zajedničkim snagama riješiti unaprijed definiran skup zadataka. Najvažniji aspekt ove metode je interakcija među korisnicima jer temeljem nje evaluator donosi zaključke o upotrebljivosti web aplikacije. Kako bi učinak primjene metode bio što veći, poželjno je da se upareni korisnici poznaju od prije. Naime, pojedincima često zna biti neugodno ili neobično surađivati i raspravljati o rješenju problema sa neznancima (Nielsen, 1993). Nedostatak metode je što u eksperimentu treba sudjelovati dva puta više korisnika nego kod ostalih oblika protokola razmišljanja naglas.

4.1.2.4 Izravni prijenos

Metoda izravnog prijenosa (eng. shadowing method) je još jedna u nizu alternativa protokolu razmišljanja naglas. Sastoji se od toga da tijekom procesa vrjednovanja stručnjak sjedi do evaluatora te mu objašnjava ponašanje i postupke korisnika (Zhang, 2007). Uglavnom se primjenjuje u situacijama kada korisnicima nije prikladno razmišljati naglas ili kada se istovremeno mjeri i radni učinak korisnika u izvršavanju zadataka.

4.1.2.5 Odgođeno emitiranje

Primjena metode odgođenog emitiranja (eng. retrospective testing; Nielsen, 1993) ili retrospektivnog razmišljanja naglas (eng. retrospective think-aloud; Guan et al., 2006) se sastoji od dva koraka. U prvom se upotrebom video kamere snima interakcija korisnika i web aplikacije dok u drugom za vrijeme reprodukcije generiranog video zapisa korisnik evaluatoru objašnjava svoje ponašanje i postupke tijekom rješavanja zadataka. Evaluator u svakom trenutku može zaustaviti snimku te postaviti korisniku dodatna pitanja kako bi prikupio što više informacija o njegovom mentalnom modelu web aplikacije. Kako bi se korisnik mogao što točnije prisjetiti o čemu je razmišljao i što je pokušavao napraviti tijekom pojedinog koraka scenarija, provedba drugog dijela ove metode bi u najboljem slučaju trebala nastupiti odmah nakon eksperimenta. Prednost metode je što njena primjena ne utječe na učinkovitost korisnika tijekom izvršavanja zadataka te se zbog toga može primijeniti u kombinaciji sa metodom mjerenja radnog učinka korisnika.

Od nedostataka je potrebno izdvojiti odstupanja u prikupljenim podacima iz razloga što su korisnici u međuvremenu zaboravili određene aspekte interakcije. Osim toga, korisnici mogu izmisliti neke činjenice o interakciji, prešutjeti ih, ili ih iz nekog razloga promijeniti (Van den Haak et al., 2003). Konačno, evaluator sa svakim korisnikom mora dva puta prolaziti kroz isti

scenarij što utječe na povećanje troškova provedbe metode. Zbog toga se kao alternativa mogu koristiti retrospektivni izvještaji u kojima korisnici prema unaprijed pripremljenim uputama opisuju postupke tijekom izvršavanja zadatka s naglaskom na probleme upotrebljivosti. Recentna istraživanja su potvrdila učinkovitost retrospektivnih izvještaja u identifikaciji problema upotrebljivosti Web 2.0 aplikacija (Orehovački, 2011a; Orehovački et al., 2013).

4.1.2.6 Stručno podučavanje

Tijekom provedbe metode stručnog podučavanja (eng. coaching method; Mack i Burdett, 1992) korisnik ima mogućnost da svaki put kada naiđe na problem u interakciji sa web aplikacijom evaluatoru postavi pitanje. U takvim situacijama evaluator preuzima ulogu stručnjaka te pokušava odgovoriti na sva pitanja što je moguće kvalitetnije i detaljnije. Svrha metode je otkriti potrebe korisnika kako bi se temeljem njih: a) pripremila što kvalitetnija dokumentacija i materijali online pomoći, b) poduzele korektivne akcije tijekom faze redizajna i na taj način olakšalo učenje korištenja web aplikacijom i c) uklonila potreba za postavljanjem pitanja. Puno učinkovitija varijanta primjene metode je kada ulogu stručnjaka ima iskusni korisnik jer se tada evaluator može bolje usredotočiti na identifikaciju problema upotrebljivosti. Osim toga, evaluator može na osnovi interakcije između korisnika i stručnjaka prikupiti podatke o njihovim mentalnim modelima web aplikacije te ih usporediti.

U slučajevima kada u vrjednovanju sudjeluje veliki broj korisnika, stručnjak može davati alternativne odgovore te tako omogućiti evaluatoru da utvrdi koji oblik i vrsta informacija najviše pomažu korisnicima u rješavanju problema. Od prednosti metode valja istaknuti činjenicu da su korisnici motivirani sudjelovati u eksperimentu zbog toga što uz pomoć stručnjaka mogu u vrlo kratkom periodu postati vješti u korištenju web aplikacijom. S druge strane, evaluator ih kasnije može angažirati u eksperimentima koji od sudionika iziskuju određenu razinu stručnosti (npr. vrjednovanje prema heuristikama, kognitivna šetnja i slično).

4.1.2.7 Učenje

Primjena metode učenja (eng. teaching method; Vora i Helander, 1995) započinje tako da se korisniku početniku (sudioniku) omogući da određeno vrijeme samostalno provede u interakciji sa web aplikacijom kako bi naučio koristiti se njome. Nakon toga se sudioniku dodijeli korisnik početnik kojem on kroz rješavanje predefiniranih zadataka objašnjava kako se upotrebljavaju pojedine funkcionalnosti sučelja web aplikacije. Tijekom ovog procesa korisnik početnik ima

pasivnu ulogu promatrača te mu nije dozvoljeno sudjelovati u rješavanju zadatka. Svrha ove metode je vrjednovanje lakoće učenja korištenja web aplikacijom.

4.1.2.8 Mjerenje radnog učinka korisnika

Metoda mjerenja radnog učinka korisnika (eng. performance measurement; Tyldesley, 1988; Nielsen, 1993) je namijenjena vrjednovanju objektivnih atributa upotrebljivosti web aplikacije. Mjerenje se provodi u laboratoriju pod kontroliranim uvjetima čime se minimizira mogućnost ometanja ili prekidanja korisnika tijekom eksperimenta. Metoda se provodi na način da korisnici izvršavaju predefinirani skup zadataka pri čemu se mjeri (Tullis i Albert, 2008):

- količina vremena potrebna za dovršetak pojedinog zadatka,
- količina vremena potrebna za dovršetak scenarija,
- postotak uspješno dovršenih zadataka,
- postotak uspješno dovršenih zadataka u jedinici vremena,
- količina pogrješaka u rješenjima zadataka, itd.

Prikupljeni podaci mogu poslužiti komparaciji web aplikacije sa srodnim aplikacijama. Isto tako, dobiveni rezultati se mogu uspoređivati sa uvriježenim pokazateljima (eng. benchmark). Ukoliko se zaključci temeljeni na prikupljenim podacima žele generalizirati, zadaci koji su upotrijebljeni tijekom eksperimenta moraju biti reprezentativni. Konačno, kako bi rezultati vrjednovanja upotrebljivosti bili što potpuniji, metodu je potrebno kombinirati sa metodama namijenjenim prikupljanju subjektivnih kvalitativnih (npr. odgođeno emitiranje ili intervju) i kvantitativnih podataka (npr. upitnik).

4.1.2.9 Automatsko zapisivanje postupaka

Metoda automatskog zapisivanja postupaka (eng. logging actual use; Nielsen, 1993) omogućava prikupljanje kvantitativnih podataka tijekom interakcije sa web aplikacijom. Navedeno uključuje način i učestalost korištenja pojedinim funkcionalnostima sučelja, vrstu i količinu pogrješaka koje su se javljale tijekom izvršavanja zadataka, frekvenciju upotrebe ulazno-izlaznih jedinica (npr. broj klikova mišem, broj pritisnutih tipaka na tipkovnici, itd.), učestalost konzultiranja materijala pomoći i slično. Prikupljeni podaci se mogu analizirati zasebno ili poslužiti rekonstrukciji cjelokupne interakcije sa web aplikacijom (Nielsen, 1993). Na osnovi prikupljenih podataka donose se odluke vezane uz redizajn sučelja. Primjerice, ukoliko pojedine funkcionalnosti sučelja nisu korištene to može biti indikator problema upotrebljivosti vezanih uz upravljivost (eng. navigability). S druge strane, navedeno može isto tako značiti da im tijekom

korištenja web aplikacijom pojedine funkcionalnosti nisu bile potrebne. Osim toga, podaci o učestalosti pojavljivanja pojedinih pogrješaka ukazuju na potrebu poduzimanja korektivnih akcija koje će spriječiti njihov nastanak u budućnosti, a u situacijama kada će to biti neizbježno da poruke o pogrješkama budu što razumljivije i konstruktivnije.

Podaci se prikupljaju na računalu kroz intervenciju na razini pogonskog programa (eng. driver) ulazno izlazne jedinice, sustava za upravljanje korisničkim sučeljem (eng. user interface management system, UIMS) ili instalacijom programa specijaliziranog za automatsko prikupljanje podataka (npr. Mousotron; Blacksun Software, 2012). Po završetku eksperimenta, podaci se mogu slati automatski, mogu ih korisnici poslati elektroničkom poštom ili ih evaluatori preuzimaju osobno.

Prednost automatskog zapisivanja postupaka jest što se mogu prikupiti objektivni podaci o interakciji sa web aplikacijom i problemima upotrebljivosti sa kojima se korisnici suočavaju. Međutim, obzirom da je riječ o kvantitativnim pokazateljima iz kojih nije moguće razaznati razloge određenih postupaka korisnika, metodu je potrebno kombinirati sa ostalim metodama poput primjerice intervjua. Potrebno je naglasiti da su karakteristike automatskog zapisivanja postupaka danas sastavni dio nešto sofisticiranijih metoda poput praćenja očiju i analitike web mjesta.

4.1.2.10 Analitika web mjesta

Analitika web mjesta (eng. web analytics) je metoda objektivnog praćenja, mjerenja, prikupljanja i analize podataka te izrade izvještaja sa svrhom boljeg razumijevanja načina upotrebe web aplikacije i njene optimizacije (Digital Analytics Association, 2006). Postoje dvije osnovne vrste analitike: izvan web mjesta (eng. off-site) te u sklopu web mjesta (eng. on-site). Svrha analitike izvan web mjesta je utvrditi marketinške indikatore uspjeha (npr. pozicija u rezultatima pretraživanja odabranih web tražilica, ključne riječi preko kojih korisnici pronalaze web aplikaciju, trendovi na tržištu, usporedba sa konkurentnim web aplikacijama i slično) te demografske karakteristike korisnika web aplikacije. Podaci se mogu prikupljati na tri načina: od skupine korisnika (eng. panel based measurement), pružatelja usluge spajanja na Internet (eng. Internet Service Provider, ISP) i od web tražilica. Prikupljanje podataka od korisnika obuhvaća instalaciju specijaliziranog softvera koji evidentira sve online aktivnosti korisnika te ih šalje proxy poslužitelju pružatelja usluge (npr. comScore). Premda se na ovaj način može prikupiti velika količina demografskih podataka koje je moguće povezati sa specifičnom vrstom online ponašanja, sudionici često ne predstavljaju reprezentativan uzorak korisnika određene web aplikacije.

Experian Hitwise je primjer posebne vrste softvera koji na osnovi podataka prikupljenih od strane pružatelja usluga spajanja na Internet generira izvještaje o ponašanju korisnika na Webu. Premda je riječ o velikom i reprezentativnom uzorku, rezultati analize ne pružaju dovoljno detaljne podatke o postupcima korisnika tijekom interakcije sa specifičnom web aplikacijom. Podaci o učestalosti pretraživanja po određenim ključnim riječima segmentirani po regiji i jeziku pretraživanja mogu se dobiti od servisa kao što je Google Trends. Riječ je o besplatnom i korisnom, no istovremeno i vrlo ograničenom izvoru podataka.

Analitika u sklopu web mjesta služi praćenju ponašanja korisnika tijekom interakcije sa web mjestom te se provodi pomoću dvije metode: analize datoteke dnevnika (eng. log file analysis) i označavanja stranica (eng. page tagging). Analiza datoteke dnevnika se primjenjuje na način da specijalizirani softver (npr. Webalizer ili Awstats) temeljem podataka pohranjenih u datoteci dnevnika generira izvještaje o broju posjeta, trajanju posjeta, državama iz koje korisnici dolaze, web preglednicima koje su korisnici upotrebljavali, tražilicama i ključnim riječima pomoću kojih su pronašli web mjesto, HTTP pogrješkama, najčešće posjećenim stranicama i slično. Od prednosti ovog pristupa potrebno je izdvojiti činjenicu da se datoteka dnevnika i softver za analizu nalaze na istom poslužitelju te što se podaci za analizu prikupljaju automatski. Međutim, metoda analize datoteke dnevnika ima nekoliko ozbiljnih nedostataka (Aivalis i Boucouvalas, 2011): a) ne podržava evidentiranje interakcije sa elementima sučelja implementiranim u AJAX-u ili Flashu; b) podaci o interakciji se ne evidentiraju u datoteku dnevnika kada je stranica web mjesta pohranjena u privremenu memoriju (eng. cache) što utječe na smanjenje preciznosti prikupljenih podataka, a time i rezultata u generiranim izvještajima; c) datoteka dnevnika se povećava proporcionalno sa količinom prometa na web mjestu te je stoga za njenu pohranu potrebno osigurati dovoljno prostora na web poslužitelju; d) obzirom da se u datoteku dnevnika pohranjuju sve transakcije, potrebno je podesiti mehanizme koji će filtrirati sve unose koji nisu predmet interesa analize.

Primjena metode označavanja stranica se sastoji od toga da se u svaku stranicu web mjesta implementira manji odsječak koda koji služi prikupljanju podataka i njihovoj pohrani na web poslužitelju. Pružatelj usluge temeljem pohranjenih podataka generira statističke podatke o aktivnostima korisnika koje istraživač može pregledati. Na osnovi prikupljenih podataka generiraju se izvještaji o aktivnostima korisnika koje istraživač može pratiti i pregledavati u sklopu web mjesta pružatelja usluge (npr. Google Analytics ili Clicktale). Izvještaji nastali primjenom ove metode variraju između pružatelja usluga, a mogu uključivati reprodukciju svih postupaka korisnika, toplinske karte na osnovi aktivnosti mišem i slično. Od prednosti označavanja stranica potrebno je izdvojiti mogućnost evidencije postupaka korisnika u skoro pa realnom vremenu, preciznost prikupljenih podataka, te evidenciju elemenata sučelja

implementiranih u AJAX-u i Flashu (Aivalis i Boucouvalas, 2011). Glavni nedostatak metode je što korisnik ili vatrozid mogu blokirati implementiranu skriptu te time onemogućiti prikupljanje podataka. Potrebno je napomenuti da se označavanje stranice može primijeniti samo u slučaju ako je evaluator vlasnik web aplikacije ili ima pristup njenom programskom kodu. Premda postoji još nekoliko vrsta analitike web mjesta poput web oznaka ili njuškanja paketa, iste uglavnom imaju više nedostataka nego prednosti te ih je stoga potrebno kombinirati sa analizom datoteke dnevnika ili označavanjem stranica (Kaushik, 2007).

4.1.2.11 Metoda praćenja očiju

Primjena metode praćenja očiju (eng. eye tracking) u kontekstu vrjednovanja web aplikacija polazi od pretpostavke da su pokreti očiju indikator kognitivnih procesa korisnika (Duchowski, 2007; Nielsen i Pernice, 2010). Podaci se prikupljaju pomoću specijaliziranog uređaja, vrlo sličnog monitoru, koji radi na sljedećem principu praćenja refleksije rožnice (Tobii, 2011):

- upotrebom jednog ili većeg broja gotovo infracrvenih osvjetljivača (eng. near-infrared illuminator) kreira uzorke refleksije na rožnice očiju,
- preko brojnih slikovnih senzora evidentira sliku korisnikovih očiju,
- primjenom algoritama za obradu slike pronalazi oči, otkriva točnu poziciju zjenica i/ili šarenica te identificira uzorke projekcije i
- upotrebom matematičkog modela oka izračunava položaj očiju u prostoru i točku pogleda.

Kako bi prikupljanje podataka bilo što preciznije, prije nego što započne proces vrjednovanja potrebno je kalibrirati uređaj na način da korisnik gleda niz točaka koje se kreću i mijenjaju veličinu. Svrha ove metode je otkriti uzorak pretraživanja i pregledavanja elemenata sučelja web aplikacije (Plantak Vukovac i Orehovački, 2010). Postoje dvije osnovne vrste pokreta očiju (Duchowski, 2007; Nielsen i Pernice, 2010):

- Fiksacija (eng. fixation) je usmjeravanje i zadržavanje pogleda na pojedinom elementu sučelja. Uglavnom traje između jedne desetine i jedne polovine sekunde što je dovoljno za prepoznavanje funkcionalnosti elementa sučelja ili razumijevanje pročitanog teksta.
- Trzaj (eng. saccade) je vrlo brz pokret oka između dvije fiksacije koji traje između jedne stotine i jedne desetine sekunde.

Obzirom da se za vrijeme trzaja oka slika na šarenici toliko zamuti da korisnik privremeno ne vidi, primjenom ove metode analiziraju se samo fiksacije oka (Nielsen i Pernice, 2010).

Prikupljene je podatke, ovisno o vrsti i tipu sustava koji se primjenjuje, moguće vizualizirati i analizirati na nekoliko različitih načina:

- Ponovno pregledavanje (eng. gaze replay) je funkcionalnost sustava za praćenje očiju primjenom koje evaluator može pregledati snimku eksperimenta na kojoj se nalazi prikaz postupaka korisnika tijekom izvršavanja zadatka te fiksacije i trzaji njegovih očiju. Obzirom da su pokreti očiju jako brzi, evaluator mora usporiti snimku te je često i po nekoliko puta reproducirati kako bi napravio što kvalitetniju analizu uzoraka pregledavanja te identificirao probleme upotrebljivosti. Premda je riječ o vrlo korisnom obliku vizualizacije, analiza prikupljenih podataka iziskuje jako puno vremena.
- Toplinska karta (eng. heat map) je grafički prikaz učestalosti pregledavanja pojedinih elemenata sučelja web aplikacije. Može biti generirana temeljem broja ili trajanja fiksacija oka. Crvenom su bojom označeni elementi sučelja koji su najčešće pregledavani nakon koje slijedi žuta te plava ili zelena (ovisno o sustavu) kao indikator najmanjeg broja fiksacija. Sivom su bojom označeni elementi sučelja na kojima nije evidentirana značajna količina fiksacija. Toplinske karte su pokazatelj prosječnog ponašanja korisnika te se u pravilu ne analiziraju pojedinačno. Međutim, kako bi se zaključci mogli generalizirati, u eksperimentu treba sudjelovati barem 39 reprezentativnih korisnika (Nielsen i Pernice, 2010).
- Nacrt pregledavanja (eng. gaze plot) je grafički prikaz redoslijeda pregledavanja pojedinih elemenata sučelja te duljine trajanja fiksacija. Sačinjen je od točaka koje predstavljaju fiksacije te tankih linija među točkama koje se odnose na trzaje oka. Veličina točke je proporcionalna duljini trajanja fiksacije dok brojevi na točkama označavaju redoslijed pregledavanja. Nacrti pregledavanja često znaju biti vrlo kompleksni te se stoga uglavnom koriste za analizu uzoraka pregledavanja pojedinih korisnika.
- Klasteri (eng. clusters) služe grafičkoj ilustraciji dijelova sučelja web aplikacije koje su korisnici najčešće pregledavali te kao takvi predstavljaju alternativu toplinskim kartama. Za svaki se klaster prikazuje postotak korisnika koji su ga pregledavali.

Uz navedene oblike vizualizacije rezultata, prikupljeni se podaci također mogu upotrebljavati za utvrđivanje vremena kojeg je korisnik utrošio u pregledavanje pojedinih dijelova web aplikacije ili vrijeme koje mu je bilo potrebno da pronađe pojedinu funkcionalnost sučelja (Tullis i Albert, 2008). Osim za analizu uzoraka pregledavanja, metoda praćenja očiju može poslužiti vrjednovanju količine uloženog fizičkog i mentalnog napora u provedbu pojedinog zadatka ili cjelokupnog scenarija. Dok je količinu uloženog fizičkog napora moguće izračunati na osnovi ukupnog broja trzaja i fiksacija oka te snage ekstraokularnih mišića, količina uloženog

mentalnog napora se temelji na prosječnom trajanju fiksacija, prosječnoj amplitudi trzaja te prosječnom promjeru zjenica (Tamir et al., 2010).

Tijekom interpretacije prikupljenih podataka valja biti oprezan jer isti često mogu biti dvosmisleni. Primjerice, dulja fiksacija oka na pojedinom dijelu web aplikacije može istovremeno biti indikator nečeg zanimljivog i nerazumljivog. Nadalje, ako korisnici pojedine elemente sučelja nisu pregledavali to može značiti da je riječ o dosljednim i od prije poznatim elementima sučelja na koje korisnici zbog usredotočenosti na rješavanje zadatka nisu obraćali pažnju ili biti pokazatelj neatraktivnih odnosno nepotrebnih funkcionalnosti sučelja. Kako bi se razriješile spomenute i slične nedoumice, metoda praćenja očiju se u praksi često kombinira sa metodom razmišljanja naglas.

4.1.2.12 Udaljeno testiranje

Metoda udaljenog testiranja (eng. remote testing; Hartson et al., 1996) se primjenjuje kada evaluator ne može direktno promatrati proces vrjednovanja (npr. kada su evaluator i korisnik prostorno udaljeni i/ili se iz nekog razloga vrjednovanje i promatranje ne mogu provesti istovremeno). Prema tome, postoje dvije vrste udaljenog testiranja:

- Ukoliko su evaluator i korisnik samo prostorno udaljeni, tada upotrebom računalne opreme (npr. video kamere, mikrofona, uređaja za praćenje rada očiju i slično) i softvera (npr. Morae), evaluator može preko mreže pratiti što se događa na ekranu računala kojeg korisnik upotrebljava, slušati što korisnik govori, komunicirati sa njime te promatrati njegovo ponašanje za vrijeme interakcije sa web aplikacijom.
- Ukoliko uz prostornu udaljenost između evaluatora i korisnika postoji i vremenski razmak između procesa vrjednovanja i analize, tada procesom testiranja upravlja specijalizirani softver na način da putem isječka programskog koda koji je implementiran u web aplikaciju koja je predmet vrjednovanja prikuplja podatke o interakciji te ih pohranjuje u datoteku koju će evaluator naknadno analizirati.

4.1.3 Metode ispitivanja

Metode ispitivanja se ubrajaju u skupinu empirijskih metoda. Podaci o upotrebljivosti se prikupljanju tako da se korisnicima usmeno ili pismeno postavljaju pitanja vezana uz zadovoljstvo, stavove i ponašajne namjere ili se promatra njihova interakcija sa web aplikacijom u realnom radnom okruženju. Ova se skupina metoda može upotrebljavati u svim razvojnim fazama životnog ciklusa web aplikacije. Metode se međusobno razlikuju prema broju korisnika

od kojih se podaci mogu istovremeno prikupljati (primjerice jedan korisnik kod provedbe intervjua ili veći broj korisnika kod primjene upitnika) ili ulozi korisnika za vrijeme prikupljanja podataka (pasivno odgovaranje na pitanja ili aktivno bilježenje aktivnosti odnosno samoinicijativno slanje povratnih informacija).

4.1.3.1 Terensko ispitivanje

Metoda terenskog ispitivanja (eng. field observation) omogućava analizu zadataka te prikupljanje podataka o upotrebljivosti web aplikacije u realnim i radnim uvjetima (Diaper 1989; Nielsen, 1993). Sastoji se od toga da evaluator koji je obično iz redova razvojnih programera posjeti korisnika na njegovom radnom mjestu te uz minimalnu količinu ometanja promatra njegovu interakciju sa web aplikacijom. Tijekom provedbe eksperimenta promatranja evaluator ne odgovara na pitanja korisnika niti mu pomaže u rješavanju zadataka već je usredotočen na bilježenje njegovih postupaka i ponašanja. Ukoliko korisnik ne uspije samostalno ukloniti problem, evaluator će mu nakon što eksperiment završi objasniti kako problem riješiti. Isto tako, ako evaluator tijekom eksperimenta osjeti potrebu da mu korisnik pojasni određene aspekte rješavanja zadataka, on ga neće prekidati već će mu pitanja postaviti tijekom diskusije koja će uslijediti nakon eksperimenta.

Prikupljanje podataka na ovaj način može za evaluatora biti otežano, posebice ako je riječ o dinamičnom radnom mjestu zbog čega može doći do prekida u izvršavanju zadataka. Međutim, takvi prekidi znaju biti vrlo korisni jer mogu evaluatoru otkriti dodatne informacije o pojedinim aspektima korištenja web aplikacijom (npr. učestalost izrade sigurnosne kopije podataka) kao i specifičnim problemima upotrebljivosti koji se u sklopu kontroliranih uvjeta u laboratoriju ne bi manifestirali (npr. vrijeme oporavka od pogrješaka, učestalost prekida u radu aplikacije i slično). U idealnim je situacijama evaluatoru uz promatranje dozvoljeno i snimanje videokamerom. Potrebno je naglasiti da terensko ispitivanje spada u kategoriju sumativnog vrjednovanja te se provodi kada je web aplikacija implementirana te se aktivno upotrebljava. Stoga se prije terenskog ispitivanja trebaju primijeniti metode vrjednovanja pomoću kojih će biti uklonjena većina problema upotrebljivosti. Konačno, metoda je zbog svojih specifičnosti prikladna za longitudinalna istraživanja.

4.1.3.2 Ciljane skupine

Metoda ciljane skupine (eng. focus groups; Caplan, 1990; O'Donnell et al., 1991) se provodi na način da šest do devet reprezentativnih korisnika sudjeluje u diskusiji vezanoj uz upotrebljivost

web aplikacije. Svaku ciljanu skupinu vodi moderator čija je uloga usmjeravati diskusiju te se pobrinuti da svaki od sudionika aktivno doprinese svojim komentarima. Prije provedbe metode, korisnicima je potrebno demonstrirati sučelje odnosno prototip web aplikacije ili im dopustiti da određeno vrijeme provedu u interakciji sa elementima njena sučelja. Navedeno ovisi o tome u kojoj se fazi životnog ciklusa web aplikacije metoda primjenjuje te koji se ciljevi njenom primjenom žele postići. Premda ciljane skupine djeluju fleksibilno i nestrukturirano, one se zapravo odvijaju prema unaprijed pripremljenom scenariju.

Po završetku ciljane skupine, moderator sastavlja izvještaj u kojem navodi popis ostvarenih ciljeva i najvažnijih rezultata. Prednost ciljanih skupina su kreativne i spontane diskusije gdje sudionici kroz međusobnu interakciju generiraju veliku količinu kvalitativnih podataka. Međutim, kako bi se osigurala kvaliteta i reprezentativnost prikupljenih podataka, a time i ostvarenje zadanih ciljeva, potrebno je provesti nekoliko ciljanih skupina sa istim scenarijem. Kao alternativa klasičnim ciljanim skupinama gdje se reprezentativni korisnici sastaju i diskutiraju uživo, moguće je organizirati virtualne ciljane skupine gdje će korisnici svoje komentare ostavljati na forumima, društvenima mrežnim stranicama, wiki sustavima ili raspravljati putem programa za Internet telefoniju (npr. Skype). Premda takvi oblici ciljanih skupina mogu značajno smanjiti troškove provedbe metode, Nielsen (1993) napominje da se isto tako mogu pojaviti problemi vezani uz reprezentativnost korisnika te pouzdanost i povjerljivost generiranih komentara.

4.1.3.3 Intervjui

Tijekom intervjua (eng. interview), evaluator reprezentativnom korisniku postavlja pitanja te na taj način prikuplja podatke o njegovim očekivanjima, iskustvima, stavovima i ponašajnim namjerama vezanim uz korištenje web aplikacijom (Dix et al., 2004; Nielsen, 1993). Postoje tri vrste intervjua. Nestrukturirani intervju ima formu opuštenog razgovora tijekom kojeg evaluator temeljem odgovora korisnika te vrste i količine informacija koje želi prikupiti osmišljava nova pitanja. Ovaj se oblik intervjua najčešće primjenjuje u početnim fazama životnog ciklusa kada se prikupljaju podaci o očekivanjima korisnika vezanim uz web aplikaciju. Kao sušta suprotnost, provedba strukturiranog intervjua se sastoji od postavljanja unaprijed definiranih pitanja koja usmjeravaju tijek razgovora. Strukturirani intervju se još naziva anketa (eng. survey) te se koristi kao alternativa upitnicima, a služi prikupljanju podataka o zadovoljstvu i stavovima korisnika vezanim uz interakciju sa web aplikacijom. Kombinacija spomenute dvije vrste intervjua se naziva polustrukturirani intervju. Zajedničko obilježje svim

oblicima intervjua jest fleksibilnost u smislu prilagodbe korisniku (npr. pojašnjenje ili preformulacija pitanja i sl.).

Pitanja koja se postavljaju su neutralna i otvorenog tipa, sročena na način da zahtijevaju odgovaranje punim rečenicama. Tijekom provedbe intervjua, evaluator ne smije pokazati svoj stav prema odgovorima korisnika te ni na koji način sugerirati odgovore na postavljena pitanja. Intervjui se često kombiniraju sa upitnicima na način da se primjenom nestrukturiranog intervjua sa manjom skupinom reprezentativnih korisnika identificiraju problemi upotrebljivosti temeljem kojih se razviju specifična pitanja te se u obliku upitnika distribuiraju velikom broju korisnika (Nielsen, 1993).

Prednost metode je visoki odaziv korisnika što omogućava prikupljanje velike količine podataka koje je jednostavno interpretirati. Međutim, navedeno je istovremeno i nedostatak jer je podatke u tom obliku vrlo teško kvantificirati. Od ostalih nedostataka potrebno je izdvojiti veliku količinu vremena koju je potrebno utrošiti u primjenu metode jer se intervju kao metoda vrjednovanja upotrebljivosti istovremeno provodi sa samo jednim korisnikom.

4.1.3.4 Kontekstualno ispitivanje

Kontekstualno ispitivanje (eng. contextual inquiry) predstavlja kombinaciju nestrukturiranog intervjua i terenskog ispitivanja. Prema tome, provedba metode se temelji na tri principa (Holtzblatt i Jones, 1993): uključivanju korisnika kao partnera u proces razvoja, razumijevanju konteksta u kojem se web aplikacija upotrebljava i usredotočenosti procesa razvoja i vrjednovanja. Najčešće se primjenjuje u ranijim razvojnim fazama te je prikladna za longitudinalna istraživanja.

4.1.3.5 Upitnici

Upitnici (eng. questionnaires) su namijenjeni prikupljanju kvantitativnih podataka o zamijećenoj upotrebljivosti web aplikacije. Procedura prikupljanja podataka primjenom ove metode se sastoji od toga da korisnici preko Likertove skale (Likert, 1932) ili semantičkog diferencijala (Osgood et al., 1957) izražavaju razinu svog slaganja sa česticama odnosno pitanjima zatvorenog tipa koja su vezana uz specifične aspekte upotrebljivosti web aplikacija. U praksi se najčešće upotrebljavaju skale od pet ili sedam stupnjeva (Tullis i Albert, 2008). Razlog tome je što omogućuju diferencijaciju u stavovima korisnika, a istovremeno zadržavaju razumljivost značenja svakog stupnja skale (Dix et al., 2004). Kako bi se pojednostavilo popunjavanje upitnika

te olakšala obrada, analiza i interpretacija prikupljenih podataka, preporučljivo je da se ista skala proteže kroz cijeli upitnik.

Kod primjene ove metode evaluatori imaju dvije mogućnosti: upotrijebiti jedan od standardiziranih upitnika ili razviti vlastiti. U slučaju odabira druge opcije, provedbi prikupljanja podataka treba prethoditi pilot istraživanje tijekom kojeg se testira razumljivost čestica te valjanost i pouzdanost upitnika (Nunnally i Bernstein, 1994). U nastavku slijedi opis nekoliko najpoznatijih standardiziranih upitnika.

Lewis (1995) je razvio tri upitnika namijenjena vrjednovanju upotrebljivosti: After-Scenario Questionnaire (ASQ), Post-Study System Usability Questionnaire (PSSUQ) i Computer System Usability Questionnaire (CSUQ). ASQ se sastoji od samo tri čestice pomoću kojih se mjeri zadovoljstvo korisnika lakoćom dovršavanja zadataka, količinom vremena koje je bilo potrebno utrošiti u dovršavanje zadataka te informacijama (online pomoć, poruke i dokumentacija) koje je web aplikacija pružala tijekom izvršavanja zadataka. PSSUQ je sačinjen od 19 čestica namijenjenih vrjednovanju korisnosti sustava, kvalitete informacija, kvalitete sučelja te cjelokupne upotrebljivosti sustava. CSUQ i PSSUQ su identični, pri čemu su čestice u slučaju upitnika PSSUQ sastavljene u prošlom, a u kontekstu upitnika CSUQ sročene u sadašnjem vremenu. Kod sva tri upitnika se primjenjuje Likertova skala od sedam stupnjeva te opcija „nije primjenjivo“ (eng. not applicable, N/A). Kako bi ispitao metrijske karakteristike upitnika PSSUQ, Lewis (2002) je proveo istraživanje u kojem je analizirao podatke vrjednovanja upotrebljivosti prikupljenih u razdoblju od pet godina. Rezultati istraživanja su pokazali da neovisno o vrsti sustava ili programskog sustava koji je predmet vrjednovanja, PSSUQ pokazuje slična metrijska svojstva što ga čini prikladnim za vrjednovanje različitih programskih proizvoda u svim njihovim razvojnim fazama.

Questionnaire for Interaction Satisfaction (QUIS; Chin et al., 1988) je razvijen na Sveučilištu u Marylandu te je od tada mnogo puta proširivan. Trenutno se nalazi u verziji 7.0 (Harper et al., 1997) koja osim demografskih pitanja sadrži: a) šest čestica namijenjenih mjerenju sveukupne reakcije korisnika na sustav; b) četiri skupine čestica namijenjenih vrjednovanju obilježja sučelja: zaslon, terminologija i povratne informacije sustava, učenje i mogućnosti sustava; c) neobavezan dio namijenjen vrjednovanju specifičnih dijelova sustava (tehnički priručnici i online pomoć, online tutorijali, multimedija, pristup Internetu i instalacija softvera). Odgovore na pitanja je moguće rangirati na skali semantičkog diferencijala od devet stupnjeva i opcije „nije primjenjivo“.

Lin et al. (1997) su oblikovali instrument pod nazivom PUTQ (kratica za eng. Purdue Usability Testing Questionnaire) namijenjen vrjednovanju upotrebljivosti računalnih sustava sa grafičkim

korisničkim sučeljem. Instrument se sastoji od ukupno stotinu pitanja pomoću kojih je moguće mjeriti osam različitih atributa upotrebljivosti, uključujući kompatibilnost (eng. compatibility), dosljednost (eng. consistency), fleksibilnost (eng. flexibility), lakoću učenja korištenja (eng. learnability), minimalnu aktivnost (eng. minimal action), minimalno opterećenje memorije (eng. minimal memory load), perceptivno ograničenje (eng. perceptual limitation) i smjernice za korisnike (eng. user guidance). Rezultati istraživanja su pokazali da PUTQ visoko korelira sa upitnikom QUIS čime je dokazana njegova valjanost. Osim toga, PUTQ je identificirao razlike u radnom učinku korisnika među vrjednovanim korisničkim sučeljima što sa instrumentom QUIS nije bilo moguće utvrditi. Time je dokazano da PUTQ ima višu razinu osjetljivosti od QUIS.

Website Analysis and MeasureMent Inventory (WAMMI; Kirakowski et al., 1998) je nasljednik upitnika Software Usability Measurement Inventory (SUMI; Kirakowski i Corbett, 1993). Sačinjen je od 20 čestica pomoću kojih se preko Likertove skale od pet stupnjeva vrjednuje atraktivnost, mogućnost kontrole, učinkovitost, raspoloživost i pružanje pomoći, lakoća učenja i sveukupna upotrebljivost web mjesta. Lund (2001) je predstavio upitnik pod nazivom USE (kratica za eng. Usefulness, Satisfaction, and Ease of Use) koji pomoću 30 čestica omogućava mjerenje tri atributa upotrebljivosti: korisnost, zadovoljstvo i lakoću korištenja. Faktorskom analizom je otkriveno da se lakoća korištenja može podijeliti na dva zasebna atributa: lakoću korištenja i lakoću učenja.

Upitnik kojeg je razvio Finstad (2010) se sastoji od 4 čestice što implicira da se učinkovitost, djelotvornost, zadovoljstvo i lakoća korištenja sustavom vrjednuju sa samo jednom česticom. Doll i Torkzadeh (1988) su oblikovali upitnik od 12 čestica pod nazivom EUCS (kratica za eng. End-User Computing Satisfaction) koji omogućava vrjednovanje zadovoljstva korisnika kroz sljedećih pet dimenzija: sadržaj, format, točnost, lakoća korištenja i pravovremenost. Abdinnour-Helm et al. (2005) su spomenuti upitnik prilagodili kontekstu vrjednovanja web mjesta.

System Usability Scale (SUS; Brooke, 1996) je upitnik sačinjen od deset čestica koje se ne interpretiraju zasebno već zajedno tvore jedinstvenu ocjenu upotrebljivosti. Ocjena može poprimiti vrijednost između 0 i 100 pri čemu rezultati iznad 70 predstavljaju prihvatljivu razinu upotrebljivosti dok su vrijednosti ispod 50 indikator značajnih problema upotrebljivosti (Bangor et al., 2008). Udio pojedine čestice u ocjeni varira između 0 i 4, a ovisi o poziciji odgovara na skali od pet stupnjeva kao i načinu na koji je čestica sročena. Ukoliko je riječ o pozitivno sročenoj čestici, njen se udio u ocjeni izračunava tako da se vrijednost pozicije odgovora na skali umanji za jedan. U slučaju negativno sročene čestice, udio se izračunava na način da se od broja pet oduzme pozicija odgovora na skali. Kako bi se izračunala ocjena upotrebljivosti, potrebno je sumirati udjele čestica te dobiveni rezultat pomnožiti sa 2,5. Bangor et al. (2008) navode

nekoliko razloga zbog kojih se SUS upitnik najčešće primjenjuje u praksi: moguće ga je prilagoditi kontekstu programskog proizvoda koji se vrjednuje, sastoji se od malog broja čestica što ga čini učinkovitim i jednostavnim za upotrebu, besplatan je te rezultira jedinstvenom ocjenom upotrebljivosti koju svatko može razumjeti i interpretirati.

Pored upitnika namijenjenih mjerenju upotrebljivosti potrebno je izdvojiti nekoliko upitnika koji služe vrjednovanju korisničkog iskustva. Hassenzahl et al. (2003) su razvili upitnik pod nazivom AttracDiff 2 koji se sastoji od 21 bipolarne čestice. Primjenom spomenutog upitnika korisnici mogu preko skale semantičkog diferencijala od sedam stupnjeva vrjednovati pragmatične i hedonističke karakteristike programskog proizvoda. Lavie i Tractinsky (2004) su oblikovali upitnik sačinjen od 25 čestica primjenom kojeg je korisnicima omogućeno da preko skale od sedam stupnjeva vrjednuju estetiku web mjesta. HED/UT (kratica za eng. Hedonic Utility Scale; Voss et al., 2003) je upitnik pomoću kojeg je preko semantičkog diferencijala od sedam stupnjeva moguće vrjednovati 12 različitih hedonističkih i pragmatičnih dimenzija koje utječu na stav korisnika.

Upitnici se mogu primijeniti prije i nakon provedbe pojedinog zadatka te prije i nakon dovršetka scenarija sa reprezentativnim koracima interakcije. Moguće ih je distribuirati u papirnatom ili digitalnom (online) obliku. Obzirom da papirnate verzije upitnika imaju veliki nedostatak u smislu potrebe za digitalizacijom prikupljenih podataka, u praksi se češće koriste online upitnici. Upotrebom specijaliziranih web aplikacija (npr. SurveyMonkey, Kwiksurveys, itd.), evaluator može na vrlo jednostavan način kreirati upitnik i upravljati prikupljenim podacima. Kako bi se smanjila odstupanja u odgovorima korisnika te povećala kvaliteta i objektivnost prikupljenih podataka, popunjavanje upitnika treba biti anonimno. Prednost metode je što se podaci mogu istovremeno prikupiti od velikog broja korisnika. Međutim, da bi se zaključci na osnovi prikupljenih podataka mogli generalizirati, u vrjednovanju treba sudjelovati reprezentativan uzorak korisnika. Od nedostataka primjene metode potrebno je izdvojiti relativno malen odaziv korisnika (25-30%; Dix et al., 2004).

4.1.3.6 Vođenje dnevnika

Metoda vođenja dnevnika (eng. self-reporting logs; Nielsen, 1993) od korisnika zahtijeva da vodi evidenciju o vlastitim postupcima za vrijeme interakcije sa web aplikacijom. Navedeno može uključivati redoslijed korištenja pojedinim funkcionalnostima sučelja ili se odnositi na zamijećene probleme upotrebljivosti. Prije provedbe metode evaluator korisniku daje upute o tome što je i koliko detaljno potrebno evidentirati, kao i popis reprezentativnih zadataka. Ova se metoda primjenjuje kao alternativa metodama udaljenog testiranja i odgođenog emitiranja u

slučajevima kada za njihovu provedbu svi potrebni resursi nisu dostupni ili kada prikupljeni podaci ne trebaju biti suviše precizni. Obzirom da kvaliteta rezultata nastalih primjenom metode ovisi o korisnicima, njihovom je odabiru potrebno posvetiti posebnu pozornost. Nedostatak metode je nemogućnost praćenja i evidentiranja stvarnog ponašanja i postupaka korisnika tijekom interakcije sa web aplikacijom te je stoga vođenje dnevnika preporučljivo kombinirati sa ostalim metodama poput primjerice spremanja izgleda ekrana.

4.1.3.7 Spremanje izgleda ekrana

Primjena metode se sastoji od toga da korisnik tijekom interakcije sa web aplikacijom, u unaprijed definiranim vremenskim intervalima ili kontrolnim točkama scenarija, sprema izgled ekrana (eng. screen snapshot; Nielsen, 1993). Prije provedbe metode, evaluator treba pripremiti detaljan opis procedure vrjednovanja, listu reprezentativnih zadataka te osigurati specijaliziran program namijenjen spremanju izgleda ekrana. Najčešće se upotrebljava u kombinaciji sa vođenjem dnevnika jer se zbog svojih specifičnosti te dvije metode nadopunjuju što značajno utječe na povećanje kvalitete prikupljenih podataka.

4.1.3.8 Povratne informacije od korisnika

Metoda se sastoji od toga da korisnici samoinicijativno šalju povratne informacije vezane uz interakciju sa web aplikacijom. U kontekstu vrjednovanja upotrebljivosti, ova metoda ima nekoliko prednosti (Nielsen, 1993): ukazuje na elemente sučelja koji zahtijevaju hitnu intervenciju, omogućava prikupljanje podataka bez ulaganja resursa i odražava reakciju na svaku promjenu u sučelju. Korisnici mogu povratne informacije poslati preko različitih kanala: slanjem e-maila, ostavljanjem poruke na forumu ili stranici društvene mreže, kontaktiranjem službe za korisnike i slično. U praksi razvoja Web 2.0 aplikacija korisnicima se daje mogućnost da nakon upotrebe istih razvojnom timu pošalju prijedloge vezane za unaprjeđenje dizajna, funkcionalnosti i upotrebljivosti sučelja. Prikupljeni se podaci kategoriziraju te im se ovisno o reprezentativnosti dodjeljuje značaj. Neovisno o načinu na koji su povratne informacije zaprimljene, korisnicima treba dati do znanja da je njihovo mišljenje važno. Navedeno se može manifestirati kao zahvala za poslanu povratnu informaciju, odgovor na postavljeno pitanje, prijedlog rješenja problema ili podatak o tome da li je problem trenutno rješiv. Ukoliko korisnici ne zaprime reakciju na poslanu povratnu informaciju, postoji opasnost od gubitka vrlo korisnog i besplatnog izvora informacija. Stoga je potrebno uložiti dodatne resurse u razvoj službe koja će se baviti upravljanjem povratnim informacijama što je ujedno i nedostatak ove metode.

5. METODOLOGIJA

Okosnicu metodologije vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama čine mjerni instrumenti i konceptualni model. Mjerni instrumenti služe neposrednom mjerenju obilježja teorijskog koncepta. U kontekstu ovog doktorskog rada pragmatični i hedonistički atributi kvalitete u korištenju mjereni su primjenom tri mjerna instrumenta: upitnikom, obrascem sa reprezentativnim koracima scenarija i alatom za automatsko zapisivanje postupaka Mousotron[1]. Konceptualni model je pojednostavljeni prikaz strukture i međuodnosa aspekata istraživačkog fenomena. Temeljni elementi svakog konceptualnog modela su mjere i konstrukti. Mjere ili manifestne varijable su opažljivi kvantitativni podaci prikupljeni promatranjem, intervjuom, upitnikom ili nekim drugim mjernim instrumentom ili empirijskom metodom (Edwards i Bagozzi, 2000). U literaturi se kao sinonim za manifestne varijable upotrebljavaju pojmovi čestice i indikatori. Međutim, za potrebe ovog doktorskog rada potrebno je napraviti jasnu distinkciju između ta dva termina. Pod pojmom čestice se podrazumijevaju tvrdnje u upitniku koje služe vrjednovanju zamijećene kvalitete u korištenju Web 2.0 aplikacijama. S druge strane, indikatori predstavljaju metrike namijenjene prikupljanju objektivnih podataka o pojedinim aspektima kvalitete u korištenju Web 2.0 aplikacijama.

Konstrukti ili latentne varijable su istraživački koncepti koje nije moguće direktno mjeriti već se o njima zaključci donose temeljem manifestnih varijabli (Polites et al., 2012). Fenomeni koje konstrukti opisuju mogu biti opažljivi (npr. učinkovitost u izvršavanju zadataka) i neopažljivi (npr. stav prema korištenju). U konceptualnom je modelu moguće razlučiti dvije vrste latentnih varijabli: egzogene i endogene konstrukte. Dok su egzogeni konstrukti nezavisne latentne varijable koje djeluju kao prediktori jedne ili većeg broja zavisnih latentnih varijabli, endogeni konstrukti predstavljaju posljedicu jednog ili većeg broja egzogenih konstrukata (Götz et al., 2010; Hair et al., 2011; Straub et al., 2004).

Kako bi se osigurala kvaliteta postupaka mjerenja i statističkog zaključivanja, mjerni instrumenti i konceptualni model trebaju udovoljavati metrijskim karakteristikama valjanosti i pouzdanosti. Stoga je u prvom koraku razvoja metodologije (opisanom u prethodnim poglavljima) proveden detaljan pregled literature koji je obuhvaćao metode, metodologije, tehnike, međunarodne standarde i mjerne instrumente namijenjene vrjednovanju upotrebljivosti, korisničkog iskustva, kvalitete, prihvaćanja i uspjeha web mjesta. Pregled literature je rezultirao popisom čestica i indikatora vrjednovanja kvalitete u korištenju koje su stručnjaci domene kategorizirali primjenom metode sortiranja karata. U sljedećem je koraku slijedom smjernica koje su ponudili

[1] http://www.blacksunsoftware.com/mousotron.html

Straub et al. (2004) oblikovan upitnik. U razvoju skale sa reflektivnim česticama autor doktorskog rada se pridržavao koraka koje su predložili Moore i Benbasat (1991) dok se u izradi indeksa sa formativnim česticama vodio preporukama koje su dali Diamantopoulos i Winklhofer (2001). Operacionalizacijom manifestnih varijabli i latentnih konstrukata izrađen je konceptualni model čije su metrijske karakteristike analizirane metodom modeliranja strukturalnih jednadžbi. U posljednjem je koraku primjenom metode logičkog bodovanja preferencija proveden izračun kompozitnog indeksa kvalitete u korištenju vrjednovanih Web 2.0 aplikacija. Svaka od spomenutih metoda će biti detaljno opisana u nastavku ovog poglavlja.

5.1 Metoda sortiranje karata

Sadržajna valjanost je jedna od temeljnih metrijskih karakteristika mjernih instrumenata i konceptualnog modela. Svrha vrjednovanja sadržajne valjanosti je utvrditi mjeru do koje manifestne varijable obuhvaćaju konceptualnu domenu temeljnog (eng. underlying) latentnog konstrukta. Vrjednovanje sadržajne valjanosti se provodi pregledom literature te primjenom metode sortiranja karata (Boudreau et al., 2001; Straub et al., 2004).

Provedba metode sortiranja karata se treba sastojati od barem dvije iteracije (Moore i Benbasat, 1991; Petter et al., 2007). U prvoj se od procjenitelja koji nisu upoznati sa detaljima istraživanja traži da svaku manifestnu varijablu pridruže samo jednome od predefiniranih latentnih konstrukata. Zbog načina na koji se prva iteracija metode primjenjuje, ista se još naziva i zatvoreno sortiranje karata.

Sadržajna valjanost se vrjednuje pomoću dva empirijska kriterija: pokazatelja sadržajne valjanosti i prosječne vrijednosti relativne važnosti. Kako bi se utvrdio pokazatelj sadržajne valjanosti (eng. Content Validity Ratio, CVR), procjenitelji trebaju svakoj varijabli preko skale od tri stupnja (1 – obavezna, 2 – poželjna, 3 – irelevantna) odrediti relativnu važnost u vrjednovanju istraživačkog fenomena. Lawshe (1975) je za izračun pokazatelja sadržajne valjanosti predložio formulu[2] prema kojoj je u daljnjim koracima istraživanja potrebno zadržati samo one varijable koje više od 50% procjenitelja smatra obaveznima. Međutim, obzirom da je za potrebe izračuna indeksa kvalitete u korištenju Web 2.0 aplikacijama u obzir bilo potrebno uzeti varijable koje su procjenitelji percipirali kao obavezne i poželjne, izračun pokazatelja sadržajne valjanosti proveden je formulom prema kojoj se iz daljnjih koraka razvoja mjernog instrumenta izostavljaju samo one varijable koje više od 50% stručnjaka smatra irelevantnima (Lewis et al., 1995):

[2] $CVR = (n - N)/N$

$$CVR = (n - N/2)/(N/2) \quad (5.1)$$

gdje n označava broj procjenitelja koji pojedinu varijablu percipiraju kao obaveznu ili poželjnu dok N predstavlja ukupan broj procjenitelja. Prihvatljive referentne vrijednosti pokazatelja sadržajne valjanosti na razini značajnosti $\alpha = 0{,}05$ nalaze se u tablici 5.1.

Tablica 5.1 Minimalne vrijednosti pokazatelja sadržajne valjanosti u odnosu na broj procjenitelja

Broj procjenitelja	**Minimalna vrijednost CVR**
5	0,99
6	0,99
7	0,99
8	0,78
9	0,75
10	0,62
11	0,59
12	0,56
13	0,54
14	0,51
15	0,49
20	0,42
25	0,37
30	0,33
35	0,31
40	0,29

Izvor: Lawshe (1975)

Prosječna vrijednost relativne važnosti pojedine varijable se izračunava kao aritmetička sredina svih vrijednosti relativne važnosti koje su varijabli pridružene. Istu su kao kriterij vrjednovanja sadržajne valjanosti predložili Lewis et al. (1995). U kontekstu gore navedene skale od tri stupnja, iz daljnjih je koraka istraživanja potrebno izuzeti sve varijable za koje vrijedi da im je prosječna vrijednost relativne važnosti veća od dva ($\bar{x} \geq 2{,}00$). Podatke prikupljene metodom zatvorenog sortiranja karata moguće je, uz kriterije sadržajne valjanosti, analizirati i kriterijem konstruktne valjanosti te kriterijem razine podudaranja među procjeniteljima.

Empirijski kriterij namijenjen vrjednovanju konstruktne valjanosti nosi naziv omjer pogodaka (eng. Hit Ratio). Isti pokazuje koliko su manifestnih varijabli procjenitelji pridružili namjeravanom latentnom konstruktu (Moore i Benbasat, 1991), a izračunava se dijeljenjem

ukupnog broja manifestnih varijabli koje su temeljnim latentnim konstruktima ispravno pridružili svi procjenitelji sa ukupnim brojem mogućih pridruživanja manifestnih varijabli po svim uključenim procjeniteljima.

Pouzdanost rezultata proizašlih iz provedbe metode zatvorenog sortiranja karata se mjeri Congerovim Kappa koeficijentom podudaranja (Conger, 1980) između n procjenitelja ($n > 2$). Congerov Kappa koeficijent predstavlja integraciju i generalizaciju istoimenih pokazatelja koje su predložili Cohen (1960) i Fleiss (1971), a izračunava se pomoću sljedeće formule (Gwet, 2012):

$$\hat{\kappa}_C = \frac{p_a - p_{eC}}{1 - p_{eC}} \tag{5.2}$$

gdje p_a predstavlja vjerojatnost cjelokupnog podudaranja, a p_{eC} označava vjerojatnost slučajnog podudaranja. U tablici 5.2 se nalaze referentne vrijednosti vezane uz interpretaciju Kappa koeficijenta.

Tablica 5.2 Skala referentnih vrijednosti za Kappa koeficijent

Vrijednost Kappa koeficijenta	**Intenzitet podudaranja**
manje od 0,21	vrlo slab
od 0,21 do 0,40	slab
od 0,41 do 0,60	dobar
od 0,61 do 0,80	vrlo dobar
više od 0,80	izvrstan

Izvor: Altman (1991), Landis i Koch (1977)

Provedba druge iteracije metode (takozvano otvoreno sortiranje karata) je vrlo slična prvoj - jedina razlika je što procjenitelji ne dobivaju popis latentnih konstrukata, već ih temeljem teorijskih sličnosti među manifestnim varijablama trebaju kreirati prema vlastitom nahođenju.

5.2 Hijerarhijska klaster analiza

Eksplorativna tehnika analize podataka koja temeljem sličnosti i razlika među varijablama omogućava identifikaciju njihove taksonomije nosi naziv klaster analiza. Temeljni element oblikovane taksonomije je klaster odnosno grupa relativno homogenih varijabli koje se po svojim karakteristikama značajno razlikuju od varijabli pridruženih preostalim klasterima u taksonomiji. Temeljni kriterij za odabir varijabli koje će biti uključene u klaster analizu ovisi o kontekstu istraživanja te ciljevima koji se primjenom klaster analize žele postići (Mooi i Sarstedt,

2011). Obzirom da u sklopu ovog doktorskog rada klaster analiza predstavlja preteču oblikovanja konceptualnog modela vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama, u primjenu iste će biti uključeni latentni konstrukti koji će udovoljiti kriterijima sadržajne valjanosti.

Način kategorizacije varijabli odnosno oblikovanja klastera ovisi o odabranoj proceduri klasterizacije. Premda postoje brojne procedure klasterizacije, sve ih je moguće svrstati u tri osnovne skupine (Mooi i Sarstedt, 2011): hijerarhijske procedure (oblikovanje klastera se temelji na odabranoj mjeri sličnosti i odabranom algoritmu klasterizacije), procedure raščlambe (najpoznatiji predstavnik ove skupine je algoritam klasterizacije *k* srednjih vrijednosti koji vrši minimizaciju varijacija unutar klastera te na taj način provodi segmentaciju varijabli) i procedure klasterizacije u dva koraka (gdje se u prvom koraku provodi procedura vrlo slična algoritmu klasterizacije *k* srednjih vrijednosti, a u drugom koraku modifikacija hijerarhijske klasterizacije). Uzimajući u obzir činjenicu da se analiza podataka prikupljenih metodom sortiranja karata provodi hijerarhijskom klaster analizom, ista će biti detaljnije opisana u nastavku.

Provedba procedure hijerarhijske klasterizacije se sastoji od oblikovanja i analize strukture klastera prikazane u obliku stabla. Postoje dvije vrste tehnika hijerarhijske klaster analize. Prva i češće korištena skupina su tehnike aglomerativne klasterizacije (eng. agglomerative clustering) primjenom kojih se oblikovanje klastera provodi uzastopno od dna prema vrhu strukture. Inicijalna pretpostavka aglomerativne klasterizacije je da svaka varijabla predstavlja zasebni klaster. Druga skupina nosi naziv diobena klasterizacija (eng. divisive clustering) pomoću koje se sve varijable inicijalno svrstavaju u jedan klaster koji se zatim iterativno dekomponira od vrha prema dnu strukture. Ono što je karakteristično za obje tehnike hijerarhijske klaster analize jest da su klasteri na višoj razini hijerarhije sačinjeni od svih klastera niže razine. Navedeno implicira da se tijekom hijerarhijske klasterizacije pojedina varijabla pridružuje samo jednom klasteru nakon čega istu više nije moguće pridruživati.

Oblikovanje klastera primjenom procedure hijerarhijske klasterizacije se temelji na mjerama sličnosti među parovima varijabli. Najpoznatije mjere sličnosti su kako slijedi (Mooi i Sarstedt, 2011):

- Euklidska udaljenost je mjera geometrijske udaljenosti između dvije varijable koja se izračunava kao kvadratni korijen iz sume kvadriranih razlika vrijednosti varijabli:

$$d_{Euklid} = \sqrt{\sum_{i=1}^{n} (x_i - y_i)^2} \tag{5.3}$$

- Kvadrirana Euklidska udaljenost je mjera aritmetičke udaljenosti između dvije varijable, a izračunava se kao suma kvadriranih razlika vrijednosti varijabli:

$$d_{Euklid^2} = \sum_{i=1}^{n} (x_i - y_i)^2 \tag{5.4}$$

- City-block ili Manhattan udaljenost koja se izračunava kao apsolutna razlika vrijednosti varijabli:

$$d_{Manhattan} = \sum_{i=1}^{n} |x_i - y_i| \tag{5.5}$$

- Čebiševljeva udaljenost koja se izračunava kao maksimalna razlika između vrijednosti varijabli:

$$d_{Čebiševljev} = \max_i |x_i - y_i| \tag{5.6}$$

- Minkowski udaljenost predstavlja generalizaciju prethodno spomenutih mjera sličnosti te se shodno tome izračunava na sljedeći način:

$$d_{Minkowski} = \sqrt[p]{\sum_{i=1}^{n} |x_i - y_i|^p} \tag{5.7}$$

Prije nego što se može primijeniti aglomerativna hijerarhijska klaster analiza, potrebno je uz mjeru sličnosti odabrati i jedan od sljedećih algoritama klasterizacije (Norušis, 2012):

- Jednostruko povezivanje (metoda najbližeg susjeda). Udaljenost između dva klastera je jednaka najmanjoj udaljenosti između bilo koje dvije varijable koje su tim klasterima pridružene.
- Potpuno povezivanje (metoda najudaljenijeg susjeda). Izračun udaljenosti između dva klastera se temelji na najvećoj udaljenosti između bilo koje dvije varijable koje su članovi tih klastera.

- Prosječno povezivanje. Postoje dvije varijante ovog algoritma klasterizacije. Primjenom algoritma prosječnog povezivanja među grupama udaljenost između dva klastera se izračunava kao prosječna udaljenost između svih parova varijabli koje su tim klasterima pridružene pri čemu članovi para ne pripadaju istom klasteru. Algoritam prosječnog povezivanja unutar grupa spaja klastere na način da udaljenost među članovima rezultirajućeg klastera bude što je moguće manja. Navedeno implicira da je udaljenost između dva klastera zapravo prosječna udaljenost između svih mogućih parova članova novokreiranog klastera.
- Metoda centroida. Pomoću ovog algoritma se udaljenost između dva klastera izračunava kao udaljenost između aritmetičkih sredina (centroida) svih varijabli u oba klastera. Centroid klastera koji nastane primjenom ove metode je ponderirana kombinacija centroida klastera čijim je spajanjem isti oblikovan pri čemu su ponderi proporcionalni veličini klastera. Nedostatak ove metode je što se udaljenost na kojoj se klasteri spajaju može između pojedinih iteracija smanjiti što u konačnici rezultira time da se klasteri spojeni u kasnijim iteracijama više razlikuju od onih spojenih u ranijim iteracijama.
- Metoda medijana. Kod izračuna centroida ponderi klastera koji se spajaju su jednaki bez obzira na broj varijabli od kojih su klasteri sačinjeni.
- Wardova metoda. Najprije se u svakom klasteru izračunava srednja vrijednost varijabli od kojih je isti sačinjen da bi se nakon toga za svaku varijablu izračunala kvadrirana Euklidska udaljenost do srednje vrijednosti klastera. U sljedećem se koraku sumiraju dobivene udaljenosti za sve varijable. Primjenom ove metode u svakoj se iteraciji spajaju ona dva klastera koja će rezultirati najmanjim povećanjem ukupne sume kvadrata udaljenosti unutar novokreiranog klastera.

Proces hijerarhijske klasterizacije se grafički prikazuje dendrogramom. Riječ je o dijagramu koji se interpretira sa lijeva na desno pri čemu skala u obliku vertikalnih linija označava udaljenost na kojoj se klasteri spajaju te na taj način pomaže u donošenju odluke vezane uz broj i veličinu klastera koji će biti uvršteni u daljnje korake istraživanja.

5.3 Modeliranje strukturalnim jednadžbama

Analiza kompleksnih konceptualnih modela sačinjenih od različitih međuodnosa latentnih i manifestnih varijabli te povezanosti između endogenih i egzogenih latentnih konstrukata provodi se metodom modeliranja strukturalnim jednadžbama (eng. Structural Equation Modeling, SEM). U posljednjih je nekoliko godina SEM postao dominantna metoda razvoja novih i testiranja postojećih teorija u području društvenih znanosti, posebice u istraživanjima vezanim

uz informacijske sustave (Freeze i Raschke, 2007; Petter et al., 2007; Polites et al., 2012) i marketing (Hair et al., 2011; Hair et al., 2012; Henseler et al., 2009). Tehnike modeliranja strukturalnim jednadžbama moguće je svrstati u dvije skupine:

- SEM baziran na kovarijanci (eng. covariance-based SEM, CB-SEM) koji omogućava analizu modela strukturalnih jednadžbi primjenom alata kao što su EQS[3] i LISREL[4].
- SEM baziran na komponentama odnosno varijanci od kojih je analiza puta tehnikom parcijalnih najmanjih kvadrata (eng. partial least squares SEM, PLS-SEM) najznačajnija predstavnica skupine. PLS-SEM algoritmi implementirani su u alatima kao što su PLS-Graph[5] i SmartPLS[6].

U sklopu ovog doktorskog rada konceptualni model vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama biti će analiziran PLS-SEM tehnikom (Lohmöller, 1989; Wold, 1975). Razlog tome su karakteristike PLS modeliranja puta koje su usklađene sa ciljevima istraživanja te specifičnostima konceptualnog modela i prikupljenih podataka:

- Tijekom rješavanja blokova varijabli u vanjskom modelu, algoritam izračunava vrijednosti latentnih konstrukata kao linearnu kombinaciju manifestnih varijabli te je zbog toga PLS-SEM tehnika prikladna za razvoj i testiranje novih teorija (Fornell i Bookstein, 1982; Hair et al., 2012; Henseler et al., 2009; Reinartz et al., 2009).
- Izračun vrijednosti koeficijenata puta u unutarnjem modelu se temelji na maksimizaciji objašnjene varijance endogenih latentnih konstrukata što čini PLS-SEM tehniku prikladnom za istraživanja usmjerena na predikciju kriterijskih varijabli (Chin, 2010; Gefen et al., 2000; Hair et al., 2011; Henseler et al., 2009).
- U slučajevima kada su pretpostavke za primjenu parametrijskih testova narušene, PLS-SEM algoritam transformira podatke u skladu sa centralnim graničnim teoremom (Beebe et al., 1998; Cassel et al., 1999; Dijkstra, 2010). Zbog toga su PLS-SEM izračuni parametara modela robusni kada postoji odstupanje od normalne raspodjele rezultata (Hair et al., 2011; Hwang et al., 2010; Ringle et al., 2009; Vilares et al., 2010) kao i kada nije osigurana neovisnost opažanja (Fornell, 1982).
- PLS-SEM algoritam je učinkovit i fleksibilan u analizi kompleksnih modela. Navedeno se odnosi na slučajeve kada je broj egzogenih latentnih konstrukata barem dva puta veći od broja endogenih latentnih konstrukata (Hair et al., 2012; Henseler et al., 2009) kao i na vrjednovanje višerazinskih modela (Chin i Gopal, 1995).

[3] http://www.mvsoft.com/eqs60.htm
[4] http://www.ssicentral.com/lisrel/
[5] http://www.plsgraph.com
[6] http://www.smartpls.de

- PLS-SEM algoritam daje precizne izračune parametara i kada je broj opažanja u odnosu na kompleksnost modela relativno malen (Chin i Newsted, 1999; Hui i Wold 1982; Reinartz et al., 2009; Tenenhaus et al., 2005; Wold, 1989). Prema Barclay et al. (1995), minimalna veličina uzorka treba biti jednaka većoj od sljedeće dvije vrijednosti: (a) deset puta veća od broja formativnih manifestnih varijabli najkompleksnijeg egzogenog latentnog konstrukta ili (b) deset puta veća od broja puteva u najsloženijem skupu prediktora endogenog latentnog konstrukta. Premda navedena pravila ne uzimaju u obzir činitelje koji utječu na valjanost statističkog zaključka, ista mogu poslužiti gruboj procjeni potrebne veličine uzorka (Hair et al., 2012). Potrebno je napomenuti da se povećanjem broja opažanja i manifestnih varijabli po latentnom konstruktu izračuni parametara modela približavaju svojim stvarnim vrijednostima (Jöreskog i Wold, 1982; Lohmöller, 1989; Wold, 1982).
- U kontekstu SEM modeliranja baziranog na kovarijanci formativne latentne konstrukte je moguće identificirati jedino u slučaju kada isti udovoljavaju sljedećim kriterijima (Bollen i Davis, 2009; MacCallum i Browne, 1993): pravilo skaliranja (svakom latentnom konstruktu je potrebno odrediti skalu kako bi model mogao biti identificiran), t-pravilo (broj slobodnih parametara *t* treba biti manji ili jednak broju neredundantnih elemenata u matrici kovarijanci opaženih varijabli), pravilo dva ili više odaslana puta (svaka latentna varijabla čija varijanca ili varijanca pogrješke nije ograničena mora biti povezana sa najmanje dvije varijable čije pogrješke nemaju ograničene varijance), egzogeno X pravilo (primjenjuje se u slučajevima kada identificirani modeli uzročnih indikatora imaju strukturu MIMIC modela) i identifikacija po dijelovima (provodi se dekompozicijom modela na dijelove kako bi se najprije identificirala matrica kovarijanci latentnih i opaženih varijabli za pojedini dio, a potom upotrijebila za identifikaciju preostalih dijelova modela). Obzirom da primjena navedenih kriterija može rezultirati narušavanjem nomološke mreže konceptualnog modela (Diamantopoulos et al., 2008; Edwards, 2011; Edwards i Bagozzi, 2000) posebice u kontekstu kompleksnih modela (Hair et al., 2011; Temme, 2006), SEM modeliranje temeljeno na varijanci pretpostavlja da su formativni latentni konstrukti ponderirana linearna kombinacija pridruženih manifestnih indikatora (Diamantopoulos, 2006; Gefen et al., 2011; MacKenzie et al., 2005) čime je identifikacija istih uvelike olakšana (Fornell, 1982; Henseler et al., 2009).
- PLS-SEM tehnika daje stabilne izračune parametara kada se vanjski model sastoji od formativnih i reflektivnih manifestnih varijabli (Diamantopoulos i Winklhofer, 2001; Ringle et al., 2012; Vilares et al., 2010) kao i kada je latentni konstrukt sačinjen od samo jedne manifestne varijable (Fuchs i Diamantopoulos, 2009; Hair et al., 2011; Hair et al., 2012).

Zbog brojnih prednosti u odnosu na ostale alate namijenjene PLS-SEM modeliranju puta uključujući jednostavnost korištenja, grafičku specifikaciju modela, procjenu efekata interakcije, učinkovitost u provedbi algoritama ponovnog uzorkovanja te generiranje izvještaja u različitim formatima (Temme et al., 2010), analiza konceptualnog modela vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama biti će provedena primjenom alata SmartPLS 2.0 M3 (Ringle et al., 2005). Primjena PLS-SEM tehnike se sastoji od specifikacije konceptualnog modela te vrjednovanja vanjskih i unutarnjeg modela (MacKenzie et al., 2005).

5.3.1 Specifikacija modela

PLS-SEM modeliranje puta omogućava specifikaciju vanjskih (mjernih) i unutarnjih (strukturalnih) modela. Vanjski model služi operacionalizaciji jednosmjernih odnosa između latentnog konstrukta i manifestnih varijabli. Ovisno o teorijski utemeljenoj perspektivi uzročno-posljedičnih veza među latentnim i manifestnim varijablama, moguće je razaznati vanjski reflektivni i formativni model (Bollen i Lennox, 1991).

Vanjski reflektivni model se temelji na klasičnoj teoriji testiranja (Nunnally i Bernstein, 1994) prema kojoj varijance u latentnom konstruktu uzrokuju opažene kovarijance u pridruženim manifestnim varijablama. Prema tome, svaka manifestna varijabla predstavlja linearnu funkciju temeljnog latentnog konstrukta plus rezidual te se definira preko jednadžbe univarijatne regresijske analize (Haenlein i Kaplan, 2004):

$$y_i = \lambda_{ij}\eta_j + \varepsilon_i \tag{5.8}$$

gdje y_i označava *i*-tu manifestnu varijablu latentnog konstrukta η_j, λ_{ij} je koeficijent standardiziranog opterećenja (eng. loading), a ε_i predstavlja pogrješku mjerenja *i*-te manifestne varijable. U vanjskom reflektivnom modelu među pridruženim manifestnim varijablama postoji visoki stupanj povezanosti što znači da je svaki latentni konstrukt jednodimenzionalan. Zbog navedenog su manifestne varijable međusobno zamjenjive te izostavljanje jedne iz vanjskog reflektivnog modela ne mijenja konceptualnu strukturu latentnog konstrukta. Sinonimi za vanjski reflektivni model su model glavnih komponenti (Jarvis et al., 2003), način rada A (Tenenhaus et al., 2005) te model zajedničkog latentnog konstrukta (MacKenzie et al., 2005).

U vanjskom formativnom modelu opažena varijanca u pojedinoj manifestnoj varijabli rezultira varijancom u temeljnom latentnom konstruktu neovisno o preostalim manifestnim varijablama. Latentni konstrukt je ponderirana linearna kombinacija pridruženih manifestnih varijabli plus

rezidual te se definira pomoću jednadžbe multivarijatne regresijske analize (Diamantopoulos, 2006):

$$\xi_j = \gamma_{ji} x_i + \zeta_j \tag{5.9}$$

gdje ξ_j predstavlja *j*-ti latentni konstrukt, γ_{ji} simbolizira težinsku vrijednost (eng. weight) odnosno utjecaj *i*-te manifestne varijable na *j*-ti latentni konstrukt dok ζ_j označava izraz smetnje (eng. disturbance term) koji obuhvaća preostale aspekte *j*-tog latentnog konstrukta koji nisu objašnjeni manifestnim varijablama. Obzirom da svaka pridružena manifestna varijabla predstavlja specifičan aspekt konceptualne domene temeljnog latentnog konstrukta, isti je u kontekstu vanjskog formativnog modela višedimenzionalan. Za razliku od vanjskog reflektivnog modela, manifestne varijable u vanjskom formativnom modelu nisu međusobno zamjenjive. Shodno tome, izostavljanje manifestne varijable iz vanjskog formativnog modela mijenja značenje latentnog konstrukta (Petter et al., 2007), nepovoljno utječe na njegovu sadržajnu valjanost (Diamantopoulos i Winklhofer, 2001) te smanjuje količinu objašnjene varijance (Bollen i Lennox, 1991). Preostali nazivi za vanjski formativni model su model kompozitnog latentnog konstrukta (Jarvis et al., 2003; MacKenzie et al., 2005) i način rada B (Tenenhaus et al., 2005).

Specifikacija unutarnjeg (strukturalnog) modela obuhvaća modeliranje veza između egzogenih i endogenih latentnih konstrukata pomoću sljedeće jednadžbe (Haenlein i Kaplan, 2004):

$$\eta = B\eta + \zeta \tag{5.10}$$

gdje je η vektor latentnih konstrukata, B označava matricu koeficijenata puta, a ζ predstavlja reziduale unutarnjeg modela. U PLS-SEM tehnici modeliranja puta veze između egzogenih i endogenih latentnih konstrukata su definirane rekurzivno te je shodno tome unutarnji model dizajniran kao uzročni lanac bez petlji. Ukoliko su svi egzogeni i endogeni latentni konstrukti reflektivni, unutarnji model je također reflektivan. Međutim, ako je samo jedan latentan konstrukt formativan, unutarnji model se smatra formativnim (Henseler et al., 2009). Specifikacija vanjskog reflektivnog modela, vanjskog formativnog modela i unutarnjeg modela ilustrirana je na slici 5.1.

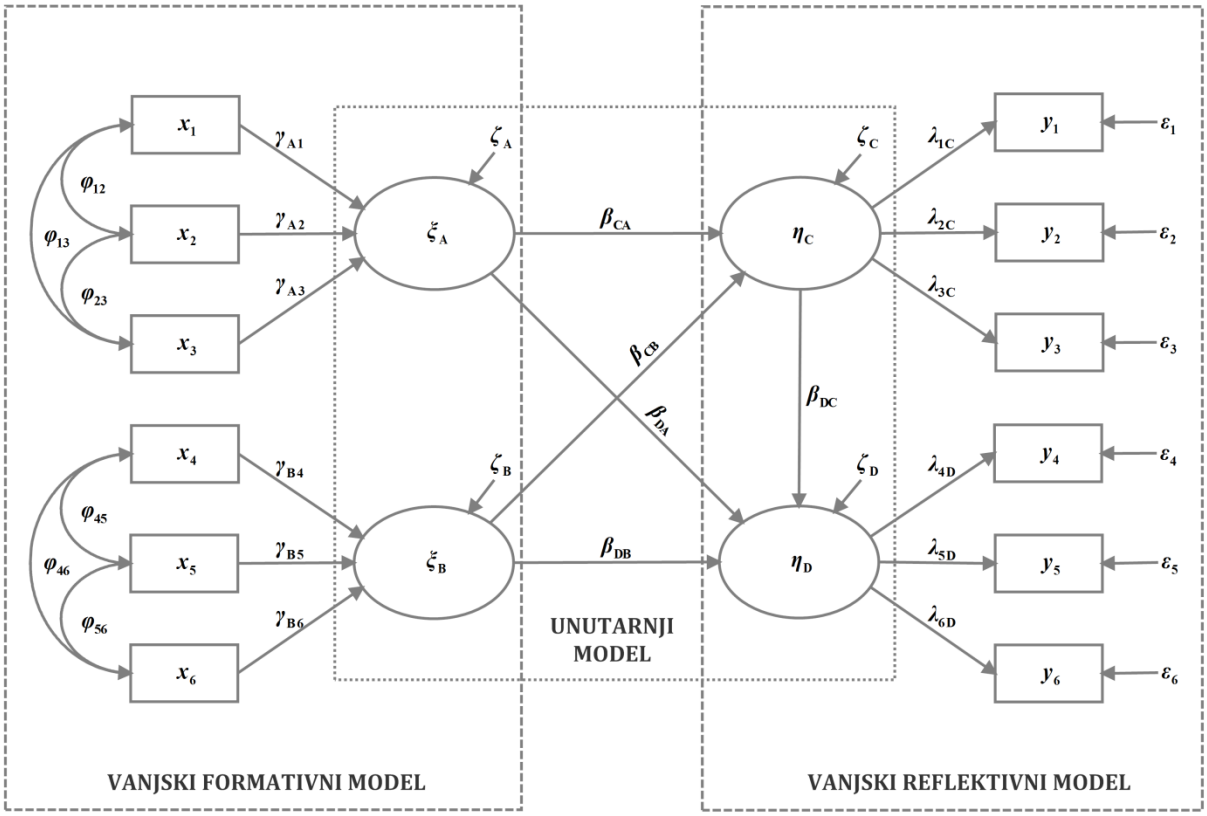

Slika 5.1 Primjer PLS-SEM modeliranja puta

Izvor: Henseler et al., 2009

Kod primjene metode modeliranja strukturalnim jednadžbama, posebnu je pozornost potrebno posvetiti operacionalizaciji uzročno-posljedičnih veza između latentnih i manifestnih varijabli. Naime, dominantna primjena CB-SEM tehnike rezultirala je pogrješnom specifikacijom velikog broja formativnih vanjskih modela (Albers, 2010; Cohen et al., 1990; Jarvis et al., 2003; Petter et al., 2007). Pogrješna specifikacija vanjskog modela povećava vjerojatnost manifestacije pogrješke Tipa I (da je vrijednost koeficijenta puta signifikantna, a zapravo nije signifikantna) i pogrješke Tipa II (da vrijednost koeficijenta puta nije signifikantna, a zapravo jest signifikantna), smanjuje valjanost statističkog zaključivanja vezanog uz unutarnji model (Jarvis et al., 2003; Law i Wong, 1999; MacKenzie, 2001; MacKenzie et al., 2005) te se negativno odražava na razvoj i testiranje teorija (Edwards i Bagozzi, 2000). Kako bi se izbjegli spomenuti problemi, potrebno je slijediti pravila konceptualizacije vanjskog modela koja se nalaze u tablici 5.3.

Tablica 5.3 Pravila odlučivanja vezana uz operacionalizaciju latentnih konstrukata

Formativni model	**Reflektivni model**
Smjer uzročnosti je od manifestnih varijabli prema latentnom konstruktu.	Smjer uzročnosti je od latentnog konstrukta prema manifestnim varijablama.
Manifestne varijable su obilježja koja određuju latentni konstrukt.	Manifestne varijable predstavljaju pojavnost latentnog konstrukta.
Promjene u manifestnim varijablama trebaju uzrokovati promjene u latentnom konstruktu.	Promjene u manifestnim varijablama ne trebaju uzrokovati promjene u latentnom konstruktu.
Promjene u latentnom konstruktu ne uzrokuju promjene u manifestnim varijablama.	Promjene u latentnom konstruktu uzrokuju promjene u manifestnim varijablama.
Manifestne varijable ne trebaju biti međusobno zamjenjive.	Manifestne varijable trebaju biti međusobno zamjenjive.
Manifestne varijable ne trebaju imati sličan sadržaj te ne trebaju dijeliti istu temu.	Manifestne varijable trebaju imati sličan sadržaj te trebaju dijeliti istu temu.
Uklanjanje manifestne varijable može promijeniti konceptualnu domenu latentnog konstrukta.	Uklanjanje manifestne varijable ne bi trebalo promijeniti konceptualnu domenu latentnog konstrukta.
Nije potrebno da manifestne varijable međusobno kovariraju.	Očekuje se da manifestne varijable međusobno kovariraju.
Nije nužno da promjena u jednoj manifestnoj varijabli bude povezana sa promjenama u preostalim manifestnim varijablama.	Promjena u jednoj manifestnoj varijabli je povezana sa promjenama u preostalim manifestnim varijablama.
Nomološka mreža manifestnih varijabli se može razlikovati.	Nomološka mreža manifestnih varijabli se ne bi smjela razlikovati.
Nije neophodno da manifestne varijable imaju iste prethodnike i sljedbenike.	Neophodno je da manifestne varijable imaju iste prethodnike i sljedbenike.
Rezidual (izraz smetnje) je na razini latentnog konstrukta.	Rezidual (pogrješka mjerenja) je na razini manifestnih varijabli.

Izvor: Bollen i Lennox (1991), Diamantopoulos i Winklhofer (2001), Jarvis et al. (2003)

Bez obzira na spomenuta pravila, Petter et al. (2007) su otkrili da je u praksi veliki broj latentnih konstrukata zapravo mješovitog tipa što znači da su im istovremeno pridružene formativne i reflektivne manifestne varijable. U takvim je slučajevima latentni konstrukt prije prikupljanja podataka potrebno modelirati na jedan od tri moguća načina (Petter et al., 2007). Prvi način je MIMIC (kratica za eng. Multiple Effect Indicators for Multiple Causes) modeliranje gdje se latentni konstrukt mjeri sa obje vrste manifestnih varijabli čime je istovremeno omogućena identifikacija formativnog latentnog konstrukta. Drugi način je da se iz skupa reflektivnih manifestnih varijabli namijenjenih mjerenju identičnog aspekta latentnog konstrukta uklone sve reflektivne manifestne varijable osim jedne. Navedeni će postupak rezultirati formativnim latentnim konstruktom čija sadržajna valjanost neće biti promijenjena. Posljednji način je višedimenzionalno modeliranje latentnog konstrukta.

Latentni konstrukt je višedimenzionalan kada su njegove manifestne varijable modelirane kao latentni konstrukti. Manifestne varijable višedimenzionalnog latentnog konstrukta se nazivaju dimenzije (Polites et al., 2012). Svaka dimenzija predstavlja specifičan aspekt konceptualne domene višedimenzionalnog latentnog konstrukta koji može biti operacionaliziran reflektivno ili formativno. Višedimenzionalni konstrukti su sačinjeni od barem dvije razine. Prva razina služi analizi veza između pojedine dimenzije i pridruženih manifestnih varijabli dok je druga razina namijenjena vrjednovanju odnosa između latentnog konstrukta druge razine i njegovih dimenzija (Diamantopoulos et al., 2008). Osnovna prednost višedimenzionalnih konstrukata je u modeliranju kompleksnih fenomena sačinjenih od velikog broja različitih prediktorskih i kriterijskih latentnih varijabli što rezultira povećanjem količine objašnjene varijance (Edwards, 2001). Ovisno o načinu modeliranja odnosa između razina i unutar pojedinih dimenzija, moguće je razlučiti nadređene (eng. superordinate), združene (eng. aggregate) i kombinirane (eng. mixed) višedimenzionalne konstrukte (Polites et al., 2012).

U nadređenom višedimenzionalnom konstruktu su veze između latentnog konstrukta druge razine i njegovih dimenzija operacionalizirane reflektivno (Edwards, 2001). Alternativni nazivi za nadređeni višedimenzionalan konstrukt su molekularan model (Chin, 2010; Chin i Gopal, 1995) i indirektno reflektivan model (Edwards i Bagozzi, 2000). Postoje dvije vrste nadređenih višedimenzionalnih konstrukata:

- reflektivan na prvoj razini, reflektivan na drugoj razini („Tip I“ prema Jarvis et al., 2003);
- formativan na prvoj razini, reflektivan na drugoj razini („Tip III“ prema Diamantopoulos et al., 2008; Jarvis et al., 2003).

Ukoliko su odnosi između latentnog konstrukta druge razine i njegovih dimenzija operacionalizirani formativno, riječ je o združenom višedimenzionalnom konstruktu. U literaturi se združeni višedimenzionalan konstrukt spominje i kao molaran model (Chin, 2010; Chin i Gopal, 1995) te indirektno formativan model (Edwards i Bagozzi, 2000). Postoje dva oblika združenih višedimenzionalnih konstrukata:

- formativan na prvoj razini, formativan na drugoj razini („Tip I“ prema Diamantopoulos et al., 2008; „Tip IV“ prema Jarvis et al., 2003);
- reflektivan na prvoj razini, formativan na drugoj razini („Tip II“ prema Diamantopoulos et al., 2008; Jarvis et al., 2003).

Kombinirani model je drugi naziv za višedimenzionalan latentan konstrukt koji udovoljava jednom od sljedeća tri kriterija (Polites et al., 2012):

a) sačinjen je od formativnih i reflektivnih dimenzija,
b) sastoji se od dimenzija sa formativnim manifestnim varijablama kao i od dimenzija sa reflektivnim manifestnim varijablama te
c) obuhvaća jednu ili veći broj dimenzija sa reflektivnim i formativnim manifestnim varijablama.

Konceptualni okvir vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama će biti modeliran kombinacijom združenih višedimenzionalnih konstrukata koji su ilustrirani na slikama 5.2 i 5.3.

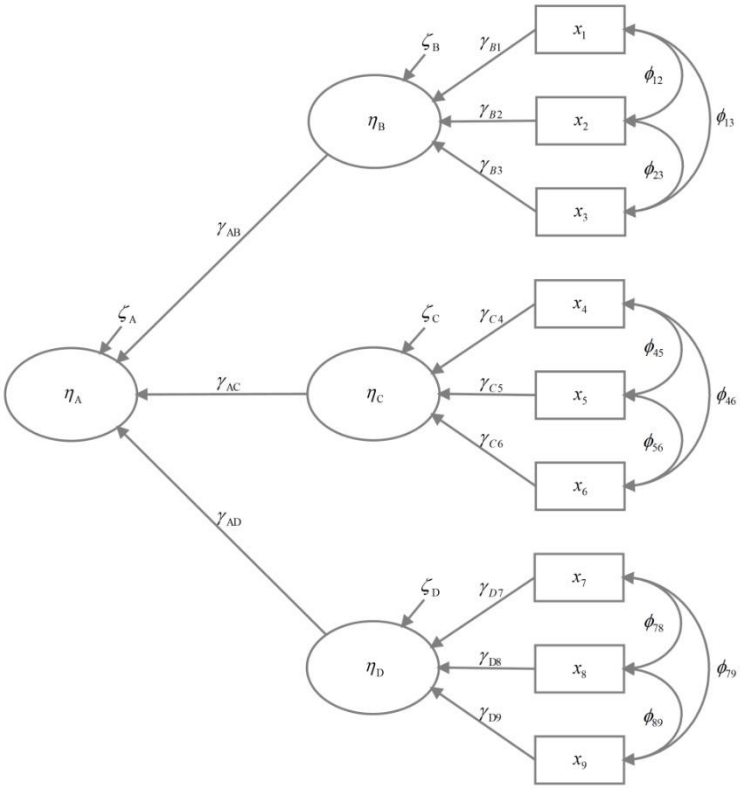

Slika 5.2 Višedimenzionalan združen konstrukt formativan na prvoj i drugoj razini

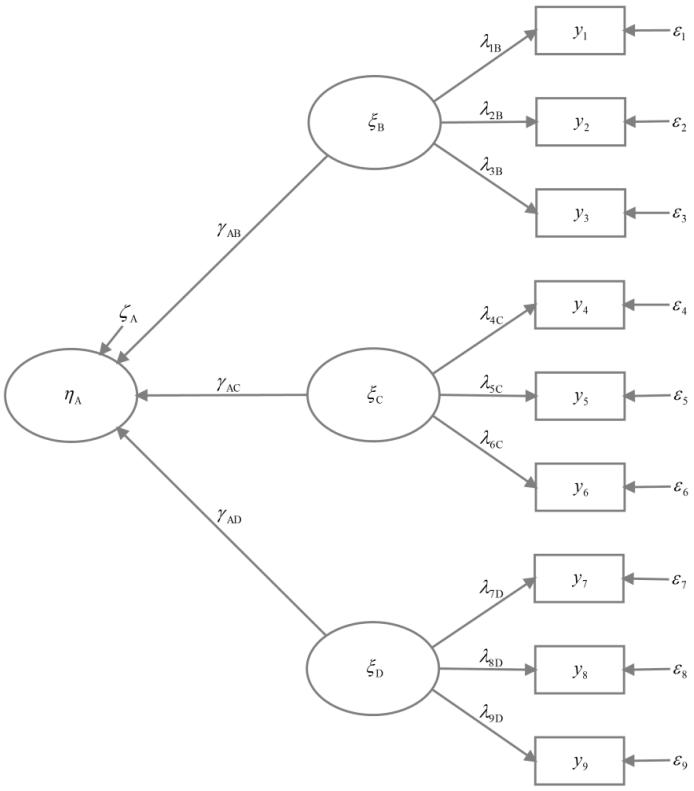

Slika 5.3 Višedimenzionalan združen konstrukt reflektivan na prvoj razini i formativan na drugoj razini

5.3.2 Vrjednovanje konceptualnog modela

PLS-SEM tehnika modeliranja puta se temelji na iterativnom algoritmu (Lohmöller, 1989) koji u prvom koraku vrši procjenu parametara vanjskog modela dok u drugom izračunava standardizirane koeficijente parcijalne regresije unutarnjeg modela (Esposito Vinzi et al., 2010). Shodno tome vrjednovanje konceptualnog modela započinje testiranjem metrijskih karakteristika vanjskog modela. Nakon što je utvrđeno da vanjski model udovoljava kriterijima valjanosti i pouzdanosti, pristupa se vrjednovanju teorijskih veza u unutarnjem modelu. Obzirom da u PLS-SEM modeliranju puta ne postoje globalni kriteriji testiranja podudaranja sa distribucijom (eng. goodness-of-fit), u nastavku će biti opisan katalog kriterija vrjednovanja vanjskih i unutarnjih modela koje je izvorno predložio Chin (1998).

5.3.2.1 Vrjednovanje vanjskog reflektivnog modela

Analiza metrijskih karakteristika vanjskog reflektivnog modela započinje vrjednovanjem pouzdanosti. Kriterij pouzdanosti se odnosi na različite aspekte dosljednosti na razini

konstrukta i manifestnih varijabli. Svrha vrjednovanja pouzdanosti je utvrditi preciznost vanjskog modela odnosno razlučiti koji dio ukupne varijance pripada pravoj varijanci, a koji dio varijanci pogrješke (Anastasi i Urbina, 1997).

Pouzdanost manifestnih varijabli

Količina varijance koju temeljni konstrukt može objasniti je indikator pouzdanosti manifestnih varijabli. Standardizirano vanjsko opterećenje manifestne varijable treba biti veće od 0,707 (Hair et al., 2011; Henseler et al., 2009) što implicira da konstrukt kojem je manifestna varijabla pridružena može objasniti više od 50% njene varijance ($\sqrt{0{,}5} \approx 0{,}707$). Navedena referentna vrijednost označava da je varijanca između konstrukta i manifestne varijable veća od varijance pogrješke mjerenja. Manifestne varijable čija su standardizirana vanjska opterećenja između 0,40 i 0,707 treba ukloniti iz vanjskog modela samo ako će to rezultirati povećanjem kompozitne pouzdanosti iznad referentne vrijednosti (Hair et al., 2011; Henseler et al., 2009). U slučajevima kada je vrijednost standardiziranog vanjskog opterećenja manja od 0,400, manifestnu je varijablu potrebno eliminirati iz vanjskog reflektivnog modela (Churchill, 1979; Hulland, 1999).

Pouzdanost latentnih konstrukata

Konstrukt je pouzdan ukoliko ga pridružene manifestne varijable dosljedno mjere. Najčešće korištena mjera vrjednovanja pouzdanosti konstrukta je Cronbachov α koeficijent unutarnje dosljednosti (Cronbach, 1951). Cronbachov α je kriterij jednodimenzionalnosti konstrukta koji se izračunava temeljem međukorelacija (eng. intercorrelations) manifestnih varijabli (Götz et al., 2010):

$$Cronbachov\ \alpha = \left(\frac{N}{N-1}\right) * \left(1 - \frac{\sum_{i=1}^{N} \sigma_i^2}{\sigma_t^2}\right) \tag{5.11}$$

gdje je N broj manifestnih varijabli pridruženih konstruktu, σ_i^2 predstavlja varijancu i-tog konstrukta dok σ_t^2 označava varijancu sume rezultata pridruženih manifestnih varijabli. Obzirom da se izračun Cronbachovog α koeficijenta zasniva na pretpostavci da je pouzdanost svih manifestnih varijabli podjednaka, isti ima tendenciju da podcijeni vrijednost unutarnje dosljednosti konstrukta. Osim toga, veličina uzorka i količina manifestnih varijabli značajno utječu na preciznost izračuna Cronbachovog α koeficijenta (Götz et al., 2010; Hair et al., 2011; Henseler et al., 2009). Zbog navedenih se razloga kao mnogo prikladnija mjera unutarnje

dosljednosti konstrukta upotrebljava kompozitna pouzdanost ρ_c (Fornell i Larcker, 1981; Werts et al., 1974):

$$\rho_c = \frac{(\sum_i \lambda_i)^2}{(\sum_i \lambda_i)^2 + \sum_i var(\varepsilon_i)} \tag{5.12}$$

gdje λ_i predstavlja opterećenje, a ε_i pogrješku mjerenja *i*-te manifestne varijable, dok je $var(\varepsilon_i)$ oznaka za $1 - \lambda_i^2$ u slučaju standardiziranih manifestnih varijabli. Kompozitna pouzdanost je precizna mjera unutarnje dosljednosti konstrukta dok Cronbachov α predstavlja njenu donju granicu. Oba kriterija mogu poprimiti vrijednost u intervalu [0,1]. Bez obzira na to koji se od spomenuta dva kriterija upotrebljava za vrjednovanje unutarnje dosljednosti konstrukta, njihove vrijednosti između 0,60 i 0,70 su prihvatljive ukoliko je riječ o eksplorativnim istraživanjima, vrijednosti iznad 0,80 su poželjne u kontekstu konfirmativnih istraživanja dok vrijednosti ispod 0,60 upozoravaju na nedovoljnu količinu pouzdanosti konstrukta (Bagozzi i Yi 1988; Hair et al., 2006; Nunnally i Bernstein, 1994).

Valjanost latentnih konstrukata

Kriteriji konstruktne valjanosti služe utvrđivanju mjere do koje je operacionalizacija konstrukta odnosno specifičnog teorijskog koncepta pomoću manifestnih varijabli empirijski opravdana (Straub et al., 2004). U kontekstu vrjednovanja vanjskog reflektivnog modela, postoje dva kriterija namijenjena utvrđivanju konstruktne valjanosti: konvergentna i diskriminacijska valjanost.

Konvergentna valjanost je postupak dokazivanja povezanosti između konstrukta i pridruženih manifestnih varijabli. Kao mjeru vrjednovanja konvergentne valjanosti, Fornell i Larcker (1981) su predložili izračun prosječne ekstrahirane varijance (eng. Average Variance Extracted, AVE):

$$AVE = \frac{\sum_i \lambda_i^2}{\sum_i \lambda_i^2 + \sum_i var(\varepsilon_i)} \tag{5.13}$$

Vrijednost AVE od 0,50 ili više označava dostatnu razinu konvergentne valjanosti što znači da konstrukt u prosjeku objašnjava 50% ili više varijance pridruženih manifestnih varijabli. S druge strane, vrijednost AVE manja od 0,50 nije prihvatljiva jer se veći dio objašnjene varijance odnosi na varijancu pogrješke, a ne na varijancu manifestnih varijabli.

Postupak kojim se dokazuje da između manifestnih varijabli temeljnog konstrukta i ostalih konstrukata u vanjskom reflektivnom modelu ne postoji povezanost ili je ona vrlo niska nosi

naziv diskriminacijska valjanost. U PLS modeliranju puta postoje dva kriterija diskriminacijske valjanosti. Prvi je Fornell-Larcker kriterij (Fornell i Larcker, 1981) prema kojem konstrukt treba dijeliti više varijance sa pridruženim manifestnim varijablama nego sa preostalim konstruktima. Shodno tome, vrijednost drugog korijena od AVE pojedinog konstrukta treba biti veća od njegove dvosmjerne korelacije sa ostalim konstruktima u vanjskom reflektivnom modelu. Prema drugom kriteriju, vrijednost standardiziranog faktorskog opterećenja pojedine manifestne varijable sa temeljnim konstruktom treba biti veća od svih vrijednosti unakrsnih opterećenja (eng. cross-loadings) sa preostalim konstruktima vanjskog reflektivnog modela (Chin, 1998; Götz et al., 2010).

* * *

Kako bi se osigurala pouzdanost i valjanost vanjskog reflektivnog modela, sve referentne vrijednosti spomenutih kriterija moraju biti zadovoljene. Ukoliko su latentni konstrukti pouzdani i valjani, tolerira se da valjanost i pouzdanost pojedinih manifestnih varijabli bude manja od referentnih vrijednosti (MacKenzie et al., 2005). U protivnom je potrebno provesti reviziju vanjskog reflektivnog modela te iz istog ukloniti manifestne varijable i/ili konstrukte koji ne udovoljavaju kriterijima valjanosti i pouzdanosti (Nunnally i Bernstein, 1994).

5.3.2.2 Vrjednovanje vanjskog formativnog modela

U vanjskom formativnom modelu se rezidual nalazi na razini latentnog konstrukta čime se implicira da su manifestne varijable bez pogrješaka (Edwards i Bagozzi, 2000). Osim toga, formativno operacionalizirane manifestne varijable su heterogene dok je njihov temeljni latentni konstrukt višedimenzionalan (Chin, 2010). Zbog toga tradicionalni oblici vrjednovanja pouzdanosti i valjanosti vanjskog reflektivnog modela nisu prikladni za testiranje metrijskih karakteristika vanjskog formativnog modela (Diamantopoulos, 2006; Petter et al., 2007). Umjesto toga, osnovni kriteriji analize formativno operacionaliziranih vanjskih modela su (Cenfetelli i Bassellier, 2009; Diamantopoulos et al., 2008; Götz et al., 2010; Hair et al., 2011; Henseler et al., 2009): testiranje multikolinearnosti, relativan i apsolutan doprinos pojedine manifestne varijable u konceptualnoj strukturi temeljnog latentnog konstrukta, eksterna valjanost i nomološka valjanost.

Kao alternativa vrjednovanju pouzdanosti formativnih manifestnih varijabli provodi se testiranje značajnosti njihovog relativnog i apsolutnog doprinosa konceptualnoj strukturi temeljnog latentnog konstrukta (Cenfetelli i Bassellier, 2009; Götz et al., 2010; Hair et al., 2011;

MacKenzie et al., 2005). Relativan doprinos manifestne varijable je njen standardizirani koeficijent parcijalne regresije (težinska vrijednost) dok apsolutan doprinos predstavlja dvosmjernu korelaciju (faktorsko opterećenje) između manifestne varijable i temeljnog latentnog konstrukta. Značajnost se testira primjenom *bootstrapping* tehnike ponovnog uzorkovanja (detaljno opisane u sljedećem potpoglavlju) koja je izvorno namijenjena vrjednovanju značajnosti koeficijenata puta između egzogenih i endogenih latentnih konstrukata u unutarnjem modelu (Chin, 1998; Chin, 2010).

Potrebno je naglasiti da je broj pridruženih manifestnih varijabli obrnuto proporcionalan količini varijance koju iste u temeljnom latentnom konstruktu mogu objasniti što može rezultirati time da težinske vrijednosti manifestnih varijabli ne budu značajno različite od nule. Naime, ukoliko je formativni latentni konstrukt sačinjen od n manifestnih varijabli, tada prosječna standardizirana težinska vrijednost može maksimalno iznositi $n^{-1/2}$ (Cenfetelli i Bassellier, 2009). Problem velikog broja manifestnih varijabli i shodno tome nesignifikantnosti težinskih vrijednosti se može riješiti jednim od sljedećih načina (Cenfetelli i Bassellier, 2009): a) pregrupiranjem manifestnih varijabli u teorijski srodne latentne konstrukte sa odvojenim utjecajem na relevantne kriterijske varijable, b) višedimenzionalnim modeliranjem konstrukta ili c) uklanjanjem manifestnih varijabli čije težinske vrijednosti nisu signifikantne.

Prilikom interpretacije relativnog doprinosa manifestnih varijabli, posebnu je pozornost potrebno obratiti na predznak težinskih vrijednosti. Ukoliko težinske vrijednosti manifestnih varijabli temeljnog latentnog konstrukta imaju različiti predznak, potrebno je provesti analizu utjecaja supresora. Pod supresorom se podrazumijeva manifestna varijabla koja umjesto da objašnjava varijancu u latentnom konstruktu zapravo objašnjava varijancu pogrješke u preostalim manifestnim varijablama (Cohen et al., 2002). Supresor varijable mogu smanjiti komunalitet u vanjskom formativnom modelu što se manifestira kao nesignifikantnost i promjena predznaka težinske vrijednosti. Ukoliko se u modelu nalaze supresori koji su kolinearni sa ostalim manifestnim varijablama, tada ih je potrebno ukloniti iz vanjskog modela (Cenfetelli i Bassellier, 2009). Međutim, ako pojedina formativna manifestna varijabla ima statistički značajnu negativnu težinsku vrijednost (beta koeficijent) i pozitivno faktorsko opterećenje, ista se interpretira u kontekstu negativnog utjecaja na temeljni latentni konstrukt (Cenfetelli i Bassellier, 2009).

Multikolinearnost

Multikolinearnost je nepoželjna karakteristika formativnih manifestnih varijabli iz razloga što su iste operacionalizirane da objašnjavaju varijancu u temeljnom latentnom konstruktu, a ne

zajedničku varijancu (Cenfetelli i Bassellier, 2009). Zbog navedenog nije prikladno vrjednovati unutarnju dosljednost formativnih latentnih konstrukata (Bagozzi, 1994; Hulland, 1999) jer bi to moglo rezultirati uklanjanjem valjanih formativnih manifestnih varijabli (Bollen i Lennox, 1991; Nunally i Bernstein, 1994). Obzirom da se izračun parametara vanjskog formativnog modela temelji na principima multivarijatne regresijske analize, visoka razina multikolinearnosti može prouzročiti nesignifikantnost i promjenu predznaka beta koeficijenata (Cenfetelli i Bassellier, 2009; Diamantopoulos i Winklhofer, 2001; Götz et al., 2010; Hair et al., 2011) i shodno tome onemogućiti identifikaciju relativnog doprinosa manifestnih varijabli u konceptualnoj strukturi temeljnog latentnog konstrukta (Bollen, 1989; Chin, 1998; MacKenzie et al., 2005). Osim toga, multikolinearnost je i pokazatelj redundance u vanjskom formativnom modelu što implicira da pojedine manifestne varijable mjere identičan aspekt temeljnog latentnog konstrukta (Bollen i Lennox, 1991; Cenfetelli i Bassellier, 2009; Hair et al., 2011; Henseler et al., 2009). Kao mjera vrjednovanja multikolinearnosti upotrebljava se koeficijent inflacije varijance (Variance Inflation Factor, VIF; Cassel et al., 2000; Chin, 2010; Diamantopoulos i Winklhofer, 2001; Götz et al., 2010; Grewal et al., 2004) koji se izračunava kao inverz koeficijenta tolerancije (Craney i Surles; 2002):

$$VIF_i = \frac{1}{1 - R_i^2} \tag{5.14}$$

gdje je R_i^2 koeficijent determinacije *i*-te manifestne varijable. Premda svaka vrijednost $VIF > 1$ ukazuje na problem multikolinearnosti (Henseler et al., 2009), u literaturi se prihvatljive referentne vrijednosti kreću u rasponu od 3.33 (Diamantopoulos i Siguaw, 2006) preko 5 (Cenfetelli i Bassellier, 2009; Hair et al., 2011) pa sve do 10 (Henseler et al, 2009; Petter et al., 2007). Primjerice, $VIF_i = 5$ implicira da je $R_i^2 = 0.8$ što znači da je 80% varijance u *i*-toj manifestnoj varijabli objašnjeno preostalim manifestnim varijablama pridruženih temeljnom latentnom konstruktu. Ukoliko je VIF veći od prihvatljive referentne vrijednosti, Diamantopoulos i Siguaw (2006) predlažu poduzimanje jedne od sljedećih mogućih aktivnosti: a) konceptualizirati formativni konstrukt kao MIMIC model, b) spojiti korelirane manifestne varijable u kompozitni indeks, c) modelirati formativni konstrukt višedimenzionalno ili d) iz vanjskog formativnog modela ukloniti manifestne varijable koje koreliraju.

Eksterna i nomološka valjanost

Kao kriterij vrjednovanja pouzdanosti formativnih latentnih konstrukata upotrebljava se testiranje eksterne valjanosti analizom redundance (Chin, 1998; MacKenzie et al., 2005). Analiza

redundance se sastoji od modeliranja povezanosti egzogenog formativnog i njemu konceptualno ekvivalentnog endogenog reflektivnog konstrukta (Cenfetelli i Bassellier, 2009). Vrijednost standardiziranog koeficijenta parcijalne regresije između navedenih konstrukata treba iznositi barem 0,80 što znači da je formativni konstrukt valjan jer sadrži 80% namjeravanog značenja (Chin, 1998). Ukoliko pojedini konceptualni aspekt nije moguće mjeriti reflektivnim već isključivo formativnim manifestnim varijablama, tada se umjesto eksterne vrjednuje nomološka valjanost formativnog konstrukta (Chin, 2010; Diamantopoulos i Winklhofer, 2001; Götz et al., 2010). Vrjednovanje nomološke valjanosti se sastoji od analize reda veličine i značajnosti teorijski utemeljenih veza između egzogenog formativnog konstrukta i endogenih konstrukata u unutarnjem modelu (Diamantopoulos et al., 2008; Henseler et al., 2009) o čemu će više biti riječi u sljedećem potpoglavlju.

Konvergentna i diskriminacijska valjanost

Brojni autori (primjerice Bagozzi, 1994; Fornell i Larcker, 1981; Hair et al., 2011) smatraju da empirijsko vrjednovanje konvergentne i diskriminacijske valjanosti formativnih latentnih konstrukata zbog prirode operacionalizacije njihovih manifestnih varijabli nije potrebno ni moguće. S druge strane, MacKenzie et al. (2005) predlažu da se vrjednovanje diskriminacijske valjanosti provodi na jednak način neovisno o operacionalizaciji latentnog konstrukta. Međukorelacija formativnih latentnih manifestnih varijabli treba biti manja od 0,707 što znači da iste dijele značajno manje od 50% zajedničke varijance (MacKenzie et al., 2005). Konačno, Petter et al. (2007) i Rossiter (2002) smatraju da su konvergentna i diskriminacijska valjanost latentnog konstrukta osigurane primjenom metode sortiranja karata.

* * *

Iz svega dosad navedenog je evidentno da je manifestnu varijablu potrebno ukloniti iz vanjskog formativnog modela ako a) je razina multikolinearnosti veća od prihvatljive referentne vrijednosti; b) beta koeficijenti i faktorska opterećenja nisu značajno veći od nule; c) preostale manifestne varijable u dostatnoj mjeri obuhvaćaju konceptualnu domenu latentnog konstrukta. Međutim, potrebno je naglasiti da izostavljanje pojedine manifestne varijable iz vanjskog formativnog modela temeljem isključivo empirijskih podataka može značajno narušiti konceptualnu strukturu latentnog konstrukta te umanjiti njegovu sadržajnu valjanost (Diamantopoulos i Siguaw, 2006). Prema tome, ukoliko postoji snažno uporište za konceptualizaciju latentnog konstrukta (temeljem primjerice rezultata vrjednovanja sadržajne valjanosti) manifestne varijable je potrebno zadržati u vanjskom formativnom modelu bez

obzira na signifikantnost njihovih standardiziranih koeficijenata parcijalne regresije (Bollen i Lennox, 1991; Jarvis et al., 2003; Henseler et al., 2009).

5.3.2.3 Vrjednovanje unutarnjeg modela

Nakon što je utvrđeno da vanjski model udovoljava kriterijima pouzdanosti i valjanosti, pristupa se vrjednovanju unutarnjeg modela pomoću sljedećih neparametrijskih kriterija (Chin, 1998): koeficijenta determinacije, značajnosti standardiziranih koeficijenata puta, veličine utjecaja i prediktivne valjanosti.

Koeficijent determinacije (R^2) ili kvadrat multiple korelacije je relativna mjera prilagođenosti regresijskog pravca empirijskim podacima. Prema tome, R^2 predstavlja proporciju zajedničke varijance između endogene (zavisne) varijable i skupa prediktora. U tablici 5.4 se nalazi pregled referentnih vrijednosti koeficijenta determinacije koje prema različitim autorima impliciraju jaku, umjerenu i slabu prediktorsku snagu skupa egzogenih (nezavisnih) latentnih varijabli.

Tablica 5.4 Referentne vrijednosti koeficijenta determinacije

Autor	**Intenzitet prediktorske snage egzogenih latentnih varijabli**		
	Jak	**Umjeren**	**Slab**
Cohen (1988)	0,26	0,13	0,02
Chin (1998)	0,67	0,33	0,19
Hair et al. (2011)	0,75	0,50	0,25

Ako je pojedina endogena latentna varijabla objašnjena sa manjim brojem egzogenih latentnih varijabli, tada je umjerena vrijednost koeficijenta R^2 dostatna. Međutim, ako endogena latentna varijabla ovisi o velikom broju egzogenih varijabli, tada je prihvatljivo da vrijednost koeficijenta R^2 ukazuje na njihovu jaku povezanost (Henseler et al., 2009). Potrebno je napomenuti da navedene referentne vrijednosti koeficijenta determinacije nije moguće generalizirati već one ovise o specifičnostima pojedine istraživačke discipline (Götz et al., 2010; Hair et al., 2011).

U sljedećem se koraku primjenom *bootstrapping* procedure vrjednuje značajnost koeficijenata puta između skupa prediktora i zavisne latentne varijable. Obzirom da koeficijenti puta pokazuju udio pojedinih endogenih latentnih varijabli u objašnjavanju zajedničke varijance, isti se mogu interpretirati kao standardizirani koeficijenti parcijalne regresije (Henseler et al., 2009; Hair et al., 2011). Pod pretpostavkom da originalan uzorak predstavlja distribuciju populacije, bootstrapping procedura generira veliki broj unaprijed definiranih bootstrap uzoraka. Minimalan broj bootstrapping uzoraka se kreće u intervalu od 1.000 (Chin, 2010) do 5.000 (Hair

et al., 2011; Henseler et al., 2009) dok broj slučajeva u svakom bootstrap uzorku treba biti identičan broju opažanja iz originalnog uzorka (Hair et al., 2011). Postoje tri načina generiranja bootstrap uzoraka (Tenenhaus et al., 2005):

- bez promjene predznaka koji se ne preporuča iz razloga što može rezultirati sa vrlo visokim standardnim pogrješkama i shodno tome niskim t-vrijednostima;
- sa individualnom promjenom predznaka gdje je predznak svakog vanjskog pondera usklađen sa pripadajućim predznakom iz originalnog uzorka, ali ga je zbog nedostatka usklađenosti na globalnoj razini (npr. obrnuto kodirane varijable) potrebno koristiti s oprezom;
- sa promjenom predznaka na razini konstrukta gdje se za svaku latentnu varijablu uspoređuju L_{jh}^{R} opterećenja h-te manifestne varijable na j-tu latentnu varijablu iz bootstrap uzorka sa L_{jh}^{S} opterećenjima h-te manifestne varijable na j-tu latentnu varijablu iz originalnog uzorka te se mijenja predznak vanjskom ponderu latentne varijable ukoliko vrijedi $\left|\sum_h \left(L_{jh}^{S} - L_{jh}^{R}\right)\right| > \left|\sum_h \left(L_{jh}^{S} + L_{jh}^{R}\right)\right|$.

Bootstrapping uzorci se generiraju na način da se opažanja iz originalnog uzorka odabiru nasumično sa zamjenom što znači da se pojedino opažanje iz originalnog uzorka može u bootstrap uzorku pojaviti više od jednom. Nakon toga PLS algoritam za sve bootstrapping uzorke izračunava koeficijente puta, njihove srednje vrijednosti i standardne pogrješke. Izračunati koeficijenti puta zajedno tvore bootstrapping distribuciju koja predstavlja aproksimaciju distribucije uzorkovanja (Hair et al., 2011; Henseler et al., 2009). Koeficijent puta čiji je predznak ujednačen sa teorijski pretpostavljenim predznakom pruža parcijalnu validaciju veze između endogene i egzogene latentne varijable. Vrijednosti dobivene bootstrapping procedurom omogućuju izračun t-statistike (Chin, 1998):

$$t_i = \frac{w_i}{se(w_i)} \tag{5.15}$$

gdje t_i predstavlja empirijsku t-vrijednost za i-ti koeficijent puta, w_i je originalan PLS izračun i-tog koeficijenta puta dok je $se(w_i)$ njegova bootstrapping standardna pogrješka. Referentne t-vrijednosti za dvosmjerni test su 1,65 ($p < 0{,}10$), 1,96 ($p < 0{,}05$) i 2,58 ($p < 0{,}01$) sa $n - 1$ stupnjeva slobode gdje je n veličina bootstrapping distribucije. Ukoliko je empirijska t-vrijednost veća od referentne t-vrijednosti, prihvaća se hipoteza o značajnosti koeficijenta puta.

Treći kriterij vrjednovanja unutarnjeg modela je promjena u koeficijentu determinacije R^2 odnosno veličina utjecaja pojedinog prediktora na endogenu latentnu varijablu. Veličina utjecaja f^2 se izračunava na sljedeći način (Cohen, 1988):

$$f^2 = \frac{R_u^2 - R_i^2}{1 - R_u^2} \tag{5.16}$$

gdje je R_u^2 vrijednost koeficijenta determinacije kada se u unutarnjem modelu nalaze sve latentne varijable dok R_i^2 predstavlja vrijednost koeficijenta determinacije kada je iz unutarnjeg modela uklonjena egzogena latentna varijabla za koju se izračunava veličina utjecaja. Vrijednosti f^2 od 0,02, 0,15 i 0,35 impliciraju mali, srednji i veliki utjecaj pojedine egzogene latentne varijable na endogenu latentnu varijablu, respektivno (Cohen, 1988).

Posljednji kriterij vrjednovanja unutarnjeg modela je Stone-Geisserov Q^2 koeficijent prediktivne valjanosti (Stone, 1974; Geisser, 1975) prema kojem model mora biti u mogućnosti do određene razine rekonstruirati manifestne varijable svakog endogenog latentnog konstrukta. Vrijednost koeficijenta Q^2 se izračunava primjenom *blindfolding* tehnike ponovnog korištenja uzorka (Wold, 1982). Počam od prvog podatkovnog elementa (prvo opažanje, prva manifestna varijabla), blindfolding procedura izostavlja svaki D-ti podatkovni element sve dok ne dosegne kraj $N \cdot K$ matrice. Vrijednost razmaka udaljenosti D treba biti cijeli broj između broja manifestnih varijabli K i broja opažanja N (Wold, 1982). Ukoliko je N velik, preporučljivo je da vrijednost od D bude između 5 i 10 (Chin, 1998). U sljedećem se koraku pomoću preostalih podatkovnih elemenata izračunavaju parametri modela te se usporedo primjenom procedure udvojenog brisanja (eng. pairwise deletion), zamjene srednje vrijednosti (eng. mean substitution) ili imputacije (eng. imputation) rekonstruiraju izostavljeni podatkovni elementi. Slijedi izračun sume kvadrata predikcije pogrješaka i sume kvadrata opažanja. Predikcija pogrješke je razlika između izostavljene i predviđene vrijednosti podatkovnog elementa (Götz et al., 2010). Nakon toga se izostavljeni podatkovni elementi vraćaju u matricu te se blindfolding procedura nastavlja sa drugim podatkovnim elementom (prvo opažanje, druga manifestna varijabla). Postupak se ponavlja sve dok svi podatkovni elementi u matrici ne budu izostavljeni i ne izvrši se predikcija njihovih vrijednosti odnosno dok se ne izračuna D suma kvadrata predikcije pogrješaka i suma kvadrata opažanja. Postoje dva oblika Q^2 statistike (Tenenhaus et al., 2005):

- Unakrsno validiran komunalitet (eng. cross-validated communality) je kriterij vrjednovanja vanjskog modela koji temeljem rezultata temeljnog latentnog konstrukta predviđa izostavljene manifestne varijable.

- Unakrsno validirana redundanca (eng. cross-validated redundancy) je mjera vrjednovanja prediktivne valjanosti unutarnjeg modela koja vrši predikciju izostavljenih endogenih manifestnih varijabli pomoću vrijednosti egzogenih latentnih konstrukata.

U PLS-SEM modeliranju puta se vrjednovanje prediktivne valjanosti unutarnjeg modela provodi pomoću indeksa unakrsno validirane redundance koji se izračunava na sljedeći način (Stone, 1974; Geisser, 1975):

$$Q_j^2 = 1 - \frac{\sum_h SSE_{jh}}{\sum_h SSO_{jh}} \tag{5.17}$$

gdje SSE_{jh} označava kvadrate predikcije pogrješaka, SSO_{jh} predstavlja kvadrate opažanja, indeks j obilježava opaženi endogeni vanjski model, a indeks h ukazuje na manifestne varijable vanjskog modela. Ukoliko je $Q^2 > 0$, opažene vrijednosti izostavljenih manifestnih varijabli su dobro rekonstruirane te je unutarnji model prediktivno relevantan (Chin, 1998; Fornell i Cha, 1994). Prediktivna valjanost egzogenog latentnog konstrukta q^2 se kao promjena u Q^2 izračunava po uzoru na koeficijent veličine utjecaja f^2:

$$q^2 = \frac{Q_u^2 - Q_i^2}{1 - Q_u^2} \tag{5.18}$$

gdje je Q_u^2 vrijednost unakrsno validirane redundance kada se u unutarnjem modelu nalaze svi egzogeni latentni konstrukti dok Q_i^2 predstavlja vrijednost unakrsno validirane redundance kada je iz unutarnjeg modela uklonjen egzogeni latentni konstrukt za kojeg se prediktivna valjanost izračunava. Vrijednosti q^2 od 0,02, 0,15 i 0,35 otkrivaju malu, srednju i veliku prediktivnu valjanost pojedinog egzogenog latentnog konstrukta, respektivno.

5.3.2.4 Vrjednovanje višedimenzionalnih konstrukata

Primjena neparametrijskih testova vrjednovanja unutarnjih i vanjskih modela u analizi višedimenzionalnih konstrukata ovisi o operacionalizaciji odnosa između razina i unutar pojedinih dimenzija. Wetzels et al. (2009) upozoravaju na dva problema koji se mogu pojaviti kod vrjednovanja valjanosti i pouzdanosti višedimenzionalnih konstrukata. Prvi je da se povećanjem heterogenosti dimenzija smanjuje unutarnja dosljednost konstrukta, s drugi u pitanje dovodi valjanost konstrukta zbog velike količine specifične i grupne varijance koja se često tretira kao varijanca pogrješke. Kako bi se reducirale posljedice spomenutih problema,

Wilson i Henseler (2007) predlažu da se vrjednovanje višedimenzionalnih konstrukata provede pomoću tehnike hijerarhijskih komponenti (eng. Hierarchical Components Approach) ili dvostupanjske tehnike (eng. Two-Stage Approach) koje su izvorno namijenjene analizi učinka moderatora.

Primjenom tehnike hijerarhijskih komponenti (Chin et al. 2003; Lohmöller, 1989; Wold, 1982) višedimenzionalan konstrukt se direktno mjeri pomoću manifestnih varijabli svih njegovih dimenzija. Ova se tehnika još naziva i pristup ponovljenih manifestnih varijabli ili super blok pristup (Tenenhaus et al., 2005) iz razloga što se iste manifestne varijable upotrebljavaju za modeliranje puta i izračun parametara na svim razinama u višedimenzionalnom latentnom konstruktu. Dvostupanjska tehnika (Henseler i Chin, 2010; Henseler i Fassott, 2010; Wilson i Henseler, 2007) je prikladna za vrjednovanje formativno operacionaliziranih višerazinskih konstrukata (Diamantopoulos i Winklhofer, 2001). Njenom se provedbom svaka razina višedimenzionalnog latentnog konstrukta modelira i vrjednuje zasebno. Najprije se temeljem manifestnih varijabli izračunavaju vrijednosti latentnih konstrukata niže razine. Dobivene vrijednosti se potom u maniri manifestnih varijabli koriste za izračun vrijednosti latentnih konstrukata više razine. Potrebno je napomenuti da se izračun vrijednosti latentnih konstrukata niže razine provodi bez prisustva latentnih konstrukata više razine u modelu. Jednako tako, vrijednosti latentnih konstrukata više razine se izračunavaju bez prisustva manifestnih varijabli pridruženih latentnim konstruktima niže razine u modelu.

U kontekstu vrjednovanja združenih višedimenzionalnih latentnih konstrukata, Ringle et al. (2012) predlažu implementaciju kombinacije spomenute dvije tehnike. U prvom se koraku primjenjuje tehnika hijerarhijskih komponenti kako bi se izračunale vrijednosti latentnih konstrukata niže razine. Dobivene vrijednosti se u drugom koraku upotrebljavaju kao manifestne varijable latentnih konstrukata više razine te služe izračunu njihovih vrijednosti. Kao i u slučaju dvostupanjske tehnike, u drugi korak provedbe kombinirane tehnike nisu uključene manifestne varijable temeljem kojih su izračunate vrijednosti latentnih varijabli niže razine. Nasuprot tome, Ciavolino i Nitti (2013) predlažu hibridnu dvostupanjsku tehniku čija se primjena od „originalne“ dvostupanjske tehnike razlikuje jedino po tome što su za vrijeme izračuna vrijednosti latentnih konstrukata više razine manifestne varijable pridružene latentnom konstruktu niže razine prisutne u modelu.

Kako bi se iskoristile prednosti i umanjili nedostatci spomenuta dva hibridna pristupa, u sklopu ovog doktorskog rada će se vrjednovanje višedimenzionalnih latentnih konstrukata temeljiti na njihovom spletu. Najprije će uz prisustvo latentnih konstrukata više razine u modelu primjenom tehnike hijerarhijskih komponenti biti izračunate vrijednosti latentnih konstrukata niže razine.

Zatim će ponovljene manifestne varijable na višoj razini latentnih konstrukata biti zamijenjene vrijednostima latentnih konstrukata niže razine te će temeljem njih biti izračunate vrijednosti latentnih konstrukata više razine pri čemu će manifestne varijable pridružene latentnim konstruktima niže razine i dalje biti prisutne u modelu. Zbog svega navedenog će se vrjednovanje metrijskih karakteristika latentnih konstrukata niže razine temeljiti na njihovom međuodnosu sa pridruženim manifestnim varijablama dok će se analiza metrijskih karakteristika latentnih konstrukata više razine bazirati na njihovom međuodnosu sa latentnim konstruktima niže razine (Becker et al., 2012).

5.4 Logičko bodovanje preferencija

Logičko bodovanje preferencija (eng. Logic Scoring of Preferences, LSP; Dujmović, 1975) je kvantitativna metoda vrjednovanja koja se zasniva na logici kontinuiranih preferencija (eng. Continuous Preference Logic; Dujmović, 2007). Metoda predstavlja poopćenje tehnika donošenja odluka te je dosad korištena u vrjednovanju različitih vrsta web mjesta. Primjerice, Alva et al. (2010) su podatke prikupljali upitnikom dok su preostali istraživači (Buckley i Dujmović, 2008; Debnath et al., 2007; Gledec, 2005; Olsina i Rossi, 2002; Tripathi et al., 2008) vrjednovanje temeljili na objektivnim metrikama. Međutim, Yip i Mendes (2005) su otkrili da se rezultati objektivnog mjerenja upotrebljivosti web mjesta bazirani na primjeni metode logičkog bodovanja preferencija i subjektivnog vrjednovanja značajno razlikuju. Kako bi se uklonio navedeni nedostatak, primjenom metode će se, na osnovi subjektivnih i objektivnih varijabli, oblikovati kriterijske funkcije te će se pomoću njih izračunati kompozitni kvantitativni pokazatelj kvalitete u korištenju Web 2.0 aplikacijama. Primjena metode logičkog bodovanja preferencija se sastoji od tri koraka: izrade stabla zahtjeva, definiranja elementarnih kriterija i preferencija te izračuna globalne preferencije.

U prvom je koraku potrebno oblikovati stablo zahtjeva. Stablo nastaje dekompozicijom varijabli više razine na varijable niže razine. Postupak se ponavlja sve dok se ne generiraju direktno mjerljive manifestne varijable. U kontekstu LSP metode, manifestne varijable nose naziv *varijable performansi* te se označavaju sa $X_1, X_2, \dots, X_n$.

U sljedećem se koraku definira elementarni kriterij odnosno funkcija $G_i: \left[X_1^{min}, X_i^{max}\right] \rightarrow [0,1]$ koja za svaku vrijednost varijable performansi X_i generira odgovarajuću elementarnu preferenciju $E_i = G_i(X_i),\ X_i^{min} \leq X_i \leq X_i^{max},\ 0 \leq E_i \leq 1,\ i = 1, \dots, n.$ Elementarni kriterij je raspon vrijednosti koji pojedina varijabla performansi može poprimiti, a izražava se preko skale preferencija. Primjeri skala preferencija prikazani su na slikama 5.10 i 5.11.

Vrijednost elementarne preferencije je normalizirana između 0 i 1 (ili 100%), a predstavlja stupanj zadovoljenja specifičnog zahtjeva definiranog u stablu. Prema tome, $E_i = 0$ označava da varijabla performansi X_i ne zadovoljava predefinirani zahtjev, $E_i = 1$ predstavlja potpuno zadovoljenje zahtjeva dok se parcijalno zadovoljenje zahtjeva nalazi u rasponu $0 < E_i < 1$.

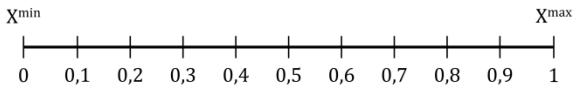

Slika 5.10 Skala preferencija sa intervalom [0, 1]

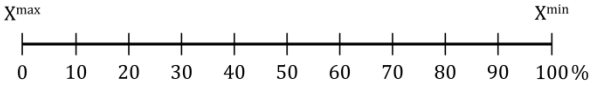

Slika 5.11 Skala preferencija sa intervalom [0, 100%]

Posljednji korak u primjeni metode logičkog bodovanja preferencija je spajanje elementarnih preferencija te izračun globalne preferencije $E_0 = L(E_1, \dots, E_n) = L\big(G_1(X_1), \dots, G_n(X_n)\big) = G(X_1, \dots, X_n), 0 \le E_0 \le 100\%$ koja predstavlja razinu do koje je udovoljeno svim predefiniranim zahtjevima. Funkcija logičkog spajanja L: $[0,1]^n \to [0,1]$ je iterativan proces koji prati hijerarhiju stabla zahtjeva krećući se od listova prema korijenu. Teorijski srodne preferencije se spajaju pomoću odgovarajućeg logičkog operatora što rezultira podsustavima preferencija. Postupak se nastavlja spajanjem podsustava preferencija sve dok se ne izračuna jedinstvena globalna preferencija E_0.

U svakom je koraku procesa spajanja potrebno odabrati logički operator spajanja te utvrditi relativnu važnost preferencija. Logički operatori se temelje na funkcijama logike kontinuiranih preferencija koje se nazivaju generalizirana konjunkcija/disjunkcija (eng. generalized conjunction/disjunction, GCD; Dujmović, 2008). GCD je implementirana pomoću ponderiranih stupnjevitih sredina (eng. weighted power means; Dujmović, 1974):

$$E(r) = E_1 \diamondsuit \dots \diamondsuit E_k = \left(\sum_{i=1}^{k} W_i E_i^r\right)^{1/r},\ -\infty \le r \le +\infty,\ 0 \le E_i \le 1,\ \sum_{i=1}^{k} W_i = 1, 0 < W_i < 1,$$

$$E(-\infty) = \min(E_1, \dots, E_k), \qquad E(+\infty) = \max(E_1, \dots, E_k), \qquad i = 1, \dots, k,\ k \ge 2. \tag{5.19}$$

Ulazne preferencije su označene sa $E_1, \dots, E_k$, njihove relativne važnosti (ponderi) nose oznaku $W_1, \dots, W_k$, parametar r je realan broj pomoću kojeg se određuje vrsta i intenzitet logičke polarizacije spajanja, $E(r)$ predstavlja preferenciju spajanja u rasponu $\min(E_1, \dots, E_k) \le E\ (r) \le$

$\max(E_1, \ldots, E_k)$ dok je operator *andor*/*orand* funkcije parcijalne konjunkcije/disjunkcije (Dujmović i Larsen, 2004) prikazan simbolom $\diamond$. Grafička notacija GCD sa tri ulazne preferencije $X_1, X_{2,}, X_3$, ponderima $W_1, W_{2,}, W_3$ i preferencijom spajanja E prikazana je na slici 5.14. Postoje tri vrste logičke polarizacije operatora spajanja: konjunktivna logička polarizacija, disjunktivna logička polarizacija i bez polarizacije.

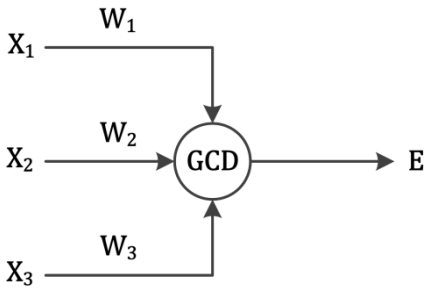

Slika 5.14 Grafička notacija generalizirane konjunkcije/disjunkcije

Konjunktivna logička polarizacija (istovremenost) se upotrebljava kada je vrijednost izlazne preferencije pod utjecajem ulazne preferencije sa najmanjom vrijednosti te je stoga potrebno da sve ulazne preferencije budu do određene mjere istovremeno zadovoljene. Ovisno o stupnju istovremenosti i vrsti ulaznih preferencija, moguće je razlikovati dvije skupine logičkih operatora spajanja sa konjunktivnom polarizacijom: operator pune konjunkcije i operatore kvazi-konjunkcije.

U logici kontinuiranih preferencija puna konjunkcija (operator C) predstavlja funkciju minimuma ($r = -\infty$, $E_1 \diamond \ldots \diamond E_k = E_1 \wedge \ldots \wedge E_k$) koja kao ekvivalent logičkom operatoru $\wedge$ služi modeliranju istovremenosti obaveznih ulaznih preferencija. Međutim, u praksi se puno češće koriste operatori kvazi-konjunkcije. Osnovno svojstvo kvazi-konjunkcije ($-\infty < r < 1$, $E_1 \diamond \ldots \diamond E_k = E_1 \Delta \ldots \Delta E_k$) je operator *andor* odnosno konjunktivni stupanj α koji određuje razinu sličnosti sa punom konjunkcijom. Istovremenost neobaveznih preferencija se modelira pomoću operatora $\mathrm{C}-$ i $\mathrm{C}--$ dok se kod modeliranja istovremenosti obaveznih preferencija primjenjuju operatori $\mathrm{C}-+$, CA, $\mathrm{C}+-$, $\mathrm{C}+$ i $\mathrm{C}++$. Vrijednosti operatora *andor* pripadaju intervalu $0 \leq \alpha \leq 1$ gdje $\alpha = 1$ označava punu konjunkciju, a $0.5 < \alpha < 1$ kvazi-konjunkciju.

Vrijednosti parametra r za željeni intenzitet konjunktivne polarizacije α i n ulaznih preferencija nalaze se u tablici 5.5. Sivo obojene ćelije se odnose na slučajeve kada je vrijednost parametra $r \leq 0$, a služe modeliranju istovremenosti obaveznih preferencija.

Tablica 5.5 Generalizirana konjunkcija/disjunkcija

				Vrijednost parametra r			
Operacija	**Simbol**	**Orand ω**	**Andor α**	**n=2**	**n=3**	**n=4**	**n≥5**
Disjunkcija	**D**	1,0000	0,0000	$+\infty$	$+\infty$	$+\infty$	$+\infty$
Jaka kvazi-disjunkcija (+)	**D + +**	0,9375	0,0625	20,630	24,300	27,110	30,090
Jaka kvazi-disjunkcija	**D +**	0,8750	0,1250	9,521	11,095	12,270	13,235
Jaka kvazi-disjunkcija (−)	**D + −**	0,8125	0,1875	5,802	6,675	7,316	7,819
Srednja kvazi-disjunkcija	**DA**	0,7500	0,2500	3,929	4,450	4,825	5,111
Slaba kvazi-disjunkcija (+)	**D − +**	0,6875	0,3125	2,792	3,101	3,318	3,479
Slaba kvazi-disjunkcija	**D −**	0,6250	0,3750	2,018	2,187	2,302	2,384
Slaba kvazi-disjunkcija (−)	**D − −**	0,5625	0,4375	1,449	1,519	1,565	1,596
Aritmetička sredina	**A**	0,5000	0,5000	1,000	1,000	1,000	1,000
Slaba kvazi-konjunkcija (−)	**C − −**	0,4375	0,5625	0,619	0,573	0,546	0,526
Slaba kvazi-konjunkcija	**C −**	0,3750	0,6250	0,261	0,192	0,153	0,129
Slaba kvazi-konjunkcija (+)	**C − +**	0,3125	0,6875	− 0,148	− 0,208	− 0,235	− 0,251
Srednja kvazi-konjunkcija	**CA**	0,2500	0,7500	− 0,720	− 0,732	− 0,721	− 0,707
Jaka kvazi-konjunkcija (−)	**C + −**	0,1875	0,8125	− 1,655	− 1,550	− 1,455	− 1,380
Jaka kvazi-konjunkcija	**C +**	0,1250	0,8750	− 3,510	− 3,114	− 2,823	− 2,606
Jaka kvazi-konjunkcija (+)	**C + +**	0,0625	0,9375	− 9,060	− 7,639	− 6,689	− 6,013
Konjunkcija	**C**	0,0000	1,0000	$-\infty$	$-\infty$	$-\infty$	$-\infty$

Izvor: Dujmović (1991)

Primjeri modeliranja istovremenosti neobaveznih i obaveznih preferencija sa rezultatima izračuna izlaznih preferencija ovisno o vrijednostima ulaznih preferencija i primijenjenim logičkim operatorima spajanja ilustrirani su na slikama 5.15 i 5.16, respektivno.

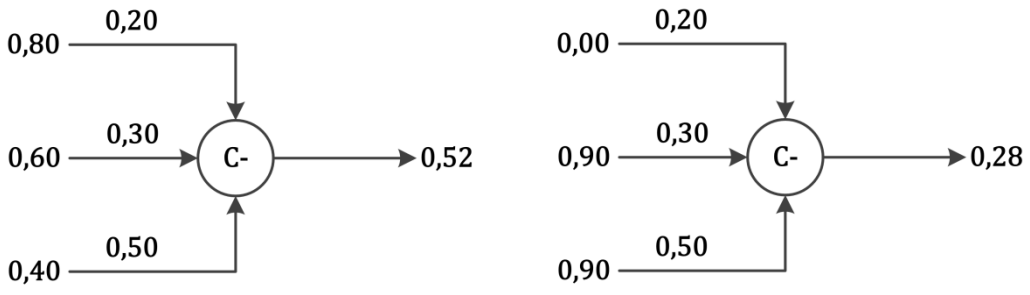

Slika 5.15. Modeliranje istovremenosti neobaveznih preferencija

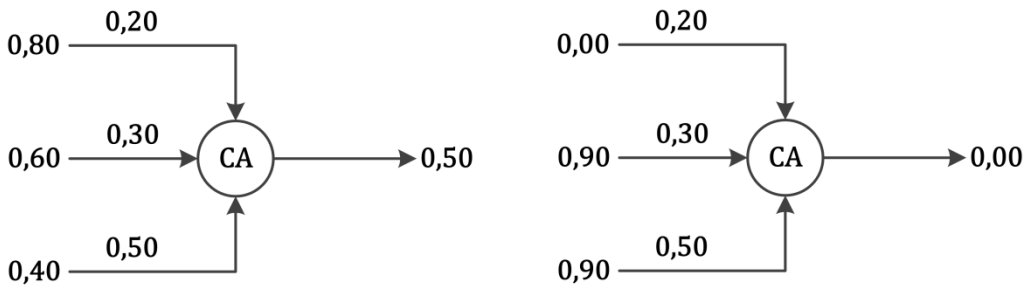

Slika 5.16 Modeliranje istovremenosti obaveznih preferencija

Iz rezultata spajanja preferencija koji su prikazani na slikama 5.15 i 5.16 je evidentno da povećanje intenziteta logičke polarizacije u modeliranju istovremenosti utječe na smanjenje izlazne preferencije. Osim toga, ako je vrijednost bilo koje ulazne preferencije nula, rezultat izlazne preferencije će se kod modeliranja istovremenosti neobaveznih preferencija značajno smanjiti dok će u slučaju modeliranja istovremenosti obaveznih preferencija poprimiti vrijednost nula bez obzira na vrijednosti preostalih ulaznih preferencija.

Disjunktivna logička polarizacija (nadomjestivost) se upotrebljava kada je vrijednost izlazne preferencije pod utjecajem najveće ulazne preferencije koja može do određene mjere kompenzirati niže vrijednosti preostalih ulaznih preferencija. Ovisno o stupnju nadomjestivosti, postoje dvije skupine logičkih operatora spajanja: operator pune disjunkcije i operatori kvazi-disjunkcije.

Puna disjunkcija (operator D) je u logici kontinuiranih preferencija predstavljena funkcijom maksimuma ($r = +\infty, E_1 \diamondsuit \dots \diamondsuit E_k = E_1 \vee \dots \vee E_k$) te je zbog svoje jednakosti sa logičkim operatorom $\vee$ namijenjena modeliranju najviše razine nadomjestivosti neobaveznih ulaznih preferencija. Osnovno svojstvo kvazi-disjunkcije ($1 < r < +\infty, E_1 \nabla \dots \nabla E_k$) je operator *orand* odnosno disjunktivni stupanj ω kojim se definira razina sličnosti sa punom disjunkcijom. Slaba polarizacija nadomjestivosti se modelira pomoću operatora $\mathrm{D}--$, $\mathrm{D}-$ i $\mathrm{D}-+$, srednja sa operatorom DA, a jaka preko operatora $\mathrm{D}+-$, $\mathrm{D}+$ i $\mathrm{D}++$. Vrijednosti operatora *orand* se nalaze u rasponu $0 \leq \omega \leq 1$ gdje $\omega = 1$ predstavlja punu disjunkciju, a $0.5 < \omega < 1$ kvazi-disjunkciju. Iz svega dosad navedenog proizlazi da su operatori *andor* i *orand* komplementarni što znači da vrijedi $\alpha + \omega = 1$. Primjer modeliranja nadomjestivosti pomoću logičkih operatora spajanja sa slabim i jakim intenzitetom polarizacije ilustriran je na slici 5.17 dok je primjer spajanja neobaveznih ulaznih preferencija sa disjunktivnim logičkim operatorom srednjeg intenziteta polarizacije prikazan na slici 5.18.

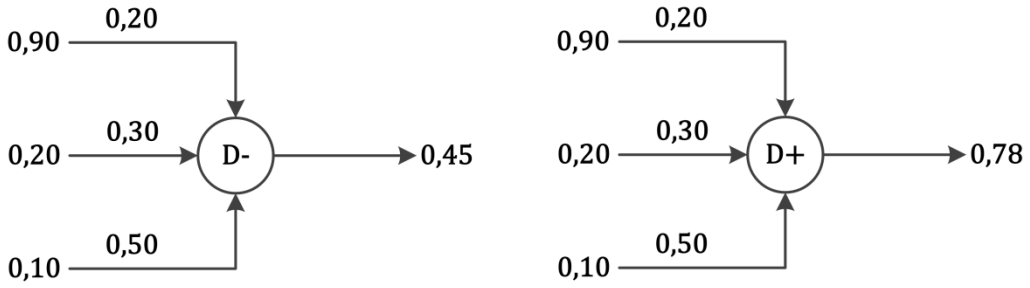

Slika 5.17 Modeliranje nadomjestivosti pomoću logičkih operatora spajanja sa slabim i jakim intenzitetom polarizacije

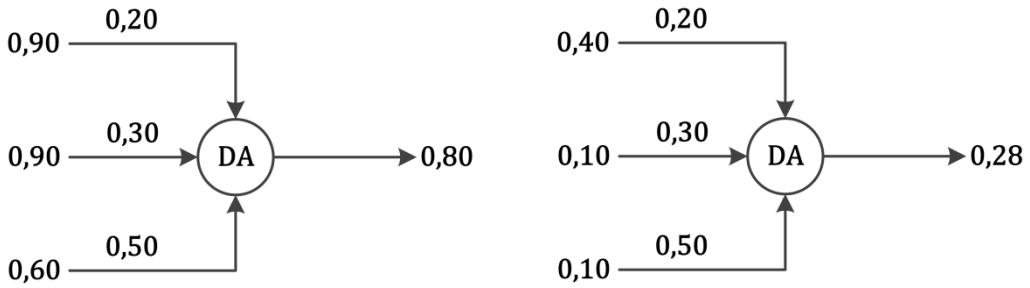

Slika 5.18 Spajanje neobaveznih ulaznih preferencija sa disjunktnim logičkim operatorom srednjeg intenziteta polarizacije

Iz rezultata izlaznih preferencija prikazanih na slici 5.17 je vidljivo da povećanje intenziteta polarizacije u modeliranju nadomjestivosti neobaveznih preferencija vodi povećanju kompenzacijske snage preferencije sa najvećom ulaznom vrijednosti. S druge strane, slika 5.18 zorno ilustrira osnovno obilježje nadomjestivosti prema kojem je vrijednost preferencije spajanja određena redom veličine većine ulaznih preferencija.

Bez polarizacije (neutralnost) se primjenjuje u slučajevima kada je potrebno da preferencija spajanja bude sačinjena od ujednačene kombinacije konjunktivnih i disjunktivnih svojstava ulaznih preferencija. Logički operator spajanja za modeliranje neutralnosti se nalazi između zamjenjivosti i nadomjestivosti ($\alpha = \omega = 0.5$), a implementiran je kao ponderirana aritmetička sredina ulaznih preferencija. Prema tome, ulazne preferencije će do određene mjere biti istovremeno zadovoljene pri čemu će preferencije sa većim ulaznim vrijednostima do određene razine kompenzirati preferencije sa manjim ulaznim vrijednostima. U situaciji ujednačenih pondera, jedna ulazna preferencija nije dostatna da uzrokuje malu ili veliku vrijednost izlazne preferencije.

Konjunktivni i disjunktivni logički operatori spajanja se još nazivaju i simetričnim operatorima iz razloga što ekstremne vrijednosti ulaznih preferencija $E_i = 0$ i $E_i = 1$ uzrokuju iste odnosno slične izlazne preferencije za svaku vrijednost od i, ali sa različitim stupnjem relativne važnosti (Dujmović i Bayucan, 1997). Međutim, modeli vrjednovanja programskih proizvoda su često sačinjeni od obaveznih i neobaveznih (dostatnih, poželjnih i opcionalnih) ulaznih preferencija koje je potrebno kombinirati kako bi se izračunala globalna preferencija. Kombinacijom obaveznih i neobaveznih ulaznih preferencija nastaju asimetrični logički operatori spajanja različitih razina složenosti. Najjednostavniji asimetrični logički operatori spajanja su konjunktivna parcijalna apsorpcija i disjunktivna parcijalna apsorpcija (Dujmović, 1979).

Konjunktivna parcijalna apsorpcija (CPA) ili obavezan/poželjan (O/P) logički operator spajanja je kombinacija obavezne (eng. mandatory) ulazne preferencije E_1 i poželjne/opcionalne (eng. desired/optional) ulazne preferencije E_2. Ukoliko obavezna ulazna preferencija nije zadovoljena, preferencija spajanja će poprimiti vrijednost nula bez obzira na vrijednost poželjne (opcionalne) ulazne preferencije E_2. S druge strane, ako je obavezna ulazna preferencija parcijalno zadovoljena, a poželjna (opcionalna) ulazna preferencija nije zadovoljena, vrijednost preferencije spajanja će iznositi $E \approx E_1 - E_1 P$ gdje P označava penal u intervalu $10\% < P < 30\%$.

Nadalje, ako je obavezna ulazna preferencija parcijalno zadovoljena, a poželjna (opcionalna) preferencija u potpunosti zadovoljena, vrijednost preferencije spajanja će biti $E \approx E_1 + E_1 N$ gdje N predstavlja nagradu u rasponu $5\% < N < 15\%$ pri čemu vrijedi $P > N$. Konačno, ako je obavezna preferencija u potpunosti zadovoljena, a poželjna (opcionalna) preferencija parcijalno zadovoljena, vrijednost preferencije spajanja će se nalaziti u intervalu $E_2 < E < 1$. Razlika između poželjne i opcionalne ulazne preferencije je u tome što se nezadovoljenje poželjne ulazne preferencije strože kažnjava, a potpuno zadovoljenje bolje nagrađuje od opcionalne ulazne preferencije. Dvije osnovne varijante konjunktivne parcijalne apsorpcije prikazane su na slici 5.19 dok se pregled karakteristika O/P logičkog operatora spajanja nalazi u tablici 5.6.

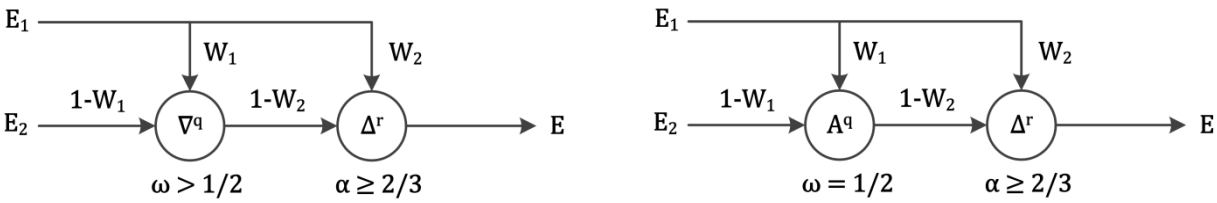

Slika 5.19 Grafička notacija dviju varijanti konjunktivne parcijalne apsorpcije

Izvor: Dujmović (1979), Dujmović (2007)

Tablica 5.6 Karakteristike konjunktivne parcijalne apsorpcije

Obavezna preferencija E_1	**Poželjna/opcionalna preferencija** E_2	**Preferencija spajanja** E
0	$0 < E_2 \leq 1$	0
$0 < E_1 \leq 1$	0	$E_1 - E_1 P$
$0 < E_1 < 1$	1	$E_1 + E_1 N$
1	$0 < E_2 < 1$	$E_2 < E < 1$

Izvor: Dujmović i Nagashima (2006)

Primjeri spajanja obavezne ulazne preferencije E_1 i poželjne ulazne preferencije E_2 prikazani su na slici 5.20. Za razliku od GCD funkcija gdje su ponderi pridruženi elementarnim preferencijama, ponderi se kod primjene parcijalnih apsorpcija određuju na osnovi vrijednosti penala i nagrada (Su et al., 1987). U tablici 5.7 se nalaze vrijednosti penala i nagrada za sve kombinacije pondera ulaznih preferencija kod primjene logičkog operatora srednje kvazi-konjunkcije (CA). Prema tome, za $W_1 = 0{,}70$ i $W_2 = 0{,}60$ vrijednost $-\delta^- = 0{,}14$ predstavlja penal u slučaju $0 < E_1 \leq 1$ i $E_2 = 0$, dok vrijednost $\delta^+ = 0{,}08$ predstavlja nagradu kada je $0 < E_1 < 1$, a $E_2 = 1$. Obzirom da su δ^+ i $-\delta^-$ iz tablice 5.7 prosječne vrijednosti nagrada i penala koje se ne mogu direktno dodati ni oduzeti od vrijednosti obavezne ulazne preferencije E_1, vrijednost preferencije spajanja E se izračunava na sljedeći način (Dujmović, 1979):

$$E = \left\{(1 - W_2)[W_1 E_1^q + (1 - W_1)E_2^q]^{r/q} + W_2 E_1^r\right\}^{1/r},$$

$$-\infty \leq q \leq +\infty, -\infty \leq r \leq +\infty, 0 \leq E_1 \leq 1,\ 0 \leq E_2 \leq 1, 0 < W_1 < 1, 0 < W_2 < 1. \qquad (5.20)$$

Primjeri primjene konjunktivne parcijalne apsorpcije u izračunu preferencije spajanja za različite vrijednosti poželjne ulazne preferencije E_2 ilustrirani su na slici 5.20.

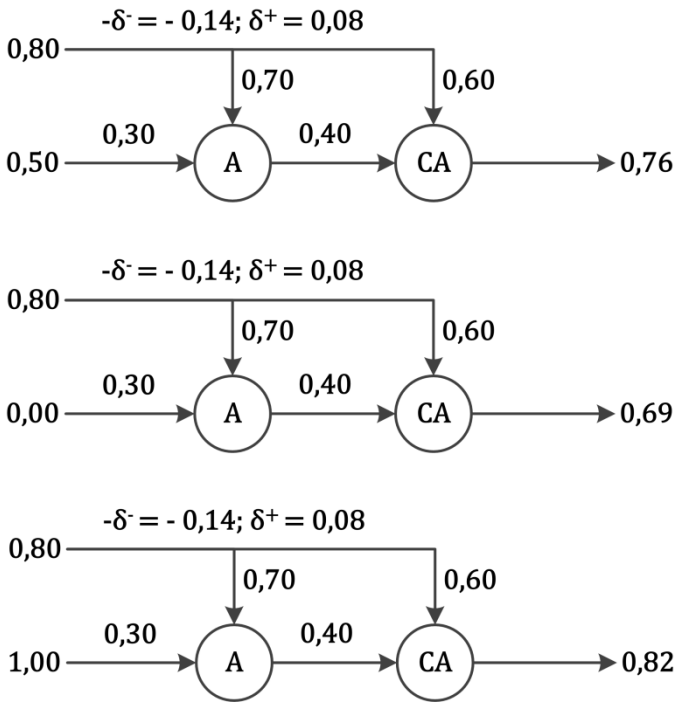

Slika 5.20 Primjeri konjunktivne parcijalne apsorpcije

Tablica 5.7 Nagrade i penali za srednju kvazi-konjunkciju

CA	$\left(\frac{-\delta^-}{\delta^+}\right)\%$	W_1								
		0,1	**0,2**	**0,3**	**0,4**	**0,5**	**0,6**	**0,7**	**0,8**	**0,9**
W_2	**0,1**	−88,8 64,0	−77,9 57,8	−67,4 51,5	−57,2 45,0	−47,1 38,2	−37,3 31,3	−27,7 24,0	−18,3 16,5	−9,1 8,5
	0,2	−87,2 49,4	−75,5 45,0	−64,4 40,4	−53,9 35,7	−44,0 30,6	−34,5 25,4	−25,3 19,8	−16,6 13,8	−8,1 7,3
	0,3	−85,3 38,7	−72,5 35,5	−60,9 32,1	−50,3 28,5	−40,5 24,7	−31,4 20,6	−22,8 16,3	−14,8 11,5	−7,2 6,2
	0,4	−82,8 30,3	−68,8 27,9	−56,7 25,4	−46,1 22,6	−36,6 19,7	−28,0 16,6	−20,1 13,2	−12,9 9,4	−6,2 5,1
	0,5	−79,4 23,3	−64,2 21,6	−51,7 19,7	−41,3 17,7	−32,3 15,5	−24,3 13,1	−17,3 10,5	−11,0 7,6	−5,2 4,2
	0,6	−74,8 17,4	−58,2 16,1	−45,7 14,8	−35,7 13,3	−27,4 11,7	−20,3 10,0	−14,3 8,0	−8,9 5,8	−4,2 3,3
	0,7	−68,1 12,2	−50,4 11,4	−38,2 10,5	−29,0 9,5	−21,8 8,4	−16,0 7,1	−11,0 5,8	−6,8 4,2	−3,2 2,4
	0,8	−57,4 7,7	−39,6 7,2	−28,7 6,6	−21,2 6,0	−15,6 5,3	−11,2 4,6	−7,6 3,7	−4,6 2,7	−2,1 1,6
	0,9	−38,9 3,6	−24,0 3,4	−16,4 3,1	−11,7 2,9	−8,3 2,5	− 5,9 2,2	−3,9 1,8	−2,4 1,3	−1,1 0,8

Izvor: Dujmović (1979)

Disjunktivna parcijalna apsorpcija (DPA) ili dostatan/poželjan (D/P) logički operator spajanja kombinira dostatnu (eng. sufficient) ulaznu preferenciju E_1 i poželjnu (opcionalnu) ulaznu preferenciju E_2. U slučaju kada je dostatna preferencija u potpunosti zadovoljena, vrijednost preferencije spajanja će iznositi $E \approx 1$ bez obzira na vrijednost poželjne (opcionalne) preferencije E_2. Ukoliko je dostatna preferencija parcijalno zadovoljena, a poželjna (opcionalna) preferencija u potpunosti zadovoljena, vrijednost preferencije spajanja će biti $E_1 + E_1 N$ gdje N predstavlja nagradu u intervalu $20\% < N < 75\%$. Međutim, ako je dostatna preferencija parcijalno zadovoljena, a poželjna (opcionalna) preferencija uopće nije zadovoljena, tada će preferencija spajanja iznositi $E_1 - E_1 P$ gdje je P oznaka za penal u rasponu $0\% < P < 10\%$ pri čemu je $N > P$. Konačno, poželjna (opcionalna) preferencija može do određene mjere kompenzirati nezadovoljenje dostatne preferencije te se u tom slučaju vrijednost preferencije spajanja nalazi u intervalu $0 < E < E_2$. Grafički prikaz disjunktivne parcijalne apsorpcije se nalazi na slici 5.21 dok su osnovna svojstva D/P operatora sažeta u tablici 5.8.

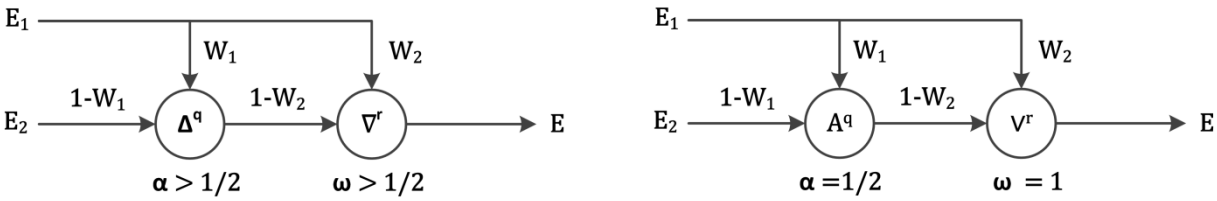

Slika 5.21 Grafička notacija dviju varijanti disjunktivne parcijalne apsorpcije

Izvor: Dujmović (1979), Dujmović (2007)

Tablica 5.8 Karakteristike disjunktivne parcijalne apsorpcije

Dostatna preferencija E_1	**Poželjna/opcionalna preferencija E_2**	**Preferencija spajanja E**
0	$0 < E_2 \leq 1$	$0 < E < E_2$
$0 < E_1 \leq 1$	0	$E_1 - E_1 P$
$0 < E_1 < 1$	1	$E_1 + E_1 N$
1	$0 < E_2 < 1$	≈ 1

Izvor: Dujmović i Nagashima (2006)

Primjeri primjene disjunktivne parcijalne apsorpcije u izračunu preferencije spajanja za različite vrijednosti poželjne ulazne preferencije E_2 prikazani su na slici 5.22.

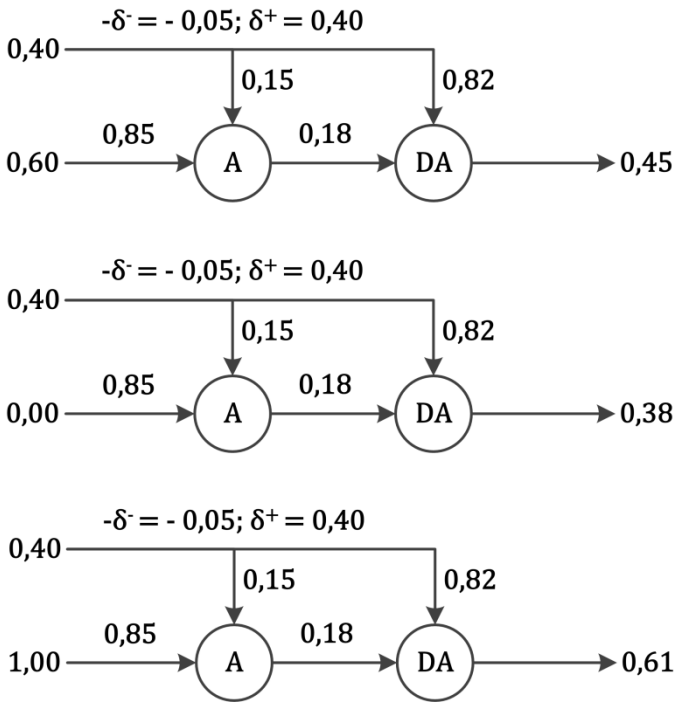

Slika 5.22 Primjeri disjunktivne parcijalne apsorpcije

Na slici 5.23 su ilustrirani koraci odabira logičkog operatora spajanja. Najprije je potrebno utvrditi da li se podsustav preferencija treba sastojati od pretežno konjunktivnih, većinom disjunktivnih ili od kombinacije konjunktivnih i disjunktivnih svojstava. Zatim se utvrđuje vrsta povezanosti među ulaznim preferencijama. U posljednjem se koraku, u slučaju simetrične povezanosti preferencija, odabire vrsta i intenzitet logičkog operatora spajanja.

U praksi vrjednovanja programskih proizvoda se dostatne preferencije (a time i disjunktivna parcijalna apsorpcija) koriste puno rjeđe od obaveznih preferencija odnosno konjunktivne parcijalne apsorpcije (Dujmović, 2007). Obzirom da su tijekom metode sortiranja karata sve varijable performansi kategorizirane kao obavezne ili poželjne, u izračunu kompozitnog indeksa kvalitete u korištenju Web 2.0 aplikacijama biti će upotrijebljeni simetrični i asimetrični logički operatori spajanja sa konjunktivnom polarizacijom. Načini na koje se logički operatori spajanja mogu kombinirati i ugnijezditi su brojni i različiti što će biti demonstrirano na primjeru vrjednovanja Web 2.0 aplikacija za kolaborativno uređivanje teksta i izradu mentalnih mapa u poglavlju koje slijedi.

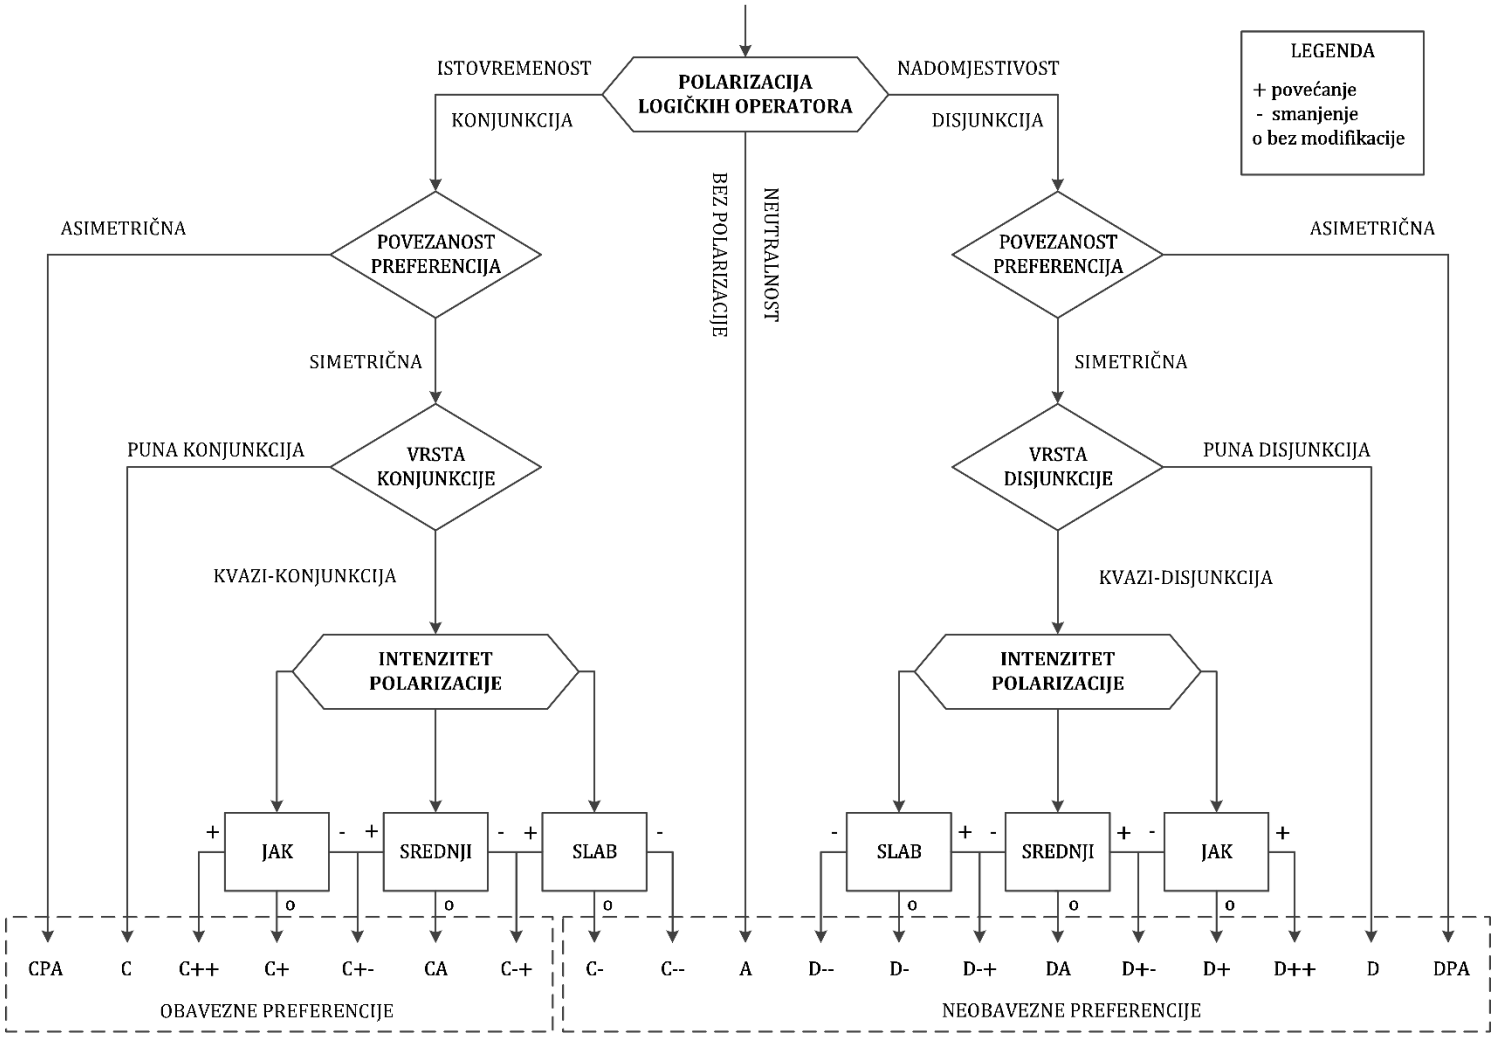

Slika 5.23 Dijagram odabira logičkih operatora spajanja

Izvor: Dujmović (1975), Dujmović i Bayucan (1997)

6. ISTRAŽIVANJE

Svrha empirijskog dijela ovog doktorskog rada jest validacija metodologije vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama. Preteča empirijskog dijela istraživanja provedenog tijekom akademske godine 2011./2012. su bila tri pilot istraživanja. Sudionici u sva tri pilot istraživanju su bili studenti preddiplomskog studija sa Fakulteta organizacije i informatike u Varaždinu. Prije vrjednovanja Web 2.0 aplikacija, sudionici su njihovom primjenom trebali izraditi različite obrazovne artefakte. Inicijalna inačica konceptualnog modela (prikazana na slici 6.1) razvijena je u sklopu prvog pilot istraživanja. Ista je bila izvorno namijenjena vrjednovanju kvalitete Web 2.0 aplikacija (Orehovački, 2010). Konceptualni model je bio sačinjen od šest kategorija koje su dalje bile dekomponirane na 33 atributa. Svaki atribut je bio mjeren samo jednom česticom u upitniku. Rezultati analize prikupljenih podataka pokazali su dostatnu razinu unutarnje dosljednosti svih šest identificiranih kategorija kvalitete (Orehovački, 2010).

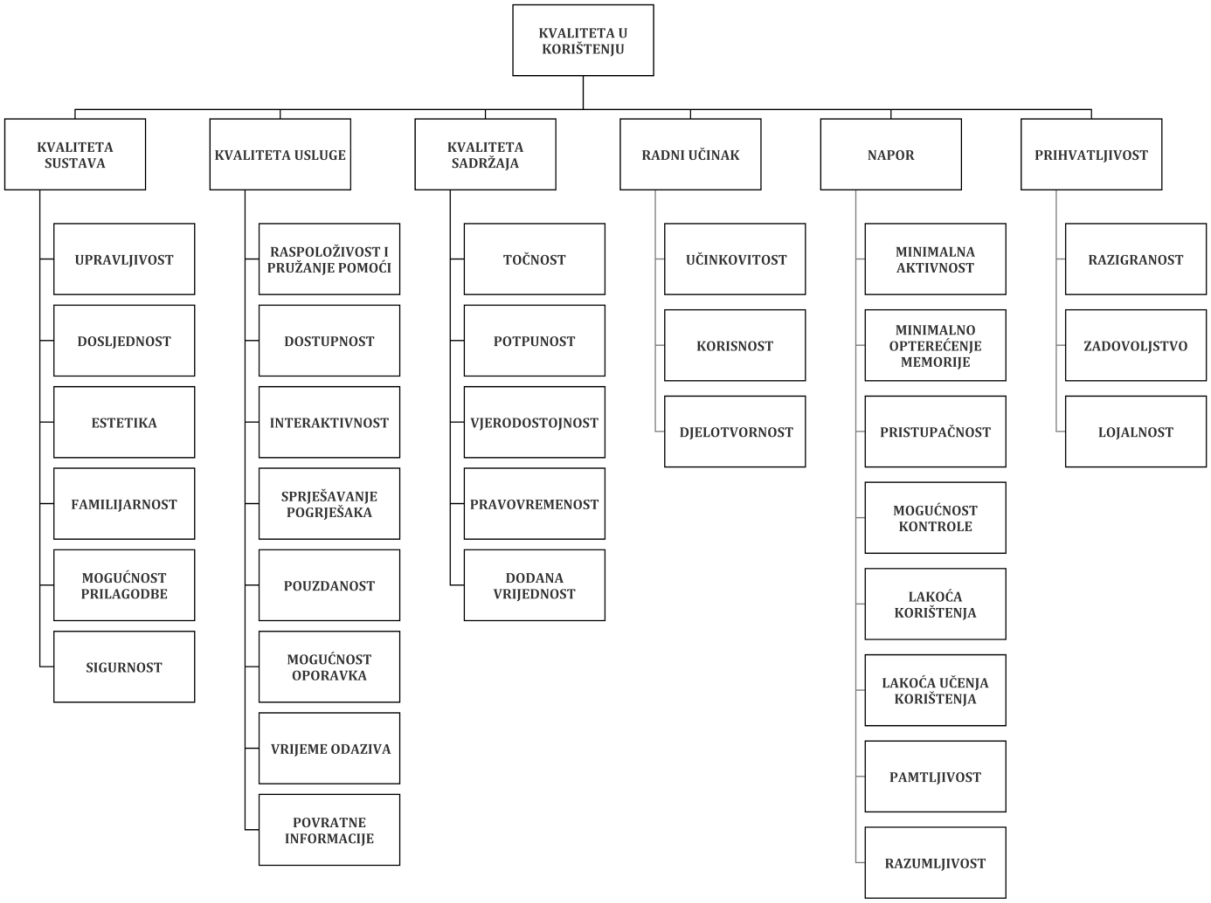

Slika 6.1 Početna inačica konceptualnog modela vrjednovanja Web 2.0 aplikacija

Izvor: Orehovački et al. (2013)

U drugom pilot istraživanju testirana je primjerenost konceptualnog modela u vrjednovanju zamijećene kvalitete Web 2.0 aplikacija za kolaborativno uređivanje teksta (Orehovački, 2011a). Primjenom online upitnika i metode retrospektivnog razmišljanja naglas identificirani su glavni problemi sa kojima se korisnici suočavaju tijekom interakcije sa kolaborativnim uređivačima teksta. Pored toga, razaznani su atributi kvalitete kojima korisnici pridaju najveći značaj u kontekstu izvršavanja zadataka pomoću Web 2.0 aplikacija za kolaborativno uređivanje teksta. Naposljetku, utvrđeno je da konceptualni model nije potpun već ga je potrebno dopuniti atributima za koje se ispostavilo da odražavaju aspekte kvalitete koji su korisnicima izuzetno važni.

U sklopu trećeg pilot istraživanja provedena su dva eksperimenta. Uzorak Web 2.0 aplikacija je u prvom eksperimentu bio sačinjen od četiri aplikacije za izradu mentalnih mapa, a u drugom eksperimentu od četiri aplikacije namijenjene izradi dijagrama (Orehovački et al., 2012a; Orehovački et al., 2013). Treće pilot istraživanje promijenilo je fokus vrjednovanja sa kvalitete na kvalitetu u korištenju. Za razliku od prvog i drugog pilot istraživanja tijekom kojih su Web 2.0 aplikacije vrjednovane isključivo subjektivno, metodologija vrjednovanja se u trećem pilot istraživanju sastojala od kombinacije subjektivnih i objektivnih metoda, mjernih instrumenata i metrika. Subjektivni atributi kvalitete u korištenju vrjednovani su primjenom proširene verzije online upitnika i metode retrospektivnog razmišljanja naglas dok je mjerenje objektivnih atributa kvalitete u korištenju provedeno pomoću alata za automatsko zapisivanje postupaka Mousotron. Analizom prikupljenih podataka utvrđeno je da su korištene metode, mjerni instrumenti i metrike prikladni za vrjednovanje kvalitete u korištenju Web 2.0 aplikacijama. Osim toga, još je jednom potvrđeno da inicijalna inačica konceptualnog modela ne obuhvaća sve atribute koji odražavaju relevantne aspekte kvalitete u korištenju Web 2.0 aplikacijama. Konačno, identificirani su najvažniji problemi koji se javljaju tijekom upotrebe Web 2.0 aplikacija namijenjenih oblikovanju mentalnih mapa i izradi dijagrama.

Revizija konceptualnog modela, metrika i instrumenata namijenjenih vrjednovanju kvalitete u korištenju Web 2.0 aplikacijama provedena je u sklopu empirijskog dijela ovog doktorskog rada koji je bio sačinjen od sljedeće četiri faze: pripreme, provedbe, analize i interpretacije. Tijekom **faze pripreme** autor je kroz slanje zamolbe za sudjelovanje u istraživanju koja se nalazi u Prilogu A uspostavio kontakt sa prigodnim uzorkom stručnjaka domene. Zamolba se sastojala od kraćeg opisa tematike doktorskog rada, istraživačkih aktivnosti u koje je svaki stručnjak domene bio uključen te poveznice na online upitnik pomoću kojeg su se prikupljali podaci o demografskim karakteristikama, iskustvu te ekspertizi sudionika. Istovremeno je autor kroz interakciju sa moderatorima dogovorio detalje koordinacije i provedbe istraživanja na tri domaće i pet inozemnih visokoškolskih institucija. Na Fakultetu organizacije i informatike u

Varaždinu kao četvrtoj domaćoj visokoškolskoj ustanovi istraživanje je proveo autor doktorskog rada osobno. Pripremna faza je također obuhvaćala izradu uputa za stručnjake domene, moderatore i korisnike, kreiranje scenarija sa reprezentativnim koracima interakcije za dvije skupine Web 2.0 aplikacija, oblikovanje mjernih instrumenata i lokalizaciju (prijevod na engleski i španjolski jezik) svega navedenog.

Faza provedbe je započela slanjem uputa koje se nalaze u Prilogu B i evaluacijskog obrasca svim stručnjacima domene koji su pristali sudjelovati u istraživanju te u potpunosti popunili online upitnik. Evaluacijski obrazac je imao formu Microsoft Excel datoteke, a bio je namijenjen klasifikaciji početnog skupa čestica, indikatora i atributa kvalitete u korištenju primjenom metode zatvorenog sortiranja karata. Provedba spomenute metode se sastojala od nekoliko koraka. Stručnjaci domene su trebali najprije pažljivo pročitati svaku česticu, procijeniti njihovu razumljivost te ih prema potrebi preformulirati. Postupak je bilo potrebno ponoviti za svaki indikator i atribut kvalitete u korištenju pri čemu su stručnjaci domene procjenjivali ispravnost njihovog nazivlja, a ne formulaciju tvrdnje kao u slučaju čestica. Zatim su stručnjaci domene svaku česticu i indikator trebali pridružiti samo jednom od 46 atributa identificirana tijekom pregleda literature. Stručnjaci domene su bili slobodni oblikovati dodatne atribute te im pridružiti čestice ako su smatrali da se iste ne mogu pridružiti nijednom od postojećih atributa. U posljednjem koraku primjene metode zatvorenog sortiranja karata, stručnjaci domene su trebali svakoj čestici, indikatoru i atributu odrediti stupanj primjerenosti za vrjednovanje kvalitete u korištenju Web 2.0 aplikacijama. Procjenu primjerenosti je bilo potrebno provesti preko sljedeće skale:

- 0 – ne mogu procijeniti (eng. cannot answer),
- 1 – obavezno vrjednovati (eng. mandatory),
- 2 – poželjno vrjednovati (eng. desired),
- 3 – nije potrebno vrjednovati (eng. not relevant).

Drugi dio faze provedbe se odnosio na prikupljanje podataka od sudionika za vrijeme i nakon interakcije sa vrjednovanim Web 2.0 aplikacijama. Podaci su prikupljeni tijekom dva eksperimenta. U prvom eksperimentu su sudionici upotrebljavali Web 2.0 aplikacije za kolaborativno uređivanje teksta dok su se u drugom koristili Web 2.0 aplikacijama za izradu mentalnih mapa. Prije nego što je eksperiment započeo, moderatori su sudionicima ukratko objasnili način na koji će istraživanje biti provedeno te ih uputili u redoslijed izvršavanja pojedinih koraka eksperimenta. Osim toga, svaki je sudionik dobio detaljne pisane upute vezane uz provedbu eksperimenta koje se nalaze u Prilogu E. Uz upute, moderatori su sudionicima

podijelili identične scenarije interakcije sa specifičnom skupinom Web 2.0 aplikacija. Objektivni podaci su se prikupljali primjenom alata Mousotron za vrijeme izvršavanja koraka scenarija. Slika 6.2 zorno ilustrira da je Mousotron namijenjen prikupljanju podataka kao što su količina vremena potrebna za dovršetak svih koraka scenarija, broj pritisnutih tipaka na tipkovnici, broj klikova mišem, broj pomicanja klizača na mišu te udaljenost koja se prijeđe pomicanjem miša tijekom provedbe scenarija. Sudionici su trebali prije izvršavanja prvog koraka scenarija pokrenuti Mousotron te isti zaustaviti po završetku posljednjeg koraka scenarija. Nakon toga je bilo potrebno napraviti ispis sadržaja zaslona (eng. print screen), zalijepiti ga u Word dokument te ga u formi Mousotron izvještaja predati moderatoru ili poslati autoru doktorskog rada putem elektroničke pošte. Po završetku svih koraka scenarija sa dvije Web 2.0 aplikacije, sudionici su trebali u obrascu uz svaki korak scenarija navesti do koje su ga mjere bili u mogućnosti dovršiti primjenom obje Web 2.0 aplikacije. U posljednjem su koraku eksperimenta sudionici trebali popuniti online upitnik te na taj način provesti subjektivno vrjednovanje Web 2.0 aplikacija koje su upotrebljavali tijekom izvršavanja koraka scenarija. Pored navedenog, online upitnikom su se prikupljali podaci o demografskim karakteristikama sudionika te njihovom iskustvu vezanom uz poznavanje rada na računalu, korištenje Internetom i upotrebu Web 2.0 aplikacija.

Slika 6.2 Mousotron izvještaj

Vrjednovanjem sadržajne valjanosti varijabli uključenih u provedbu metode zatvorenog sortiranja karata započela je **faza analize**. Svaki atribut koji je udovoljio kriterijima sadržajne valjanosti bio je uključen u otvoreno sortiranje karata koje se po načinu izvođenja razlikovalo od zatvorenog sortiranja karata. Naime, stručnjaci domene su trebali po vlastitom nahođenju oblikovati kategorije te u njih svrstati atribute kvalitete u korištenju. Osim toga, otvoreno sortiranje karata je provedeno primjenom aplikacije Card Sorting Editor (prikazana na slici 6.3) koju je razvio Porta (2005) u sklopu GRIHO[7] (cat. Grup de Recerca en Interacció Persona Ordinador i Integració de Dades) istraživačke grupe Sveučilišta u Lleidi u Španjolskoj.

Rezultati otvorenog sortiranja karata analizirani su primjenom hijerarhijske klaster analize te shodno tome poslužili kao temelj za oblikovanje konceptualnog modela vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama. Analiza metrijskih karakteristika valjanosti i pouzdanosti konceptualnog modela provedena je metodom modeliranja strukturalnih jednadžbi baziranoj na varijanci odnosno tehnikom parcijalnih najmanjih kvadrata. Valjan i pouzdan konceptualni

[7] http://griho.udl.cat/

model poslužio je kao uporište za oblikovanje stabla zahtjeva kvalitete u korištenju Web 2.0 aplikacijama. Temeljem podataka prikupljenih za vrijeme provedbe pilot istraživanja za svaku je varijablu performansi oblikovan elementarni kriterij. Zatim su na osnovi podataka koji su tijekom provedbe eksperimenata prikupljeni od korisnika utvrđene elementarne preferencije za sve varijable performansi. Uslijedilo je pokretanje procedure određivanja relativne važnosti konačnog skupa manifestnih i latentnih varijabli odnosno varijabli i podsustava performansi u stablu zahtjeva. U grupno procjenjivanje težina bili su uključeni stručnjaci domene koji su relativnu važnost manifestnih i latentnih varijabli namijenjenih vrjednovanju kvalitete u korištenju Web 2.0 aplikacijama određivali preko sljedeće skale od pet stupnjeva:

- 1 – vrlo slaba važnost,
- 2 – slaba važnost,
- 3 – umjerena važnost,
- 4 – jaka važnost,
- 5 – vrlo jaka važnost.

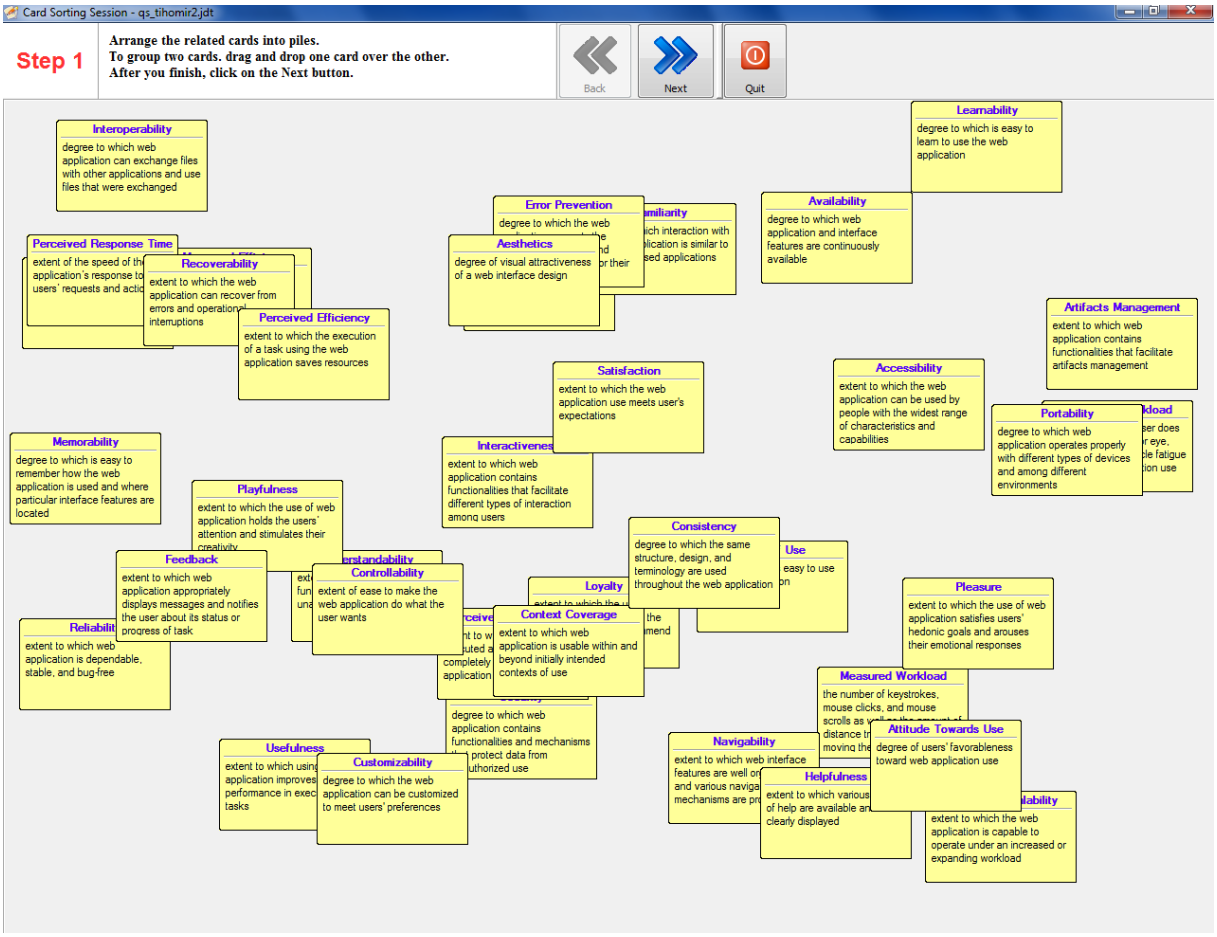

Slika 6.3 Aplikacija za provedbu metode otvorenog sortiranja karata

Na osnovi podataka prikupljenih tijekom grupnog procjenjivanja težina, za svaku je varijablu performansi izračunata normalizirana težina odnosno njen relativan doprinos specifičnom podsustavu stabla zahtjeva kvalitete u korištenju Web 2.0 aplikacijama. Razina slaganja među stručnjacima u kontekstu pridruživanja brojčanih ocjena varijablama performansi vrjednovana je Kendallovim koeficijentom podudaranja W. Naposljetku su primjenom iterativne procedure temeljem elementarnih preferencija i normaliziranih težina varijabli performansi najprije izračunate preferencije podsustava performansi, a zatim i globalne preferencije odnosno kompozitni indeksi kvalitete u korištenju za sve vrjednovane Web 2.0 aplikacije.

Tijekom **faze interpretacije** protumačeni su rezultati proizašli iz faze analize. Pored toga, identificirani su problemi sa kojima se korisnici suočavaju za vrijeme interakcije sa vrjednovanim Web 2.0 aplikacijama. Naposljetku, oblikovane su smjernice i preporuke koje se mogu upotrebljavati u različitim fazama životnog ciklusa Web 2.0 aplikacija.

U nastavku ovog poglavlja slijedi pregled ishoda provedbe svih spomenutih faza empirijskog dijela istraživanja. Na početku svakog potpoglavlja se nalazi opis karakteristika sudionika nakon čega slijedi interpretacija rezultata proizašlih iz svake pojedine faze. Analiza prikupljenih podataka vezanih uz obilježja sudionika analizirane su mjerama deskriptivne statistike uključujući frekvenciju obilježja, proporciju, aritmetičku sredinu, standardnu devijaciju te minimalnu i maksimalnu vrijednost.

6.1 Oblikovanje mjernih instrumenata

Prije provedbe metode zatvorenog sortiranja karata, autor doktorskog rada je temeljem pregleda literature i rezultata tri pilot istraživanja generirao 257 čestica i 6 indikatora namijenjenih mjerenju 46 predefiniranih atributa kvalitete u korištenju Web 2.0 aplikacijama. Zatim je sa ciljem oblikovanja mjernih instrumenata u primjenu metode zatvorenog sortiranja karata uključio 29 stručnjaka domene. Uzorak stručnjaka domene uključenih u provedbu metode zatvorenog sortiranja karata je svojim većim dijelom (65,52%) bio sačinjen od znanstvenika koji provode istraživanja u području interakcije čovjeka i računala (eng. Human Computer Interaction, HCI) i web inženjerstva (eng. Web Engineering, WE) dok se preostali dio (34,48%) sastojao od web razvojnih inženjera (eng. Web Developers, WD) koji se bave razvojem web mjesta i web aplikacija. Zbog heterogenosti uzorka, podaci vezani uz demografska obilježja stručnjaka domene, njihovo profesionalno iskustvo i razinu ekspertize u domicilnom području, prikupljeni su pomoću dva različita online upitnika: jedan za HCI/WE stručnjake, a drugi za WD stručnjake.

6.1.1 Karakteristike HCI/WE stručnjaka

Struktura HCI/WE stručnjaka prema demografskim karakteristikama uključujući spol, akademski stupanj, zvanje, zanimanje, državu iz koje potječu, osnovno obrazovanje i područje interesa prikazana je u tablicama 6.1 – 6.7, respektivno. Od ukupno 19 HCI/WE stručnjaka njih 57,89% je bilo muškog, a 42,11% ženskog spola.

Prosječna starosna dob HCI/WE stručnjaka je iznosila 37,32 godine ($\sigma = 8{,}870$) gdje je najmlađi imao 25, a najstariji 65 godina. Većina HCI/WE stručnjaka (57,89%) ima akademski stupanj doktora znanosti dok su preostali pripadnici uzorka HCI/WE stručnjaka (42,11%) stekli akademski stupanj magistra znanosti.

Tablica 6.1 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema spolu

Spol	Frekvencija	%
Muški	11	57,89
Ženski	8	42,11
Ukupno	19	100,00

Tablica 6.2 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema akademskom stupnju

Akademski stupanj	Frekvencija	%
Magistar znanosti	8	42,11
Doktor znanosti	11	57,89
Ukupno	19	100,00

Gotovo svi sudionici (94,74%) su stekli naobrazbu iz znanstvenog polja računarstva. Nešto više od trećine (36,84%) ih je steklo naobrazbu u polju informacijskih i komunikacijskih znanosti, 26,32% u polju dizajna, 21,05% u polju inženjerstva, a 10,53% u polju psihologije. Iz navedenog je evidentno da pripadnici uzorka HCI/WE stručnjaka imaju interdisciplinarno temeljno obrazovanje. Potrebno je napomenuti da su sudionici na pitanje o osnovnom obrazovanju mogli dati više od jednog odgovora zbog čega je suma vrijednosti frekvencija u tablici 6.3 veća od 19.

Tablica 6.3 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema osnovnom obrazovanju

Znanstvena polja	Frekvencija	%
Informacijske i komunikacijske znanosti	7	36,84
Računarstvo	18	94,74
Dizajn	5	26,32
Psihologija	2	10,53
Inženjerstvo	4	21,05

Skupina HCI/WE stručnjaka se većinom sastojala od sudionika izabranih u suradnička zvanja (52,63%). Najveći broj sudionika ($n = 5$) je bio izabran u znanstveno-nastavno zvanje izvanrednog profesora i suradničko zvanje asistenta, a najmanji ($n = 2$) u znanstveno-nastavna zvanja redovitog profesora i docenta te suradničko zvanje znanstvenog novaka.

Tablica 6.4 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema zvanju

Zvanje	Frekvencija	%
Znanstveni novak	2	10,53
Asistent	5	26,32
Viši asistent	3	15,79
Docent	2	10,53
Izvanredni profesor	5	26,32
Redoviti profesor	2	10,53
Ukupno	19	100,00

Velika većina HCI/WE stručnjaka se bavi znanstvenoistraživačkim radom (84,21%), 47,37% ih sudjeluje u nastavi dok ih 10,53% djeluje u praksi.

Tablica 6.5 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema zanimanju

Zanimanje	Frekvencija	%
Stručnjak u praksi	2	10,53
Istraživač	16	84,21
Nastavnik	9	47,37

Uzorak HCI/WE stručnjaka obuhvaćao je pojedince iz sedam različitih država. Najveći ih broj živi u Hrvatskoj (31,58%) dok ih najmanje (5,26%) dolazi sa Cipra te iz Čilea i Kolumbije.

Tablica 6.6 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema državi iz koje dolaze

Država	Frekvencija	%
Cipar	1	5,26
Čile	1	5,26
Italija	3	15,79
Hrvatska	6	31,58
Kolumbija	1	5,26
Slovenija	2	10,53
Španjolska	5	26,32
Ukupno	19	100,00

Od ukupnog broja HCI/WE stručnjaka, 36,84% ih djeluje interdisciplinarno. Znanstvenoistraživački interes gotovo svih HCI/WE stručnjaka (94,74%) je usmjeren na područje interakcije čovjeka i računala dok ih 42,11% provodi istraživanja u području web inženjerstva.

Tablica 6.7 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema području interesa

Područje interesa	Frekvencija	%
Interakcija čovjeka i računala	18	94,74
Web inženjerstvo	8	42,11

Struktura HCI/WE stručnjaka prema pokazateljima profesionalnog iskustva u domicilnom području prikazana je u tablici 6.8. Pripadnici uzorka HCI/WE stručnjaka su u trenutku provedbe istraživanja djelovali prosječno 6,89 godina u području interakcije čovjeka i računala te prosječno 6,36 godina u području web inženjerstva. Isti su u prosjeku proveli vrjednovanje 11,84 web mjesta pri čemu ih je 21,05% vrjednovalo tri, a 10,53% čak pedeset različitih web mjesta. HCI/WE stručnjaci su u prosjeku objavili 13,05 znanstvenih radova iz područja interakcije čovjeka i računala od čega ih je 69,35% prezentirano na međunarodnim konferencijama dok ih je 30,65% objavljeno u časopisima. Od prosječno 7,16 znanstvenih radova koje su HCI/WE stručnjaci publicirali u području web inženjerstva, 67,65% ih je tiskano u zbornicima međunarodnih skupova dok ih je 32,35% objavljeno u časopisima. Osim navedenog, stručnjaci su u prosjeku objavili 11,79 znanstvenih radova izvan HCI/WE područja.

Pojedinci koji su bili uključeni u uzorak HCI/WE stručnjaka su također bili aktivni članovi različitih odbora HCI/WE međunarodnih konferencija. Naime, HCI/WE stručnjaci su u prosjeku napisali 8,21 recenzija, prosječno 1,42 puta vršili dužnost voditelja sekcije i/ili meta recenzenta te se u prosjeku 5,58 puta našli u ulozi člana organizacijskog ili programskog odbora HCI/WE međunarodne konferencije. Konačno, HCI/WE stručnjaci su u prosjeku sudjelovali u 3,37 znanstvena projekta financirana iz nacionalnih sredstava te bili uključeni u prosječno 3,27 međunarodna znanstvena projekta.

U tablici 6.9 je prikazana struktura stručnjaka prema različitim područjima ekspertize u domeni interakcije čovjeka i računala te web inženjerstva. Stručnjaci su svoju ekspertizu u pojedinom području trebali procijeniti preko sljedeće skale od 4 stupnja:

- **Razina 0** označava da pojedinac ne poznaje područje domene.
- **Razina 1** implicira da pojedinac ima dostatno znanje o području domene.
- **Razina 2** ukazuje da pojedinac vrlo dobro poznaje područje domene.
- **Razina 3** označava da je pojedinac ekspert u području domene.

Većina HCI/WE stručnjaka (63,16%) smatra da je njihovo poimanje Web 2.0 tehnologija i uzoraka dizajna dostatno, 21,05% ih vrlo dobro poznaje spomenuto područje dok ih se 10,53% smatra ekspertom domene. Kada je riječ o samoprocjeni vezanoj uz vrjednovanje različitih aspekata web mjesta, HCI/WE stručnjaci vjeruju da imaju najviši stupanj ekspertize u vrjednovanju upotrebljivosti (63,16%), korisničkog iskustva (42,11%) i kvalitete u korištenju (36,84%). Od preostalih područja, većina pojedinaca se smatra ekspertom u dizajnu usmjerenom korisnicima interaktivnih sustava (52,63%). Nadalje, najveći broj HCI/WE stručnjaka vrlo dobro poznaje područje inteligentnih korisničkih sučelja (73,68%), modeliranja korisnika (73,68%), dlanovnika i mobilnog računarstva (63,16%), ljudskih čimbenika i ergonomije (57,89%), dizajna korisničkih sučelja (57,89%) te implementacije i analize upotrebe web aplikacija (52,63%). Konačno, više od polovice HCI/WE stručnjaka smatra da ima dostatno znanje iz područja arhitekture i inženjeringa programskih proizvoda (52,63%) te kolaborativnog razvoja programskih proizvoda (52,63%).

Tablica 6.8 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema profesionalnom iskustvu

Pokazatelji profesionalnog iskustva	$\bar{x}$	σ	**min**	**maks**
Broj godina u HCI području	6,89	3,724	2	15
Broj godina u WE području	6,36	3,455	2	12
Broj vrjednovanih web aplikacija	11,84	14,124	3	50
Broj znanstvenih radova objavljenih u HCI zbornicima skupova	9,05	7,692	0	25
Broj znanstvenih radova objavljenih u WE zbornicima skupova	4,84	11,471	0	50
Broj znanstvenih radova objavljenih u HCI časopisima	4,00	4,830	0	20
Broj znanstvenih radova objavljenih u WE časopisima	2,32	3,888	0	15
Broj znanstvenih radova objavljenih izvan HCI/WE područja	11,79	15,925	0	55
Broj napisanih recenzija za HCI/WE znanstvene skupove	8,21	11,243	0	40
Učestalost vršenja dužnosti kao voditelj sekcije i/ili meta recenzent za HCI/WE znanstvene skupove	1,42	2,524	0	10
Učestalost vršenja dužnosti kao član programskog/organizacijskog odbora za HCI/WE znanstvene skupove	5,58	9,252	0	30
Broj sudjelovanja u nacionalnim znanstvenim projektima	3,37	3,041	1	10
Broj sudjelovanja u međunarodnim znanstvenim projektima	3,26	4,012	0	15

Tablica 6.9 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema području ekspertize

Područje ekspertize	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Vrjednovanje pristupačnosti	4	21,05	6	31,58	7	36,84	2	10,53
Adaptivne, kontekstualizirane i personalizirane web aplikacije	4	21,05	9	47,37	6	31,58	0	0,00
Afektivni, emocionalni i motivacijski aspekti HCI	3	15,79	5	26,32	8	42,11	3	15,79
Računarstvo u oblacima	0	0,00	6	31,58	6	31,58	7	36,84
Kolaborativni razvoj programskih proizvoda	2	10,53	2	10,53	10	52,63	5	26,32
Razvoj web aplikacija temeljen na komponentama	1	5,26	3	15,79	8	42,11	7	36,84
Računalom posredovana komunikacija	2	10,53	3	15,79	9	47,37	5	26,32
Računalom podržan kooperativan rad	4	21,05	3	15,79	8	42,11	4	21,05
Konceptualno modeliranje web aplikacija	3	15,79	7	36,84	5	26,32	4	21,05
Implementacija i analiza upotrebe web aplikacija	1	5,26	10	52,63	8	42,11	0	0,00
Programski jezici specifične domene namijenjeni razvoju web aplikacija	2	10,53	4	21,05	4	21,05	9	47,37
Vrjednovanje uloženog napora tijekom upotrebe web aplikacije	0	0,00	5	26,32	7	36,84	7	36,84
Računalne igre i zabava	1	5,26	3	15,79	8	42,11	7	36,84
Dlanovnici i mobilno računarstvo	1	5,26	12	63,16	4	21,05	2	10,53
Edukacija u HCI/WE području	4	21,05	8	42,11	4	21,05	3	15,79
Ljudski čimbenici i ergonomija	2	10,53	11	57,89	4	21,05	2	10,53
Vrjednovanje kvalitete informacija i sadržaja	5	26,32	6	31,58	7	36,84	1	5,26
Inteligentna korisnička sučelja	0	0,00	14	73,68	4	21,05	1	5,26
Dizajn interakcija	7	36,84	8	42,11	3	15,79	1	5,26
Dizajn i modeliranje temeljeno na međunarodnim (ISO/IEC) standardima	1	5,26	6	31,58	7	36,84	5	26,32
Razvoj i vrjednovanje mashupova / Web programiranje za krajnje korisnike	1	5,26	4	21,05	8	42,11	6	31,58

Tablica 6.9 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema području ekspertize (nastavak)

Područje ekspertize	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Mobilne web aplikacije i isporuka neovisna o uređaju	1	5,26	7	36,84	7	36,84	4	21,05
Dizajn interaktivnih sustava temeljen na modelima	4	21,05	3	15,79	9	47,37	3	15,79
Multidisciplinarni i interdisciplinarni dizajn	1	5,26	9	47,37	5	26,32	4	21,05
Uzorci za razvoj web aplikacija i rudarenje uzoraka	1	5,26	3	15,79	8	42,11	7	36,84
Vrjednovanje zamijećene i procijenjene kvalitete	3	15,79	5	26,32	4	21,05	7	36,84
Modeliranje, praćenje i vrjednovanje performansi	2	10,53	4	21,05	7	36,84	6	31,58
Vrjednovanje privatnosti i sigurnosti	0	0,00	3	15,79	9	47,37	7	36,84
Vrjednovanje kvalitete u korištenju	7	36,84	5	26,32	5	26,32	2	10,53
Vrjednovanje kvalitete servisa (QoS)	1	5,26	6	31,58	9	47,37	3	15,79
Kvantitativne i kvalitativne empirijske metode	5	26,32	9	47,37	4	21,05	1	5,26
Bogate internetske aplikacije	0	0,00	9	47,37	6	31,58	4	21,05
Semantički web servisi	0	0,00	5	26,32	7	36,84	7	36,84
Servisno orijentirane arhitekture	0	0,00	5	26,32	7	36,84	7	36,84
Vrjednovanje kvalitete usluge	2	10,53	2	10,53	9	47,37	6	31,58
Društveno računarstvo	0	0,00	7	36,84	9	47,37	3	15,79
Arhitektura i inženjering programskih proizvoda	0	0,00	8	42,11	10	52,63	1	5,26
Vrjednovanje kvalitete sustava	4	21,05	5	26,32	8	42,11	2	10,53
Modeliranje prihvaćanja tehnologije	1	5,26	5	26,32	4	21,05	9	47,37
Sveprisutno računarstvo / Računarstvo svjesno konteksta	3	15,79	7	36,84	5	26,32	4	21,05
Univerzalni pristup	3	15,79	9	47,37	4	21,05	3	15,79
Vrjednovanje upotrebljivosti	12	63,16	5	26,32	2	10,53	0	0,00

Tablica 6.9 Struktura sudionika (HCI/WE stručnjaka) u zatvorenom sortiranju karata prema području ekspertize (nastavak)

Područje ekspertize	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Dizajn usmjeren korisnicima interaktivnih sustava	10	52,63	8	42,11	1	5,26	0	0,00
Dizajn korisničkog sučelja	7	36,84	11	57,89	1	5,26	0	0,00
Vrjednovanje korisničkog iskustva	8	42,11	9	47,37	1	5,26	1	5,26
Modeliranje korisnika	1	5,26	14	73,68	3	15,79	1	5,26
Dizajn i vrjednovanje virtualnih svjetova	1	5,26	4	21,05	6	31,58	8	42,11
Web 2.0 tehnologije i uzorci dizajna	2	10,53	4	21,05	12	63,16	1	5,26
Arhitekture i radna okruženja web aplikacija	0	0,00	8	42,11	5	26,32	6	31,58
Upravljanje sadržajem na Webu i podatkovno intenzivne web aplikacije	1	5,26	8	42,11	6	31,58	4	21,05
Uspjeh web informacijskih sustava	1	5,26	3	15,79	8	42,11	7	36,84
Metode i procesi web inženjerstva	2	10,53	5	26,32	8	42,11	4	21,05
Rudarenje Weba i ekstrakcija informacija	0	0,00	4	21,05	6	31,58	9	47,37
Znanost o Webu i buduće primjene Interneta	0	0,00	8	42,11	4	21,05	7	36,84

6.1.2 Karakteristike WD stručnjaka

Svi pripadnici uzorka WD stručnjaka su muškog spola (100%). Samo jedan od njih živi u Sloveniji dok preostalih devet stanuje u Hrvatskoj. Starosna dob WD stručnjaka u prosjeku iznosi 34,30 godine ($\sigma = 4{,}498$) pri čemu najmlađi sudionik ima 29, a najstariji 45 godina. Struktura WD stručnjaka prema stečenom akademskom stupnju prikazana je u tablici 6.10. Najveći broj ih ima akademski stupanj magistra struke ($n = 6$) dok su preostali akademski stupnjevi poput stručnog pristupnika, sveučilišnog prvostupnika, sveučilišnog specijalista i doktora znanosti zastupljeni sa po jednim WD stručnjakom.

Tablica 6.10 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema akademskom stupnju

Akademski stupanj	Frekvencija	%
Stručni pristupnik	1	10,00
Sveučilišni prvostupnik	1	10,00
Magistar struke	6	60,00
Sveučilišni specijalist	1	10,00
Doktor znanosti	1	10,00
Ukupno	10	100,00

U tablici 6.11 se nalazi pregled strukture WD stručnjaka prema temeljnom obrazovanju. Više od pola uzorka WD stručnjaka (70%) ima naobrazbu u znanstvenom polju računarstva, 50% ih je steklo obrazovanje u znanstvenom polju informacijskih i komunikacijskih znanosti, 40% ih ima temeljno obrazovanje u znanstvenom polju ekonomije i matematike, 30% je steklo naobrazbu u znanstvenom polju elektrotehnike, a 10% u znanstvenom polju psihologije. Nadalje, 90% WD stručnjaka ima naobrazbu u znanstvenoj grani informacijski sustavi, 40% u znanstvenoj grani procesno računarstvo, a 30% u znanstvenoj grani menadžment. Konačno, 80% WD stručnjaka ima naobrazbu iz discipline razvoja web mjesta dok ih 10% posjeduje obrazovanje iz discipline grafičkog dizajna. Potrebno je napomenuti da su sudionici na pitanje o osnovnom obrazovanju mogli dati više od jednog odgovora zbog čega je suma vrijednosti frekvencija po poljima, granama i disciplinama u tablici 6.11 veća od 10.

Struktura WD stručnjaka prema pokazateljima profesionalnog iskustva se nalazi u tablici 6.12. U trenutku provedbe istraživanja, WD stručnjaci su imali prosječno 10,60 godina iskustva u izradi web mjesta i aplikacija. Potrebno je naglasiti da se čak 30% WD stručnjaka bavi razvojem web mjesta već petnaest godina dok ih samo 10% ima manje od osam godina iskustva u spomenutoj domeni. WD stručnjaci su u prosjeku izradili 21,70 različitih web mjesta i prosječno 9,60

jedinstvenih Web 2.0 aplikacija. Od ukupnog broja WD stručnjaka, njih 20% je izradilo pedeset web mjesta dok ih je 30% razvilo više od petnaest Web 2.0 aplikacija. WD stručnjaci su u prosjeku proveli vrjednovanje 15,90 web mjesta i prosječno 9,10 Web 2.0 aplikacija. Isti su se u ulozi voditelja projekta izrade web mjesta našli prosječno jedanaest puta dok su ulogu voditelja projekta razvoja Web 2.0 aplikacije preuzeli u prosjeku 5,90 puta. Konačno, WD stručnjaci su bili uključeni u prosječno 28,30 projekata od čega ih je 64,66% bilo usmjereno na izradu web mjesta, a preostalih 35,34% na razvoj Web 2.0 aplikacija.

Tablica 6.11 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema osnovnom obrazovanju

Polja, grane i discipline	**Frekvencija**	**%**
Informacijske i komunikacijske znanosti	5	50,00
Računarstvo	7	70,00
Ekonomija	4	40,00
Matematika	4	40,00
Psihologija	1	10,00
Elektrotehnika	3	30,00
Informacijski sustavi	9	90,00
Procesno računarstvo	4	40,00
Menadžment	3	30,00
Grafički dizajn	1	10,00
Razvoj web mjesta	8	80,00

Tablice 6.13-6.15 sadrže strukturu WD stručnjaka prema ključnim ulogama u razvojnom timu koje su isti obnašali u proteklih pet, tri i godinu dana, respektivno. Nazivi uloga su preuzeti od Lynch i Horton (2009) te prilagođeni kontekstu ovog doktorskog rada. Kako bi naznačili učestalost obnašanja pojedine uloge u timu, WD stručnjaci su upotrebljavali sljedeću skalu od četiri stupnja:

- **Nikad** označava da pojedinac nije obnašao pojedinu ulogu.
- **Rijetko** implicira da je pojedinac obnašao pojedinu ulogu u manje od 20% slučajeva.
- **Povremeno** ukazuje da je pojedinac obnašao pojedinu ulogu u 20-50% slučajeva.
- **Redovito** označava da je pojedinac obnašao pojedinu ulogu u više od 50% slučajeva.

Od ukupno 10 WD stručnjaka, njih 70% se u posljednjih godinu dana redovito našlo u ulozi voditelja tehnoloških aspekata razvoja web mjesta te programera web aplikacija. U istom se vremenskom razdoblju 50% WD stručnjaka redovito bavilo administracijom baze podataka dok

ih je jednako toliko povremeno programiralo HTML stranice. U posljednje tri godine većina WD stručnjaka je pored spomenutih uloga redovito vršila dužnost arhitekta informacija (60%) i projektanta web mjesta (60%). Osim toga, 50% WD stručnjaka se nešto rjeđe bavilo vrjednovanjem kvalitete. Podaci za proteklih pet godina pokazuju manje promjene u učestalosti vršenja pojedine uloge. Većina WD stručnjaka se redovito bavila programiranjem web aplikacija (80%) i HTML stranica (60%) te projektiranjem web mjesta (70%) odnosno informacija (70%). Osim toga, pola uzorka WD stručnjaka je povremeno vršilo dužnost voditelja projekta razvoja web mjesta dok ih se jednako toliko u rijetkim slučajevima našlo u ulozi urednika web mjesta. Zbirni podaci za sva tri vremenska razdoblja pokazuju da je riječ o heterogenom uzorku WD stručnjaka u kontekstu obavljanja svih relevantnih uloga u razvojnom timu.

Struktura WD stručnjaka po razinama ekspertize u različitim područjima domene razvoja i vrjednovanja web mjesta nalazi se u tablici 6.16. WD stručnjaci su za procjenu razine ekspertize koristili identičnu skalu kao i HCI/WE stručnjaci. Točno pola uzorka WD stručnjaka se aktivno bavi razvojem Web 2.0 aplikacija dok ih se 40% smatra ekspertom u tom području. Kada je riječ o vrjednovanju različitih aspekata web mjesta, 50% WD stručnjaka smatra da vrlo dobro poznaje područje vrjednovanja upotrebljivosti dok ih 40% na jednak način percipira svoju ekspertizu u kontekstu vrjednovanja kvalitete u korištenju i korisničkog iskustva. Većina pojedinaca (60%) se smatra ekspertom u području arhitekture i radnog okruženja web aplikacija. Osim toga, 60% WD stručnjaka vrlo dobro poznaje područje razvoja web aplikacija temeljenog na komponentama, konceptualnog modeliranja web aplikacija, implementacije algoritama zaštite sigurnosti i privatnosti korisnika te servisno orijentiranih arhitektura. Konačno, većina (60%) WD stručnjaka vjeruje da posjeduje dostatno znanje iz područja semantičkih web servisa, adaptivnih, kontekstualiziranih i personaliziranih web aplikacija te modeliranja, praćenja i vrjednovanja performansi.

WD stručnjaci su preko sljedeće skale od četiri stupnja proveli samoprocjenu vezanu uz iskustvo u primjeni pojedinih razvojnih okruženja i programskih jezika:

- **Razina 0** označava da pojedinac nije nikada upotrebljavao pojedino razvojno okruženje ili programski jezik.
- **Razina 1** implicira da je pojedinac primjenom pojedinog razvojnog okruženja ili programskog jezika dizajnirao ili razvio mali broj web mjesta ili Web 2.0 aplikacija.
- **Razina 2** implicira da je pojedinac primjenom pojedinog razvojnog okruženja ili programskog jezika dizajnirao ili razvio nekoliko web mjesta ili Web 2.0 aplikacija.
- **Razina 3** implicira da je pojedinac primjenom pojedinog razvojnog okruženja ili programskog jezika dizajnirao ili razvio mnoštvo web mjesta ili Web 2.0 aplikacija.

Većina WD stručnjaka su eksperti u primjeni AJAX-a (60%), HTML-a i XHTML-a (60%), JavaScript-a (60%), MySQL-a (70%) i PHP-a (60%). Osim toga, 60% WD stručnjaka je implementiralo nekoliko web aplikacija upotrebom jezika XML. Konačno, pola uzorka WD stručnjaka je upotrebljavalo razvojna okruženja Adobe Flash i Adobe Dreamweaver te programske jezike VBScript i XSLT za potrebe razvoja manjeg broja web mjesta. Pregled strukture WD stručnjaka prema iskustvu u primjeni pojedinih razvojnih okruženja i programskih jezika nalazi se u tablici 6.17.

Tablica 6.12 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema profesionalnom iskustvu

Pokazatelji profesionalnog iskustva	$\bar{x}$	σ	**min**	**maks**
Broj godina u WD području	10,60	4,248	1	15
Broj izrađenih web mjesta	21,70	16,398	2	50
Broj izrađenih Web 2.0 aplikacija	9,60	6,670	0	20
Broj vrjednovanih web mjesta	15,90	17,065	0	60
Broj vrjednovanih Web 2.0 aplikacija	9,10	7,233	0	18
Učestalost vršenja dužnosti voditelja projekta razvoja web mjesta	11,00	9,117	0	30
Učestalost vršenja dužnosti voditelja projekta razvoja Web 2.0 aplikacije	5,90	6,118	0	20
Broj sudjelovanja u projektima vezanim uz razvoj web mjesta	18,30	17,708	0	50
Broj sudjelovanja u projektima vezanim uz razvoj Web 2.0 aplikacija	10,00	7,542	0	23

Tablica 11.13 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema ulogama u timu za razvoj web mjesta u posljednjih pet godina

Naziv uloge u razvojnom timu	Redovito		Povremeno		Rijetko		Nikad	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Voditelj projekta razvoja web mjesta	2	20	5	50	1	10	2	20
Prodajni predstavnik	0	0	0	0	3	30	7	70
Vrjednovatelj osiguranja kvalitete	0	0	2	20	4	40	4	40
Voditelj vrjednovanja upotrebljivosti/korisničkog iskustva/kvalitete u korištenju	1	10	3	30	3	30	3	30
Arhitekt informacija	7	70	2	20	0	0	1	10
Umjetnički direktor	1	10	0	0	3	30	6	60
Grafički dizajner web mjesta	1	10	3	30	3	30	3	30
Dizajner interaktivnih elemenata web mjesta	2	20	4	40	2	20	2	20
Medijski specijalist	1	10	0	0	4	40	5	50
Voditelj tehnoloških aspekata razvoja web mjesta	5	50	3	30	1	10	1	10
Programer web aplikacija	8	80	0	0	1	10	1	10
Projektant web mjesta	7	70	1	10	1	10	1	10
Administrator baze podataka	5	50	2	20	2	20	1	10
Webmaster	4	40	2	20	1	10	3	30
Voditelj produkcije web mjesta	2	20	4	40	1	10	3	30
Programer HTML stranica	6	60	2	20	1	10	1	10
Urednik web mjesta	1	10	1	10	5	50	3	30
Autor kreativnih tekstova na web mjestu	1	10	0	0	4	40	5	50
Stručnjak u domeni sadržaja	1	10	3	30	2	20	4	40

Tablica 6.14 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema ulogama u timu za razvoj web mjesta u posljednje tri godine

Naziv uloge u razvojnom timu	Redovito		Povremeno		Rijetko		Nikad	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Voditelj projekta razvoja web mjesta	3	30	4	40	1	10	2	20
Prodajni predstavnik	0	0	0	0	2	20	8	80
Vrjednovatelj osiguranja kvalitete	0	0	0	0	5	50	5	50
Voditelj vrjednovanja upotrebljivosti/korisničkog iskustva/kvalitete u korištenju	1	10	3	30	2	20	4	40
Arhitekt informacija	6	60	3	30	0	0	1	10
Umjetnički direktor	1	10	0	0	1	10	8	80
Grafički dizajner web mjesta	1	10	2	20	3	30	4	40
Dizajner interaktivnih elemenata web mjesta	3	30	2	20	3	30	2	20
Medijski specijalist	1	10	1	10	1	10	7	70
Voditelj tehnoloških aspekata razvoja web mjesta	7	70	2	20	0	0	1	10
Programer web aplikacija	7	70	1	10	1	10	1	10
Projektant web mjesta	6	60	1	10	2	20	1	10
Administrator baze podataka	5	50	1	10	3	30	1	10
Webmaster	3	30	2	20	1	10	4	40
Voditelj produkcije web mjesta	2	20	3	30	2	20	3	30
Programer HTML stranica	4	40	2	20	3	30	1	10
Urednik web mjesta	1	10	1	10	2	20	6	60
Autor kreativnih tekstova na web mjestu	1	10	0	0	3	30	6	60
Stručnjak u domeni sadržaja	1	10	0	0	3	30	6	60

Tablica 6.15 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema ulogama u timu za razvoj web mjesta u posljednjih godinu dana

Naziv uloge u razvojnom timu	Redovito		Povremeno		Rijetko		Nikad	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Voditelj projekta razvoja web mjesta	5	50	0	0	2	20	3	30
Prodajni predstavnik	0	0	0	0	0	0	10	100
Vrjednovatelj osiguranja kvalitete	0	0	1	10	1	10	8	80
Voditelj vrjednovanja upotrebljivosti/korisničkog iskustva/kvalitete u korištenju	1	10	3	30	1	10	5	50
Arhitekt informacija	4	40	4	40	1	10	1	10
Umjetnički direktor	1	10	0	0	1	10	8	80
Grafički dizajner web mjesta	1	10	1	10	3	30	5	50
Dizajner interaktivnih elemenata web mjesta	3	30	1	10	2	20	4	40
Medijski specijalist	1	10	1	10	1	10	7	70
Voditelj tehnoloških aspekata razvoja web mjesta	7	70	1	10	0	0	2	20
Programer web aplikacija	7	70	0	0	2	20	1	10
Projektant web mjesta	4	40	3	30	2	20	1	10
Administrator baze podataka	5	50	1	10	3	30	1	10
Webmaster	3	30	2	20	2	20	3	30
Voditelj produkcije web mjesta	2	20	2	20	3	30	3	30
Programer HTML stranica	2	20	5	50	2	20	1	10
Urednik web mjesta	1	10	1	10	2	20	6	60
Autor kreativnih tekstova na web mjestu	1	10	0	0	2	20	7	70
Stručnjak u domeni sadržaja	1	10	3	30	0	0	6	60

Tablica 6.16 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema području ekspertize

Područje ekspertize	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Vrjednovanje pristupačnosti	0	0	2	20	5	50	3	30
Adaptivne, kontekstualizirane i personalizirane web aplikacije	2	20	1	10	6	60	1	10
Računarstvo u oblacima	1	10	2	20	2	20	5	50
Kolaborativni razvoj web aplikacija	3	30	4	40	2	20	1	10
Razvoj web aplikacija temeljen na komponentama	3	30	6	60	0	0	1	10
Konceptualno modeliranje web aplikacija	2	20	6	60	0	0	2	20
Implementacija i analiza upotrebe web aplikacija	0	0	5	50	3	30	2	20
Programski jezici specifične domene namijenjeni razvoju web aplikacija	0	0	5	50	4	40	1	10
Implementacija algoritama zaštite sigurnosti i privatnosti korisnika	0	0	6	60	2	20	2	20
Dizajn interakcija	1	10	4	40	3	30	2	20
Razvoj i vrjednovanje mashupova / Web programiranje za krajnje korisnike	1	10	4	40	3	30	2	20
Mobilne web aplikacije i isporuka neovisna o uređaju	2	20	2	20	3	30	3	30
Dizajn interaktivnih sustava temeljen na modelima	2	20	2	20	5	50	1	10
Uzorci za razvoj web aplikacija i rudarenje uzoraka	3	30	2	20	4	40	1	10
Modeliranje, praćenje i vrjednovanje performansi	1	10	2	20	6	60	1	10
Vrjednovanje kvalitete u korištenju	0	0	4	40	4	40	2	20
Bogate internetske aplikacije	4	40	3	30	2	20	1	10
Semantički web servisi	0	0	3	30	6	60	1	10
Servisno orijentirane arhitekture	2	20	6	60	0	0	2	20
Društveno računarstvo	1	10	4	40	3	30	2	20
Sveprisutno računarstvo / Računarstvo svjesno konteksta	0	0	1	10	5	50	4	40
Vrjednovanje upotrebljivosti	0	0	5	50	3	30	2	20

Tablica 6.16 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema području ekspertize (nastavak)

Područje ekspertize	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Dizajn usmjeren korisnicima interaktivnih sustava	1	10	2	20	5	50	2	20
Dizajn korisničkog sučelja	3	30	3	30	3	30	1	10
Vrjednovanje korisničkog iskustva	0	0	4	40	4	40	2	20
Web 2.0 tehnologije i uzorci dizajna	4	40	5	50	0	0	1	10
Arhitekture i radna okruženja web aplikacija	6	60	3	30	0	0	1	10
Upravljanje sadržajem na Webu i podatkovno intenzivne web aplikacije	4	40	4	40	1	10	1	10
Metode i procesi web inženjerstva	3	30	4	40	2	20	1	10
Rudarenje Weba i ekstrakcija informacija	3	30	2	20	4	40	1	10

Tablica 6.17 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema iskustvu u primjeni pojedinog razvojnog okruženja i programskog jezika

Naziv razvojnog okruženja/programskog jezika	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
ActionScript	1	10	1	10	4	40	4	40
Adobe AIR	0	0	0	0	3	30	7	70
Adobe Flash	0	0	1	10	5	50	4	40
Adobe Dreamweaver	2	20	1	10	5	50	2	20
Adobe ColdFusion	0	0	0	0	2	20	8	80
ASP i ASP.Net	1	10	3	30	4	40	2	20
AJAX	6	60	2	20	0	0	2	20
Bespin	0	0	0	0	1	10	9	90
CGI	0	0	3	30	2	20	5	50
Cocoon	0	0	0	0	1	10	9	90
CorelDRAW Graphics Suite	1	10	1	10	3	30	5	50
C#	0	0	3	30	3	30	4	40
CSS	4	40	4	40	1	10	1	10
Django	0	0	1	10	1	10	8	80
DreamFace 2.0	0	0	0	0	0	0	10	100
Eclipse	4	40	3	30	2	20	1	10
Exhibit	0	0	0	0	0	0	10	100
Google Web Toolkit	1	10	3	30	3	30	3	30
Groovy	0	0	0	0	0	0	10	100
HTML i XHTML	6	60	3	30	1	10	0	0
HTML 5	2	20	3	30	3	30	2	20

Tablica 6.17 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema iskustvu u primjeni pojedinog razvojnog okruženja i programskog jezika (nastavak)

Naziv razvojnog okruženja/programskog jezika	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Java	4	40	2	20	2	20	2	20
JavaFX	0	0	0	0	2	20	8	80
JavaScript	6	60	3	30	1	10	0	0
JQuery	2	20	4	40	3	30	1	10
JSF	1	10	0	0	4	40	5	50
JSP	4	40	0	0	3	30	3	30
Microsoft Expression Web	0	0	1	10	2	20	7	70
Microsoft Frontpage	1	10	2	20	3	30	4	40
Microsoft Silverlight	0	0	0	0	4	40	6	60
Microsoft Visual Studio	1	10	3	30	4	40	2	20
MODx	0	0	0	0	0	0	10	100
ModalBox	1	10	0	0	0	0	9	90
MooTools	1	10	2	20	0	0	7	70
MVC	4	40	3	30	1	10	2	20
MySQL	7	70	2	20	1	10	0	0
NetBeans	0	0	2	20	1	10	7	70
OpenSocial	0	0	0	0	1	10	9	90
Perl	0	0	4	40	2	20	4	40
PHP	6	60	3	30	0	0	1	10
PRADO	0	0	0	0	0	0	10	100
Prototype	0	0	1	10	2	20	7	70

Tablica 6.17 Struktura sudionika (WD stručnjaka) u zatvorenom sortiranju karata prema iskustvu u primjeni pojedinog razvojnog okruženja i programskog jezika (nastavak)

Naziv razvojnog okruženja/programskog jezika	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Python	0	0	2	20	4	40	4	40
Ruby	0	0	1	10	1	10	8	80
Smarty	1	10	1	10	1	10	7	70
Spring	1	10	2	20	2	20	5	50
Spry	0	0	0	0	0	0	10	100
SSI	0	0	0	0	0	0	10	100
Struts	0	0	1	10	4	40	5	50
TYPOlight	0	0	0	0	0	0	10	100
VBScript	1	10	2	20	5	50	2	20
XML	3	30	6	60	1	10	0	0
XSLT	2	20	2	20	5	50	1	10
Zend	1	10	4	40	0	0	5	50

6.1.3 Rezultati primjene metode zatvorenog sortiranja karata

Proces analize podataka prikupljenih metodom zatvorenog sortiranja karata sastojao se od tri koraka. U prvom je koraku iz početnog skupa manifestnih varijabli izuzeto 8 čestica za koje je temeljem podataka prikupljenih od stručnjaka domene ustanovljeno da su redundantne. U sljedećem je koraku za svaku od preostalih 255 manifestnih varijabli izračunata vrijednost pokazatelja sadržajne valjanosti kao i prosječna vrijednost njihove relativne važnosti u vrjednovanju kvalitete u korištenju Web 2.0 aplikacijama. Manifestne varijable čija je vrijednost pokazatelja sadržajne valjanosti (CVR) iznosila manje od 0,33 (što je prema Lawshe (1975) referentna vrijednost na razini značajnosti $\alpha = 0{,}05$ za 29 procjenitelja) kao i manifestne varijable čija je prosječna vrijednost relativne važnosti (vrjednovana preko skale od tri stupnja: 1 – obavezna, 2 – poželjna, 3 – irelevantna) iznosila više od 2 su izostavljane iz daljnjih koraka razvoja mjernog instrumenta.

Vrijednosti pokazatelja sadržajne valjanosti i prosječne vrijednosti relativne važnosti početnog skupa manifestnih varijabli zbirno su prikazane u tablici 6.18. Najveća vrijednost pokazatelja sadržajne valjanosti ($\mathrm{CVR} = 1{,}00$) utvrđena je za osam čestica („Dizajn sučelja je jednak u svim dijelovima Web 2.0 aplikacije.“, „Web 2.0 aplikaciju je jednostavno pronaći preko web tražilice.“ „Izgled ikona koje se nalaze na sučelju Web 2.0 aplikacije je usklađen sa njihovom namjenom.“, „Web 2.0 aplikacija omogućava izvršavanje složenih zadataka.“, „Ukoliko tijekom izvršavanja zadataka korisnik napravi pogrješku, istu je moguće brzo i jednostavno ispraviti.“, „Web 2.0 aplikacija sadrži različite navigacijske mehanizme (npr. tražilica, izbornik i sl.).“, „Vrijeme odaziva Web 2.0 aplikacije je prihvatljivo.“ i „Web 2.0 aplikacija me se dojmila.“) i tri indikatora („Postotak dovršenosti predefiniranih koraka scenarija interakcije sa Web 2.0 aplikacijom.“, „Broj klikova mišem.“ i „Količina vremena potrebna za dovršetak predefiniranih koraka scenarija interakcije sa Web 2.0 aplikacijom.“) što znači da svih 29 stručnjaka domene vjeruje da je iste potrebno vrjednovati u kontekstu 11 različitih inicijalno definiranih dimenzija (dosljednost, dostupnost, razumljivost, skalabilnost, sprječavanje pogrješaka, upravljivost, vrijeme odaziva, zadovoljstvo, djelotvornost, minimalna aktivnost i učinkovitost, respektivno) kvalitete u korištenju Web 2.0 aplikacijama. S druge strane, čak 21 manifestna varijabla (od čega po tri namijenjene mjerenju pristupačnosti i vjerodostojnosti sadržaja, po dvije namijenjene vrjednovanju interaktivnosti, potpunosti sadržaja i vjerodostojnosti sadržaja te po jedna namijenjena mjerenju djelotvornosti, lakoće učenja korištenja, mogućnosti suradnje, reputacije, stava prema ponašanju, točnosti sadržaja, učinkovitosti i utjecaja društva) je poprimila najmanju vrijednost pokazatelja sadržajne valjanosti ($\mathrm{CVR} = 0{,}03$) što implicira da je mišljenje

stručnjaka domene da iste ne doprinose kvaliteti u korištenju Web 2.0 aplikacijama u dostatnoj mjeri te ih shodno tome nije potrebno vrjednovati.

Kada je riječ o drugom pokazatelju sadržajne valjanosti manifestnih varijabli, najmanja prosječna vrijednost ($\bar{x} = 1{,}17$) kao pokazatelj izrazito visoke relevantnosti utvrđena je za dvije čestice („Ukoliko tijekom korištenja Web 2.0 aplikacijom dođe do pogrješke ili prekida u radu, nakon ponovnog učitavanja, ista će prikazati oporavljenu verziju artefakta.“ i „Web 2.0 aplikacija je stabilna.“ namijenjene vrjednovanju mogućnosti oporavka i pouzdanosti, respektivno) i jedan indikator („Postotak dovršenosti predefiniranih koraka scenarija interakcije sa Web 2.0 aplikacijom.“ namijenjen mjerenju djelotvornosti) dok su najveću prosječnu vrijednost ($\bar{x} = 2{,}48$) kao mjerilo vrlo niske relevantnosti poprimile četiri manifestne varijable od čega su dvije izvorno bile namijenjene vrjednovanju interaktivnosti, a po jedna mjerenju kompatibilnosti i pristupačnosti.

Kao rezultat analize spomenuta dva kriterija sadržajne valjanosti, početni broj čestica je smanjen na 117 dok je broj indikatora ostao nepromijenjen. Iz daljnjih koraka oblikovanja mjernog instrumenta izuzeto je i 9 atributa kvalitete u korištenju (dodana vrijednost sadržaja, mogućnost pretraživanja, odupiranje promjenama, potpunost sadržaja, pravovremenost sadržaja, reputacija i vjerodostojnost sadržaja) iz razloga što nijedna od pridruženih im manifestnih varijabli nije udovoljila spomenutim kriterijima sadržajne valjanosti. Iz navedenog je evidentno da nijedan atribut kvalitete sadržaja nije udovoljio kriterijima sadržajne valjanosti. Premda su na tu temu mišljenja stručnjaka domene bila oprečna, većina ih se složila da je vrjednovanje kvalitete sadržaja važno, ali ne sa aspekta kvalitete u korištenju već zasebno. Naime, stručnjaci domene smatraju da će rezultati vrjednovanja biti valjani i nepristrani tek ako će kvalitetu sadržaja procjenjivati korisnici koji nisu sudjelovali u njihovoj izradi. U tom se kontekstu mišljenje stručnjaka domene podudara sa mišljenjem korisnika koji su sudjelovali u drugom (Orehovački, 2011a) i trećem pilot istraživanju (Orehovački et al., 2012a). Navedeno se odnosi i na preostala četiri atributa koja nisu udovoljila referentnim vrijednostima spomenutih kriterija sadržajne valjanosti.

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
DJELOTVORNOST (eng. EFFECTIVENESS)**		
DTV1. Upotrebom Web 2.0 aplikacije povećava se produktivnost korisnika u izvršavanju zadataka.*	0,03	2,28
DTV2. Upotrebom Web 2.0 aplikacije povećava se djelotvornost korisnika u izvršavanju zadataka.	0,72	1,41
DTV3. Upotrebom Web 2.0 aplikacije, zadatke je moguće izvršiti točno i u potpunosti.	0,79	1,41
DTV4. Sučelje Web 2.0 aplikacije sadrži sve funkcionalnosti potrebne za izvršavanje zadataka.	0,93	1,52
DTV5. Sučelje Web 2.0 aplikacije sadrži veliki broj različitih funkcionalnosti.*	0,31	2,21
DTV6. Postotak dovršenosti predefiniranih koraka scenarija interakcije sa Web 2.0 aplikacijom.	1,00	1,17
DODANA VRIJEDNOST SADRŽAJA (eng. CONTENT VALUE-ADDED)***		
DVS1. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je koristan.*	0,31	2,03
DVS2. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je upotrebljiv.*	0,03	2,07
DVS3. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je pristupačan.*	0,03	2,07
DVS4. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je usklađen sa ciljevima korisnika.*	0,10	2,45
DVS5. Sadržaj koji nastane upotrebom Web 2.0 aplikacije utječe na donošenje odluka kod korisnika.*	0,17	1,76
DOSLJEDNOST (eng. CONSISTENCY)		
DSD1. Izvršavanje jednakih aktivnosti dovodi do jednakih rezultata u svim dijelovima Web 2.0 aplikacije.*	0,45	2,24
DSD2. Funkcionalnosti sučelja su jednako razmještene u svim dijelovima Web 2.0 aplikacije.	0,66	1,76
DSD3. Dizajn sučelja je jednak u svim dijelovima Web 2.0 aplikacije.	1,00	1,41
DSD4. Način i mjesto prikazivanja poruka i informiranja korisnika su jednaki u svim dijelovima Web 2.0 aplikacije.	0,93	1,45
DSD5. U svim dijelovima Web 2.0 aplikacije se primjenjuje jednaka terminologija.*	0,31	2,34

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($\text{CVR} \geq 0{,}33;\ \bar{x} < 2{,}00$)
** latentna varijabla kojoj je u finalnoj verziji mjernog instrumenta promijenjen naziv
*** latentna varijabla izuzeta iz finalne verzije mjernog instrumenta jer joj pridružene manifestne varijable nisu udovoljile kriterijima sadržajne valjanosti ($\text{CVR} \geq 0{,}33;\ \bar{x} < 2{,}00$)

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
DOSTUPNOST (eng. AVAILABILITY)		
DST1. Web 2.0 aplikacija je dostupna svaki put kada je korisniku to potrebno.	0,72	1,52
DST2. Da bi se isprobale funkcionalnosti sa kojima raspolaže Web 2.0 aplikacija, nije potrebno kreirati korisnički račun.*	0,17	2,07
DST3. Sve funkcionalnosti koje su potrebne za izvršavanje zadataka pomoću Web 2.0 aplikacije su omogućene.*	0,17	2,28
DST4. Web 2.0 aplikaciju je jednostavno pronaći preko web tražilice.	1,00	1,45
DST5. Web 2.0 aplikacija omogućava prijavu sa postojećim (npr. Google, Facebook, Yahoo, ili OpenID) korisničkim računom.	0,79	1,52
DST6. Web 2.0 aplikacija sadrži funkcionalnost upotrebe u offline načinu rada.*	0,59	2,14
ESTETIKA (eng. AESTHETICS)		
EST1. Dizajn sučelja Web 2.0 aplikacije je vizualno privlačan.*	0,17	2,21
EST2. Boje koje prevladavaju na sučelju Web 2.0 aplikacije su prikladno usklađene.	0,86	1,66
EST3. Boje koje prevladavaju na sučelju Web 2.0 aplikacije su ugodne za oči.*	0,66	2,10
EST4. Web 2.0 aplikacija ima atraktivno sučelje.	0,72	1,76
EST5. Web 2.0 aplikacija lijepo izgleda.	0,52	1,72
FAMILIJARNOST (eng. FAMILIARITY)		
FML1. Raspored elemenata na korisničkom sučelju Web 2.0 aplikacije je sličan rasporedu u aplikacijama kojima se redovito koristim.	0,66	1,79
FML2. Način izvršavanja zadataka pomoću Web 2.0 aplikacije se bitno ne razlikuje od načina izvršavanja zadataka pomoću aplikacija kojima se svakodnevno koristim.*	0,52	2,07
FML3. Web 2.0 aplikacija upotrebljava jednake nazive za funkcionalnosti sučelja kao i aplikacije kojima se inače koristim.	0,66	1,83
FML4. Web 2.0 aplikacija upotrebljava slične ikone za pokretanje pojedinih funkcionalnosti kao i aplikacije kojima se svakodnevno koristim.	0,86	1,86
FML5. Sučelje Web 2.0 aplikacije sadrži iste funkcionalnosti kao i aplikacije kojima se redovito koristim.*	0,24	2,10

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($\text{CVR} \geq 0{,}33;\ \bar{x} < 2{,}00$)

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
INTERAKTIVNOST (eng. INTERACTIVITY)**		
ITR1. Web 2.0 aplikacija sadrži funkcionalnost generiranja direktne poveznice za svaki kreirani artefakt.*	0,31	1,79
ITR2. Web 2.0 aplikacija sadrži funkcionalnost za dodjelu razina vidljivosti kreiranom artefaktu.	0,79	1,62
ITR3. Web 2.0 aplikacija sadrži funkcionalnost za dodjeljivanje dozvola nad kreiranim artefaktom.	0,79	1,66
ITR4. Web 2.0 aplikacija sadrži funkcionalnost označavanja kreiranih artefakata pomoću ključnih riječi (tagova).	0,59	1,72
ITR5. Web 2.0 aplikacija sadrži funkcionalnost automatske pohrane artefakata (autosave).	0,79	1,79
ITR6. Web 2.0 aplikacija sadrži funkcionalnost objave kreiranih artefakata na društvenim mrežama.*	0,31	2,24
ITR7. Web 2.0 aplikacija sadrži funkcionalnost slanja obavijesti o promjenama nad artefaktom (RSS kanal, e-mail, poruka na društvenoj mreži).	0,66	1,90
ITR8. Web 2.0 aplikacija sadrži funkcionalnost kreiranja RSS kanala.*	0,45	2,03
ITR9. Web 2.0 aplikacija sadrži funkcionalnost prikaza sadržaja sa više različitih izvora.*	0,24	1,69
ITR10. Web 2.0 aplikacija sadrži funkcionalnost pretplate na sadržaje od interesa.*	0,45	2,03
ITR11. Sučelje Web 2.0 aplikacije sadrži funkcionalnost ispisa kreiranog artefakta na pisač.*	0,03	2,48
ITR12. Web 2.0 aplikacija pohranjuje informacije o autoru artefakta te datumu njegova nastanka ili modifikacije.*	0,10	2,45
ITR13. Web 2.0 aplikacija sadrži statistiku o učestalosti pristupanja i pregledavanja kreiranih artefakata.*	0,66	2,07
ITR14. Web 2.0 aplikacija sadrži detaljan pregled svih kreiranih artefakata (naziv, veličina, autor, datum kreiranja, datum modifikacije i sl.).*	0,03	2,48
ITR15. Web 2.0 aplikacija omogućava učitavanje vlastitih multimedijskih artefakata (slika, ikona, videozapisa).*	0,45	2,10
ITR16. Web 2.0 aplikacija prikazuje popis artefakata koji su zadnji mijenjani.*	0,59	2,10
INTEROPERABILNOST (eng. INTEROPERABILITY)		
INT1. Prilikom prenošenja artefakta (preuzimanje i umetanje) između Web 2.0 aplikacije i aplikacija kojima se svakodnevno koristim, ne dolazi do promjena u strukturi artefakta.	0,86	1,59
INT2. Prilikom prenošenja artefakta (kopiranje i lijepljenje) između Web 2.0 aplikacije i aplikacija kojima se svakodnevno koristim, ne dolazi do promjena u strukturi artefakta.	0,86	1,66
INT3. Artefakte koji nastanu upotrebom Web 2.0 aplikacije moguće je pohraniti u formatima datoteka koji su mi potrebni.	0,93	1,48

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)
** latentna varijabla kojoj je u finalnoj verziji mjernog instrumenta promijenjen naziv

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
JEDINSTVENOST (eng. UNIQUENESS)		
JDN1. Web 2.0 aplikacija ima ono nešto po čemu se razlikuje od drugih aplikacija.	0,72	1,83
JDN2. Web 2.0 aplikacija je jedinstvena.	0,66	1,86
JDN3. Web 2.0 aplikacija se ističe u skupini aplikacija sa istom namjenom.	0,86	1,83
KOMPATIBILNOST (eng. COMPATIBILITY)**		
KMP1. Način korištenja Web 2.0 aplikacijom se ne razlikuje među web preglednicima.	0,93	1,45
KMP2. Dostupnost elemenata sučelja Web 2.0 aplikacije se ne razlikuje među web preglednicima.	0,93	1,45
KMP3. Način korištenja Web 2.0 aplikacijom te dostupnost elemenata njena sučelja se ne razlikuje među uređajima koje je moguće spojiti na Internet.	0,66	1,86
KMP4. Artefakt koji nastane upotrebom Web 2.0 aplikacije je kompatibilan sa aplikacijama koje korisnik svakodnevno upotrebljava.*	0,10	2,45
KMP5. Web 2.0 aplikacija se može upotrebljavati na svakom uređaju koji ima vezu na Internet.*	0,03	2,48
KORISNOST (eng. USEFULNESS)		
KRS1. Korištenje Web 2.0 aplikacijom utječe na povećanje kvalitete artefakata.*	0,45	2,07
KRS2. Upotrebom Web 2.0 aplikacije povećavaju se performanse korisnika u izvršavanju zadataka.	0,86	1,52
KRS3. Web 2.0 aplikacija je korisna za izvršavanje zadataka.	0,72	1,69
KRS4. Web 2.0 aplikacija je prikladna za izvršavanje zadataka.	0,72	1,62
LAKOĆA KORIŠTENJA (eng. EASE OF USE)		
LAK1. Lako je izvršavati zadatke pomoću Web 2.0 aplikacije.	0,79	1,41
LAK2. Web 2.0 aplikacija je jednostavna za upotrebu.	0,93	1,38
LAK3. Jednostavno je raditi sa Web 2.0 aplikacijom.	0,45	1,55
LAK4. Jednostavno je upravljati kreiranim artefaktima.*	0,10	2,24
LAK5. Da bi se izvršio zadatak pomoću Web 2.0 aplikacije, nije potrebno konzultirati sadržaje pomoći.*	0,45	2,03

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)
** latentna varijabla kojoj je u finalnoj verziji mjernog instrumenta promijenjen naziv

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
LAKOĆA UČENJA KORIŠTENJA (eng. LEARNABILITY)		
LUK1. Jednostavno je postati vješt/a u korištenju Web 2.0 aplikacijom.	0,86	1,48
LUK2. Lako je naučiti izvršavati zadatke pomoću Web 2.0 aplikacije.	0,72	1,34
LUK3. Funkcionalnosti sučelja Web 2.0 aplikacije moguće je brzo naučiti upotrebljavati.	0,72	1,48
LOJALNOST (eng. LOYALTY)		
LOJ1. Web 2.0 aplikaciju namjeravam nastaviti upotrebljavati.	0,59	1,59
LOJ2. Svakome bih preporučio/preporučila ovu Web 2.0 aplikaciju.	0,66	1,59
LOJ3. Web 2.0 aplikaciju ubuduće planiram često upotrebljavati.	0,59	1,59
LOJ4. Web 2.0 aplikaciju namjeravam redovito upotrebljavati.*	0,38	2,10
LOJ5. Web 2.0 aplikaciju namjeravam upotrebljavati u slobodno vrijeme.*	0,17	1,97
MINIMALNA AKTIVNOST (eng. MINIMAL ACTION)**		
MAK1. Korištenje Web 2.0 aplikacijom ne iziskuje mnogo motoričkih aktivnosti pomoću tipkovnice i miša.*	0,24	2,38
MAK2. Izvršavanje zadataka pomoću Web 2.0 aplikacije ne iziskuje mnogo korištenja mišem.*	0,31	2,10
MAK3. Izvršavanje zadataka pomoću Web 2.0 aplikacije ne iziskuje mnogo korištenja tipkovnicom.*	0,45	2,03
MAK4. Tijekom korištenja Web 2.0 aplikacijom, nije potrebno često izmjenjivati rad sa tipkovnicom i mišem.*	0,31	1,93
MAK5. Nakon korištenja Web 2.0 aplikacijom, korisnik ne osjeća umor u očima.	0,66	1,76
MAK6. Nakon izvršavanja zadataka pomoću Web 2.0 aplikacije, korisnik ne osjeća umor u prstima, zglobovima i mišićima ruku.	0,52	1,38
MAK7. Broj pritisnutih tipaka na tipkovnici.	0,86	1,83
MAK8. Broj klikova mišem.	1,00	1,72
MAK9. Broj pomicanja klizača na mišu.	0,66	1,86
MAK10. Udaljenost prijeđena pomicanjem miša.	0,72	1,83

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)
** latentna varijabla kojoj je u finalnoj verziji mjernog instrumenta promijenjen naziv

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
MINIMALNO OPTEREĆENJE MEMORIJE (eng. MINIMAL MEMORY LOAD)**		
MOM1. Korištenje Web 2.0 aplikacijom ne zahtijeva puno mentalnih i perceptivnih aktivnosti.*	0,38	2,03
MOM2. Korištenje Web 2.0 aplikacijom ne zahtijeva puno razmišljanja i odlučivanja.*	0,10	2,14
MOM3. Korištenje Web 2.0 aplikacijom ne zahtijeva puno pamćenja.*	0,31	1,72
MOM4. Korištenje Web 2.0 aplikacijom ne zahtijeva puno pregledavanja i pretraživanja.*	0,17	2,21
MOM5. Korisnik se nakon korištenja Web 2.0 aplikacijom ne osjeća iscrpljeno.	0,79	1,66
MOM6. Korisnik se nakon korištenja Web 2.0 aplikacijom osjeća opušteno.*	0,31	1,90
MOGUĆNOST KOMUNIKACIJE (eng. COMMUNICATIVITY)**		
MKM1. Web 2.0 aplikacija sadrži funkcionalnost sinkrone komunikacije sa ostalim korisnicima.	0,66	1,83
MKM2. Web 2.0 aplikacija sadrži funkcionalnost asinkrone komunikacije sa ostalim korisnicima.	0,79	1,76
MKM3. Web 2.0 aplikacija omogućava komunikaciju među korisnicima.*	0,24	2,24
MKM4. Web 2.0 aplikacija omogućava razmjenu znanja i iskustva među korisnicima.*	0,24	2,14
MOGUĆNOST KONTROLE (eng. CONTROLLABILITY)		
MOK1. Jednostavno je postići da Web 2.0 aplikacija radi što korisnik želi.	0,66	1,52
MOK2. Redoslijed upotrebe funkcionalnosti sučelja Web 2.0 aplikacije u potpunosti ovisi o korisniku.	0,86	1,76
MOK3. Korisnik ima potpunu slobodu u izvršavanju zadataka pomoću Web 2.0 aplikacije.	0,66	1,62
MOGUĆNOST OPORAVKA (eng. RECOVERABILITY)		
MOP1. Ukoliko tijekom korištenja Web 2.0 aplikacijom dođe do pogrješke ili prekida u radu, nakon ponovnog učitavanja, ista će prikazati oporavljenu verziju artefakta.	0,79	1,17
MOP2. Ukoliko tijekom izvršavanja zadataka dođe do pogrješke ili prekida u radu Web 2.0 aplikacije, ne izgubi se sav posao koji se do tada napravio.	0,86	1,34
MOP3. Ukoliko tijekom korištenja Web 2.0 aplikacijom dođe do pogrješke ili prekida u radu, potrebno je ugasiti web preglednik i ponovno učitati Web 2.0 aplikaciju.*	0,31	1,72
MOP4. Web 2.0 aplikacija se može brzo oporaviti od pogrješke ili prekida u radu.	0,93	1,45

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)
** latentne varijable kojima je u finalnoj verziji mjernog instrumenta promijenjen naziv

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
MOGUĆNOST PRETRAŽIVANJA (eng. SEARCHABILITY)* **		
MPT1. Interna tražilica nudi različite mogućnosti pretraživanja kreiranih artefakata.*	0,10	2,28
MPT2. Rezultati pretraživanja interne tražilice su točni i precizni.*	0,31	2,31
MPT3. Rezultati pretraživanja interne tražilice su relevantni.*	0,17	2,41
MPT4. Interna tražilica je učinkovita.*	0,10	2,41
MPT5. Za svaki uneseni upit, interna tražilica automatski generira rezultate pretraživanja.*	0,24	1,83
MOGUĆNOST PRILAGODBE (eng. CUSTOMIZABILITY)		
MPR1. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe radnog prostora.	0,93	1,66
MPR2. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe jezika prikaza.	0,59	1,69
MPR3. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe prikaza formata datuma i vremena.	0,38	1,62
MPR4. Web 2.0 aplikacija sadrži funkcionalnosti koje omogućuju personalizaciju elemenata sučelja.*	0,59	2,03
MPR5. Web 2.0 aplikaciju je moguće prilagoditi željama i potrebama korisnika.*	0,17	2,17
MPR6. Web 2.0 aplikaciju je moguće prilagoditi karakteristikama zadatka.*	0,10	1,79
MPR7. Web 2.0 aplikaciju je moguće prilagoditi kulturnim i lokalnim specifičnostima korisnika.*	0,17	2,28
MPR8. Radni prostor Web 2.0 aplikacije moguće je postaviti na puni ekran.*	0,24	2,24
MPR9. Web 2.0 aplikacija sadrži funkcionalnost organizacije zasebnih zadataka u kartice.*	0,31	2,00
MPR10. Na sučelju Web 2.0 aplikacije postoji funkcionalnost kojom je moguće odrediti količinu detalja koji se prikazuju za pojedini artefakt.*	0,10	2,31
MPR11. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe načina prikazivanja kreiranih artefakata.*	0,31	1,66

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti (CVR $\geq 0{,}33$; $\bar{x} < 2{,}00$)
*** latentna varijabla izuzeta iz finalne verzije mjernog instrumenta jer joj pridružene manifestne varijable nisu udovoljile kriterijima sadržajne valjanosti (CVR $\geq 0{,}33$; $\bar{x} < 2{,}00$)

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
MOGUĆNOST SURADNJE (eng. COLLABORATIVITY)**		
MSU1. Web 2.0 aplikacija sadrži funkcionalnost dodjele pristupa kreiranom artefaktu preko liste kontakata.	0,79	1,86
MSU2. Web 2.0 aplikacija sadrži funkcionalnost dodjele pristupa kreiranom artefaktu preko direktne poveznice.	0,59	1,86
MSU3. Web 2.0 aplikacija omogućava suradnju u izradi artefakata.*	0,52	2,17
MSU4. Web 2.0 aplikacija podržava timski rad.*	0,03	1,66
MSU5. Web 2.0 aplikacija podržava rad većeg broja korisnika na izradi artefakta.	0,86	1,69
MSU6. Web 2.0 aplikacija omogućava razmjenu artefakata među korisnicima.*	0,31	2,00
ODUPIRANJE PROMJENAMA (eng. RESISTANCE TO CHANGES)***		
ODP1. Zainteresiran/a sam za nove web tehnologije.*	0,31	1,90
ODP2. Volim čitati, gledati i slušati o novim web tehnologijama.*	0,31	1,83
ODP3. Volim isprobati nove web tehnologije.*	0,31	1,86
ODP4. Sklon/a sam promijeniti aplikacije koje koristim za svakodnevne online aktivnosti (web preglednik, mail klijent i sl.).*	0,24	1,86
PAMTLJIVOST (eng. MEMORABILITY)		
PMT1. Jednostavno je zapamtiti kako se upotrebljava Web 2.0 aplikacija.	0,86	1,48
PMT2. Lako je zapamtiti gdje se nalaze pojedine funkcionalnosti sučelja Web 2.0 aplikacije.	0,79	1,28
PMT3. Biti će jednostavno prisjetiti se gdje se nalaze i kako se upotrebljavaju funkcionalnosti sučelja, čak i ako se Web 2.0 aplikacija ne bude dulje vrijeme upotrebljavala.	0,86	1,52
POTPUNOST SADRŽAJA (eng. CONTENT COVERAGE)***		
PTS1. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je potpun.*	0,24	2,21
PTS2. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je pregledan.*	0,03	2,31
PTS3. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je prikladno prikazan.*	0,03	2,07
PTS4. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je jezgrovit.*	0,17	1,86

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti (CVR $\geq 0{,}33$; $\bar{x} < 2{,}00$)
** latentna varijabla kojoj je u finalnoj verziji mjernog instrumenta promijenjen naziv
*** latentne varijable izuzete iz finalne verzije mjernog instrumenta jer im pridružene manifestne varijable nisu udovoljile kriterijima sadržajne valjanosti (CVR $\geq 0{,}33$; $\bar{x} < 2{,}00$)

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
POUZDANOST (eng. RELIABILITY)		
PZD1. Tijekom korištenja Web 2.0 aplikacijom, nije dolazilo do prekida u radu.*	0,17	2,24
PZD2. Tijekom izvršavanja zadataka pomoću Web 2.0 aplikacije, pogrješke se nisu javljale.*	0,31	2,21
PZD3. Web 2.0 aplikacija je pouzdana.	0,66	1,72
PZD4. Web 2.0 aplikacija je stabilna.	0,93	1,17
PZD5. Web 2.0 aplikacija nema softverskih pogrješaka (bugova).	0,86	1,34
POVRATNE INFORMACIJE (eng. FEEDBACK)		
PIN1. Web 2.0 aplikacija obavještava korisnika kada će pojedina aktivnost biti izvršena.	0,86	1,34
PIN2. Nakon provedbe određene aktivnosti nad artefaktom (npr. pohrana), Web 2.0 aplikacija prikazuje prikladnu povratnu poruku.	0,93	1,34
PIN3. Poruke koje prikazuje Web 2.0 aplikacija su jasne.	0,93	1,28
PIN4. Poruke koje prikazuje Web 2.0 aplikacija su precizne.	0,66	1,86
PIN5. Poruke koje prikazuje Web 2.0 aplikacija su korisne.*	0,31	2,24
PIN6. Ukoliko tijekom izvršavanja zadataka dođe do pogrješke ili prekida u radu, Web 2.0 aplikacija o tome pravovremeno obavještava korisnika.	0,79	1,34
PIN7. Web 2.0 aplikacija prikazuje status dovršenosti zadatka.*	0,38	2,24
PIN8. Web 2.0 aplikacija nudi mogućnost kontaktiranja službe za korisnike.*	0,10	2,34
PRAVOVREMENOST SADRŽAJA (eng. CONTENT TIMELINESS)* **		
PVS1. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je moguće nadopuniti.*	0,10	2,10
PVS2. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je moguće ažurirati.*	0,31	2,24
PVS3. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je moguće mijenjati.*	0,24	1,86

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)

*** latentna varijabla izuzeta iz finalne verzije mjernog instrumenta jer joj pridružene manifestne varijable nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
PRISTUPAČNOST (eng. ACCESSIBILITY)		
PST1. Web 2.0 aplikacija sadrži popis tipkovničkih kratica za pokretanje često korištenih elemenata sučelja.	0,66	1,83
PST2. Kada se miš zaustavi na pojedinom elementu sučelja Web 2.0 aplikacije, prikazuje se oznaka koja opisuje njegovu funkcionalnost.*	0,24	2,38
PST4. Tekst koji opisuje funkcionalnost pojedinih elemenata sučelja Web 2.0 aplikacije je dovoljno velik za čitanje.	0,72	1,41
PST5. Da bi se izvršio zadatak pomoću Web 2.0 aplikacije, dovoljno je upotrebljavati samo tipkovnicu.*	0,03	2,34
PST6. Objekti koji se nalaze na sučelju Web 2.0 aplikacije su dovoljno veliki.	0,72	1,34
PST7. Osobe koje imaju neki oblik invaliditeta će moći upotrebljavati Web 2.0 aplikaciju.*	0,03	2,28
PST8. Web 2.0 aplikacija je pristupačna sa svakog uređaja koji ima vezu na Internet.*	0,03	2,48
RASPOLOŽIVOST I PRUŽANJE POMOĆI (eng. HELPFULNESS)		
RIP1. Web 2.0 aplikacija sadrži različite oblike pomoći korisnicima.	0,86	1,62
RIP2. Pomoć korisnicima je dostupna sa bilo kojeg dijela Web 2.0 aplikacije.*	0,38	2,03
RIP3. Različiti oblici pomoći korisnicima su dostupni sa bilo kojeg dijela Web 2.0 aplikacije.	0,66	1,69
RIP4. U situaciji kad korisnik ne zna upotrebljavati neku funkcionalnost sučelja Web 2.0 aplikacije, rješenje problema moguće je pronaći u materijalima pomoći.*	0,17	2,31
RIP5. Sadržaji online pomoći Web 2.0 aplikacije su jasni.	0,93	1,52
RIP6. U sadržajima online pomoći moguće je jednostavno i brzo pronaći kako se upotrebljava pojedina funkcionalnost Web 2.0 aplikacije.	0,72	1,62
RIP7. Sadržaji online pomoći Web 2.0 aplikacije su pregledni.	0,59	1,55
RAZIGRANOST (eng. PLAYFULNESS)		
RZG1. Korištenje Web 2.0 aplikacijom uspješno zadržava moju pažnju dulje vrijeme.	0,45	1,83
RZG2. Tijekom korištenja Web 2.0 aplikacijom, u potpunosti sam koncentriran(a) na izvršavanje zadataka.*	0,31	2,07
RZG3. Kada upotrebljavam Web 2.0 aplikaciju, ne primjećujem što se oko mene događa.*	0,24	2,10
RZG4. Korištenje Web 2.0 aplikacijom me u potpunosti zaokuplja.*	0,17	1,93
RZG5. Korištenje Web 2.0 aplikacijom potiče moju kreativnost.	0,45	1,62
RZG6. Korištenje Web 2.0 aplikacijom potiče moju stvaralačku maštu.	0,38	1,72

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($\text{CVR} \geq 0{,}33;\ \bar{x} < 2{,}00$)

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
RAZUMLJIVOST (eng. UNDERSTANDABILITY)		
RZM1. Kada korisnik odabere i pokrene pojedine elemente sučelja Web 2.0 aplikacije, dobije što je i očekivao.*	0,10	2,41
RZM2. Funkcionalnost elemenata sučelja Web 2.0 aplikacije je razumljiva.	0,93	1,41
RZM3. Izgled ikona koje se nalaze na sučelju Web 2.0 aplikacije je usklađen sa njihovom namjenom.	1,00	1,45
RZM4. Naziv funkcionalnih elemenata sučelja Web 2.0 aplikacije odgovara kontekstu njihove upotrebe.	0,86	1,41
REPUTACIJA (eng. REPUTATION)* **		
RPT1. Da bi upotrebljavao/upotrebljavala Web 2.0 aplikaciju, važno mi je da ona ima veliki broj aktivnih korisnika.*	0,10	2,24
RPT2. Da bi upotrebljavao/upotrebljavala Web 2.0 aplikaciju, važno mi je da je istu razvila ugledna kompanija.*	0,24	2,24
RPT3. Da bi upotrebljavao/upotrebljavala Web 2.0 aplikaciju, važno mi je da ista ima dobar portfolio.*	0,03	2,24
RPT4. Na moju odluku o korištenju određenim Web 2.0 aplikacijama utječe njihova popularnost.*	0,38	2,03
SIGURNOST (eng. SECURITY)		
SGR1. Obrazac za izradu korisničkog računa sadrži indikator jačine lozinke.*	0,59	2,07
SGR2. Tijekom izrade korisničkog računa potrebno je unijeti previše osobnih podataka.*	0,24	1,90
SGR3. Tijekom popunjavanja obrasca za registraciju novog korisnika potrebno je unijeti CAPTCHA znakove.	0,38	1,79
SGR4. Tijekom izrade korisničkog računa potrebno je definirati sigurnosno pitanje i odgovor.	0,45	1,83
SGR5. Tijekom izrade korisničkog računa, potrebno je potvrditi prethodno unesenu lozinku.	0,86	1,52
SGR6. Tijekom izrade korisničkog računa, potrebno je unijeti lozinku koja sadrži minimalan broj znakova.	0,66	1,72
SGR7. Tijekom izrade korisničkog računa potrebno je unijeti lozinku koja sadrži posebne znakove (!@#$%^*()~`{}[]|\&_).*	0,17	2,00
SGR8. Kod svakog učitavanja Web 2.0 aplikacije u web preglednik, potrebno je unijeti korisničko ime i lozinku.*	0,24	2,17
SGR9. Web 2.0 aplikacija sadrži funkcionalnost pamćenja korisničkog imena i lozinke.*	0,24	2,21
SGR10. Artefakti koji nastanu upotrebom Web 2.0 aplikacije su zaštićeni od neautoriziranih korisnika.	0,86	1,24
SGR11. Web 2.0 aplikacija sadrži funkcionalnost oporavka korisničkog računa.*	0,72	2,07
SGR12. Web 2.0 aplikacija sadrži uvjete korištenja i politiku privatnosti.*	0,45	2,17

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)
*** latentna varijabla izuzeta iz finalne verzije mjernog instrumenta jer joj pridružene manifestne varijable nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
SKALABILNOST (eng. SCALABILITY)**		
SLB1. Web 2.0 aplikacija omogućava pohranu velike količine artefakata.	0,79	1,79
SLB2. Web 2.0 aplikacija omogućava istovremeni rad velikog broja korisnika.*	0,31	1,83
SLB3. Web 2.0 aplikacija omogućava istovremeni rad na većem broju zadataka.	0,86	1,79
SLB4. Web 2.0 aplikacija omogućava izvršavanje složenih zadataka.	1,00	1,69
SPRJEČAVANJE POGRJEŠAKA (eng. ERROR PREVENTION)		
SPO1. Ukoliko tijekom izvršavanja zadataka korisnik napravi pogrješku, istu je moguće brzo i jednostavno ispraviti.	1,00	1,28
SPO2. Web 2.0 aplikacija sadrži funkcionalnost za praćenje promjena nad artefaktom.*	0,31	2,07
SPO3. Web 2.0 aplikacija omogućuje korisniku da poništi i ponovi promjene na artefaktu.	0,79	1,41
SPO4. Prije provedbe bilo kakve destruktivne operacije, Web 2.0 aplikacija traži potvrdu od korisnika.	0,93	1,28
STAV PREMA PONAŠANJU (eng. ATTITUDE TOWARDS BEHAVIOUR)**		
STP1. Korištenje Web 2.0 aplikacijom je dobra ideja.	0,79	1,38
STP2. Korištenje Web 2.0 aplikacijom je mudra ideja.	0,72	1,41
STP3. Sviđa mi se ideja o korištenju Web 2.0 aplikacijom.	0,52	1,45
STP4. Imam pozitivan stav prema korištenju Web 2.0 aplikacijom.*	0,17	2,31
STP5. Veselim se zadacima zbog kojih ću trebati upotrebljavati Web 2.0 aplikaciju.*	0,03	2,00
SVEOBUHVATNOST KONTEKSTA (eng. CONTEXT COVERAGE)		
SVK1. Web 2.0 aplikacija omogućava izradu raznovrsnih artefakata.	0,45	1,86
SVK2. Web 2.0 aplikaciju je moguće upotrebljavati i izvan konteksta za koji je originalno namijenjena.	0,45	1,86
SVK3. Web 2.0 aplikacija ima široku mogućnost primjene.	0,72	1,83

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)
** latentne varijable kojima je u finalnoj verziji mjernog instrumenta promijenjen naziv

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
TOČNOST SADRŽAJA (eng. CONTENT CORRECTNESS)* **		
TNS1. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je točan.*	0,24	2,24
TNS2. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je bez pogrješaka.*	0,24	2,34
TNS3. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je jasan i razumljiv.*	0,03	2,24
TNS4. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je valjan.*	0,31	1,97
TNS5. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je precizan.*	0,17	2,07
TNS6. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je ispravan.*	0,17	1,97
UČINKOVITOST (eng. EFFICIENCY)**		
UNK1. Upotrebom Web 2.0 aplikacije, zadatke je moguće brzo izvršiti.	0,79	1,52
UNK2. Da bi se izvršio zadatak pomoću Web 2.0 aplikacije, potrebno je poduzeti mali broj koraka.*	0,03	2,31
UNK3. Upotrebom Web 2.0 aplikacije povećava se učinkovitost u izvršavanju zadataka.	0,79	1,48
UNK4. Izvršavanjem zadataka pomoću Web 2.0 aplikacije, dobiva se na uštedi vremena.	0,72	1,41
UNK5. Količina vremena potrebna za dovršetak predefiniranih koraka scenarija interakcije sa Web 2.0 aplikacijom.	1,00	1,24

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)
** latentna varijabla kojoj je u finalnoj verziji mjernog instrumenta promijenjen naziv
*** latentna varijabla izuzeta iz finalne verzije mjernog instrumenta jer joj pridružene manifestne varijable nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
UPRAVLJIVOST (eng. NAVIGABILITY)		
UPR1. Web 2.0 aplikacija sadrži različite navigacijske mehanizme (npr. tražilica, izbornik i sl.).	1,00	1,45
UPR2. Korisnik može sa bilo kojeg dijela Web 2.0 aplikacije pristupiti svim funkcionalnostima sučelja koje su mu potrebne za izvršavanje zadataka.*	0,17	1,79
UPR3. Korisnik može brzo i jednostavno pronaći funkcionalnosti sučelja Web 2.0 aplikacije koje su mu potrebne za izvršavanje zadataka.	0,86	1,55
UPR4. Elementi sučelja Web 2.0 aplikacije su tako raspoređeni da se oni koji imaju srodnu funkcionalnost nalaze jedni pored drugih.	0,72	1,66
UPR5. Broj elemenata u izborniku i podizbornicima je optimalan.	0,86	1,59
UPR6. Elementi sučelja Web 2.0 aplikacije su intuitivni za upotrebu.	0,79	1,45
UPR7. Web 2.0 aplikacija sadrži oblak tagova.*	0,17	2,31
UPR8. Web 2.0 aplikacija sadrži funkcionalnost koja prikazuje trenutnu poziciju u radnom prostoru.*	0,31	1,86
UPR9. Web 2.0 aplikacija sadrži mapu web mjesta. *	0,24	2,10
UPR10. Radni prostor Web 2.0 aplikacije stane u jedan ekran (nije potrebno koristiti klizače).*	0,38	2,17
UPR11. Navigacija između pojedinih dijelova Web 2.0 aplikacije moguća je upotrebom funkcijskih tipki *sljedeći* i *prethodan* u web pregledniku.*	0,31	2,10
UPR12. Navigacija između pojedinih dijelova Web 2.0 aplikacije moguća je upotrebom funkcijskih tipki *sljedeći* i *prethodan* koje se nalaze na njenom sučelju.*	0,24	2,21
UTJECAJ DRUŠTVA (eng. SOCIAL INFLUENCE)* **		
UDR1. Na moju odluku o korištenju Web 2.0 aplikacijom utječu ljudi čije mišljenje mi je važno.*	0,31	2,14
UDR2. Na moju odluku o korištenju Web 2.0 aplikacijom utječu informacije iz raznih medija (Internet, stručni časopisi).*	0,52	2,07
UDR3. Na moju odluku o korištenju Web 2.0 aplikacijom utječe činjenica da istu upotrebljavaju moji prijatelji i kolege.*	0,03	1,72

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)

*** latentna varijabla izuzeta iz finalne verzije mjernog instrumenta jer joj pridružene manifestne varijable nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)

Tablica 6.18 Rezultati vrjednovanja sadržajne valjanosti početnog skupa manifestnih varijabli (nastavak)

POČETNI SKUP MANIFESTNIH I LATENTNIH VARIJABLI	CVR	$\bar{x}$
UŽITAK (eng. PLEASURE)		
UTK1. Korištenje Web 2.0 aplikacijom je zabavno.*	0,31	2,10
UTK2. Korištenje Web 2.0 aplikacijom je zanimljivo.	0,59	1,69
UTK3. Tijekom upotrebe Web 2.0 aplikacije, korisnik se dobro osjeća.*	0,10	2,24
UTK4. Ugodno je upotrebljavati Web 2.0 aplikaciju.	0,66	1,62
UTK5. Sviđa mi se način izvršavanja zadataka pomoću funkcionalnosti sučelja Web 2.0 aplikacije.	0,59	1,76
VJERODOSTOJNOST SADRŽAJA (eng. CONTENT CREDIBILITY)* **		
VDS1. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je istinit.*	0,17	1,86
VDS2. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je vjerodostojan.*	0,03	2,10
VDS3. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je pouzdan.*	0,03	1,45
VDS4. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je objektivan.*	0,45	2,21
VDS5. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je relevantan.*	0,03	1,66
VDS6. Sadržaj koji nastane upotrebom Web 2.0 aplikacije je provjerljiv.*	0,17	1,66
VRIJEME ODAZIVA (eng. RESPONSIVENESS)**		
VOD1. Početna stranica Web 2.0 aplikacije se brzo učitava u web pregledniku.*	0,52	2,17
VOD2. Radni prostor Web 2.0 aplikacije i elementi sučelja se brzo učitavaju u web pregledniku.	0,93	1,41
VOD3. Nije potrebno dugo čekati da se pokrenu i izvrše odabrane funkcionalnosti sučelja Web 2.0 aplikacije.	0,86	1,55
VOD4. Vrijeme odaziva Web 2.0 aplikacije je prihvatljivo.	1,00	1,38
VOD5. Tijekom izvršavanja zadatka nije dolazilo do zastoja u radu Web 2.0 aplikacije.*	0,10	2,41
ZADOVOLJSTVO (eng. SATISFACTION)		
ZDV1. Web 2.0 aplikacija je ispunila moja očekivanja.	0,93	1,38
ZDV2. Zadovoljan/zadovoljna sam korištenjem Web 2.0 aplikacijom.	0,79	1,38
ZDV3. Zadovoljan/zadovoljna sam sa načinom izvršavanja zadataka pomoću elemenata sučelja Web 2.0 aplikacije.*	0,17	2,34
ZDV4. Web 2.0 aplikacija me se dojmila.	1,00	1,41

* manifestne varijable izuzete iz finalne verzije mjernog instrumenta jer nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)
** latentna varijabla kojoj je u finalnoj verziji mjernog instrumenta promijenjen naziv
*** latentna varijabla izuzeta iz finalne verzije mjernog instrumenta jer joj pridružene manifestne varijable nisu udovoljile kriterijima sadržajne valjanosti ($CVR \geq 0{,}33$; $\bar{x} < 2{,}00$)

Treći korak analize podataka prikupljenih primjenom metode zatvorenog sortiranja karata sastojao se od vrjednovanja sadržajne valjanosti izračunom omjera pogodaka i podudaranja između stručnjaka izračunom Congerovog Kappa koeficijenta. Potrebno je napomenuti da su u ovaj korak analize bile uključene samo one manifestne i latentne varijable koji su udovoljile referentnim vrijednostima pokazatelja sadržajne valjanosti i prosječne vrijednosti relativne važnosti. Ukupan omjer pogodaka dobiven je dijeljenjem broja pogodaka (ukupnog broja ispravnih pridruživanja) i ukupnog broja pridruživanja (produkt broja manifestnih varijabli i stručnjaka domene). Tablica 6.19 zorno prikazuje da je ukupan omjer pogodaka iznosio 89%. Najveći omjer pogodaka (100%) utvrđen je za tri latentne varijable (familijarnost, jedinstvenost i pouzdanost) što implicira da su im stručnjaci domene ispravno pridružili sve manifestne varijable namijenjene mjerenju njihovih dimenzija. S druge strane, najmanji omjer pogodaka (77%) izračunat je za latentnu varijablu upravljivost najviše iz razloga što su stručnjaci domene značajan dio (12%) manifestnih varijabli pridružili teorijski srodnoj latentnoj varijabli namijenjenoj vrjednovanju lakoće korištenja. Obzirom da u literaturi ne postoji eksplicitno definirana referentna vrijednost za ukupan omjer pogodaka, kao uporište za donošenje odluke o prihvatljivosti utvrđene vrijednosti omjera pogodaka korišteno je nekoliko istraživanja (Alsaghier et al., 2009; Moore i Benbasat, 1991; Nahm et al., 2002) u kojima je donja granica vrijednosti ovog kriterija sadržajne valjanosti iznosila 75%. Prema tome, utvrđena vrijednost ukupnog omjera pogodaka se smatra prihvatljivom.

Iz tablice 6.19 je također vidljivo da je vrijednost Congerovog Kappa koeficijenta iznosila $\hat{\kappa}_c = 0{,}8059$. Moore i Benbasat (1991) navode da se vrijednosti Kappa koeficijenta iznad 0,65 smatraju dostatnima. Osim toga, prema skali referentnih vrijednosti za Kappa koeficijent (Altman, 1991; Landis i Koch, 1977), vrijednosti iznad 0,80 odražavaju izvrsno podudaranje među stručnjacima domene. Shodno tome izračunata se vrijednost Congerovog Kappa koeficijenta smatra prihvatljivom.

Tablica 6.19 Rezultati vrjednovanja konstruktne valjanosti i pouzdanosti provedbe metode zatvorenog sortiranja karata

		AKTUALNE LATENTNE VARIJABLE																			
		DTV	DSD	DST	EST	FML	ITR	INT	JDN	KMP	KRS	LAK	LUK	LOJ	MAK	MOM	MKM	MOK	MOP	MPR	MSU
TEORIJSKE LATENTNE VARIJABLE	Djelotvornost (DTV)	**105**									4										
	Dosljednost (DSD)		**80**		1							1				1					
	Dostupnost (DST)			**78**				5								1					
	Estetika (EST)				**75**				1												
	Familijarnost (FML)					**87**															
	Interaktivnost (ITR)						**121**	1											1		3
	Interoperabilnost (INT)							**74**		3	2									1	
	Jedinstvenost (JDN)								**87**												
	Kompatibilnost (KMP)		7					5		**75**											
	Korisnost (KRS)	2									**75**										
	Lakoća korištenja (LAK)	4										**72**			1	4		1			
	Lakoća učenja korištenja (LUK)											**9**	**72**			1					
	Lojalnost (LOJ)													**84**							
	Minimalna aktivnost (MAK)											8			**153**	13					
	Min. opterećenje memorije (MOM)														4	**25**					
	Mogućnost komunikacije (MKM)						2										**51**				5
	Mogućnost kontrole (MOK)											4						**74**		8	
	Mogućnost oporavka (MOP)																		**85**		
	Mogućnost prilagodbe (MPR)										2	3				2		3		**73**	
	Mogućnost suradnje (MSU)			1			3											1			**81**

Tablica 6.19 Rezultati vrjednovanja konstruktne valjanosti i pouzdanosti provedbe metode zatvorenog sortiranja karata (nastavak)

		AKTUALNE LATENTNE VARIJABLE																			
		DTV	DSD	DST	EST	FML	ITR	INT	JDN	KMP	KRS	LAK	LUK	LOJ	MAK	MOM	MKM	MOK	MOP	MPR	MSU
TEORIJSKE LATENTNE VARIJABLE	Pamtljivost (PMT)											7									
	Pouzdanost (PZD)																				
	Povratne informacije (PIN)										1										
	Pristupačnost (PST)											5									
	Raspoloživost i pružanje pomoći (RIP)	1	1									2				1					
	Razigranost (RZG)																				
	Razumljivost (RZM)		3			5						2									
	Sigurnost (SGR)																		1		
	Skalabilnost (SKB)										6										
	Sprječavanje pogrješaka (SPO)						1												11		
	Stav prema ponašanju (STP)													2							
	Sveobuhvatnost konteksta (SVK)	4									3							1		3	
	Učinkovitost (UNK)	2									3										
	Upravljivost (UPR)		2									17			1	3					
	Užitak (UTK)																				
	Vrijeme odaziva (VOD)																				
	Zadovoljstvo (ZDV)																				

Tablica 6.19 Rezultati vrjednovanja konstruktne valjanosti i pouzdanosti provedbe metode zatvorenog sortiranja karata (nastavak)

		AKTUALNE LATENTNE VARIJABLE																		Σ	%
		PMT	PZD	PIN	PST	RIP	RZG	RZM	SGR	SKB	SPO	STP	SVK	UNK	UPR	UTK	VOD	ZDV	OST*		
TEORIJSKE LATENTNE VARIJABLE	Djelotvornost (DTV)												2	2					3	**116**	**91**
	Dosljednost (DSD)	2													2					**87**	**92**
	Dostupnost (DST)		1														1		1	**87**	**90**
	Estetika (EST)															7		4		**87**	**86**
	Familijarnost (FML)																			**87**	**100**
	Interaktivnost (ITR)			1					10		2								6	**145**	**83**
	Interoperabilnost (INT)		2								4		1							**87**	**85**
	Jedinstvenost (JDN)																			**87**	**100**
	Kompatibilnost (KMP)																			**87**	**86**
	Korisnost (KRS)													9					1	**87**	**86**
	Lakoća korištenja (LAK)													4	1					**87**	**83**
	Lakoća učenja korištenja (LUK)	5																		**87**	**83**
	Lojalnost (LOJ)											1						2		**87**	**97**
	Minimalna aktivnost (MAK)																			**174**	**88**
	Min. opterećenje memorije (MOM)																			**29**	**86**
	Mogućnost komunikacije (MKM)																			**58**	**88**
	Mogućnost kontrole (MOK)														1					**87**	**85**
	Mogućnost oporavka (MOP)		1	1																**87**	**98**
	Mogućnost prilagodbe (MPR)																		4	**87**	**84**
	Mogućnost suradnje (MSU)									1										**87**	**93**

* OSTALO

Tablica 6.19 Rezultati vrjednovanja konstruktne valjanosti i pouzdanosti provedbe metode zatvorenog sortiranja karata (nastavak)

		AKTUALNE LATENTNE VARIJABLE																	**Σ**	**%**
		PMT	PZD	PIN	PST	RIP	RZG	RZM	SGR	SKB	SPO	STP	SVK	UNK	UPR	UTK	VOD	ZDV	OST*		
TEORIJSKE LATENTNE VARIJABLE	Pamtljivost (PMT)	**80**																		**87**	**92**
	Pouzdanost (PZD)		**87**																	**87**	**100**
	Povratne informacije (PIN)			**130**		1		7			5						1			**145**	**90**
	Pristupačnost (PST)				**73**	1								6					2	**87**	**84**
	Raspoloživost i pružanje pomoći (RIP)					**133**		3			1				3					**145**	**92**
	Razigranost (RZG)						**77**									9		1		**87**	**89**
	Razumljivost (RZM)	1						**76**												**87**	**87**
	Sigurnost (SGR)								**136**		3								5	**145**	**94**
	Skalabilnost (SKB)									**81**										**87**	**93**
	Sprječavanje pogrješaka (SPO)										**75**									**87**	**86**
	Stav prema ponašanju (STP)											**84**							1	**87**	**97**
	Sveobuhvatnost konteksta (SVK)												**72**						4	**87**	**83**
	Učinkovitost (UNK)													**111**						**116**	**96**
	Upravljivost (UPR)	1						7						3	**111**					**145**	**77**
	Užitak (UTK)						5									**80**		1	1	**87**	**92**
	Vrijeme odaziva (VOD)													16			**71**			**87**	**82**
	Zadovoljstvo (ZDV)															10		**76**	1	**87**	**87**
UKUPNO PRIDRUŽENIH MANIFESTNIH VARIJABLI: 3567				**BROJ POGODAKA: 3180**						**UKUPAN OMJER POGODAKA: 89%**						**CONGEROV KAPPA ($\hat{\kappa}_c$) KOEFICIJENT: 0,8059**					

* OSTALO

Potrebno je također napomenuti da su kao posljedica analize podataka prikupljenih metodom zatvorenog sortiranja karata pojedine latentne varijable spojene dok je određenim latentnim varijablama prema sugestijama stručnjaka domene promijenjen naziv. Latentnim varijablama koje je moguće vrjednovati subjektivnim i objektivnim mjernim instrumentima u naziv je dodana riječ „zamijećeno/zamijećena“ ukoliko su njihove dimenzije vrjednovane česticama upitnika odnosno „izmjereno/izmjerena“ ukoliko su njihovi aspekti mjereni indikatorima. Navedenim su postupkom dobiveni sljedeći atributi: zamijećena djelotvornost, izmjerena djelotvornost, zamijećena učinkovitost, izmjerena učinkovitost, zamijećena skalabilnost i zamijećeno vrijeme odaziva. Nadalje, srodne latentne varijable kojima su kao posljedica vrjednovanja sadržajne valjanosti ostale pridružene dvije ili jedna manifestna varijabla su spojene u latentnu varijablu sa novim nazivom. Tako su čestice namijenjene vrjednovanju latentnih varijabli „minimalno opterećenje memorije“ i „minimalna aktivnost“ spojene u latentnu varijablu „zamijećeno radno opterećenje“, indikatori namijenjeni mjerenju latentne varijable „minimalna aktivnost“ su izdvojeni kao zasebna latentna varijabla pod nazivom „izmjereno radno opterećenje“ dok su čestice latentnih varijabli „mogućnost komunikacije“ i „mogućnost suradnje“ spojene u latentnu varijablu „mogućnost interakcije“. Konačno, latentnim varijablama kojima se naziv nije podudarao sa kontekstom vrjednovanja i/ili pridruženim manifestnim varijablama, isti je promijenjen u cijelosti. Tako je latentna varijabla „interaktivnost“ preimenovana u „upravljanje artefaktima“, „stav prema ponašanju“ u „stav prema korištenju“, a „kompatibilnost“ u „prenosivost“. Uzimajući u obzir sve navedeno broj latentnih varijabli odnosno atributa kvalitete u korištenju Web 2.0 aplikacijama je, kao rezultat provedbe metode zatvorenog sortiranja karata, smanjen sa 46 na 38.

Od konačnog skupa sadržajno valjanih manifestnih varijabli, njih 117 je oblikovano u čestice upitnika namijenjenog vrjednovanju subjektivnih aspekata kvalitete u korištenju Web 2.0 aplikacijama. Preostalih 6 manifestnih varijabli oblikovano je u objektivne metrike namijenjene mjerenju djelotvornosti, radnog opterećenja i učinkovitosti tijekom interakcije sa vrjednovanim Web 2.0 aplikacijama.

6.2 Oblikovanje konceptualnog modela

Uzorak sudionika uključenih u primjenu metode otvorenog sortiranja karata bio je sačinjen isključivo od istraživača u području interakcije čovjeka i računala te web inženjerstva. Tijekom provedbe metode otvorenog sortiranja karata, stručnjaci domene su primjenom aplikacije Card Sorting Editor (Porta, 2005) po vlastitom nahođenju kategorizirali 38 atributa kvalitete u korištenju Web 2.0 aplikacijama.

6.2.1 Karakteristike HCI/WE stručnjaka

Struktura sudionika uključenih u primjenu metode otvorenog sortiranja karata prema demografskim karakteristikama uključujući spol, akademski stupanj, osnovno obrazovanje, zanimanje, državu iz koje dolaze i područje interesa nalaze se u tablicama 6.20 – 6.26, respektivno. Od ukupno 14 HCI/WE istraživača koliko ih je sudjelovalo u otvorenom sortiranju latentnih konstrukata kvalitete u korištenju Web 2.0 aplikacijama, 57,14% ih je bilo ženskog, a 42,86% muškog spola.

Tablica 6.20 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema spolu

Spol	Frekvencija	%
Muški	6	42,86
Ženski	8	57,14
Ukupno	14	100,00

Prosječna starosna dob sudionika otvorenog sortiranja karata iznosi 36,86 godina ($\sigma = 7{,}113$). Najstariji sudionik je imao 50, a najmlađi 25 godina. Najveći broj HCI/WE stručnjaka ima akademski stupanj doktora znanosti ($n = 7$) dok samo jedan sudionik ima akademski stupanj stručnog pristupnika.

Tablica 6.21 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema akademskom stupnju

Akademski stupanj	Frekvencija	%
Stručni pristupnik	1	7,14
Magistar znanosti	6	42,86
Doktor znanosti	7	50,00
Ukupno	14	100,00

Većina HCI/WE stručnjaka ima temeljno obrazovanje iz područja računarstva (85,71%) dok je područje psihologije zastupljeno sa samo 7,14% sudionika. Pola uzorka sudionika u otvorenom sortiranju karata je izabrano u znanstveno-nastavno zvanje, 35,71% ih se nalazi u suradničkom zvanju dok ih 14,29% ne radi u visokoškolskim odnosno znanstvenim institucijama. Najveći broj HCI/WE stručnjaka (28,57%) je izabran u suradničko zvanje asistenta i znanstveno-nastavno zvanje izvanrednog profesora.

Tablica 6.22 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema osnovnom obrazovanju

Znanstvena polja	Frekvencija	%
Informacijske i komunikacijske znanosti	3	21,43
Računarstvo	12	85,71
Dizajn	5	35,71
Psihologija	1	7,14
Inženjerstvo	4	28,57

Tablica 6.23 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema zvanju

Zvanje	Frekvencija	%
Bez znanstveno-nastavnog/suradničkog zvanja	2	14,29
Znanstveni novak	4	28,57
Asistent	1	7,14
Docent	1	7,14
Izvanredni profesor	4	28,57
Redoviti profesor	2	14,29
Ukupno	14	100,00

Svi sudionici otvorenog sortiranja karata se bave istraživačkim radom, pola ih sudjeluje u nastavi, a 14,29% ih djeluje u praksi.

Tablica 6.24 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema zanimanju

Zanimanje	Frekvencija	%
Stručnjak u praksi	2	14,29
Istraživač	14	100,00
Nastavnik	7	50,00

Uzorak HCI/WE stručnjaka je bio sačinjen od pojedinaca iz tri države. Većina ih dolazi iz Španjolske (85,71%) dok ih po 7,14% stanuje u Čileu i Kolumbiji.

Tablica 6.25 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema državi iz koje dolaze

Država	Frekvencija	%
Čile	1	7,14
Kolumbija	1	7,14
Španjolska	12	85,71
Ukupno	14	100,00

Istraživački interes svih sudionika u otvorenom sortiranju karata je usmjeren prema području interkacije čovjeka i računala. Osim toga, 21,43% HCI/WE stručnjaka djeluje interdisciplinarno.

Tablica 6.26 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema području interesa

Područje interesa	Frekvencija	%
Interakcija čovjeka i računala	14	100,00
Web inženjerstvo	3	21,43

U tablici 6.27 se nalazi struktura sudionika u primjeni metode otvorenog sortiranja karata prema trinaest različitih pokazatelja profesionalnog iskustva. U trenutku provedbe metode otvorenog sortiranja karata, HCI/WE stručnjaci su u prosjeku djelovali 7,64 godina ($\sigma = 4{,}448$) u području interakcije čovjeka i računala i prosječno 3,86 godine ($\sigma = 3{,}718$) u području web inženjerstva. Isti su prosječno vrjednovali 17,07 web aplikacija ($\sigma = 24{,}763$) od čega je 21,43% sudionika vrjednovalo manje od pet, a 35,71% više od petnaest web aplikacija. Sudionici otvorenog sortiranja karata su objavili prosječno 15,21 radova u području interakcije čovjeka i računala od čega su 79,36% prezentirali na eminentnim međunarodnim konferencijama dok su preostalih 20,64% radova objavili u znanstvenim časopisima. Od prosječno 3,79 rada koje su HCI/WE istraživači publicirali u području web inženjerstva, 77,31% ih je objavljeno u zbornicima međunarodnih skupova, a 22,69% je tiskano u znanstvenim časopisima. Uz spomenuto, sudionici otvorenog sortiranja karata su objavili u prosjeku 4,93 rada ($\sigma = 4{,}682$) izvan osnovnih područja od interesa.

Uzorak HCI/WE stručnjaka je također aktivno sudjelovao u brojnim organizacijskim i inim aktivnostima vezanim uz međunarodne znanstvene konferencije u interesnom području. Naime, sudionici otvorenog sortiranja karata su napisali prosječno 5,43 recenzija, u prosjeku 0,64 puta vršili dužnost voditelja sekcije ili meta recenzenta te bili prosječno 5,64 puta članom

organizacijskog ili programskog odbora. Konačno, HCI/WE stručnjaci su sudjelovali u prosječno jednom međunarodnom i 4,93 nacionalna znanstvena projekta.

Struktura stručnjaka prema različitim područjima ekspertize u domeni interakcije čovjeka i računala te web inženjerstva prikazana je tablicom 6.28. Značenje razina je identično onome prema kojem su sudionici zatvorenog sortiranja karata procjenjivali svoju stručnost u području (opisano u prethodnom potpoglavlju). Većina sudionika drugog kruga kategorizacija (64,29%) smatra da ima dostatno znanje iz područja Web 2.0 aplikacija i uzoraka dizajna. Pola ih se smatra ekspertom u području vrjednovanja upotrebljivosti dok ih šestero vjeruje da ima najviši stupanj ekspertize u vrjednovanju korisničkog iskustva. Nadalje, 42,86% vrlo dobro poznaje područje vrjednovanja pristupačnosti dok ih jednako toliko ima dostatno znanje iz područja vrjednovanja kvalitete sustava, kvalitete usluge i uloženog napora tijekom upotrebe web aplikacija. Osim toga, 57,14% sudionika u otvorenom sortiranju karata je uvjereno da posjeduje dostatno znanje iz područja vrjednovanja zamijećene i procijenjene kvalitete.

Vezano uz preostala područja ekspertize valja istaknuti da se po 35,71% HCI/WE istraživača smatra ekspertom u području dizajna interakcija i univerzalnog pristupa. Većina sudionika otvorenog sortiranja karata vjeruje da vrlo dobro poznaje područje arhitekture i inženjeringa programskih proizvoda (85,71%), dizajna usmjerenog korisnicima interaktivnih sustava (64,29%), dizajna korisničkog sučelja (64,29%) i uzoraka za razvoj web aplikacija i rudarenje uzoraka (57,14%). Naposljetku, više od pola HCI/WE stručnjaka je mišljenja da posjeduje dostatno znanje iz područja računalom posredovane komunikacije (78,57%), razvoja web aplikacija temeljnog na komponentama (57,14%), mobilnih web aplikacija i isporuke neovisne o uređaju (71,43%), programskih jezika specifične domene namijenjenih razvoju web aplikacija (64,29%), uspjeha web informacijskih sustava (64,29%), vrjednovanja kvalitete servisa (57,14%), servisno orijentiranih arhitektura (57,14%), modeliranja prihvaćanja tehnologije (57,14%), metoda i procesa web inženjerstva (57,14%) te rudarenja Weba i ekstrakcije informacija (57,14%).

Iz svega navedenog je evidentno da uzorak stručnjaka domene posjeduje dostatnu razinu iskustva i ekspertize u domicilnim područjima što ih čini kompetentnima za sudjelovanje u kategorizaciji latentnih i manifestnih varijabli te procjeni težina varijabli performansi koje su sastavni dio stabla zahtjeva kvalitete u korištenju Web 2.0 aplikacijama.

Tablica 6.27 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema profesionalnom iskustvu

Pokazatelji profesionalnog iskustva	$\bar{x}$	σ	**min**	**maks**
Broj godina u HCI području	7,64	4,448	3	20
Broj godina u WE području	3,86	3,718	0	12
Broj vrjednovanih web aplikacija	17,07	24,763	3	100
Broj znanstvenih radova objavljenih u HCI zbornicima skupova	12,07	16,373	1	58
Broj znanstvenih radova objavljenih u WE zbornicima skupova	2,93	5,942	0	21
Broj znanstvenih radova objavljenih u HCI časopisima	3,14	3,231	0	10
Broj znanstvenih radova objavljenih u WE časopisima	0,86	1,657	0	6
Broj znanstvenih radova objavljenih izvan HCI/WE područja	4,93	4,682	0	15
Broj napisanih recenzija za HCI/WE znanstvene skupove	5,43	6,947	0	25
Učestalost vršenja dužnosti kao voditelj sekcije i/ili meta recenzent za HCI/WE znanstvene skupove	0,64	1,008	0	3
Učestalost vršenja dužnosti kao član programskog/organizacijskog odbora za HCI/WE znanstvene skupove	5,64	7,909	0	25
Broj sudjelovanja u nacionalnim znanstvenim projektima	4,93	5,210	0	20
Broj sudjelovanja u međunarodnim znanstvenim projektima	1,00	1,038	0	3

Tablica 6.28 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema području ekspertize

Područje ekspertize	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Vrjednovanje pristupačnosti	4	28,57	6	42,86	4	28,57	0	0,00
Adaptivne, kontekstualizirane i personalizirane web aplikacije	2	14,29	5	35,71	7	50,00	0	0,00
Afektivni, emocionalni i motivacijski aspekti HCI	2	14,29	6	42,86	6	42,86	0	0,00
Računarstvo u oblacima	0	0,00	4	28,57	7	50,00	3	21,43
Kolaborativni razvoj programskih proizvoda	0	0,00	5	35,71	6	42,86	3	21,43
Razvoj web aplikacija temeljen na komponentama	1	7,14	1	7,14	8	57,14	4	28,57
Računalom posredovana komunikacija	0	0,00	0	0,00	11	78,57	3	21,43
Računalom podržan kooperativan rad	0	0,00	3	21,43	9	64,29	2	14,29
Konceptualno modeliranje web aplikacija	2	14,29	3	21,43	6	42,86	3	21,43
Implementacija i analiza upotrebe web aplikacija	3	21,43	7	50,00	4	28,57	0	0,00
Programski jezici specifične domene namijenjeni razvoju web aplikacija	2	14,29	1	7,14	9	64,29	2	14,29
Vrjednovanje uloženog napora tijekom upotrebe web aplikacije	0	0,00	5	35,71	6	42,86	3	21,43
Računalne igre i zabava	1	7,14	3	21,43	6	42,86	4	28,57
Dlanovnici i mobilno računarstvo	1	7,14	4	28,57	7	50,00	2	14,29
Edukacija u HCI/WE području	1	7,14	10	71,43	2	14,29	1	7,14
Ljudski čimbenici i ergonomija	1	7,14	8	57,14	5	35,71	0	0,00
Vrjednovanje kvalitete informacija i sadržaja	3	21,43	8	57,14	3	21,43	0	0,00
Inteligentna korisnička sučelja	1	7,14	5	35,71	5	35,71	3	21,43
Dizajn interakcija	5	35,71	5	35,71	3	21,43	0	0,00
Dizajn i modeliranje temeljeno na međunarodnim (ISO/IEC) standardima	2	14,29	8	57,14	4	28,57	0	0,00
Razvoj i vrjednovanje mashupova / Web programiranje za krajnje korisnike	0	0,00	3	21,43	7	50,00	4	28,57

Tablica 6.28 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema području ekspertize (nastavak)

Područje ekspertize	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Mobilne web aplikacije i isporuka neovisna o uređaju	0	0,00	3	21,43	10	71,43	1	7,14
Dizajn interaktivnih sustava temeljen na modelima	2	14,29	6	42,86	4	28,57	2	14,29
Multidisciplinarni i interdisciplinarni dizajn	2	14,29	7	50,00	4	28,57	1	7,14
Uzorci za razvoj web aplikacija i rudarenje uzoraka	2	14,29	8	57,14	4	28,57	0	0,00
Vrjednovanje zamijećene i procijenjene kvalitete	1	7,14	4	28,57	8	57,14	1	7,14
Modeliranje, praćenje i vrjednovanje performansi	2	14,29	3	21,43	7	50,00	2	14,29
Vrjednovanje privatnosti i sigurnosti	0	0,00	2	14,29	7	50,00	5	35,71
Vrjednovanje kvalitete u korištenju	4	28,57	6	42,86	3	21,43	1	7,14
Vrjednovanje kvalitete servisa (QoS)	0	0,00	5	35,71	8	57,14	1	7,14
Kvantitativne i kvalitativne empirijske metode	0	0,00	6	42,86	7	50,00	1	7,14
Bogate internetske aplikacije	0	0,00	6	42,86	6	42,86	2	14,29
Semantički web servisi	1	7,14	5	35,71	6	42,86	2	14,29
Servisno orijentirane arhitekture	0	0,00	3	21,43	8	57,14	3	21,43
Vrjednovanje kvalitete usluge	1	7,14	3	21,43	6	42,86	4	28,57
Društveno računarstvo	0	0,00	3	21,43	7	50,00	4	28,57
Arhitektura i inženjering programskih proizvoda	0	0,00	12	85,71	2	14,29	0	0,00
Vrjednovanje kvalitete sustava	2	14,29	4	28,57	6	42,86	2	14,29
Modeliranje prihvaćanja tehnologije	0	0,00	1	7,14	8	57,14	5	35,71
Sveprisutno računarstvo / Računarstvo svjesno konteksta	0	0,00	3	21,43	6	42,86	5	35,71
Univerzalni pristup	5	35,71	4	28,57	4	28,57	1	7,14
Vrjednovanje upotrebljivosti	7	50,00	6	42,86	1	7,14	0	0,00

Tablica 6.28 Struktura sudionika (HCI/WE stručnjaka) u otvorenom sortiranju karata prema području ekspertize (nastavak)

Područje ekspertize	Razina 3		Razina 2		Razina 1		Razina 0	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Dizajn usmjeren korisnicima interaktivnih sustava	5	35,71	9	64,29	0	0,00	0	0,00
Dizajn korisničkog sučelja	5	35,71	9	64,29	0	0,00	0	0,00
Vrjednovanje korisničkog iskustva	6	42,86	5	35,71	3	21,43	0	0,00
Modeliranje korisnika	0	0,00	6	42,86	6	42,86	2	14,29
Dizajn i vrjednovanje virtualnih svjetova	0	0,00	4	28,57	7	50,00	3	21,43
Web 2.0 tehnologije i uzorci dizajna	1	7,14	4	28,57	9	64,29	0	0,00
Arhitekture i radna okruženja web aplikacija	1	7,14	5	35,71	5	35,71	3	21,43
Upravljanje sadržajem na Webu i podatkovno intenzivne web aplikacije	1	7,14	4	28,57	6	42,86	3	21,43
Uspjeh web informacijskih sustava	0	0,00	2	14,29	9	64,29	3	21,43
Metode i procesi web inženjerstva	0	0,00	5	35,71	8	57,14	1	7,14
Rudarenje Weba i ekstrakcija informacija	0	0,00	2	14,29	8	57,14	4	28,57
Znanost o Webu i buduće primjene Interneta	1	7,14	3	21,43	6	42,86	4	28,57

6.2.2 Rezultati primjene metode otvorenog sortiranja karata

Analiza podataka prikupljenih primjenom metode otvorenog sortiranja karata provedena je pomoću aplikacije Card Sorting Clustering (prikazana na slici 6.4) koju je razvio Pardell (2006) u sklopu GRIHO[8] (cat. Grup de Recerca en Interacció Persona Ordinador i Integració de Dades) istraživačke grupe Sveučilišta u Lleidi u Španjolskoj.

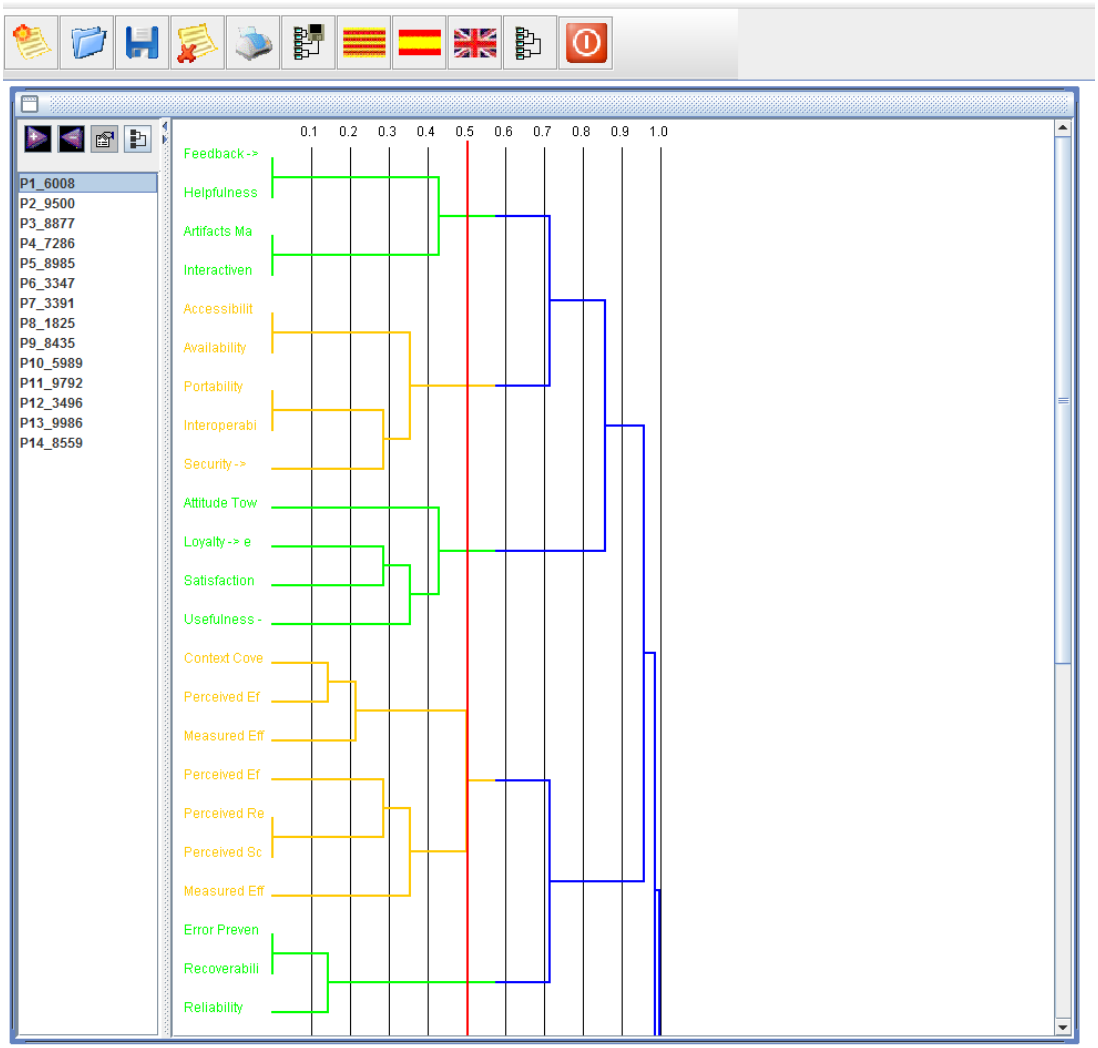

Slika 6.4 Aplikacija za provedbu hijerarhijske klaster analize

Proces analize se sastojao od interpretacije grafičkog prikaza strukture klastera odnosno dendrograma (prikazan na slici 6.5) kojeg je spomenuta aplikacija generirala temeljem Euklidske udaljenosti implementirane u svojstvu mjere sličnosti i metode najbližeg susjeda implementirane u svojstvu algoritma klasterizacije.

[8] http://griho.udl.cat/

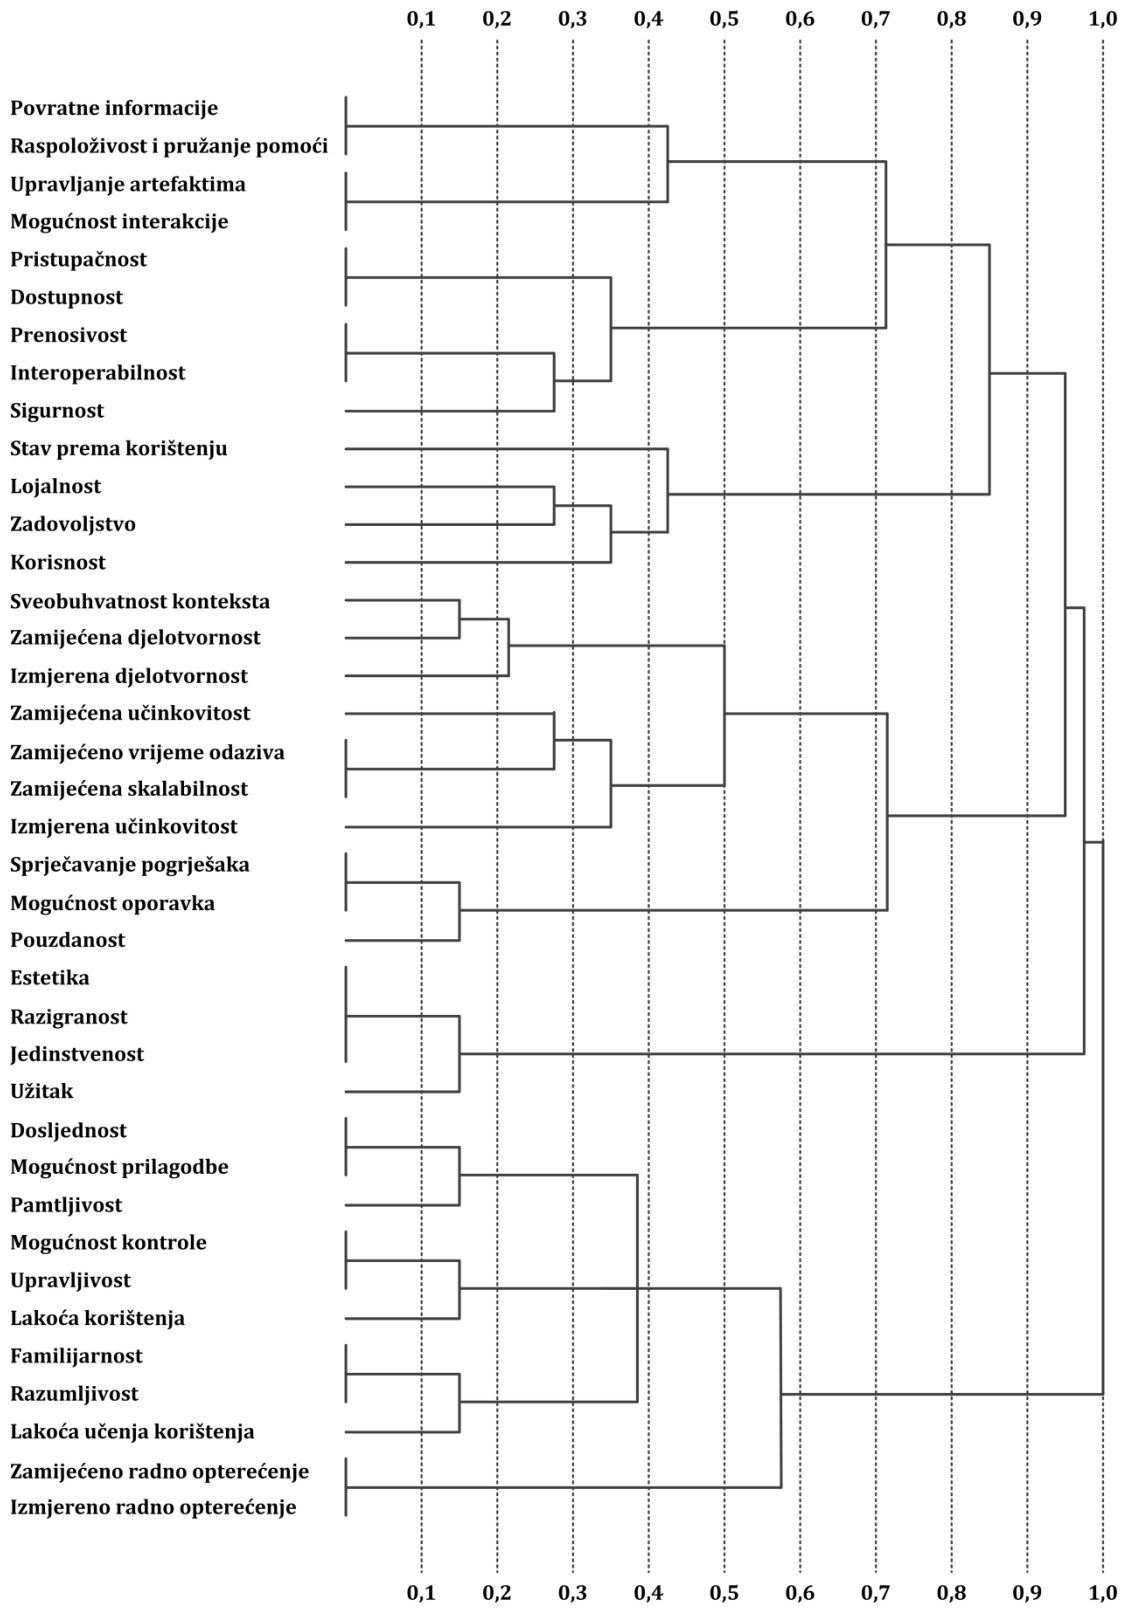

Slika 6.5 Grafički prikaz strukture klastera (dendrogram)

Dendrogram zorno prikazuje da je na udaljenosti 0 svih 14 stručnjaka domene spojilo 23 atributa kvalitete u korištenju u sljedećih 11 klastera: klaster 1 (nastao spajanjem atributa „povratne informacije“ sa atributom „raspoloživost i pružanje pomoći“), klaster 2 (nastao povezivanjem atributa „upravljanje artefaktima“ sa atributom „mogućnost interakcije“), klaster 3 (nastao spajanjem atributa „pristupačnost“ i „dostupnost“), klaster 4 (nastao povezivanjem atributa „prenosivost“ i „interoperabilnost“), klaster 5 (nastao spajanjem atributa „zamijećeno vrijeme odaziva“ sa atributom „zamijećena skalabilnost“), klaster 6 (nastao povezivanjem atributa „sprječavanje pogrješaka“ sa atributom „mogućnost oporavka“), klaster 7 (nastao spajanjem atributa „estetika“, „razigranost“ i „jedinstvenost“), klaster 8 (nastao povezivanjem atributa „dosljednost“ i „mogućnost prilagodbe“), klaster 9 (nastao spajanjem atributa „mogućnost kontrole“ sa atributom „upravljivost“), klaster 10 (nastao povezivanjem atributa „familijarnost“ sa atributom „razumljivost“) i klaster 11 (nastao spajanjem atributa „zamijećeno radno opterećenje“ i „izmjereno radno opterećenje“).

U sljedećoj je iteraciji hijerarhijske analize na udaljenosti 0,15 oblikovano sljedećih 6 klastera: klaster 12 (nastao povezivanjem atributa „sveobuhvatnost konteksta“ sa atributom „zamijećena djelotvornost“), klaster 13 (nastao spajanjem klastera 6 sa atributom „pouzdanost“), klaster 14 (nastao povezivanjem klastera 7 i atributa „užitak“), klaster 15 (nastao spajanjem klastera 8 i atributa „pamtljivost“), klaster 16 (nastao povezivanjem klastera 9 sa atributom „lakoća korištenja“) i klaster 17 (nastao spajanjem klastera 10 sa atributom „lakoća učenja korištenja“). Zatim je na udaljenosti 0,22 oblikovan klaster 18, a nastao je povezivanjem klastera 12 i atributa „izmjerena djelotvornost“. Na udaljenosti 0,27 oblikovana su sljedeća 3 klastera: klaster 19 (nastao spajanjem klastera 4 sa atributom „sigurnost“), klaster 20 (nastao povezivanjem atributa „lojalnost“ sa atributom „zadovoljstvo“) i klaster 21 (nastao spajanjem atributa „zamijećena učinkovitost“ i klastera 5).

Nakon toga su na udaljenosti 0,35 oblikovana sljedeća tri klastera: klaster 22 (nastao povezivanjem klastera 3 sa klasterom 19), klaster 23 (nastao spajanjem klastera 20 sa atributom „korisnost“) i klaster 24 (nastao povezivanjem klastera 21 sa atributom „izmjerena učinkovitost“). Klaster 25 oblikovan je na udaljenosti 0,38 spajanjem klastera 15, klastera 16 i klastera 17. U sljedećem su koraku hijerarhijske klaster analize na udaljenosti 0,43 nastala sljedeća dva klastera: klaster 26 (oblikovan spajanjem klastera 1 sa klasterom 2) i klaster 27 (oblikovan povezivanjem atributa „stav prema korištenju“ sa klasterom 23). Klaster 28 nastao je spajanjem klastera 18 i klastera 24 na udaljenosti 0,5 da bi nakon toga na udaljenosti 0,57 bio oblikovan klaster 29 koji je nastao povezivanjem klastera 25 i klastera 11. Zatim su na udaljenosti 0,72 nastala sljedeća dva klastera: klaster 30 (nastao spajanjem klastera 26 i klastera 22) i klaster 31 (nastao povezivanjem klastera 28 i klastera 13).

Premda je udaljenost 0,72 predstavljala granicu za odabir klastera koji će se upotrebljavati u daljnjim fazama istraživanja, u nastavku će biti spomenuta i preostala 4 klastera kojima je rezultirala hijerarhijska klaster analiza: klaster 32 nastao je na udaljenosti 0,85 spajanjem klastera 30 i klastera 27, klaster 33 oblikovan je na udaljenosti 0,95 spajanjem klastera 32 i klastera 31, klaster 34 nastao je na udaljenosti 0,97 povezivanjem klastera 33 i klastera 14 dok je klaster 35 oblikovan na udaljenosti 1 spajanjem klastera 34 i klastera 29.

6.2.3 Sadržajna valjanost latentnih varijabli

Uzorak stručnjaka domene koji je bio uključen u primjenu metode zatvorenog sortiranja karata, sudjelovao je i u vrjednovanju sadržajne valjanosti latentnih varijabli. Procedura je bila identična onoj koja je provedena za vrjednovanje sadržajne valjanosti manifestnih varijabli što znači da se također sastojala od izračuna vrijednosti pokazatelja sadržajne valjanosti (CVR) i prosječne vrijednosti relativne važnosti ($\bar{x}$). Utvrđene vrijednosti spomenuta dva kriterija u kontekstu vrjednovanja sadržajne valjanosti latentnih varijabli nalaze se u tablici 6.29.

Tablica 6.29 Vrijednosti pokazatelja sadržajne valjanosti za konačan skup latentnih varijabli

Konačan skup latentnih varijabli	**Kratica**	**CVR**	$\bar{x}$
Dohvatljivost	DHV	1,00	1,41
Dosljednost	DSD	0,86	1,28
Dostupnost	DST	0,86	1,10
Estetika	EST	0,93	1,79
Familijarnost	FML	1,00	1,79
Funkcionalna prikladnost	FUP	1,00	1,62
Interoperabilnost	INT	1,00	1,62
Izmjerena djelotvornost	IZD	1,00	1,17
Izmjerena učinkovitost	IZU	1,00	1,24
Izmjereno radno opterećenje	IRO	0,81	1,81
Jedinstvenost	JDN	1,00	1,66
Korisnost	KRS	1,00	1,34
Kvaliteta sustava	KVS	1,00	1,24
Kvaliteta usluge	KVU	1,00	1,10
Lakoća korištenja	LAK	0,93	1,00
Lakoća učenja korištenja	LUK	1,00	1,21
Lojalnost	LOJ	1,00	1,38

Tablica 6.29 Vrijednosti pokazatelja sadržajne valjanosti za konačan skup latentnih varijabli (nastavak)

Konačan skup latentnih varijabli	**Kratica**	**CVR**	$\bar{x}$
Mogućnost interakcije	MIN	1,00	1,45
Mogućnost kontrole	MOK	1,00	1,10
Mogućnost oporavka	MOP	0,72	1,45
Mogućnost prilagodbe	MPR	1,00	1,66
Napor	NPR	1,00	1,45
Operabilnost	OPR	1,00	1,07
Otvorenost	OTV	1,00	1,31
Pamtljivost	PMT	1,00	1,31
Podrška korisnicima	POK	1,00	1,14
Pouzdanost	PZD	0,93	1,28
Povratne informacije	PIN	0,79	1,45
Prenosivost	PNS	0,72	1,52
Pristupačnost	PST	0,79	1,41
Produktivnost	PDK	1,00	1,07
Radni učinak	RAU	1,00	1,24
Raspoloživost i pružanje pomoći	RIP	1,00	1,45
Razigranost	RZG	1,00	1,69
Razumljivost	RZM	0,93	1,48
Sigurnost	SGR	1,00	1,24
Sprječavanje pogrješaka	SPO	0,93	1,28
Stav prema korištenju	SPK	0,59	1,41
Sveobuhvatnost konteksta	SVK	1,00	1,55
Upravljanje artefaktima	UPA	1,00	1,66
Upravljivost	UPR	0,93	1,28
Užitak	UTK	0,66	1,76
Zadovoljstvo	ZDV	0,93	1,28
Zamijećena djelotvornost	ZAD	1,00	1,14
Zamijećena skalabilnost	ZAS	0,93	1,72
Zamijećena učinkovitost	ZAU	1,00	1,14
Zamijećeno radno opterećenje	ZRO	1,00	1,79
Zamijećeno vrijeme odaziva	ZVO	1,00	1,21

Iz tablice 6.29 je evidentno da sve izračunate vrijednosti udovoljavaju referentnim vrijednostima pokazatelja sadržajne valjanosti (CVR $\geq$ 0,33; $\bar{x} < 2{,}00$). Svakako je potrebno istaknuti da je za 31 latentnu varijablu utvrđena maksimalna vrijednost pokazatelja sadržajne valjanosti

(CVR = 1,00) što znači da ih svi stručnjaci domene smatraju relevantnima (obaveznima ili poželjnima) za vrjednovanje kvalitete u korištenju Web 2.0 aplikacijama. Najmanja vrijednost pokazatelja sadržajne valjanosti (CVR = 0,59) utvrđena je za latentnu varijablu „stav prema korištenju“. Premda je riječ o latentnoj varijabli koju 48,28% stručnjaka domene smatra obaveznom, istu je 20,69% stručnjaka domene okarakteriziralo kao irelevantnu u kontekstu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama. Sa aspekta prosječne vrijednosti relativne važnosti, većina stručnjaka domene smatra latentnu varijablu „lakoća korištenja“ najviše važnom ($\bar{x} = 1{,}00$), a latentnu varijablu „izmjereno radno opterećenje“ najmanje važnom ($\bar{x} = 1{,}81$) za vrjednovanje kvalitete u korištenju Web 2.0 aplikacijama. Uzimajući u obzir sve navedeno moguće je zaključiti da je konačan skup latentnih varijabli sadržajno valjan.

* * *

Sukus provedbe obje iteracije metode sortiranja karata prikazan je tablicom 6.30. Od ukupno 48 latentnih varijabli većinu ih je (68,75%), prema mišljenju 29 stručnjaka domene, potrebno obavezno vrjednovati. Premda su manifestne varijable pridružene istom temeljnom latentnom konstruktu sa aspekta relevantnosti uglavnom homogene, nekoliko je latentnih konstrukata mjereno kombinacijom obaveznih i poželjnih manifestnih varijabli. Primjerice, latentnim varijablama „dosljednost“, „mogućnost kontrole“, „prenosivost“ i „pristupačnost“ su pridružene dvije obavezne i jedna poželjna manifestna varijabla, dok je u slučaju latentne varijable „interoperabilnost“ situacija obrnuta odnosno pridružena joj je jedna obavezna i dvije poželjne manifestne varijable. Osim toga, latentna varijabla „povratne informacije“ se mjeri sa četiri obavezne i jednom poželjnom manifestnom varijablom dok se latentne varijable „raspoloživost i pružanje pomoći“ i „sigurnost“ vrjednuju sa tri obavezne i dvije poželjne manifestne varijable.

Iz rezultata hijerarhijske klaster analize je evidentno da će konceptualni model vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama jednim svojim dijelom biti sačinjen od višedimenzionalnih latentnih varijabli čije će metrijske karakteristike biti analizirane kombinacijom hibridnih tehnika koje su predložili Ringle et al. (2012) te Ciavolino i Nitti (2013). Prema tome, latentne varijable treće razine će biti mjerene latentnim varijablama druge razine dok će latentne varijable druge razine biti vrjednovane latentnim varijablama prve razine. Zbog navedenog razloga latentnim varijablama druge i treće razine u tablici 6.30 nisu pridruživane manifestne varijable.

Tablica 6.30 Konačan skup manifestnih i latentnih varijabli sa naznakom njihove relevantnosti

KONAČAN SKUP MANIFESTNIH I LATENTNIH VARIJABLI	RELEVANTNOST
DOHVATLJIVOST (eng. REACHABILITY)*	obavezno
DOSLJEDNOST (eng. CONSISTENCY)	obavezno
DSD2. Funkcionalnosti sučelja su jednako razmještene u svim dijelovima Web 2.0 aplikacije.	poželjno
DSD3. Dizajn sučelja je jednak u svim dijelovima Web 2.0 aplikacije.	obavezno
DSD4. Način i mjesto prikazivanja poruka i informiranja korisnika su jednaki u svim dijelovima Web 2.0 aplikacije.	obavezno
DOSTUPNOST (eng. AVAILABILITY)	obavezno
DST1. Web 2.0 aplikacija je dostupna svaki put kada je korisniku to potrebno.	obavezno
DST4. Web 2.0 aplikaciju je jednostavno pronaći preko web tražilice.	obavezno
DST5. Web 2.0 aplikacija omogućava prijavu sa postojećim (npr. Google, Facebook, Yahoo, ili OpenID) korisničkim računom.	poželjno
ESTETIKA (eng. AESTHETICS)	poželjno
EST2. Boje koje prevladavaju na sučelju Web 2.0 aplikacije su prikladno usklađene.	poželjno
EST4. Web 2.0 aplikacija ima atraktivno sučelje.	poželjno
EST5. Web 2.0 aplikacija lijepo izgleda.	poželjno
FAMILIJARNOST (eng. FAMILIARITY)	poželjno
FML1. Raspored elemenata na korisničkom sučelju Web 2.0 aplikacije je sličan rasporedu u aplikacijama kojima se redovito koristim.	poželjno
FML3. Web 2.0 aplikacija upotrebljava jednake nazive za funkcionalnosti sučelja kao i aplikacije kojima se inače koristim.	poželjno
FML4. Web 2.0 aplikacija upotrebljava slične ikone za pokretanje pojedinih funkcionalnosti kao i aplikacije kojima se svakodnevno koristim.	poželjno
FUNKCIONALNA PRIKLADNOST (eng. FUNCTIONAL SUITABILITY)*	poželjno
INTEROPERABILNOST (eng. INTEROPERABILITY)	poželjno
INT1. Prilikom prenošenja artefakta (preuzimanje i umetanje) između Web 2.0 aplikacije i aplikacija kojima se svakodnevno koristim, ne dolazi do promjena u strukturi artefakta.	poželjno
INT2. Prilikom prenošenja artefakta (kopiranje i lijepljenje) između Web 2.0 aplikacije i aplikacija kojima se svakodnevno koristim, ne dolazi do promjena u strukturi artefakta.	poželjno
INT3. Artefakte koji nastanu upotrebom Web 2.0 aplikacije moguće je pohraniti u formatima datoteka koji su mi potrebni.	obavezno
IZMJERENA DJELOTVORNOST (eng. MEASURED EFFECTIVENESS)	obavezno
IZD1. Postotak dovršenosti predefiniranih koraka scenarija interakcije sa Web 2.0 aplikacijom.	obavezno
IZMJERENO RADNO OPTEREĆENJE (eng. MEASURED WORKLOAD)	poželjno
IRO1. Broj pritisnutih tipaka na tipkovnici.	poželjno
IRO2. Udaljenost prijeđena pomicanjem miša.	poželjno
IRO3. Broj klikova mišem.	poželjno
IRO4. Broj pomicanja klizača na mišu.	poželjno

* latentne varijable druge razine

Tablica 6.30 Konačan skup manifestnih i latentnih varijabli sa naznakom njihove relevantnosti (nastavak)

KONAČAN SKUP MANIFESTNIH I LATENTNIH VARIJABLI	RELEVANTNOST
IZMJERENA UČINKOVITOST (eng. MEASURED EFFICIENCY)	obavezno
IZU1. Količina vremena potrebna za dovršetak predefiniranih koraka scenarija interakcije sa Web 2.0 aplikacijom.	obavezno
JEDINSTVENOST (eng. UNIQUENESS)	poželjno
JDN1. Web 2.0 aplikacija ima ono nešto po čemu se razlikuje od drugih aplikacija.	poželjno
JDN2. Web 2.0 aplikacija je jedinstvena.	poželjno
JDN3. Web 2.0 aplikacija se ističe u skupini aplikacija sa istom namjenom.	poželjno
KORISNOST (eng. USEFULNESS)	obavezno
KRS2. Upotrebom Web 2.0 aplikacije povećavaju se performanse korisnika u izvršavanju zadataka.	obavezno
KRS3. Web 2.0 aplikacija je korisna za izvršavanje zadataka.	obavezno
KRS4. Web 2.0 aplikacija je prikladna za izvršavanje zadataka.	obavezno
KVALITETA SUSTAVA (eng. SYSTEM QUALITY)**	obavezno
KVALITETA USLUGE (eng. SERVICE QUALITY)**	obavezno
LAKOĆA KORIŠTENJA (eng. EASE OF USE)	obavezno
LAK1. Lako je izvršavati zadatke pomoću Web 2.0 aplikacije.	obavezno
LAK2. Web 2.0 aplikacija je jednostavna za upotrebu.	obavezno
LAK3. Jednostavno je raditi sa Web 2.0 aplikacijom.	obavezno
LAKOĆA UČENJA KORIŠTENJA (eng. LEARNABILITY)	obavezno
LUK1. Jednostavno je postati vješt/a u korištenju Web 2.0 aplikacijom.	obavezno
LUK2. Lako je naučiti izvršavati zadatke pomoću Web 2.0 aplikacije.	obavezno
LUK3. Funkcionalnosti sučelja Web 2.0 aplikacije moguće je brzo naučiti upotrebljavati.	obavezno
LOJALNOST (eng. LOYALTY)	obavezno
LOJ1. Web 2.0 aplikaciju namjeravam nastaviti upotrebljavati.	obavezno
LOJ2. Svakome bih preporučio/preporučila ovu Web 2.0 aplikaciju.	obavezno
LOJ3. Web 2.0 aplikaciju ubuduće planiram često upotrebljavati.	obavezno

** latentne varijable treće razine

Tablica 6.30 Konačan skup manifestnih i latentnih varijabli sa naznakom njihove relevantnosti (nastavak)

KONAČAN SKUP MANIFESTNIH I LATENTNIH VARIJABLI	RELEVANTNOST
MOGUĆNOST INTERAKCIJE (eng. INTERACTIVENESS)	poželjno
MIN1. Web 2.0 aplikacija sadrži funkcionalnost dodjele pristupa kreiranom artefaktu preko liste kontakata.	poželjno
MIN2. Web 2.0 aplikacija sadrži funkcionalnost dodjele pristupa kreiranom artefaktu preko direktne poveznice.	poželjno
MIN5. Web 2.0 aplikacija podržava rad većeg broja korisnika na izradi artefakta.	poželjno
MIN7. Web 2.0 aplikacija sadrži funkcionalnost sinkrone komunikacije sa ostalim korisnicima.	poželjno
MIN8. Web 2.0 aplikacija sadrži funkcionalnost asinkrone komunikacije sa ostalim korisnicima.	poželjno
MOGUĆNOST KONTROLE (eng. CONTROLLABILITY)	obavezno
MOK1. Jednostavno je postići da Web 2.0 aplikacija radi što korisnik želi.	obavezno
MOK2. Redoslijed upotrebe funkcionalnosti sučelja Web 2.0 aplikacije u potpunosti ovisi o korisniku.	poželjno
MOK3. Korisnik ima potpunu slobodu u izvršavanju zadataka pomoću Web 2.0 aplikacije.	obavezno
MOGUĆNOST OPORAVKA (eng. RECOVERABILITY)	obavezno
MOP1. Ukoliko tijekom korištenja Web 2.0 aplikacijom dođe do pogrješke ili prekida u radu, nakon ponovnog učitavanja, ista će prikazati oporavljenu verziju artefakta.	obavezno
MOP2. Ukoliko tijekom izvršavanja zadataka dođe do pogrješke ili prekida u radu Web 2.0 aplikacije, ne izgubi se sav posao koji se do tada napravio.	obavezno
MOP4. Web 2.0 aplikacija se može brzo oporaviti od pogrješke ili prekida u radu.	obavezno
MOGUĆNOST PRILAGODBE (eng. CUSTOMIZABILITY)	poželjno
MPR1. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe radnog prostora.	poželjno
MPR2. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe jezika prikaza.	poželjno
MPR3. Web 2.0 aplikacija sadrži funkcionalnost prilagodbe prikaza formata datuma i vremena.	poželjno
NAPOR (eng. EFFORT)**	obavezno
OPERABILNOST (eng. OPERABILITY)*	obavezno
OTVORENOST (eng. OPENNESS)*	obavezno
PAMTLJIVOST (eng. MEMORABILITY)	obavezno
PMT1. Jednostavno je zapamtiti kako se upotrebljava Web 2.0 aplikacija.	obavezno
PMT2. Lako je zapamtiti gdje se nalaze pojedine funkcionalnosti sučelja Web 2.0 aplikacije.	obavezno
PMT3. Biti će jednostavno prisjetiti se gdje se nalaze i kako se upotrebljavaju funkcionalnosti sučelja, čak i ako se Web 2.0 aplikacija ne bude dulje vrijeme upotrebljavala.	obavezno
PODRŠKA KORISNICIMA (eng. USERS' SUPPORT)*	obavezno

* latentne varijable druge razine
** latentna varijabla treće razine

Tablica 6.30 Konačan skup manifestnih i latentnih varijabli sa naznakom njihove relevantnosti (nastavak)

KONAČAN SKUP MANIFESTNIH I LATENTNIH VARIJABLI	RELEVANTNOST
POUZDANOST (eng. RELIABILITY)	obavezno
PZD3. Web 2.0 aplikacija je pouzdana.	obavezno
PZD4. Web 2.0 aplikacija je stabilna.	obavezno
PZD5. Web 2.0 aplikacija nema softverskih pogrješaka (bugova).	obavezno
POVRATNE INFORMACIJE (eng. FEEDBACK)	obavezno
PIN1. Web 2.0 aplikacija obavještava korisnika kada će pojedina aktivnost biti izvršena.	obavezno
PIN2. Nakon provedbe određene aktivnosti nad artefaktom (npr. pohrana), Web 2.0 aplikacija prikazuje prikladnu povratnu poruku.	obavezno
PIN3. Poruke koje prikazuje Web 2.0 aplikacija su jasne.	obavezno
PIN4. Poruke koje prikazuje Web 2.0 aplikacija su precizne.	poželjno
PIN6. Ukoliko tijekom izvršavanja zadataka dođe do pogrješke ili prekida u radu, Web 2.0 aplikacija o tome pravovremeno obavještava korisnika.	obavezno
PRODUKTIVNOST (eng. PRODUCTIVITY)*	obavezno
PRENOSIVOST (eng. PORTABILITY)	obavezno
PNS1. Način korištenja Web 2.0 aplikacijom se ne razlikuje među web preglednicima.	obavezno
PNS2. Dostupnost elemenata sučelja Web 2.0 aplikacije se ne razlikuje među web preglednicima.	obavezno
PNS3. Način korištenja Web 2.0 aplikacijom te dostupnost elemenata njena sučelja se ne razlikuje među uređajima koje je moguće spojiti na Internet.	poželjno
PRISTUPAČNOST (eng. ACCESSIBILITY)	obavezno
PST1. Web 2.0 aplikacija sadrži popis tipkovničkih kratica za pokretanje često korištenih elemenata sučelja.	poželjno
PST4. Tekst koji opisuje funkcionalnost pojedinih elemenata sučelja Web 2.0 aplikacije je dovoljno velik za čitanje.	obavezno
PST6. Objekti koji se nalaze na sučelju Web 2.0 aplikacije su dovoljno veliki.	obavezno
RADNI UČINAK (eng. PERFORMANCE)*	obavezno
RASPOLOŽIVOST I PRUŽANJE POMOĆI (eng. HELPFULNESS)	obavezno
RIP1. Web 2.0 aplikacija sadrži različite oblike pomoći korisnicima.	poželjno
RIP3. Različiti oblici pomoći korisnicima su dostupni sa bilo kojeg dijela Web 2.0 aplikacije.	poželjno
RIP5. Sadržaji online pomoći Web 2.0 aplikacije su jasni.	obavezno
RIP6. U sadržajima online pomoći moguće je jednostavno i brzo pronaći kako se upotrebljava pojedina funkcionalnost Web 2.0 aplikacije.	obavezno
RIP7. Sadržaji online pomoći Web 2.0 aplikacije su pregledni.	obavezno

* latentne varijable druge razine

Tablica 6.30 Konačan skup manifestnih i latentnih varijabli sa naznakom njihove relevantnosti (nastavak)

KONAČAN SKUP MANIFESTNIH I LATENTNIH VARIJABLI	RELEVANTNOST
RAZIGRANOST (eng. PLAYFULNESS)	poželjno
RZG1. Korištenje Web 2.0 aplikacijom uspješno zadržava moju pažnju dulje vrijeme.	poželjno
RZG5. Korištenje Web 2.0 aplikacijom potiče moju kreativnost.	poželjno
RZG6. Korištenje Web 2.0 aplikacijom potiče moju stvaralačku maštu.	poželjno
RAZUMLJIVOST (eng. UNDERSTANDABILITY)	obavezno
RZM2. Funkcionalnost elemenata sučelja Web 2.0 aplikacije je razumljiva.	obavezno
RZM3. Izgled ikona koje se nalaze na sučelju Web 2.0 aplikacije je usklađen sa njihovom namjenom.	obavezno
RZM4. Naziv funkcionalnih elemenata sučelja Web 2.0 aplikacije odgovara kontekstu njihove upotrebe.	obavezno
SIGURNOST (eng. SECURITY)	obavezno
SGR3. Tijekom popunjavanja obrasca za registraciju novog korisnika potrebno je unijeti CAPTCHA znakove.	poželjno
SGR4. Tijekom izrade korisničkog računa potrebno je definirati sigurnosno pitanje i odgovor.	poželjno
SGR5. Tijekom izrade korisničkog računa, potrebno je potvrditi prethodno unesenu lozinku.	obavezno
SGR6. Tijekom izrade korisničkog računa, potrebno je unijeti lozinku koja sadrži minimalan broj znakova.	obavezno
SGR10. Artefakti koji nastanu upotrebom Web 2.0 aplikacije su zaštićeni od neautoriziranih korisnika.	obavezno
SPRJEČAVANJE POGRJEŠAKA (eng. ERROR PREVENTION)	obavezno
SPO1. Ukoliko tijekom izvršavanja zadataka korisnik napravi pogrješku, istu je moguće brzo i jednostavno ispraviti.	obavezno
SPO3. Web 2.0 aplikacija omogućuje korisniku da poništi i ponovi promjene na artefaktu.	obavezno
SPO4. Prije provedbe bilo kakve destruktivne operacije, Web 2.0 aplikacija traži potvrdu od korisnika.	obavezno
STAV PREMA KORIŠTENJU (eng. ATTITUDE TOWARDS USE)	obavezno
SPK1. Korištenje Web 2.0 aplikacijom je dobra ideja.	obavezno
SPK2. Korištenje Web 2.0 aplikacijom je mudra ideja.	obavezno
SPK3. Sviđa mi se ideja o korištenju Web 2.0 aplikacijom.	obavezno
SVEOBUHVATNOST KONTEKSTA (eng. CONTEXT COVERAGE)	poželjno
SVK1. Web 2.0 aplikacija omogućava izradu raznovrsnih artefakata.	poželjno
SVK2. Web 2.0 aplikaciju je moguće upotrebljavati i izvan konteksta za koji je originalno namijenjena.	poželjno
SVK3. Web 2.0 aplikacija ima široku mogućnost primjene.	poželjno

Tablica 6.30 Konačan skup manifestnih i latentnih varijabli sa naznakom njihove relevantnosti (nastavak)

KONAČAN SKUP MANIFESTNIH I LATENTNIH VARIJABLI	RELEVANTNOST
UPRAVLJANJE ARTEFAKTIMA (eng. ARTIFACTS MANAGEMENT)	poželjno
UPA2. Web 2.0 aplikacija sadrži funkcionalnost za dodjelu razina vidljivosti kreiranom artefaktu.	poželjno
UPA3. Web 2.0 aplikacija sadrži funkcionalnost za dodjeljivanje dozvola nad kreiranim artefaktom.	poželjno
UPA4. Web 2.0 aplikacija sadrži funkcionalnost označavanja kreiranih artefakata pomoću ključnih riječi (tagova).	poželjno
UPA5. Web 2.0 aplikacija sadrži funkcionalnost automatske pohrane artefakata (autosave).	poželjno
UPA7. Web 2.0 aplikacija sadrži funkcionalnost slanja obavijesti o promjenama nad artefaktom (RSS kanal, e-mail, poruka na društvenoj mreži).	poželjno
UPRAVLJIVOST (eng. NAVIGABILITY)	obavezno
UPR1. Web 2.0 aplikacija sadrži različite navigacijske mehanizme (npr. tražilica, izbornik i sl.).	obavezno
UPR3. Korisnik može brzo i jednostavno pronaći funkcionalnosti sučelja Web 2.0 aplikacije koje su mu potrebne za izvršavanje zadataka.	obavezno
UPR4. Elementi sučelja Web 2.0 aplikacije su tako raspoređeni da se oni koji imaju srodnu funkcionalnost nalaze jedni pored drugih.	obavezno
UPR5. Broj elemenata u izborniku i podizbornicima je optimalan.	obavezno
UPR6. Elementi sučelja Web 2.0 aplikacije su intuitivni za upotrebu.	obavezno
UŽITAK (eng. PLEASURE)	poželjno
UTK2. Korištenje Web 2.0 aplikacijom je zanimljivo.	poželjno
UTK4. Ugodno je upotrebljavati Web 2.0 aplikaciju.	poželjno
UTK5. Sviđa mi se način izvršavanja zadataka pomoću funkcionalnosti sučelja Web 2.0 aplikacije.	poželjno
ZADOVOLJSTVO (eng. SATISFACTION)	obavezno
ZDV1. Web 2.0 aplikacija je ispunila moja očekivanja.	obavezno
ZDV2. Zadovoljan/zadovoljna sam korištenjem Web 2.0 aplikacijom.	obavezno
ZDV4. Web 2.0 aplikacija me se dojmila.	obavezno
ZAMIJEĆENA DJELOTVORNOST (eng. PERCEIVED EFFECTIVENESS)	obavezno
ZAD2. Upotrebom Web 2.0 aplikacije povećava se djelotvornost korisnika u izvršavanju zadataka.	obavezno
ZAD3. Upotrebom Web 2.0 aplikacije, zadatke je moguće izvršiti točno i u potpunosti.	obavezno
ZAD4. Sučelje Web 2.0 aplikacije sadrži sve funkcionalnosti potrebne za izvršavanje zadataka.	obavezno
ZAMIJEĆENA SKALABILNOST (eng. PERCEIVED SCALABILITY)	poželjno
ZAS1. Web 2.0 aplikacija omogućava pohranu velike količine artefakata.	poželjno
ZAS3. Web 2.0 aplikacija omogućava istovremeni rad na većem broju zadataka.	poželjno
ZAS4. Web 2.0 aplikacija omogućava izvršavanje složenih zadataka.	poželjno

Tablica 6.30 Konačan skup manifestnih i latentnih varijabli sa naznakom njihove relevantnosti (nastavak)

KONAČAN SKUP MANIFESTNIH I LATENTNIH VARIJABLI	RELEVANTNOST
ZAMIJEĆENA UČINKOVITOST (eng. PERCEIVED EFFICIENCY)	obavezno
ZAU1. Upotrebom Web 2.0 aplikacije, zadatke je moguće brzo izvršiti.	obavezno
ZAU3. Upotrebom Web 2.0 aplikacije povećava se učinkovitost u izvršavanju zadataka.	obavezno
ZAU4. Izvršavanjem zadataka pomoću Web 2.0 aplikacije, dobiva se na uštedi vremena.	obavezno
ZAMIJEĆENO RADNO OPTEREĆENJE (eng. PERCEIVED WORKLOAD)	poželjno
ZRO1. Korisnik se nakon korištenja Web 2.0 aplikacijom ne osjeća iscrpljeno.	poželjno
ZRO2. Nakon korištenja Web 2.0 aplikacijom, korisnik ne osjeća umor u očima.	poželjno
ZRO3. Nakon izvršavanja zadataka pomoću Web 2.0 aplikacije, korisnik ne osjeća umor u prstima, zglobovima i mišićima ruku.	poželjno
ZAMIJEĆENO VRIJEME ODAZIVA (eng. PERCEIVED RESPONSE TIME)	obavezno
ZVO2. Radni prostor Web 2.0 aplikacije i elementi sučelja se brzo učitavaju u web pregledniku.	obavezno
ZVO3. Nije potrebno dugo čekati da se pokrenu i izvrše odabrane funkcionalnosti sučelja Web 2.0 aplikacije.	obavezno
ZVO4. Vrijeme odaziva Web 2.0 aplikacije je prihvatljivo.	obavezno

6.2.4 Modeliranje

Struktura klastera opisana u potpoglavlju 6.2.2 korištena je kao uporište za oblikovanje sljedećih 7 latentnih varijabli druge razine: podrška korisnicima (klaster 1), funkcionalna prikladnost (klaster 2), dohvatljivost (klaster 3), otvorenost (klaster 4), radni učinak (klaster 5), operabilnost (klaster 25) i produktivnost (klaster 28). Osim toga, temeljem spomenute strukture klastera kreirane su i sljedeće tri latentne varijable treće razine: kvaliteta usluge (klaster 22), kvaliteta sustava (klaster 26) i napor (klaster 29). Preostali klasteri su zajedno sa pregledom literature poslužili kao ishodište za oblikovanje konceptualnog modela vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama i uspostavu teorijskih veza između latentnih konstrukata od kojih je isti sačinjen.

Od ukupno 48 latentnih varijabli, 38 ih se nalazi na prvoj, 7 na drugoj i 3 na trećoj razini višedimenzionalnog konceptualnog modela. Uzimajući u obzir pravila konceptualizacije vanjskog modela koja se nalaze u tablici 10.3, 19 latentnih varijabli prve razine (dosljednost, estetika, familijarnost, jedinstvenost, korisnost, lakoća korištenja, lakoća učenja korištenja, lojalnost, mogućnost kontrole, pamtljivost, pouzdanost, razigranost, razumljivost, stav prema korištenju, užitak, zadovoljstvo, zamijećena djelotvornost, zamijećena učinkovitost i zamijećeno radno opterećenje) je operacionalizirano reflektivno dok je preostalih 19 latentnih varijabli prve razine (dostupnost, interoperabilnost, izmjerena djelotvornost, izmjereno radno opterećenje, izmjerena učinkovitost, mogućnost interakcije, mogućnost oporavka, mogućnost prilagodbe, povratne informacije, prenosivost, pristupačnost, raspoloživost i pružanje pomoći, sigurnost, sprječavanje pogrješaka, sveobuhvatnost konteksta, upravljanje artefaktima, upravljivost, zamijećena skalabilnost i zamijećeno vrijeme odaziva) operacionalizirano formativno. Nadalje, od sedam latentnih varijabli druge razine, samo dvije (operabilnost i produktivnost) su operacionalizirane reflektivno dok ih je pet (dohvatljivost, funkcionalna prikladnost, otvorenost, podrška korisnicima i radni učinak) operacionalizirano formativno. Konačno, od tri latentne varijable treće razine, jedna (napor) je operacionalizirana reflektivno dok su dvije (kvaliteta sustava i kvaliteta usluge) operacionalizirane formativno.

U nastavku će biti navedene definicije svih 48 latentnih konstrukata koji se nalaze u konceptualnom modelu. Pored toga, na osnovi teorijskog okvira koji je predstavljen u trećem poglavlju i rezultata hijerarhijske klaster analize koji su interpretirani u potpoglavlju 6.2.2 biti će specificirano 25 pothipoteza kojima se pretpostavljaju odnosi između latentnih konstrukata. Obzirom da su pothipoteze nastale dekompozicijom prve hipoteze, njima se ujedno vrjednuju i metrijske karakteristike unutarnjeg modela.

Dohvatljivost je formativni konstrukt druge razine kojim se vrjednuju dostupnost i pristupačnost Web 2.0 aplikacije.

Dosljednost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri jednaka struktura elemenata sučelja, jednak dizajn i jednaka terminologija prevladavaju u svim dijelovima Web 2.0 aplikacije.

$H_{1.1}$ Dosljednost Web 2.0 aplikacije ima pozitivan utjecaj na pamtljivost Web 2.0 aplikacije.

Dostupnost je formativni konstrukt prve razine kojim se utvrđuje u kolikoj su mjeri elementi sučelja Web 2.0 aplikacije neprestano dostupni korisnicima.

Estetika je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri dizajn sučelja Web 2.0 aplikacije korisnicima vizualno privlačan.

$H_{1.2}$ Estetika Web 2.0 aplikacije ima pozitivan utjecaj na užitak kojeg pruža korištenje Web 2.0 aplikacijom.

Familijarnost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj su mjeri elementi sučelja Web 2.0 aplikacije slični istima u aplikacijama koje su korisnici ranije upotrebljavali.

$H_{1.3}$ Familijarnost Web 2.0 aplikacije ima pozitivan utjecaj na lakoću učenja korištenja Web 2.0 aplikacijom.

Funkcionalna prikladnost je formativni konstrukt druge razine kojim se utvrđuje u kolikoj mjeri Web 2.0 aplikacija raspolaže sa funkcionalnostima koje korisnicima omogućuju interakciju i upravljanje artefaktima.

Interoperabilnost je formativni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri korisnici mogu prenositi artefakte između Web 2.0 aplikacije i aplikacija koje svakodnevno upotrebljavaju.

Izmjerena djelotvornost je formativni konstrukt prve razine kojim se utvrđuje koliko reprezentativnih koraka scenarija korisnici mogu dovršiti primjenom Web 2.0 aplikacije.

$H_{1.4}$ U kontekstu korištenja Web 2.0 aplikacijom, izmjerena djelotvornost korisnika ima pozitivan utjecaj na zamijećenu djelotvornost korisnika.

Izmjereno radno opterećenje je formativni konstrukt prve razine kojim se utvrđuje koliko motoričkih aktivnosti upotrebom tipkovnice i miša korisnici trebaju izvršiti kako bi pomoću Web 2.0 aplikacije dovršili reprezentativne korake scenarija.

$H_{1.5}$ U kontekstu korištenja Web 2.0 aplikacijom, izmjereno radno opterećenje korisnika ima negativan utjecaj na zamijećeno radno opterećenje korisnika.

Izmjerena učinkovitost je formativni konstrukt prve razine kojim se utvrđuje koliko vremena korisnici trebaju utrošiti u provedbu reprezentativnih koraka scenarija interakcije sa Web 2.0 aplikacijom.

$H_{1.6}$ U kontekstu korištenja Web 2.0 aplikacijom, izmjerena učinkovitost korisnika ima negativan utjecaj na zamijećenu učinkovitost korisnika.

Jedinstvenost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj se mjeri Web 2.0 aplikacija razlikuje od ostalih aplikacija iste namjene.

$H_{1.7}$ Jedinstvenost Web 2.0 aplikacije ima pozitivan utjecaj na užitak kojeg pruža korištenje Web 2.0 aplikacijom.

Korisnost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri upotreba Web 2.0 aplikacije rezultira unaprjeđenjem performansi korisnika u dovršavanju reprezentativnih koraka scenarija.

$H_{1.8}$ Korisnost Web 2.0 aplikacije ima pozitivan utjecaj na lojalnost korisnika.

Kvaliteta sustava je formativni konstrukt treće razine kojim se vrjednuju dohvatljivost, otvorenost i sigurnost Web 2.0 aplikacije.

$H_{1.9}$ Kvaliteta sustava Web 2.0 aplikacije ima pozitivan utjecaj na stav prema korištenju Web 2.0 aplikacijom.

Kvaliteta usluge je formativni konstrukt treće razine kojim se vrjednuju funkcionalna prikladnost Web 2.0 aplikacije i kvaliteta podrške koju ista pruža svojim korisnicima.

$H_{1.10}$ Kvaliteta usluge Web 2.0 aplikacije ima pozitivan utjecaj na stav prema korištenju Web 2.0 aplikacijom.

Lakoća korištenja je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri korisnicima jednostavno upotrebljavati Web 2.0 aplikaciju.

Lakoća učenja korištenja je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri korisnicima jednostavno razviti vještinu korištenja Web 2.0 aplikacijom.

Lojalnost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj su mjeri korisnici voljni nastaviti upotrebljavati Web 2.0 aplikaciju.

Mogućnost interakcije je formativni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri Web 2.0 aplikacija raspolaže sa funkcionalnostima koje omogućuju komunikaciju i suradnju među korisnicima.

Mogućnost kontrole je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri korisnici imaju kontrolu nad interakcijom sa Web 2.0 aplikacijom.

$H_{1.11}$ Mogućnost kontrole Web 2.0 aplikacije ima pozitivan utjecaj na lakoću korištenja Web 2.0 aplikacijom.

Mogućnost oporavka je formativni konstrukt prve razine kojim se utvrđuje u kolikoj se mjeri Web 2.0 aplikacija može oporaviti od pogrješaka ili prekida u radu.

$H_{1.12}$ Mogućnost oporavka Web 2.0 aplikacije ima pozitivan utjecaj na pouzdanost Web 2.0 aplikacije.

Mogućnost prilagodbe je formativni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri korisnici mogu prilagoditi Web 2.0 aplikaciju svojim željama i potrebama.

$H_{1.13}$ Mogućnost prilagodbe Web 2.0 aplikacije ima pozitivan utjecaj na pamtljivost Web 2.0 aplikacije.

Napor je reflektivni konstrukt treće razine kojim se vrjednuju operabilnost Web 2.0 aplikacije i zamijećeno radno opterećenje korisnika.

$H_{1.14}$ Napor kojeg korisnici trebaju uložiti u korištenje Web 2.0 aplikacijom ima pozitivan utjecaj na zadovoljstvo korisnika Web 2.0 aplikacijom.

Operabilnost je reflektivni konstrukt druge razine kojim se vrjednuju lakoća učenja korištenja, pamtljivost i lakoća korištenja Web 2.0 aplikacijom.

Otvorenost je formativni konstrukt druge razine kojim se vrjednuju prenosivost i interoperabilnost Web 2.0 aplikacije.

Pamtljivost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri korisnicima jednostavno zapamtiti kako se upotrebljava Web 2.0 aplikacije te se prisjetiti gdje se nalaze pojedini elementi njena sučelja.

Podrška korisnicima je formativni konstrukt druge razine kojim se vrjednuje kvaliteta povratnih informacija i materijala pomoći koje Web 2.0 aplikacija pruža svojim korisnicima.

Pouzdanost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri Web 2.0 aplikacija stabilna u radu.

$H_{1.15}$ Pouzdanost Web 2.0 aplikacije ima pozitivan utjecaj na korisnost Web 2.0 aplikacije.

Povratne informacije je formativni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri Web 2.0 aplikacija putem prikladnih poruka pravovremeno obavještava korisnike o promjenama u svom statusu ili radu.

Produktivnost je reflektivni konstrukt druge razine kojim se vrjednuju zamijećena učinkovitost i zamijećena djelotvornost korisnika u provedbi reprezentativnih koraka scenarija interakcije sa Web 2.0 aplikacijom.

$H_{1.16}$ Produktivnost Web 2.0 aplikacije ima pozitivan utjecaj na korisnost Web 2.0 aplikacije.

Prenosivost je formativni konstrukt prve razine kojim se utvrđuje u kolikoj se mjeri način upotrebe Web 2.0 aplikacije razlikuje među uređajima koje je moguće spojiti na Internet i među web preglednicima.

Pristupačnost je formativni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri Web 2.0 aplikacija upotrebljiva svim skupinama korisnika bez obzira na njihove karakteristike i sposobnosti.

Radni učinak je formativni konstrukt druge razine kojim se vrjednuju zamijećeno vrijeme odaziva i zamijećena skalabilnost Web 2.0 aplikacije.

$H_{1.17}$ Radni učinak Web 2.0 aplikacije ima pozitivan utjecaj na zamijećenu učinkovitost korisnika.

Raspoloživost i pružanje pomoći je formativni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri Web 2.0 aplikacija sadrži različite oblike pomoći korisnicima koji su jasni i pregledni.

Razigranost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri Web 2.0 aplikacija može zadržati pažnju korisnika i potaknuti njihovu kreativnost.

$H_{1.18}$ Razigranost korisnika ima pozitivan utjecaj na užitak kojeg pruža korištenje Web 2.0 aplikacijom.

Razumljivost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri značenje elemenata sučelja Web 2.0 aplikacije korisnicima jednoznačno.

$H_{1.19}$ Razumljivost Web 2.0 aplikacije ima pozitivan utjecaj na lakoću učenja korištenja Web 2.0 aplikacijom.

Sigurnost je formativni konstrukt prve razine kojim se utvrđuje u kolikoj su mjeri podaci i artefakti korisnika zaštićeni od neautorizirane upotrebe.

Sprječavanje pogrješaka je formativni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri Web 2.0 aplikacija raspolaže sa funkcionalnostima koje sprječavaju nastanak pogrješaka i omogućuju njihovo ispravljanje.

$H_{1.20}$ Razina do koje Web 2.0 aplikacija raspolaže sa funkcionalnostima koje sprječavaju nastanak pogrješaka i omogućuju njihovo ispravljanje ima pozitivan utjecaj na pouzdanost Web 2.0 aplikacije.

Stav prema korištenju je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri mišljenje korisnika o upotrebi Web 2.0 aplikacije pozitivno.

$H_{1.21}$ Stav prema korištenju Web 2.0 aplikacijom ima pozitivan utjecaj na lojalnost korisnika.

Sveobuhvatnost konteksta je formativni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri Web 2.0 aplikacija upotrebljiva izvan inicijalno definiranog konteksta korištenja.

$H_{1.22}$ Sveobuhvatnost konteksta Web 2.0 aplikacije ima pozitivan utjecaj na zamijećenu djelotvornost korisnika.

Upravljanje artefaktima je formativni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri Web 2.0 aplikacija raspolaže sa funkcionalnostima koje omogućuju rukovanje artefaktima.

Upravljivost je formativni konstrukt prve razine kojim se utvrđuje u kolikoj su mjeri elementi sučelja Web 2.0 aplikacije namijenjeni navigaciji upotrebljivi.

$H_{1.23}$ Upravljivost Web 2.0 aplikacijom ima pozitivan utjecaj na lakoću korištenja Web 2.0 aplikacijom.

Užitak je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri korisnicima ugodno upotrebljavati Web 2.0 aplikaciju.

$H_{1.24}$ Užitak kojeg pruža korištenje Web 2.0 aplikacijom ima pozitivan utjecaj na zadovoljstvo korisnika Web 2.0 aplikacijom.

Zadovoljstvo je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri Web 2.0 aplikacija ispunila očekivanja korisnika.

$H_{1.25}$ Zadovoljstvo korisnika ima pozitivan utjecaj na lojalnost korisnika.

Zamijećena djelotvornost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri korisnici mogu točno i u potpunosti dovršiti reprezentativne korake scenarija interakcije sa Web 2.0 aplikacijom.

Zamijećena skalabilnost je formativni konstrukt prve razine kojim se utvrđuje u kolikoj je mjeri Web 2.0 aplikacija upotrebljiva u slučaju povećanog radnog opterećenja.

Zamijećena učinkovitost je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri provedba reprezentativnih koraka scenarija upotrebom Web 2.0 aplikacije štedi vrijeme korisnika.

Zamijećeno radno opterećenje je reflektivni konstrukt prve razine kojim se utvrđuje u kolikoj se mjeri korisnici nakon interakcije sa Web 2.0 aplikacijom osjećaju umorno i iscrpljeno.

Zamijećeno vrijeme odaziva je formativni konstrukt prve razine kojim se utvrđuje u kolikoj mjeri Web 2.0 aplikacija brzo reagira na aktivnosti korisnika.

Konceptualni model vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama ilustriran je slikom 6.6.

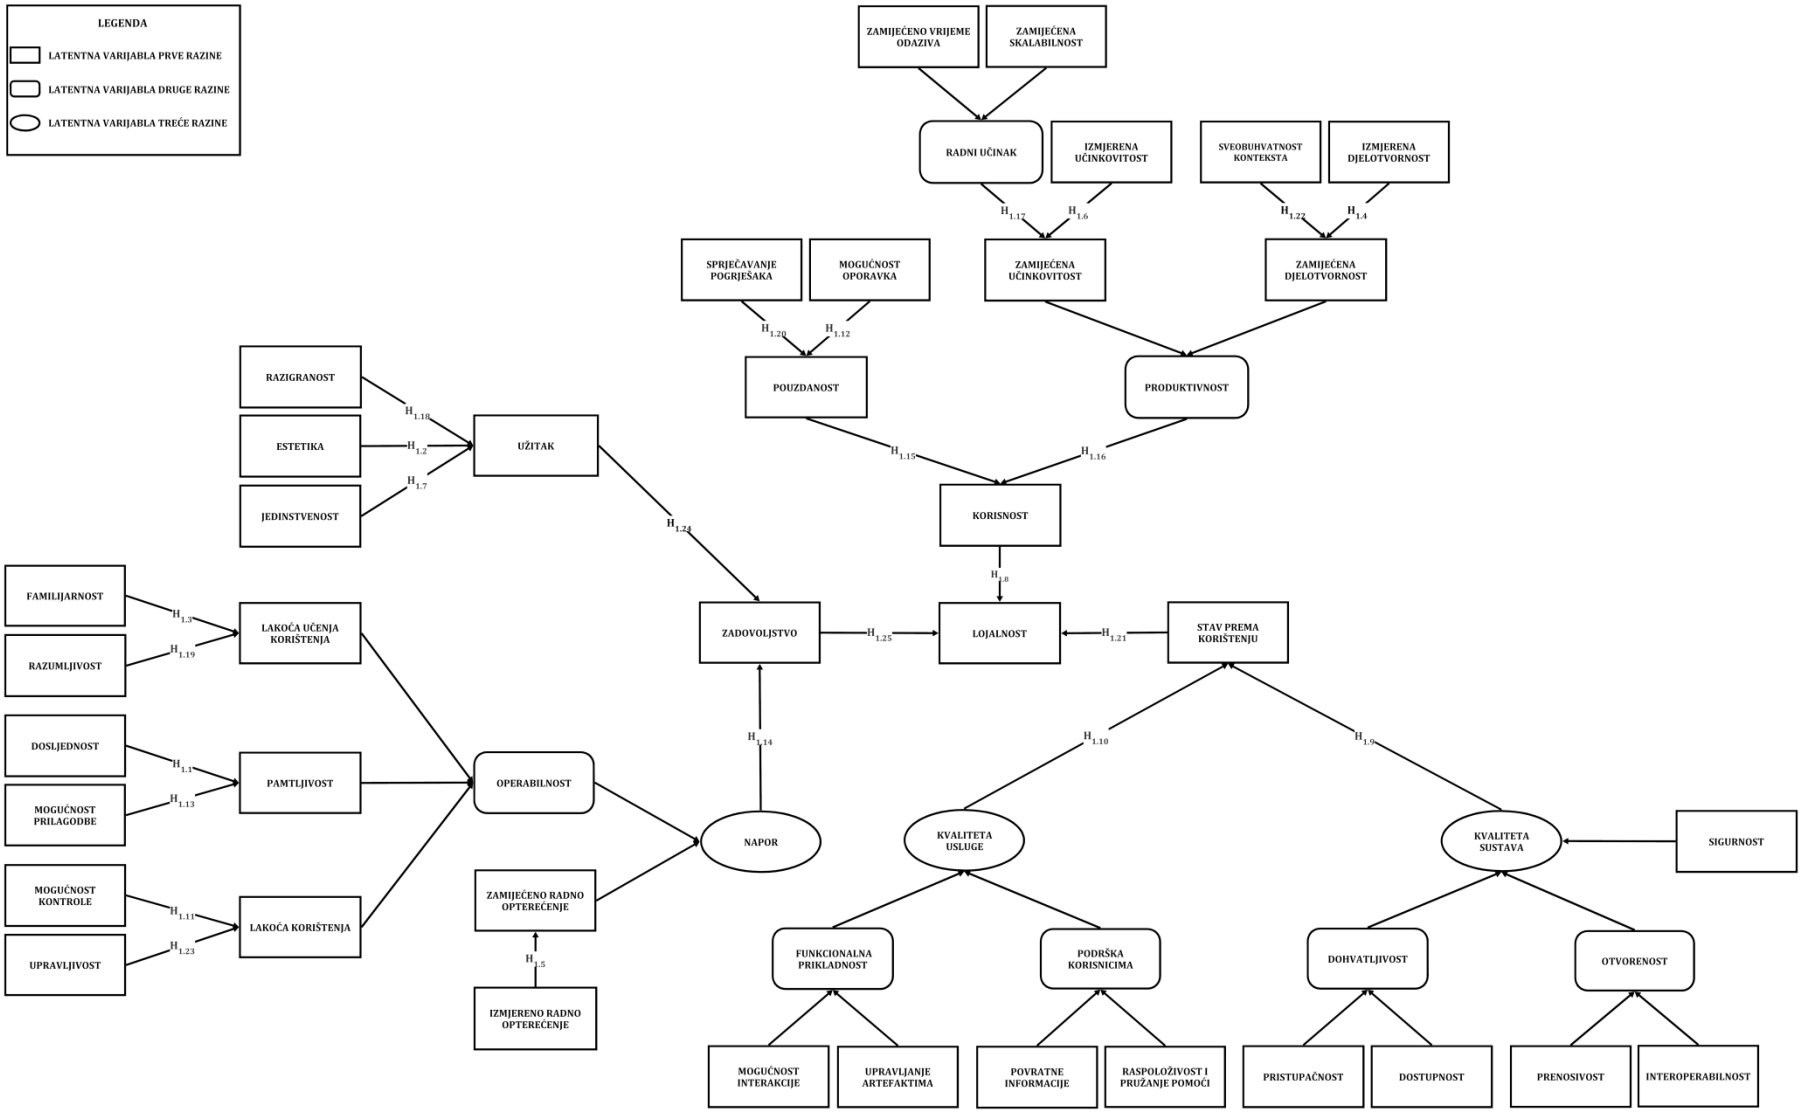

Slika 6.6 Konceptualni model vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama

6.2.5 Postavke algoritama korištenih u analizi konceptualnog modela

Prije provedbe analize metrijskih karakteristika konceptualnog modela, potrebno je prilagoditi postavke algoritama koji će biti korišteni u izračunu parametara vanjskog reflektivnog i/ili formativnog modela te unutarnjeg modela. U tablici 6.31 se nalazi pregled postavki korištenih u izračunu parametara konceptualnog modela vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama. Izuzev postavku koja se odnosi na broj slučajeva odnosno broj opservacija u originalnom uzorku podataka te upotrebljava kod izračuna vrijednosti parametara pomoću bootstrapping procedure, preostale su postavke bile istovjetne za sve četiri vrjednovane Web 2.0 aplikacije. Potrebno je napomenuti da su postavke algoritama usklađene sa preporukama istraživača koji su navedeni u tablici 6.31. Kao što je već spomenuto u potpoglavlju 5.3, analiza konceptualnog modela vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama provedena je primjenom alata SmartPLS 2.0 M3 (Ringle et al., 2005).

Tablica 6.31 Prilagođene postavke algoritama korištenih u izračunu parametara unutarnjeg i vanjskog modela

Naziv postavke	Vrijednost postavke	Reference
PLS-SEM algoritam		
Shema izračuna vrijednosti LV*	Shema ponderiranog puta	Esposito Vinzi et al., 2010
Distribucija podataka	Srednja vrijednost 0, varijanca 1	Ringle et al., 2005
Maksimalan broj iteracija	300	Ringle et al., 2005
Kriterij zaustavljanja	1.0E-5	Wold, 1982
Inicijalna vrijednost pondera	1.0	Henseler, 2010
Bootstrapping procedura		
Promjene predznaka	Individualne promjene	Henseler et al., 2009
Broj slučajeva**	264*** ili 269****	Hair et al., 2011
Broj uzoraka	5.000	Hair et al., 2011
Blindfolding procedura		
Razmak udaljenosti	7	Chin, 1998

* latentnih varijabli
** broj opservacija u originalnom uzorku
*** u slučaju Web 2.0 aplikacija za kolaborativno uređivanje teksta
**** u slučaju Web 2.0 aplikacija za izradu mentalnih mapa

6.2.6 Izrada stabla zahtjeva

Kao što je već navedeno u poglavlju 5.4, izračunu globalne preferencije prethodi izrada stabla zahtjeva te definiranje elementarnih kriterija i preferencija. U kontekstu ovog doktorskog rada, čvorovi stabla zahtjeva Web 2.0 aplikacija predstavljaju specifične aspekte vrjednovanja

kvalitete u korištenju. Premda su se dosad kao osnova za izradu stabla zahtjeva web mjesta upotrebljavali modeli kvalitete definirani u međunarodnom standardu ISO/IEC 9126-1 (2001), stablo zahtjeva Web 2.0 aplikacija izrađeno je temeljem rezultata analize podataka prikupljenih od korisnika (studenata) i stručnjaka (istraživača i web razvojnih inženjera). Isto je sačinjeno od tri razine čvorova odnosno latentnih varijabli. Listovi su čestice upitnika namijenjene vrjednovanju relevantnih aspekata zamijećene kvalitete u korištenju te indikatori koji služe mjerenju djelotvornosti, radnog opterećenja i učinkovitosti korisnika tijekom interakcije sa Web 2.0 aplikacijom. Koraci primjene metode logičkog bodovanja preferencija (Buckley i Dujmović, 2008) ilustrirani su slikom 6.7.

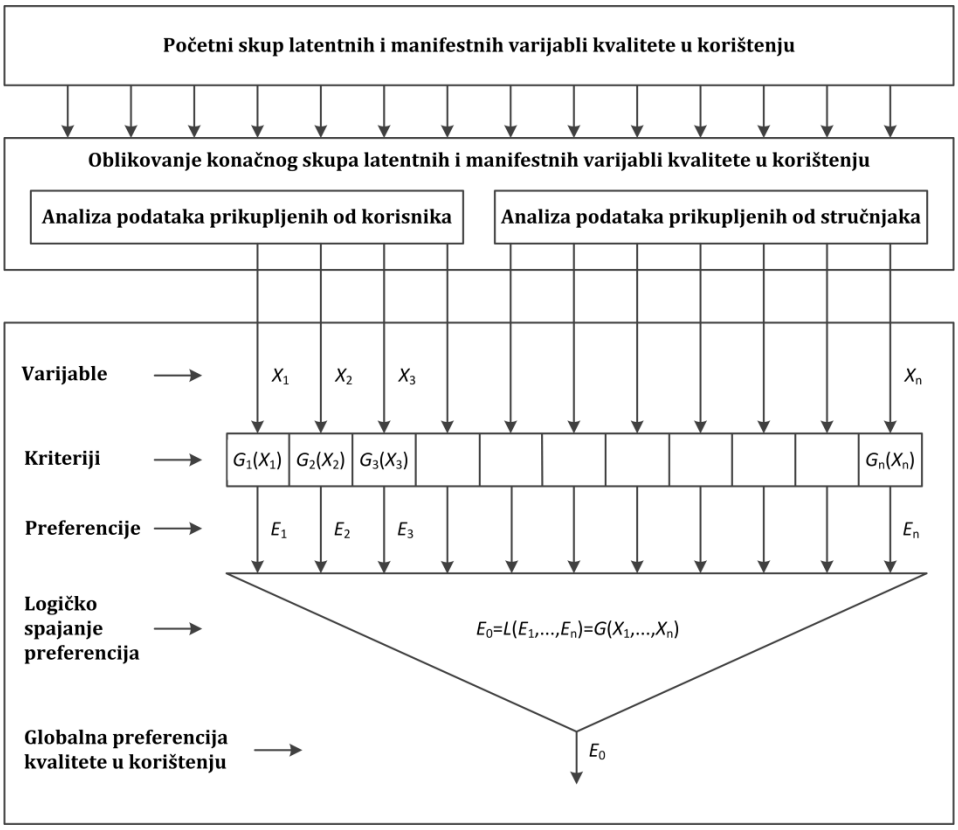

Slika 6.7 Koraci primjene metode logičkog bodovanja preferencija prilagođeni kontekstu doktorskog rada

6.2.7 Definiranje kriterijskih funkcija

Nakon izrade stabla zahtjeva kvalitete u korištenju Web 2.0 aplikacijama odnosno oblikovanja konačnog skupa manifestnih i latentnih varijabli pristupilo se definiranju elementarnih kriterija za svaku od spomenutih varijabli. Oblikovanje elementarnih kriterija za šest indikatora

namijenjenih mjerenju objektivnih aspekata kvalitete u korištenju (djelotvornosti, radnog opterećenja i učinkovitosti) temeljilo se na vrijednostima proizašlim iz provedbe pilot istraživanja (Orehovački, 2011a; Orehovački et al., 2012a).

Elementarni kriteriji za objektivno vrjednovanje djelotvornosti korisnika u izvršavanju predefiniranih koraka scenarija tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta odnosno izradu mentalnih mapa prikazani su na slikama 6.8 i 6.9, respektivno. Minimalne i maksimalne vrijednosti na skalama preferencija dobivene su na osnovi minimalnog i maksimalnog broja koraka scenarija kojeg su sudionici pilot istraživanja uspjeli dovršiti tijekom interakcije sa svim Web 2.0 aplikacijama iste namjene.

Iz slike 6.8 je evidentno da u kontekstu Web 2.0 aplikacija za kolaborativno uređivanje teksta mogućnost dovršavanja svih 45 koraka scenarija (X^{max}) predstavlja potpuno zadovoljenje zahtjeva ($E^{max} = 100\%$) izmjerene djelotvornosti korisnika dok mogućnost dovršavanja 17 koraka scenarija i manje (X^{min}) ukazuje na potpuno nezadovoljenje zahtjeva ($E^{min} = 0\%$) izmjerene djelotvornosti korisnika.

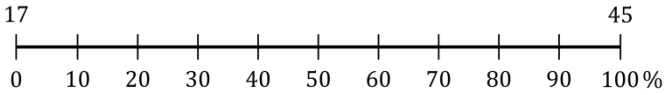

Slika 6.8 Elementarni kriterij za postotak dovršenosti koraka scenarija u kontekstu vrjednovanja izmjerene djelotvornosti korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta

Slika 6.9 zorno ilustrira da u kontekstu Web 2.0 aplikacija za izradu mentalnih mapa mogućnost dovršavanja sva 43 koraka scenarija (X^{max}) implicira potpuno zadovoljenje zahtjeva ($E^{max} = 100\%$) izmjerene djelotvornosti korisnika dok mogućnost dovršavanja 13 koraka scenarija i manje (X^{min}) predstavlja potpuno nezadovoljenje zahtjeva ($E^{min} = 0\%$) izmjerene djelotvornosti korisnika.

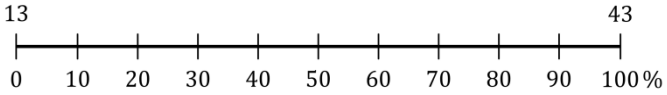

Slika 6.9 Elementarni kriterij za postotak dovršenosti koraka scenarija u kontekstu vrjednovanja izmjerene djelotvornosti korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa

Za obje se skupine Web 2.0 aplikacija vrijednosti elementarnih preferencija izračunavaju pomoću sljedeće rastuće funkcije sačinjene od tri linearna dijela (Dujmović, 2007; Dujmović i Nagashima, 2006):

$$E_i = G_i(X_i) = \begin{cases} 0, & X \leq X^{min} \\ max\{0, min[1, (X - X^{min})/(X^{max} - X^{min})]\}, & X^{min} < X < X^{max} \\ 1, & X \geq X^{max} \end{cases} \quad (6.1)$$

Elementarni kriteriji za preostalih pet indikatora izračunati su u nekoliko koraka. Najprije su vrijednosti indikatora podijeljene sa brojem koraka scenarija koje je pojedini sudionik u pilot istraživanju upotrebom Web 2.0 aplikacije uspio dovršiti čime su izračunate vrijednosti indikatora po koraku scenarija za svakog sudionika. Zatim su dobivene vrijednosti pomnožene sa ukupnim brojem koraka scenarija te na taj način izračunate vrijednosti koje bi indikatori poprimili u slučaju da je specifični sudionik uspio upotrebom Web 2.0 aplikacije dovršiti sve korake scenarija. Naposljetku su primjenom donjeg i gornjeg interkvartila na uzorku vrijednosti indikatora za sve Web 2.0 aplikacije iste namjene koje su sudionici pilot istraživanja upotrebljavali izračunate minimalne i maksimalne vrijednosti na skalama preferencija indikatora, respektivno.

Ukoliko su korisnici tijekom izvršavanja svih 45 koraka scenarija pomoću Web 2.0 aplikacije za kolaborativno uređivanje teksta pritisnuli 591 tipku na tipkovnici ili manje (X^{min}), broj pritisnutih tipaka na tipkovnici kao zahtjev izmjerenog radnog opterećenja korisnika (prikazan na slici 6.10) je u potpunosti zadovoljen ($E^{min} = 100\%$). S druge strane, ako su korisnici za vrijeme provedbe svih koraka scenarija pritisnuli 1184 tipaka na tipkovnici ili više (X^{max}), zahtjev izmjerenog radnog opterećenja korisnika koji se odnosi na broj pritisnutih tipaka na tipkovnici nije zadovoljen ($E^{max} = 0\%$).

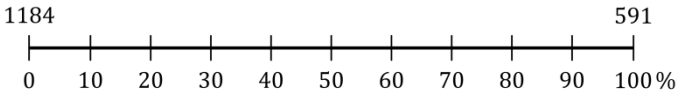

Slika 6.10 Elementarni kriterij za broj pritisnutih tipaka na tipkovnici potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta

Prema vrijednostima skale preferencija prikazane na slici 6.11, broj pritisnutih tipaka na tipkovnici manji ili jednak 642 (X^{min}) u potpunosti zadovoljava ($E^{min} = 100\%$) istoimeni zahtjev izmjerenog radnog opterećenja korisnika u kontekstu izvršavanja svih koraka scenarija

upotrebom Web 2.0 aplikacija za izradu mentalnih mapa. Međutim, ukoliko je broj pritisnutih tipaka na tipkovnici nakon provedbe svih koraka scenarija jednak ili veći od 1011 (X^{max}), ovaj zahtjev izmjerenog radnog opterećenja korisnika nije zadovoljen ($E^{max} = 0\%$).

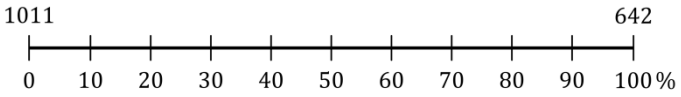

Slika 6.11 Elementarni kriterij za broj pritisnutih tipaka na tipkovnici potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa

Iz slike 6.12 je evidentno da ukoliko korisnici po dovršetku svih koraka scenarija pomoću Web 2.0 aplikacije za kolaborativno uređivanje teksta pomicanjem miša prijeđu udaljenost od 75961 milimetara ili manje (X^{min}), zahtjev izmjerenog radnog opterećenja korisnika koji se odnosi na udaljenost prijeđenu mišem je u potpunosti zadovoljen ($E^{min} = 100\%$). S druge strane, udaljenost prijeđena pomicanjem miša od 169756 milimetara ili više (X^{max}) indikator je nezadovoljenja ($E^{max} = 0\%$) ovog zahtjeva izmjerenog radnog opterećenja korisnika.

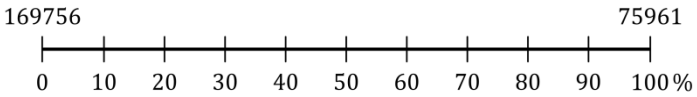

Slika 6.12 Elementarni kriterij za udaljenost prijeđenu pomicanjem miša tijekom izvršavanja svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta

Prema vrijednostima skale preferencija prikazane na slici 6.13, udaljenost od 80834 milimetra ili manje (X^{min}) predstavlja potpuno zadovoljenje ($E^{min} = 100\%$) udaljenosti prijeđene pomicanjem miša kao zahtjeva izmjerenog radnog opterećenja korisnika tijekom provedbe sviih koraka scenarija dok prijeđena udaljenost od 160140 milimetara ili više (X^{max}) nije prihvatljiva ($E^{max} = 0\%$) u kontekstu Web 2.0 aplikacija za izradu mentalnih mapa.

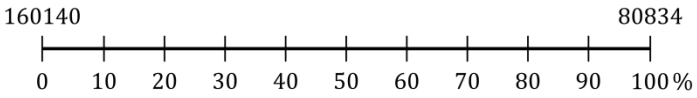

Slika 6.13 Elementarni kriterij za udaljenost prijeđenu pomicanjem miša tijekom izvršavanja svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa

Iz slike 6.14 je vidljivo da ako korisnici tijekom izvršavanja svih koraka scenarija pomoću Web 2.0 aplikacija za kolaborativno uređivanje teksta kliknu mišem 484 puta ili manje (X^{min}), zahtjev izmjerenog radnog opterećenja korisnika vezan uz broj klikova mišem će biti u potpunosti zadovoljen ($E^{min} = 100\%$). Nasuprot tome, ukoliko su korisnici za vrijeme provedbe svih koraka scenarija kliknuli mišem 1038 puta ili više (X^{max}), zahtjev izmjerenog radnog opterećenja korisnika koji se odnosi na broj klikova mišem u kontekstu Web 2.0 aplikacija za kolaborativno uređivanje teksta nije zadovoljen ($E^{max} = 0\%$).

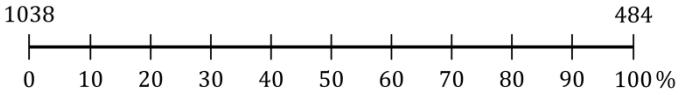

Slika 6.14 Elementarni kriterij za broj klikova mišem potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta

Slika 6.15 eksplicitno prikazuje da u kontekstu izvršavanja svih koraka scenarija pomoću Web 2.0 aplikacija za izradu mentalnih mapa 534 klika mišem ili manje (X^{min}) predstavljaju potpuno zadovoljenje ($E^{min} = 100\%$) istoimenog zahtjeva izmjerenog radnog opterećenja korisnika dok 991 klik mišem ili više (X^{max}) nije prihvatljiv ($E^{max} = 0\%$).

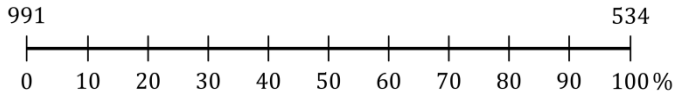

Slika 6.15 Elementarni kriterij za broj klikova mišem potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa

Slika 6.16 jasno prikazuje da broj pomicanja klizača na mišu jednak ili manji od 130 (X^{min}) implicira potpuno zadovoljenje ($E^{min} = 100\%$) istoimenog zahtjeva izmjerenog radnog opterećenja korisnika u kontekstu izvršavanja svih koraka scenarija pomoću Web 2.0 aplikacija za kolaborativno uređivanje teksta. Međutim, ukoliko je broj pomicanja klizača na mišu veći od ili jednak 871 (X^{max}) tada ovaj zahtjev izmjerenog radnog opterećenja korisnika vezan uz Web 2.0 aplikacije za kolaborativno uređivanje teksta nije zadovoljen ($E^{max} = 0\%$).

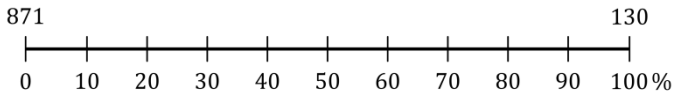

Slika 6.16 Elementarni kriterij za broj pomicanja klizača na mišu potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta

Skala preferencija za broj pomicanja klizača na mišu u kontekstu Web 2.0 aplikacija za izradu mentalnih mapa prikazana je na slici 6.17. Ukoliko je nakon dovršetka svih koraka scenarija sa Web 2.0 aplikacijama za izradu mentalnih mapa broj pomicanja klizača na mišu jednak ili manji od 22 (X^{min}), istoimeni je zahtjev izmjerenog radnog opterećenja korisnika u potpunosti zadovoljen ($E^{min} = 100\%$). Nasuprot tome, ako tijekom provedbe svih koraka scenarija korisnici pomaknu klizač na mišu 450 ili više puta (X^{max}), ovaj zahtjev izmjerenog radnog opterećenja korisnika nije zadovoljen ($E^{max} = 0\%$).

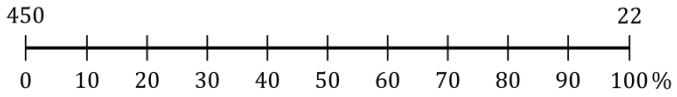

Slika 6.17 Elementarni kriterij za broj pomicanja klizača na mišu potrebnih za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerenog radnog opterećenja korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa

Iz slike 6.18 je vidljivo da u kontekstu Web 2.0 aplikacija za kolaborativno uređivanje teksta dovršetak svih koraka scenarija u vremenu od 2506 sekundi i kraće (X^{min}) predstavlja potpuno zadovoljenje zahtjeva ($E^{min} = 100\%$) izmjerene učinkovitosti korisnika dok vrijeme od 5900 sekundi i dulje (X^{max}) nije prihvatljivo ($E^{max} = 0\%$).

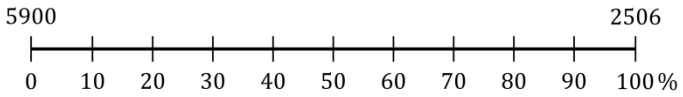

Slika 6.18 Elementarni kriterij za količinu vremena potrebnog za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerene učinkovitosti korisnika tijekom interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta

Slika 6.19 prikazuje da se u kontekstu Web 2.0 aplikacija za izradu mentalnih mapa dovršetak svih koraka scenarija u vremenu od 2466 sekundi i kraće (X^{min}) smatra izvrsnim ($E^{min} = 100\%$) dok vrijeme od 5192 sekunde i dulje (X^{max}) implicira potpuno nezadovoljenje zahtjeva izmjerene učinkovitosti korisnika ($E^{max} = 0\%$).

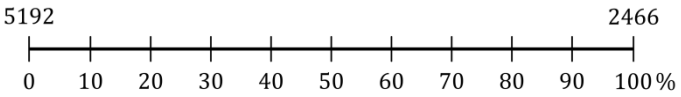

Slika 6.19 Elementarni kriterij za količinu vremena potrebnog za dovršetak svih koraka scenarija u kontekstu vrjednovanja izmjerene učinkovitosti korisnika tijekom interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa

Vrijednosti elementarnih preferencija se za spomenutih pet indikatora (broj pritisnutih tipaka na tipkovnici, broj klikova mišem, broj pomicanja klizača na mišu, udaljenost prijeđena pomicanjem miša i količina vremena potrebnog za dovršetak svih koraka scenarija) izračunavaju pomoću sljedeće padajuće funkcije sačinjene od tri linearna dijela (Dujmović, 2007; Dujmović i Nagashima, 2006):

$$E_i = G_i(X_i) = \begin{cases} 1, & X \le X^{min} \\ max\{0, min[1, (X^{max} - X)/(X^{max} - X^{min})]\}, & X^{min} < X < X^{max} \\ 0, & X \ge X^{max} \end{cases} \quad (6.2)$$

Elementarni kriterij za subjektivno vrjednovanje kvalitete u korištenju preko Likertove skale od pet stupnjeva (1 – u potpunosti se slažem, 5 – uopće se ne slažem) prikazan je na slici 6.20.

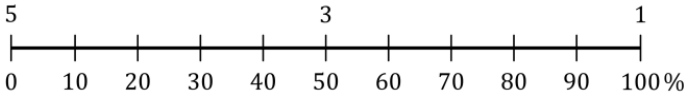

Slika 6.20 Elementarni kriterij za vrjednovanje zamijećene kvalitete u korištenju

Za razliku od objektivnih elementarnih kriterija koji se međusobno razlikuju ovisno o korištenom indikatoru mjerenja, subjektivni elementarni kriteriji su jednaki za sve čestice vrjednovanja kvalitete u korištenju. Vrijednost 1 na Likertovoj skali zadovoljava 100% zahtjeva, vrijednost 3 zadovoljava 50% zahtjeva dok vrijednost 5 ne zadovoljava zahtjev definiran česticom upitnika. Preostale dvije vrijednosti se izračunavaju linearnom interpolacijom. Elementarna preferencija za subjektivno vrjednovanje kvalitete u korištenju izračunava se pomoću sljedeće funkcije:

$$E_i = G_i(X_i) = \begin{cases} 1, & X \le X^{min} \\ 0{,}25(5 - X), & X^{min} < X < X^{max} \\ 0, & X \ge X^{max} \end{cases} \quad (6.3)$$

6.2.8 Grupno procjenjivanje težina

Kako bi se primjenom metode logičkog bodovanja preferencija mogao izračunati kompozitni indeks kvalitete u korištenju Web 2.0 aplikacijama potrebno je svakoj varijabli performansi odrediti relativnu važnost u izračunu specifičnog podsustava preferencija. Relativna važnost varijabli performansi se izražava u terminima težina odnosno pondera koji se određuju temeljem prosudbe skupine stručnjaka domene. U sklopu ovog doktorskog rada uzorak stručnjaka domene uključenih u grupno procjenjivanje težina je bio identičan uzorku stručnjaka uključenih u primjenu metode zatvorenog sortiranja karata. Stručnjaci domene su primjenom ocjenjivanja kao metode za grupno procjenjivanje težina (Babić, 2011; Pomerol i Barba-Romero, 2000) svakoj varijabli iz stabla zahtjeva dodijelili brojčanu ocjenu u intervalu od 1 (slaba relevantnost) do 5 (jaka relevantnost) te na taj način izrazili svoju prosudbu o njihovoj relativnoj važnosti unutar specifičnog podsustava preferencija. Temeljem zbirnih podataka prikupljenih od svih stručnjaka domene uključenih u grupno procjenjivanje, težine su za svaku varijablu performansi izračunate u sljedeća tri koraka. Najprije su dijeljenjem ocjene ρ_{jk} koju je k-ti ekspert dodijelio j-toj varijabli performansi sa sumom ocjena koje je k-ti ekspert dodijelio svim varijablama performansi u sklopu određenog podsustava preferencija izračunate normalizirane težine w_{jk} za svaku j-tu varijablu performansi po svakom od k eksperata (Babić, 2011):

$$w_{jk} = \frac{\rho_{jk}}{\sum_{j=1}^{n} \rho_{jk}} \tag{6.4}$$

Nakon toga je izračunata suma normaliziranih težina w_{jk} za j-tu varijablu performansi po svih l stručnjaka domene. Konačna normalizirana težina w_j za j-tu varijablu performansi dobivena je dijeljenjem sume normaliziranih težina w_{jk} sa sumom normaliziranih težina za svih n varijabli performansi po svih l stručnjaka domene (Babić, 2011):

$$w_j = \frac{\sum_{k=1}^{l} w_{jk}}{\sum_{j=1}^{n} \sum_{k=1}^{l} w_{jk}} \tag{6.5}$$

Stablo zahtjeva Web 2.0 aplikacija na kojem su istaknute normalizirane težine za sve varijable performansi (manifestne i latentne varijable) u kontekstu vrjednovanja kvalitete u korištenju prikazano je na slici 6.21. Veze u stablu slijede hipoteze konceptualnog modela prikazanog na slici 6.6. Odabir logičkog operatora spajanja se temeljio na relevantnosti varijabli performansi pojedinog podsustava preferencija koja je identificirana analizom podataka prikupljenih primjenom metode zatvorenog sortiranja karata čiji se rezultati nalaze u tablici 6.30.

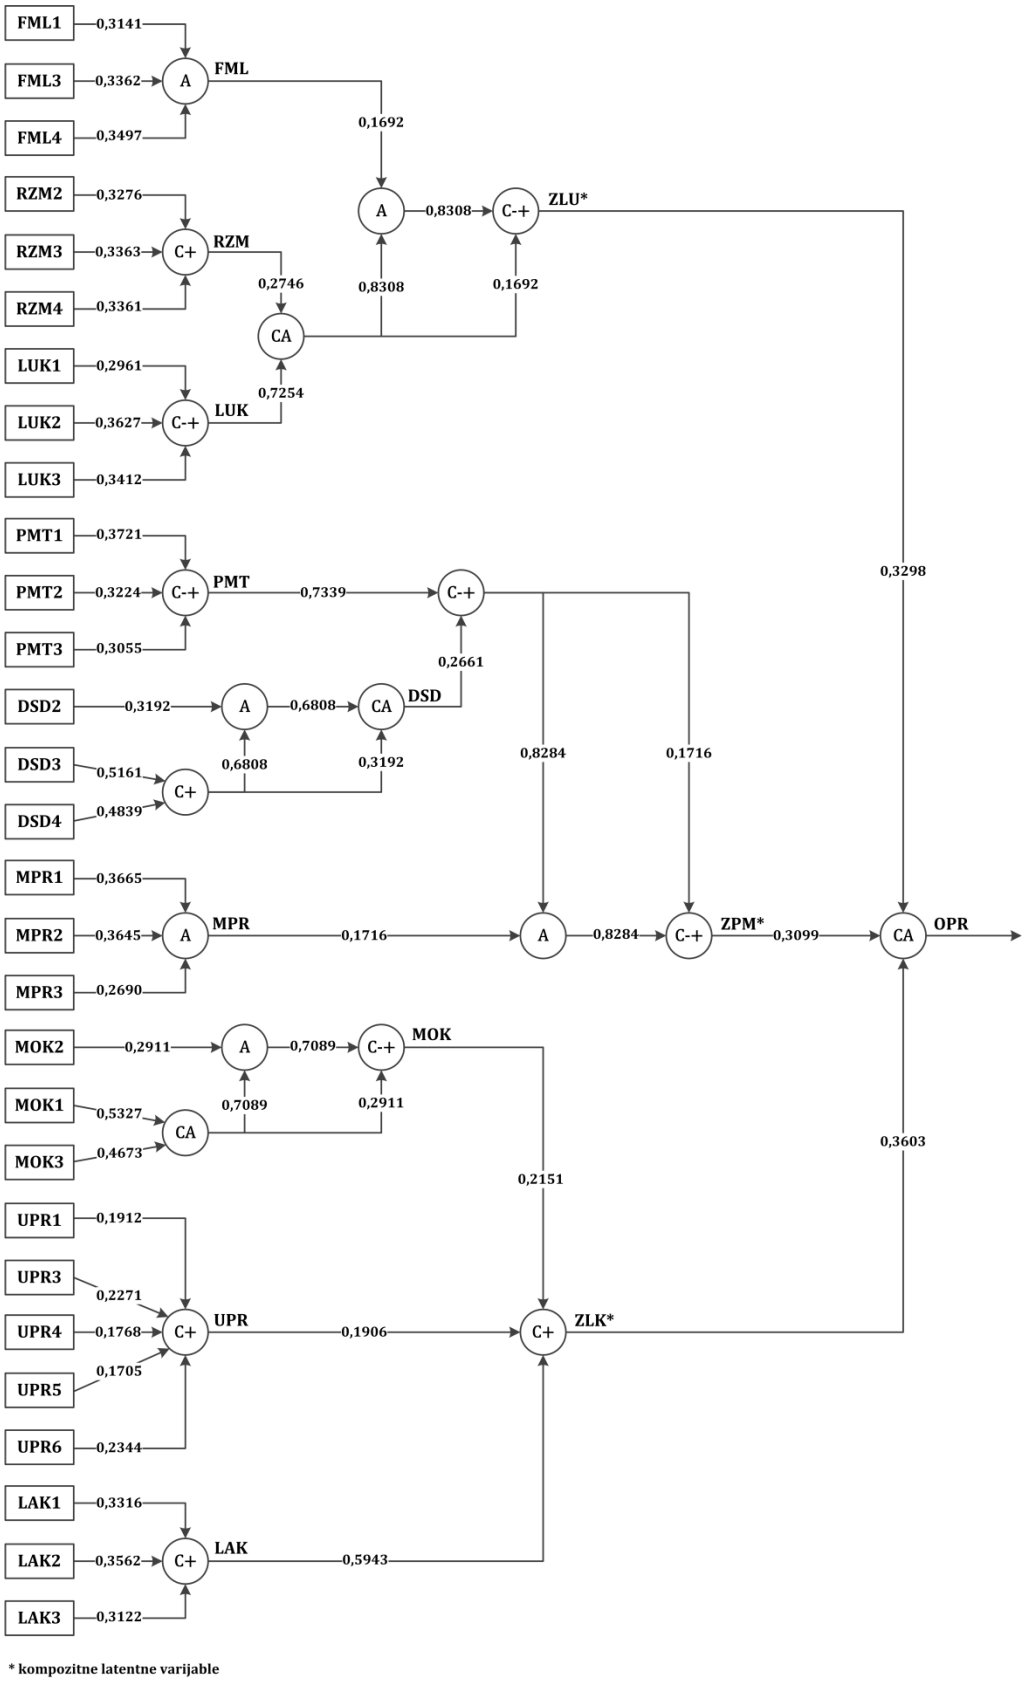

Slika 6.21. Stablo zahtjeva kvalitete u korištenju Web 2.0 aplikacijama

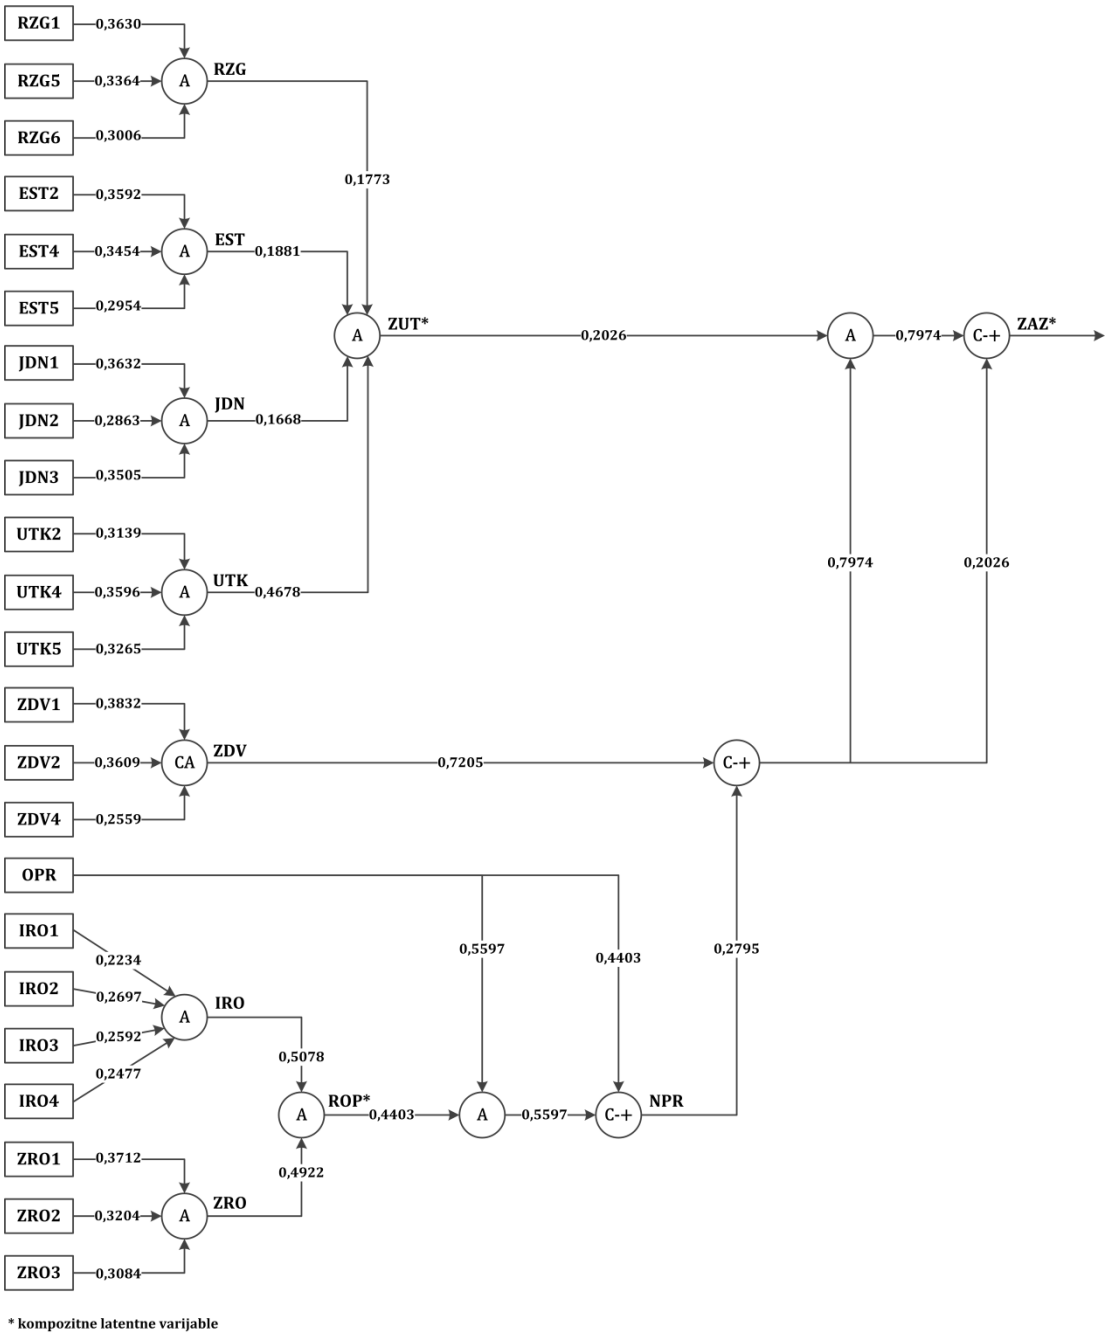

Slika 6.21. Stablo zahtjeva kvalitete u korištenju Web 2.0 aplikacijama (nastavak)

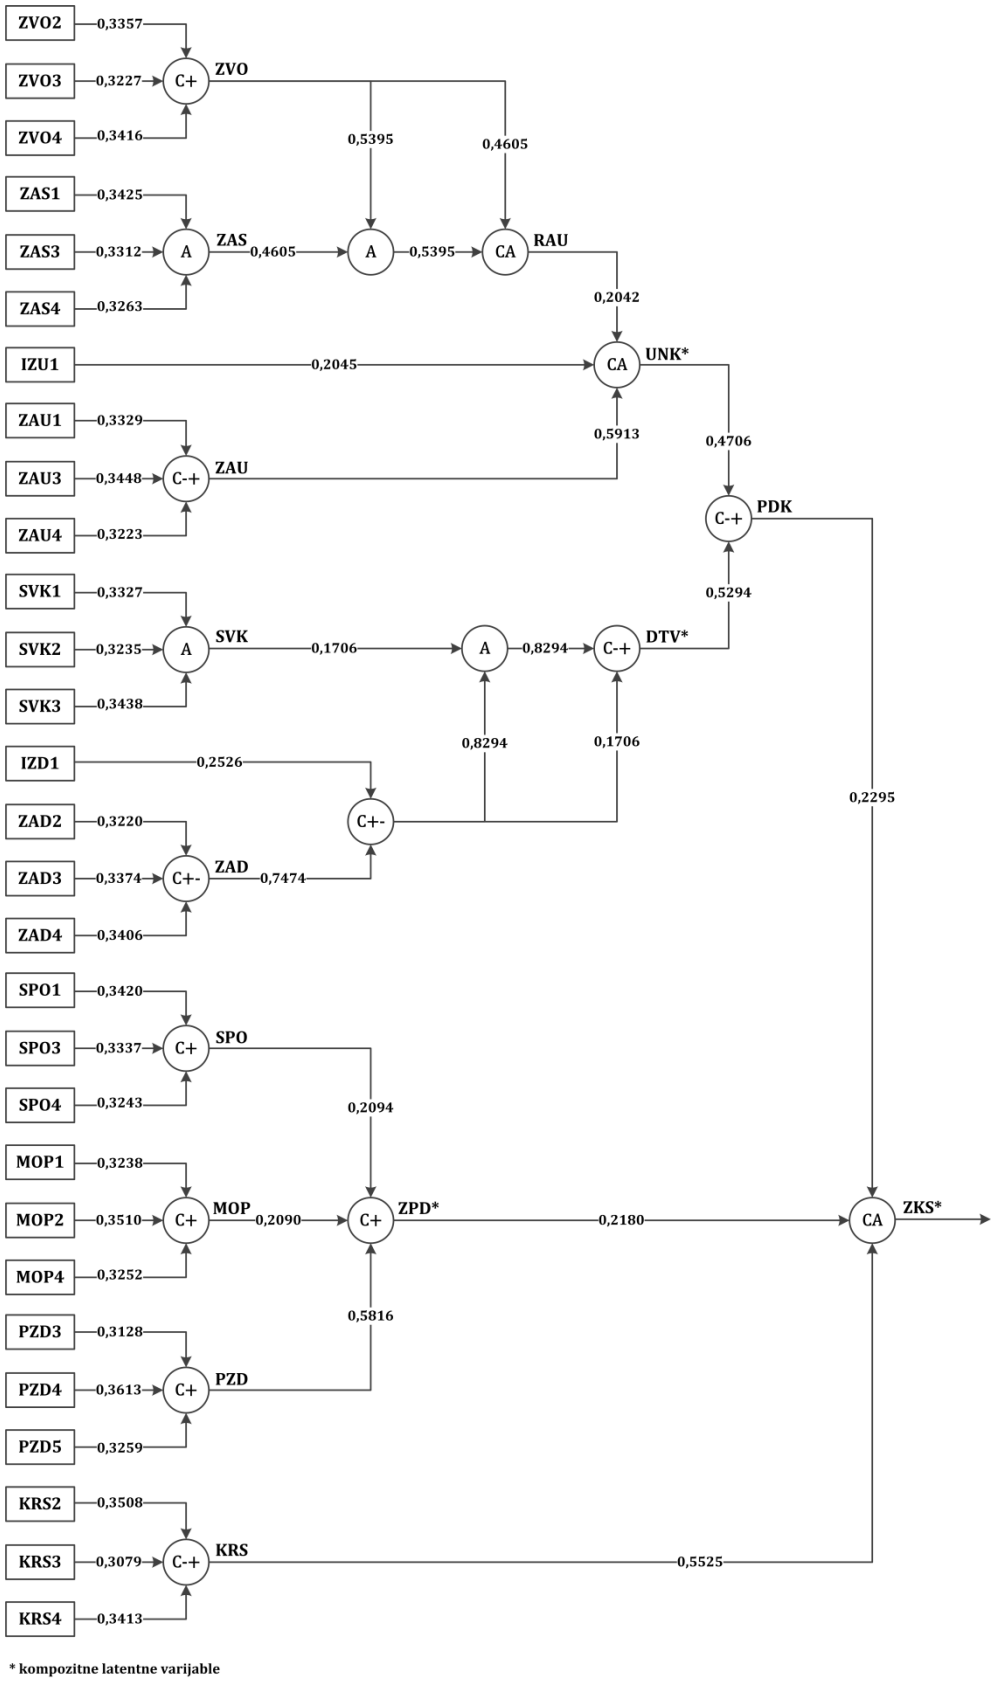

Slika 6.21. Stablo zahtjeva kvalitete u korištenju Web 2.0 aplikacijama (nastavak)

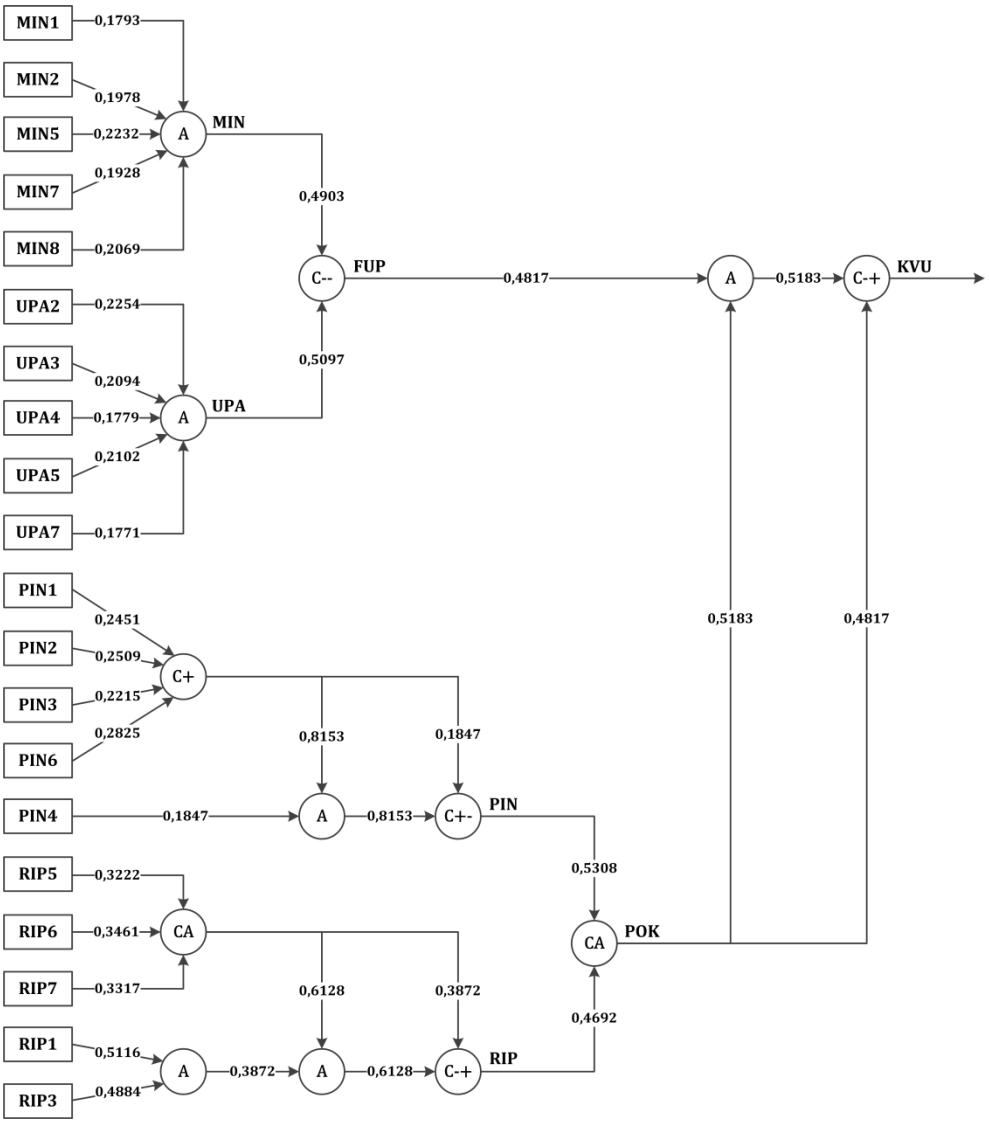

Slika 6.21. Stablo zahtjeva kvalitete u korištenju Web 2.0 aplikacijama (nastavak)

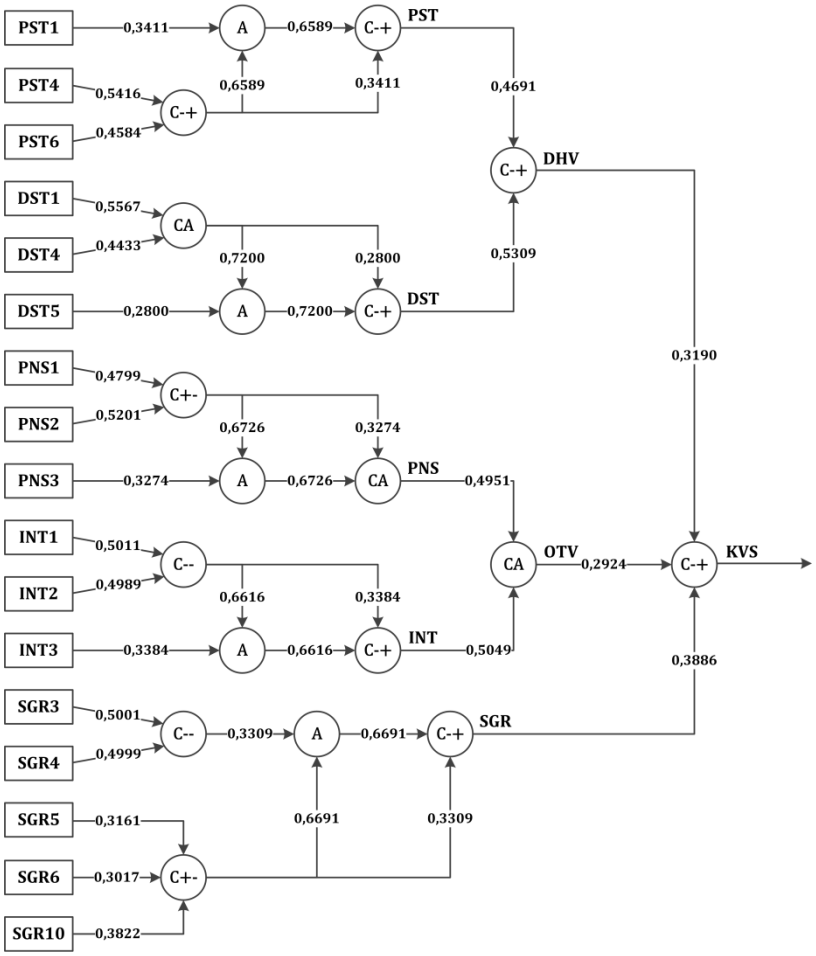

Slika 6.21. Stablo zahtjeva kvalitete u korištenju Web 2.0 aplikacijama (nastavak)

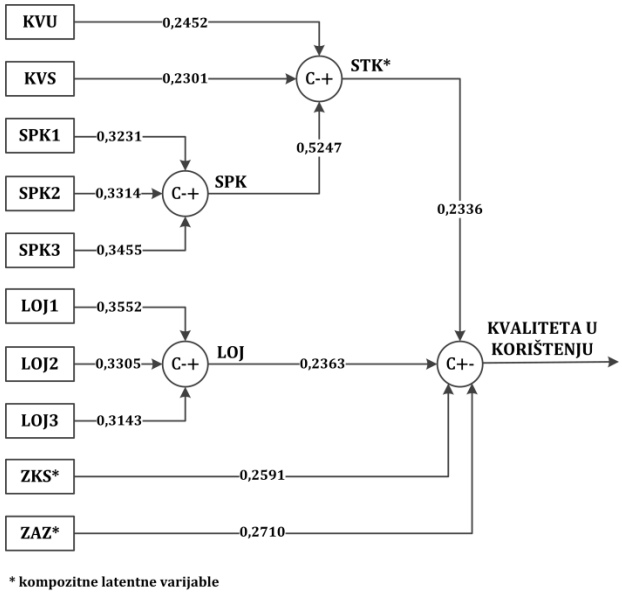

Slika 6.21. Stablo zahtjeva kvalitete u korištenju Web 2.0 aplikacijama (nastavak)

6.2.9 Izračun globalne preferencije

U kontekstu ovog doktorskog rada, globalna preferencija E_0 predstavlja razinu do koje vrjednovane Web 2.0 aplikacije udovoljavaju svim predefiniranim zahtjevima vezanim uz kvalitetu u korištenju. Zbog specifičnosti konceptualnog modela odnosno potrebe da u izračun globalne preferencije kvalitete u korištenju Web 2.0 aplikacijama budu uključene sve varijable performansi, autor doktorskog rada je modificirao primjenu metode logičkog bodovanja preferencija. Naime, u dosadašnjim se radovima primjena spomenute metode temeljila na konceptu „cilj, pitanje, metrika" (eng. Goal, Question, Metric – GQM; Basili i Weiss, 1984) prema kojem se varijable performansi nalaze jedino na razini listova u stablu. Međutim, u stablo zahtjeva kvalitete u korištenju Web 2.0 aplikacijama su uvedene sljedeće kompozitne latentne varijable: zamijećena lakoća učenja (ZLU*), zamijećena pamtljivost (ZPM*), zamijećena lakoća korištenja (ZLK*), zamijećen užitak (ZUT*), radno opterećenje (ROP*), zamijećeno zadovoljstvo (ZAZ*), učinkovitost (UNK*), djelotvornost (DTV*), zamijećena pouzdanost (ZPD*), zamijećena korisnost (ZKS*) i stav korisnika (STK*).

Izračun globalnih preferencija kompozitnih latentnih varijabli se pored vrijednosti pridruženih manifestnih varijabli temelji i na vrijednostima latentnih varijabli koje prema konceptualnom modelu predstavljaju njihove prediktore. Primjerice, izračun vrijednosti kompozitne latentne varijable zamijećena pamtljivost (ZPM*) se bazira na vrijednostima manifestnih varijabli (PMT1, PMT2 i PMT3) koje mjere njene teorijske aspekte (PMT), ali i na vrijednostima latentnih varijabli dosljednost (DSD) i mogućnost prilagodbe (MPR) koje su prema konceptualnom modelu njeni prediktori. Osim navedenog, kod izračuna vrijednosti preferencije spajanja pomoću konjunktivne parcijalne apsorpcije se kao težine zahtjeva nisu koristile vrijednosti iz tablica za željenu razinu nagrade odnosno penala (Dujmović, 1979) već vrijednosti dobivene primjenom metode grupnog procjenjivanja težina. Konačno, za razliku od ostalih autora koji su izračun globalnih preferencija temeljili isključivo na objektivnim (Olsina i Rossi, 2002; Gledec, 2005; Debnath et al., 2007; Buckley i Dujmović, 2008; Tripathi et al., 2008) ili subjektivnim (Alva et al., 2010) varijablama performansi, stablo zahtjeva kvalitete u korištenju Web 2.0 aplikacijama se sastoji od kombinacije subjektivnih i objektivnih varijabli performansi.

6.2.10 Razina podudaranja u grupnom procjenjivanju težina

Stupanj korelacije među stručnjacima domene u kontekstu procjenjivanja težina za varijable performansi vrjednovan je Kendallovim koeficijentom podudaranja W (Kendall i Babington-Smith, 1939; Wallis, 1939). Riječ o pokazatelju pouzdanosti između 3 ili više procjenitelja čiji se

izračun temelji na rezultatima rangiranja n varijabli koje pripadaju istom skupu. Obzirom da se procjena težina varijabli performansi temeljila na brojčanim ocjenama, iste je prije izračuna koeficijenta W bilo potrebno konvertirati u rangove (Sheskin, 2004). Vrijednosti Kendallovog koeficijenta W se nalaze u intervalu [0,1] gdje 0 predstavlja odsutnost podudaranja, a 1 potpuno podudaranje. Daljnji se postupak izračuna Kendallovog koeficijenta podudaranja W i testiranja njegove značajnosti temeljio na koracima koje su predložili Siegel i Castellan Jr. (1988):

- Za svaku od N varijabli performansi izračunata je suma rangova R_i koje je pojedinoj varijabli performansi pridružilo k stručnjaka domene. Nakon toga je svaka suma rangova R_i kvadrirana.
- U situacijama kada u skupu procjena stručnjaka domene nije bilo izjednačenih rangova, koeficijent W se izračunavao pomoću sljedeće formule:

$$W = \frac{12\sum R_i^2 - 3k^2N(N+1)^2}{k^2N(N^2-1)} \tag{6.6}$$

- U slučajevima kada su u skupu procjena stručnjaka domene postojali izjednačeni rangovi, koeficijent W se izračunavao pomoću sljedeće formule:

$$W = \frac{12\sum R_i^2 - 3k^2N(N+1)^2}{k^2N(N^2-1) - k\sum T_j} \tag{6.7}$$

  gdje $\sum T_j$ označava sumu vrijednosti faktora korekcije izjednačenosti rangova za svih k stručnjaka domene odnosno skupova rangova. Faktor korekcije izjednačenosti rangova T_j za j-ti skup rangova se izračunavao na sljedeći način:

$$T_j = \sum_{i=1}^{g_j} \left(t_i^3 - t_i\right) \tag{6.8}$$

  pri čemu t_i označava broj varijabli izjednačenog ranga u i-toj grupi izjednačenosti dok g_j predstavlja broj grupa izjednačenosti u j-tom skupu rangova.
- Obzirom da je u grupnom procjenjivanju težina sudjelovalo 29 stručnjaka domene, bilo je potrebno izračunati $\chi^2 = k(N-1)W$ koji ima približno jednaku distribuciju kao i hi-kvadrat sa $n-1$ stupnjeva slobode te se shodno tome vrjednovanje značajnosti koeficijenta podudaranja W temeljilo na referentnim vrijednostima za hi-kvadrat distribuciju koje se nalaze u tablici C (Siegel i Castellan, 1988, str. 323).

Vrijednosti Kendallovog koeficijenta podudaranja W za sve latentne varijable koje su prema vezama u stablu zahtjeva bile uključene u izračun globalne preferencije kvalitete u korištenju Web 2.0 aplikacijama prikazane su u tablici 6.32.

Tablica 6.32 Razina podudaranja između stručnjaka domene u grupnom procjenjivanju težina

Latentne varijable	**Kendallov *W****
Dohvatljivost	0,966
Dosljednost	0,764
Dostupnost	0,830
Estetika	0,702
Familijarnost	0,860
Funkcionalna prikladnost	0,642
Interoperabilnost	0,664
Jedinstvenost	0,817
Korisnost	0,799
Kvaliteta sustava	0,833
Kvaliteta usluge	0,676
Lakoća korištenja	0,669
Lakoća učenja korištenja	0,727
Lojalnost	0,823
Mogućnost interakcije	0,740
Mogućnost kontrole	0,719
Mogućnost oporavka	0,622
Mogućnost prilagodbe	0,716
Napor	0,897
Operabilnost	0,755
Otvorenost	0,833
Pamtljivost	0,776
Podrška korisnicima	0,862
Pouzdanost	0,773
Povratne informacije	0,802
Prenosivost	0,667
Pristupačnost	0,755
Produktivnost	0,798
Radni učinak	0,862
Raspoloživost i pružanje pomoći	0,767
Razigranost	0,792
Razumljivost	0,676

* $p < 0,001$

Tablica 6.32 Razina podudaranja između stručnjaka domene u grupnom procjenjivanju težina (nastavak)

Latentne varijable	Kendallov W*
Sigurnost	0,744
Sprječavanje pogrješaka	0,752
Stav prema korištenju	0,743
Sveobuhvatnost konteksta	0,648
Upravljanje artefaktima	0,759
Upravljivost	0,650
Užitak	0,769
Zadovoljstvo	0,762
Zamijećena djelotvornost	0,855
Zamijećena skalabilnost	0,683
Zamijećena učinkovitost	0,824
Zamijećeno radno opterećenje	0,672
Zamijećeno vrijeme odaziva	0,687

* $p < 0{,}001$

Iz tablice 6.32 je vidljivo da su se ocjene stručnjaka domene najviše podudarale kod procjenjivanja težina za latentnu varijablu „dohvatljivost“ ($W = 0{,}966$) dok je razlika među istima bila najveća u slučaju procjene težine latentne varijable „mogućnost oporavka“ ($W = 0{,}622$). Obzirom da su sve vrijednosti Kendallovog koeficijenta podudaranja W značajno različite od nule ($p < 0{,}001$), može se zaključiti da ocjene koje su stručnjaci domene dodijelili latentnim varijablama nisu nezavisne. Međutim, potrebno je napomenuti da koeficijent podudaranja W nije računat za latentne varijable kojima je pridružena samo jedna manifestna varijabla (izmjerena djelotvornost, izmjereno radno opterećenje i izmjerena učinkovitost) već su one sudjelovale u izračunu koeficijenta podudaranja W za kompozitnu latentnu varijablu (zamijećena djelotvornost, zamijećeno radno opterećenje i zamijećena učinkovitost, respektivno) na koju, prema konceptualnom modelu, imaju utjecaj.

6.3 Prvi eksperiment

Tijekom prvog eksperimenta sudionici su izvršavali pedeset koraka scenarija (nalazi se u Prilogu F) od čega su dva bili uvodna, tri završna, dok ih je 45 bilo reprezentativno u kontekstu interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta. Svaki sudionik je dva puta prolazio kroz identičan scenarij – prvi put upotrebom Web 2.0 aplikacije Zoho Writer[9] (prikazana na slici 6.22), a drugi put primjenom Web 2.0 aplikacije Microsoft Word Web App[10] (ilustrirana na slici 6.23).

Zbirni podaci prikazani u tablici 6.33 impliciraju da su sudionici u prvom eksperimentu upotrebljavali svih pet najpopularnijih web preglednika[11]. Google Chrome je kao dominantan web preglednik upotrebljavalo 73,11% sudionika dok se Mozillom Firefox kao alternativnim web preglednikom za izvršavanje četiri specifična koraka scenarija koristilo 62,88% sudionika.

Tablica 6.33 Struktura sudionika u prvom eksperimentu prema učestalosti upotrebe web preglednika tijekom izvršavanja koraka scenarija interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta

Naziv web preglednika	**Dominantan web preglednik**		**Alternativan web preglednik**	
	Frekvencija	**%**	**Frekvencija**	**%**
Apple Safari	63	23,86	0	0,00
Google Chrome	193	73,11	62	23,48
Microsoft Internet Explorer	8	3,03	30	11,36
Mozilla Firefox	0	0,00	166	62,88
Opera	0	0,00	6	2,27
Ukupno	264	100,00	264	100,00

[9] https://writer.zoho.com
[10] http://office.microsoft.com/en-us/web-apps/
[11] http://www.w3schools.com/browsers/browsers_stats.asp

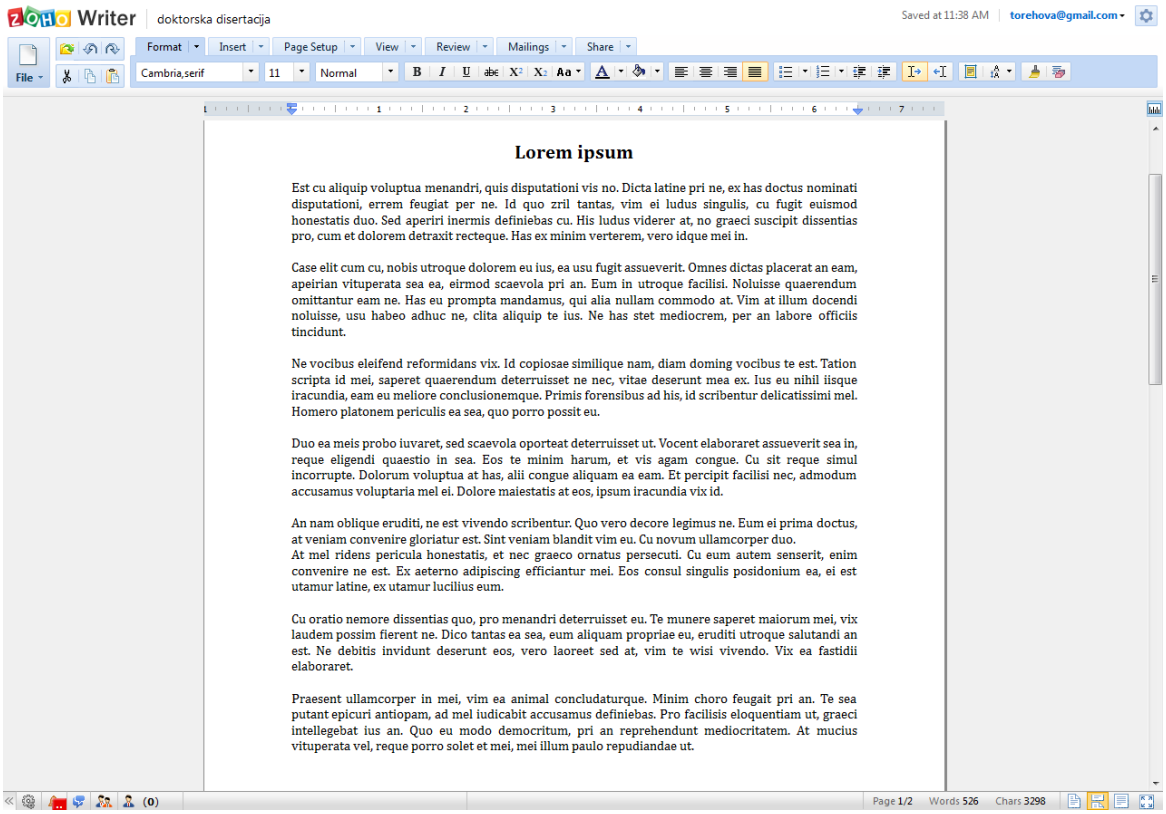

Slika 6.21 Radno okruženje Web 2.0 aplikacije Zoho Writer

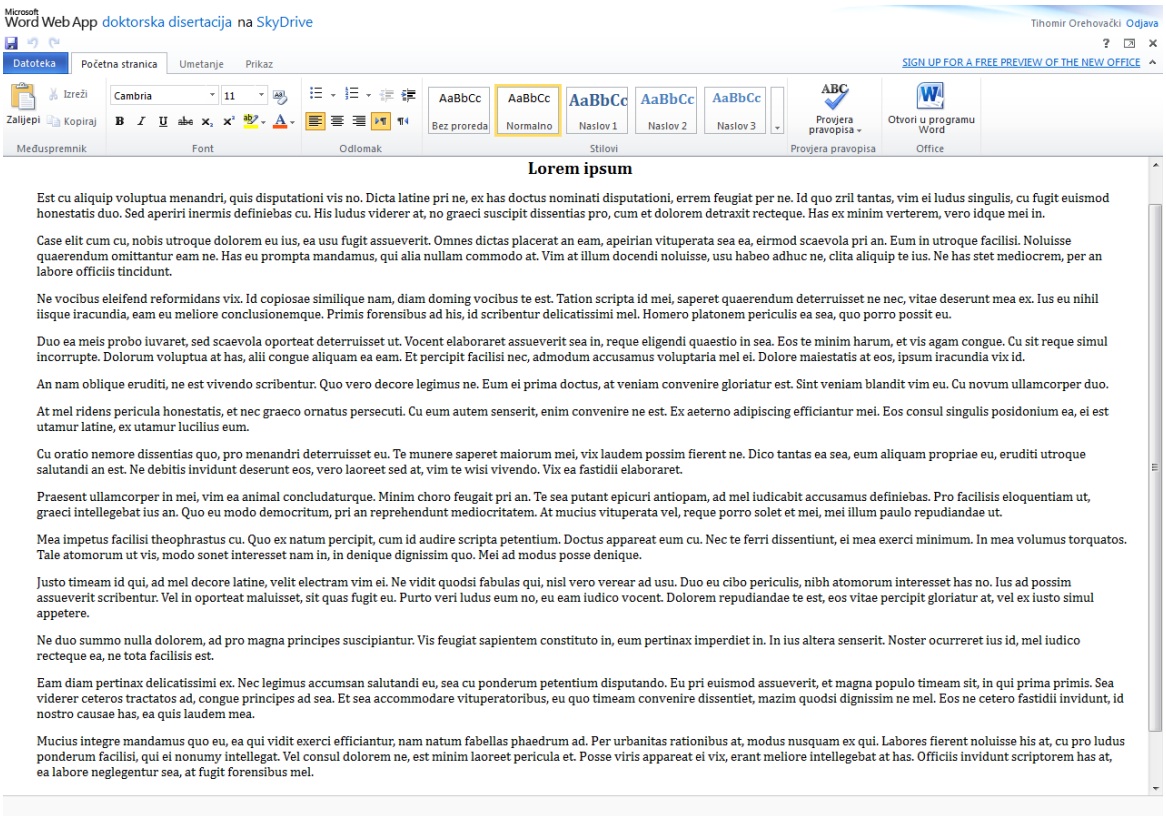

Slika 6.22 Radno okruženje Web 2.0 aplikacije Microsoft Word Web App

6.3.1 Karakteristike sudionika

Tijekom prvog eksperimenta prikupljeno je ukupno 264 ispravno popunjenih upitnika i Mousotron izvještaja sa svim relevantnim podacima. Jednako toliko bilo je i u potpunosti popunjenih izvještaja vezanih uz djelotvornost korisnika u izvršavanju reprezentativnog skupa predefiniranih koraka scenarija. Distribucija sudionika u prvom eksperimentu prema spolu, visokoškolskoj ustanovi i godini studija koju pohađaju prikazana je u tablicama 6.34-6.36, respektivno. Osim toga, njihova struktura prema starosnoj dobi te godinama iskustva u interakciji sa računalom i korištenju Internetom ilustrirana je grafikonima 6.1-6.3, respektivno. Od ukupno 264 sudionika u prvom eksperimentu, njih 59,47% je bilo muškog, a 40,53% ženskog spola.

Tablica 6.34 Struktura sudionika u prvom eksperimentu prema spolu

Spol	Frekvencija	%
Muški	157	59,47
Ženski	107	40,53
Ukupno	264	100,00

Prosječna starosna dob je iznosila 20,59 godina ($\sigma = 2{,}175$) pri čemu su najmlađi sudionici imali 18, a najstariji 38 godina. Obzirom da je riječ o populaciji studenata, većina (74,24%) ih je imala između 19 i 21 godinu.

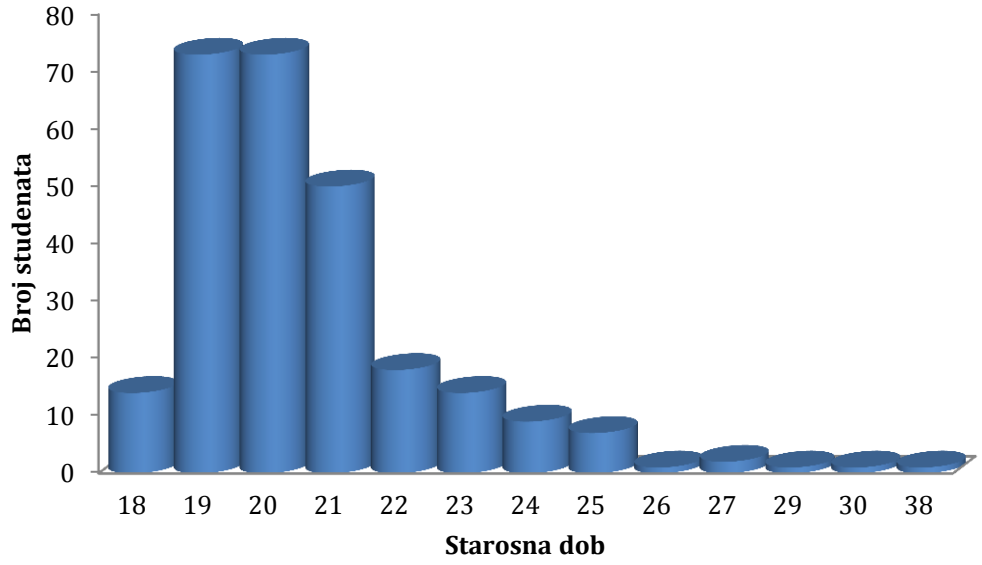

Grafikon 6.1 Struktura sudionika u prvom eksperimentu prema starosnoj dobi

Uzorak sudionika prvog eksperimenta je svojim većim dijelom bio sačinjen od studenata sa Veleučilišta u Rijeci (35,61%) i Fakulteta organizacije i informatike u Varaždinu (34,47%).

Tablica 6.35 Struktura sudionika u prvom eksperimentu prema visokoškolskoj ustanovi koju pohađaju

Naziv visokoškolske ustanove	Grad	Država	Frekvencija	%
Ekonomski fakultet	Split	Hrvatska	24	9,09
Fakultet organizacije i informatike	Varaždin	Hrvatska	91	34,47
Filozofski fakultet	Osijek	Hrvatska	30	11,36
Veleučilište u Rijeci	Rijeka	Hrvatska	94	35,61
Escola Politècnica Superior	Lleida	Španjolska	18	6,82
Universidad del Quindío	Armenia	Kolumbija	5	1,89
Universidad Tecnológica de Panamá	Panama	Panama	1	0,38
Universidad Nacional de San Juan	San Juan	Argentina	1	0,38
Ukupno			264	100,00

Studenti su većinom (90,53%) bili polaznici preddiplomskog studija. Naime, uzorak sudionika u prvom eksperimentu se sastojao od podjednakog broja (37,88%) studenata prve i druge godine preddiplomskog studija.

Tablica 6.36 Struktura sudionika u prvom eksperimentu prema godini studija koju pohađaju

Godina studija	Frekvencija	%
Prva godina preddiplomskog studija	100	37,88
Druga godina preddiplomskog studija	100	37,88
Treća godina preddiplomskog studija	39	14,77
Prva godina diplomskog studija	20	7,58
Druga godina diplomskog studija	5	1,89
Ukupno	264	100,00

Sudionici su imali u prosjeku 9,81 godina iskustva ($\sigma = 2{,}611$) u interakciji sa računalom. Od ukupno 264 sudionika, 1,52% ih je imalo samo četiri godine iskustva u korištenju računalom dok ih je jednako toliko upotrebljavalo računalo više od petnaest godina.

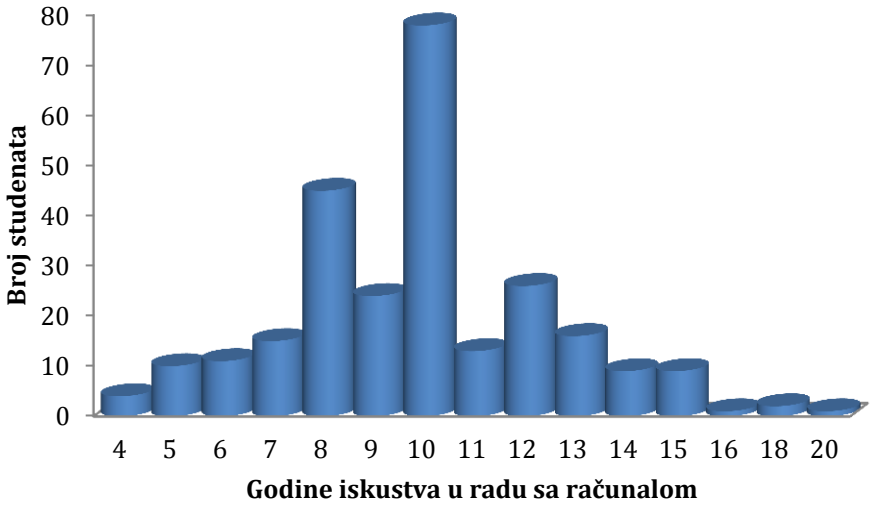

Grafikon 6.2 Struktura sudionika u prvom eksperimentu prema godinama iskustva u interakciji sa računalom

U trenutku provođenja prvog eksperimenta sudionici su imali prosječno 7,66 godina iskustva ($\sigma = 2{,}455$) u interakciji sa Internetom. Samo je 3,42% sudionika upotrebljavalo Internet manje od četiri godine te ih se jednako toliko koristilo Internetom više od dvanaest godina.

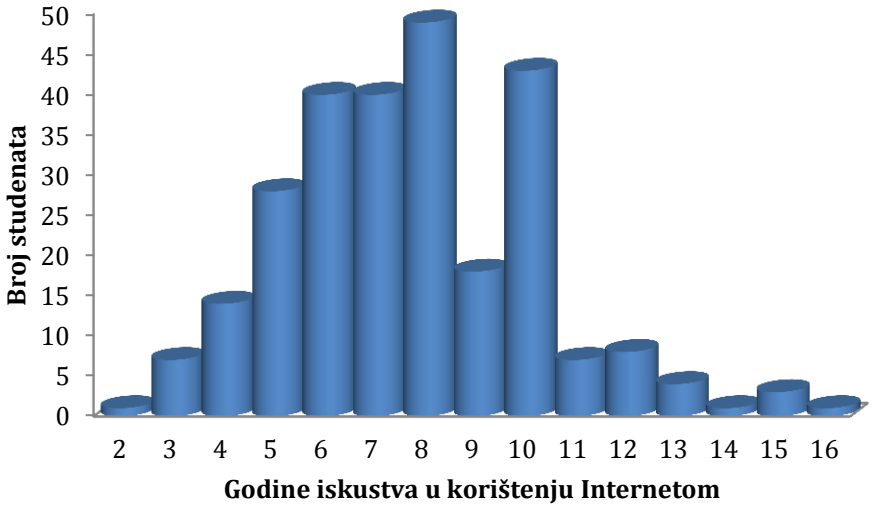

Grafikon 6.3 Struktura sudionika u prvom eksperimentu prema godinama iskustva u korištenju Internetom

Zbirni podaci u tablici 6.37 zorno pokazuju da se većina sudionika prvog eksperimenta koristi Internetom najmanje jednom dnevno u svrhu komunikacije (72,73%) i zabave (61,74%) te obrazovanja (55,68%). Iz podataka prikazanih u tablici 6.38 je evidentno da najveći broj

sudionika na korištenje Internetom utroši minimalno četiri sata tjedno od čega njih 78,04% u svrhu komunikacije, 75,37% radi zabave, a 68,18% za potrebe obrazovanja. Obzirom da je riječ o uzorku studenata, gotovo pola (46,97%) ih ne upotrebljava Internet u poslovne svrhe.

Kao što je i vidljivo iz podataka prikazanih u tablici 6.39, najpopularnije Web 2.0 aplikacije među studentima su društvene mreže i video podcasting servisi. Naime, najveći broj studenata upotrebljava Facebook (51,52%) najmanje tri puta dnevno, a YouTube (67,04%) jednom do dva puta dnevno ili češće. Od preostalih Web 2.0 aplikacija, 54,93% studenata se barem tri puta tjedno koristi Gmailom dok ih 65,53% upotrebljava Wikipediju minimalno jednom tjedno.

U tablici 6.40 se nalaze rezultati samoprocjene sudionika prvog eksperimenta u kontekstu poznavanja rada na računalu te korištenju Internetom i Web 2.0 aplikacijama. Od ukupnog broja sudionika, 42,80% ih smatra da vrlo dobro poznaje rad na računalu, 46,59% je mišljenja da se vrlo dobro služi Internetom dok 34,47% vjeruje da dobro poznaje interakciju sa Web 2.0 aplikacijama.

Tablica 6.37 Struktura sudionika u prvom eksperimentu prema intenzitetu i svrsi korištenja Internetom

Intenzitet korištenja	Komunikacija		Obrazovanje		Zabava		Posao	
	Frekvencija	%	Frekvencija	%	Frekvencija	%	Frekvencija	%
Ne koristim	1	0,38	2	0,76	3	1,14	124	46,97
Manje od jednom tjedno	5	1,89	10	3,79	11	4,17	38	14,39
1-2 puta tjedno	20	7,58	40	15,15	38	14,39	42	15,91
3-6 puta tjedno	46	17,42	65	24,62	49	18,56	20	7,58
1-2 puta dnevno	66	25,00	81	30,68	67	25,38	22	8,33
3 i više puta dnevno	126	47,73	66	25,00	96	36,36	18	6,82
Ukupno	264	100,00	264	100,00	264	100,00	264	100,00

Tablica 6.38 Struktura sudionika u prvom eksperimentu prema učestalosti i svrsi korištenja Internetom

Učestalost korištenja	Komunikacija		Obrazovanje		Zabava		Posao	
	Frekvencija	%	Frekvencija	%	Frekvencija	%	Frekvencija	%
Ne koristim	1	0,38	2	0,76	3	1,14	124	46,97
Manje od sata tjedno	11	4,17	14	5,30	23	8,71	44	16,67
1-3 sata tjedno	46	17,42	68	25,76	39	14,77	43	16,29
4-10 sati tjedno	69	26,14	82	31,06	71	26,89	25	9,47
11-20 sati tjedno	60	22,73	55	20,83	63	23,86	18	6,82
21-40 sati tjedno	45	17,05	34	12,88	38	14,39	5	1,89
Više od 40 sati tjedno	32	12,12	9	3,41	27	10,23	5	1,89
Ukupno	264	100,00	264	100,00	264	100,00	264	100,00

Tablica 6.39 Struktura sudionika u prvom eksperimentu prema učestalosti korištenja Web 2.0 aplikacijama

Web 2.0 aplikacije	Ne koristim		Manje od jednom tjedno		1-2 puta tjedno		3-6 puta tjedno		1-2 puta dnevno		3 i više puta dnevno		Ukupno	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Digg	253	95,83	7	2,65	4	1,52	0	0,00	0	0,00	0	0,00	264	100,00
Facebook	21	7,95	2	0,76	11	4,17	37	14,02	57	21,59	136	51,52	264	100,00
Flickr	233	88,26	19	7,20	9	3,41	1	0,38	1	0,38	1	0,38	264	100,00
Gmail	59	22,35	22	8,33	38	14,39	36	13,64	60	22,73	49	18,56	264	100,00
Last.fm	223	84,47	15	5,68	15	5,68	5	1,89	3	1,14	3	1,14	264	100,00
Mahara	250	94,70	10	3,79	2	0,76	1	0,38	1	0,38	0	0,00	264	100,00
Second Life	258	97,73	4	1,52	2	0,76	0	0,00	0	0,00	0	0,00	264	100,00
Skype	81	30,68	53	20,08	33	12,50	25	9,47	24	9,09	48	18,18	264	100,00
Twitter	228	86,36	13	4,92	4	1,52	4	1,52	5	1,89	10	3,79	264	100,00
YouTube	5	1,89	4	1,52	24	9,09	54	20,45	55	20,83	122	46,21	264	100,00
WordPress	225	85,23	20	7,58	12	4,55	4	1,52	1	0,38	2	0,76	264	100,00
Wikipedia	22	8,33	69	26,14	89	33,71	51	19,32	22	8,33	11	4,17	264	100,00

Tablica 6.40 Struktura sudionika u prvom eksperimentu prema samoprocjeni poznavanja rada na računalu te korištenja Internetom i Web 2.0 aplikacijama

Razina poznavanja	**Rad na računalu**		**Upotreba Interneta**		**Korištenje Web 2.0 aplikacijama**	
	Frekvencija	**%**	**Frekvencija**	**%**	**Frekvencija**	**%**
Odlično	56	21,21	70	26,52	26	9,85
Vrlo dobro	113	42,80	123	46,59	58	21,97
Dobro	87	32,95	69	26,14	91	34,47
Slabo	8	3,03	2	0,76	73	27,65
Vrlo slabo	0	0,00	0	0,00	16	6,06
Ukupno	264	100,00	264	100,00	264	100,00

6.3.2 Rezultati analize metrijskih karakteristika konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer

Analiza metrijskih karakteristika započela je vrjednovanjem pouzdanosti manifestnih varijabli na svim razinama višedimenzionalnog konceptualnog modela. Vrjednovanje pouzdanosti reflektivnih manifestnih varijabli sastojalo se od analize njihovih standardiziranih faktorskih opterećenja dok je vrjednovanje pouzdanosti formativnih manifestnih varijabli bilo sačinjeno od analize značajnosti njihovih standardiziranih faktorskih opterećenja i težinskih vrijednosti.

Vrijednosti standardiziranih faktorskih opterećenja koje su poprimile reflektivne manifestne varijable na prvoj, drugoj i trećoj razini u konceptualnom modelu prikazane su u tablicama 6.41–6.43, respektivno. Iz spomenutih je tablica vidljivo da se vrijednosti standardiziranih faktorskih opterećenja nalaze u intervalu od 0,712 do 0,950 što implicira da reflektivne manifestne varijable objašnjavaju između 50,69% i 90,25% varijance temeljnih latentnih konstrukata. Prema tome, sve su reflektivne manifestne varijable u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer pouzdane.

Rezultati analize značajnosti apsolutnog doprinosa formativnih manifestnih varijable prve, druge i treće razine u konceptualnom modelu prikazani su u tablicama 6.44–6.46, respektivno. Tablica 6.44 jasno prikazuje da je većina (89,06%) standardiziranih faktorskih opterećenja formativnih manifestnih varijabli prve razine značajna na razini $\alpha = 0{,}001$, 9,38% ih je značajno na razini $\alpha = 0{,}01$ dok ih je 1,56% značajno na razini $\alpha = 0{,}05$. Iz tablica 6.45 i 6.46 je vidljivo da su standardizirana faktorska opterećenja svih formativnih manifestnih varijabli na drugoj i trećoj razini značajna na razini $\alpha = 0{,}001$. Rezultati vrjednovanja značajnosti relativnog doprinosa formativnih manifestnih varijabli prve, druge i treće razine višedimenzionalnog modela nalaze se u tablicama 6.47–6.49, respektivno. Iz tablice 6.47 je vidljivo da su težinske vrijednosti većine (93,75%) formativnih manifestnih varijabli prve razine značajne na razini $\alpha = 0{,}001$ dok ih je preostalih 6,25% značajno na razini $\alpha = 0{,}01$. Tablica 6.48 zorno prikazuje da je 81,82% težinskih vrijednosti formativnih manifestnih varijabli druge razine značajno na razini $\alpha = 0{,}001$ dok ih je po 9,09% značajno na razinama $\alpha = 0{,}01$ i $\alpha = 0{,}05$. Konačno, iz tablice 6.49 je očigledno da je 50% težinskih vrijednosti formativnih manifestnih varijabli treće razine značajno na razini $\alpha = 0{,}05$ dok ih je po 25% značajno na razinama $\alpha = 0{,}001$ i $\alpha = 0{,}01$. Uzimajući u obzir rezultate vrjednovanja sadržane u tablicama 6.44–6.49, moguće je zaključiti da su sve formativne manifestne varijable u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer pouzdane.

Tablica 6.41 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
DSD2	**0,877**	0,176	0,394	-0,069	0,216	0,397	0,075	0,500	0,337	0,353	0,344	0,149	0,425	0,103	0,194	0,305	0,379	0,385	0,225
DSD3	**0,866**	0,240	0,374	-0,011	0,174	0,412	0,107	0,461	0,320	0,298	0,328	0,126	0,378	0,174	0,144	0,325	0,351	0,330	0,184
DSD4	**0,850**	0,126	0,352	-0,043	0,147	0,366	0,054	0,432	0,282	0,241	0,270	0,061	0,350	0,128	0,079	0,307	0,367	0,258	0,136
EST2	0,228	**0,863**	0,276	0,141	0,292	0,354	0,248	0,304	0,272	0,280	0,268	0,172	0,338	0,278	0,293	0,209	0,255	0,334	0,236
EST4	0,154	**0,827**	0,108	0,314	0,223	0,162	0,208	0,109	0,184	0,018	0,134	0,189	0,141	0,335	0,289	0,248	0,246	0,254	0,071
EST5	0,172	**0,912**	0,216	0,217	0,253	0,287	0,285	0,180	0,156	0,145	0,200	0,175	0,204	0,348	0,320	0,226	0,238	0,284	0,147
FML1	0,409	0,129	**0,826**	-0,001	0,317	0,549	0,274	0,519	0,290	0,460	0,386	0,237	0,441	0,239	0,285	0,433	0,457	0,457	0,221
FML3	0,316	0,233	**0,855**	0,065	0,260	0,363	0,127	0,512	0,325	0,390	0,434	0,193	0,526	0,169	0,208	0,277	0,288	0,369	0,285
FML4	0,391	0,231	**0,891**	-0,047	0,249	0,441	0,147	0,558	0,323	0,469	0,464	0,182	0,602	0,172	0,242	0,322	0,386	0,410	0,322
JDN1	-0,026	0,265	0,038	**0,908**	0,392	0,128	0,470	0,065	0,221	0,115	0,187	0,496	0,141	0,354	0,499	0,301	0,272	0,364	-0,009
JDN2	-0,081	0,184	-0,025	**0,851**	0,322	-0,036	0,256	-0,023	0,167	-0,054	0,117	0,335	0,116	0,228	0,316	0,226	0,175	0,191	-0,065
JDN3	-0,037	0,219	-0,015	**0,899**	0,329	0,019	0,385	-0,017	0,120	-0,003	0,116	0,324	0,114	0,206	0,392	0,265	0,189	0,237	-0,065
KRS2	0,148	0,262	0,287	0,377	**0,928**	0,427	0,503	0,329	0,398	0,342	0,404	0,483	0,435	0,415	0,595	0,540	0,539	0,624	0,269
KRS3	0,166	0,306	0,276	0,429	**0,905**	0,454	0,475	0,339	0,384	0,386	0,376	0,463	0,442	0,389	0,568	0,523	0,599	0,618	0,235
KRS4	0,269	0,252	0,325	0,300	**0,941**	0,515	0,496	0,349	0,406	0,374	0,420	0,432	0,482	0,369	0,546	0,578	0,634	0,665	0,237
LAK1	0,399	0,295	0,430	0,069	0,506	**0,910**	0,402	0,513	0,544	0,527	0,459	0,281	0,464	0,346	0,459	0,574	0,609	0,643	0,360
LAK2	0,421	0,282	0,542	0,068	0,481	**0,950**	0,332	0,592	0,552	0,638	0,471	0,252	0,506	0,296	0,392	0,539	0,615	0,650	0,386
LAK3	0,453	0,292	0,498	0,020	0,429	**0,944**	0,319	0,590	0,526	0,627	0,406	0,167	0,498	0,299	0,355	0,497	0,571	0,613	0,439
LOJ1	0,081	0,255	0,223	0,365	0,470	0,342	**0,927**	0,245	0,192	0,308	0,199	0,456	0,218	0,482	0,567	0,414	0,409	0,529	0,177
LOJ2	0,123	0,284	0,221	0,425	0,511	0,357	**0,909**	0,268	0,244	0,319	0,203	0,449	0,233	0,462	0,596	0,442	0,441	0,529	0,136
LOJ3	0,050	0,251	0,139	0,410	0,488	0,334	**0,927**	0,220	0,203	0,275	0,168	0,456	0,155	0,452	0,583	0,418	0,459	0,488	0,106
LUK1	0,528	0,233	0,569	0,006	0,314	0,562	0,257	**0,949**	0,468	0,676	0,485	0,264	0,523	0,243	0,336	0,400	0,459	0,554	0,416
LUK2	0,516	0,200	0,547	0,023	0,379	0,588	0,261	**0,934**	0,433	0,656	0,494	0,265	0,520	0,224	0,345	0,401	0,482	0,548	0,437
LUK3	0,485	0,210	0,626	0,021	0,343	0,559	0,233	**0,940**	0,407	0,688	0,494	0,214	0,568	0,216	0,313	0,368	0,433	0,535	0,456

Tablica 6.41 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer (nastavak)

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
MOK1	0,360	0,150	0,291	0,142	0,422	0,582	0,255	0,419	**0,838**	0,428	0,399	0,317	0,448	0,329	0,336	0,494	0,557	0,511	0,166
MOK2	0,089	0,159	0,191	0,195	0,245	0,242	0,076	0,212	**0,712**	0,208	0,263	0,181	0,304	0,186	0,118	0,312	0,312	0,252	0,077
MOK3	0,337	0,262	0,368	0,167	0,322	0,463	0,168	0,421	**0,861**	0,367	0,421	0,232	0,465	0,318	0,232	0,479	0,429	0,414	0,241
PMT1	0,358	0,149	0,493	0,044	0,337	0,604	0,318	0,702	0,402	**0,933**	0,483	0,297	0,482	0,238	0,330	0,298	0,419	0,593	0,412
PMT2	0,342	0,161	0,481	0,043	0,404	0,572	0,284	0,687	0,412	**0,941**	0,509	0,281	0,565	0,200	0,357	0,356	0,425	0,563	0,453
PMT3	0,279	0,167	0,462	0,013	0,369	0,615	0,311	0,609	0,426	**0,921**	0,448	0,247	0,460	0,269	0,321	0,373	0,449	0,550	0,388
PZD3	0,347	0,239	0,482	0,174	0,431	0,497	0,229	0,511	0,466	0,493	**0,938**	0,334	0,557	0,266	0,324	0,446	0,474	0,593	0,257
PZD4	0,357	0,221	0,492	0,184	0,439	0,448	0,208	0,497	0,485	0,497	**0,946**	0,359	0,614	0,241	0,344	0,393	0,427	0,594	0,324
PZD5	0,271	0,145	0,341	0,050	0,254	0,303	0,088	0,372	0,244	0,377	**0,786**	0,137	0,442	0,154	0,162	0,198	0,279	0,408	0,206
RZG1	0,198	0,242	0,296	0,357	0,450	0,256	0,379	0,313	0,336	0,334	0,346	**0,746**	0,325	0,350	0,493	0,466	0,423	0,482	0,173
RZG5	0,080	0,162	0,199	0,406	0,441	0,230	0,467	0,203	0,253	0,238	0,260	**0,928**	0,242	0,323	0,581	0,424	0,413	0,448	0,079
RZG6	0,083	0,132	0,127	0,390	0,393	0,159	0,423	0,173	0,238	0,199	0,248	**0,901**	0,227	0,244	0,529	0,354	0,345	0,392	0,069
RZM2	0,409	0,298	0,524	0,147	0,506	0,519	0,240	0,530	0,529	0,520	0,571	0,356	**0,876**	0,318	0,371	0,459	0,527	0,556	0,420
RZM3	0,399	0,222	0,582	0,121	0,400	0,439	0,183	0,496	0,426	0,458	0,532	0,209	**0,912**	0,191	0,319	0,409	0,428	0,512	0,340
RZM4	0,409	0,188	0,556	0,114	0,421	0,460	0,172	0,520	0,449	0,484	0,549	0,256	**0,924**	0,206	0,323	0,420	0,504	0,575	0,401
SPK1	0,173	0,345	0,217	0,264	0,393	0,311	0,445	0,240	0,343	0,245	0,238	0,320	0,282	**0,946**	0,449	0,429	0,462	0,413	0,238
SPK2	0,153	0,334	0,256	0,269	0,412	0,324	0,462	0,236	0,328	0,223	0,242	0,305	0,266	**0,931**	0,442	0,441	0,482	0,424	0,234
SPK3	0,107	0,354	0,159	0,323	0,377	0,302	0,504	0,203	0,343	0,238	0,230	0,362	0,195	**0,920**	0,479	0,413	0,445	0,406	0,239
UTK2	0,139	0,315	0,224	0,430	0,509	0,333	0,555	0,276	0,286	0,290	0,277	0,589	0,323	0,458	**0,913**	0,426	0,441	0,588	0,265
UTK4	0,151	0,290	0,258	0,463	0,519	0,374	0,601	0,307	0,250	0,296	0,249	0,600	0,300	0,430	**0,926**	0,444	0,431	0,583	0,255
UTK5	0,174	0,348	0,300	0,396	0,659	0,468	0,582	0,383	0,324	0,403	0,361	0,525	0,403	0,460	**0,913**	0,507	0,519	0,711	0,361
ZAD2	0,239	0,216	0,296	0,237	0,502	0,443	0,411	0,313	0,445	0,255	0,292	0,418	0,324	0,433	0,434	**0,813**	0,667	0,447	0,147
ZAD3	0,371	0,213	0,373	0,260	0,533	0,509	0,365	0,409	0,524	0,339	0,422	0,443	0,464	0,408	0,470	**0,904**	0,624	0,608	0,205
ZAD4	0,318	0,249	0,366	0,286	0,502	0,530	0,422	0,348	0,461	0,351	0,330	0,385	0,439	0,354	0,398	**0,874**	0,617	0,581	0,179

Tablica 6.41 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer (nastavak)

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
ZAU1	0,460	0,244	0,407	0,137	0,495	0,670	0,359	0,496	0,493	0,483	0,402	0,328	0,501	0,342	0,415	0,548	**0,806**	0,636	0,315
ZAU3	0,245	0,260	0,343	0,286	0,576	0,461	0,435	0,345	0,462	0,332	0,413	0,423	0,469	0,485	0,460	0,686	**0,837**	0,558	0,258
ZAU4	0,349	0,201	0,346	0,191	0,521	0,462	0,385	0,370	0,453	0,336	0,309	0,386	0,372	0,409	0,385	0,593	**0,849**	0,516	0,175
ZDV1	0,419	0,292	0,460	0,263	0,584	0,622	0,466	0,569	0,496	0,561	0,591	0,447	0,581	0,367	0,582	0,586	0,625	**0,917**	0,345
ZDV2	0,329	0,261	0,436	0,271	0,663	0,657	0,532	0,544	0,487	0,549	0,559	0,439	0,569	0,390	0,615	0,606	0,649	**0,930**	0,322
ZDV4	0,311	0,364	0,425	0,320	0,640	0,589	0,535	0,484	0,447	0,567	0,521	0,512	0,519	0,460	0,682	0,552	0,614	**0,902**	0,371
ZRO1	0,219	0,220	0,342	-0,001	0,311	0,492	0,220	0,460	0,236	0,449	0,333	0,138	0,408	0,281	0,334	0,280	0,370	0,438	**0,900**
ZRO2	0,200	0,118	0,255	-0,106	0,199	0,344	0,132	0,405	0,132	0,398	0,236	0,081	0,397	0,180	0,260	0,127	0,230	0,300	**0,908**
ZRO3	0,153	0,121	0,260	-0,019	0,195	0,279	0,041	0,369	0,206	0,346	0,225	0,103	0,339	0,215	0,262	0,132	0,191	0,261	**0,867**

Tablica 6.42 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	OPR	PDK
LAK	**0,848**	0,651
LUK	**0,885**	0,483
PMT	**0,898**	0,445
ZAD	0,512	**0,929**
ZAU	0,600	**0,933**

Tablica 6.43 Vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	NPR
OPR	0,899
ZRO	0,835

Tablica 6.44 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DST1 -> DST	0,826	0,825	0,027	30,930***
DST4 -> DST	0,447	0,445	0,061	7,367***
DST5 -> DST	0,343	0,341	0,067	5,135***
INT1 -> INT	0,675	0,671	0,069	9,814***
INT2 -> INT	0,488	0,486	0,074	6,580***
INT3 -> INT	0,553	0,549	0,082	6,743***
IRO1 -> IRO	0,475	0,471	0,075	6,300***
IRO2 -> IRO	0,567	0,560	0,085	6,710***
IRO3 -> IRO	0,448	0,445	0,091	4,946***
IRO4 -> IRO	0,503	0,501	0,085	5,891***
MIN1 -> MIN	0,414	0,410	0,067	6,216***
MIN2 -> MIN	0,333	0,333	0,078	4,294***
MIN5 -> MIN	0,500	0,498	0,063	7,876***
MIN7 -> MIN	0,601	0,599	0,054	11,175***
MIN8 -> MIN	0,328	0,330	0,074	4,436***
MOP1 -> MOP	0,486	0,467	0,166	2,927**
MOP2 -> MOP	0,503	0,482	0,166	3,025**
MOP4 -> MOP	0,714	0,695	0,135	5,288***
MPR1 -> MPR	0,737	0,719	0,122	6,066**
MPR2 -> MPR	0,430	0,406	0,151	2,850**
MPR3 -> MPR	0,521	0,509	0,148	3,518***
PIN1 -> PIN	0,379	0,377	0,074	5,123***
PIN2 -> PIN	0,301	0,299	0,080	3,775***
PIN3 -> PIN	0,610	0,610	0,050	12,162***
PIN4 -> PIN	0,438	0,439	0,077	5,720***
PIN6 -> PIN	0,460	0,456	0,065	7,101***
PNS1 -> PNS	0,505	0,502	0,069	7,291***
PNS2 -> PNS	0,610	0,607	0,059	10,350***
PNS3 -> PNS	0,611	0,609	0,057	10,665***
PST1 -> PST	0,612	0,611	0,076	8,053***
PST4 -> PST	0,454	0,447	0,083	5,476***
PST6 -> PST	0,648	0,642	0,068	9,553***
RIP1 -> RIP	0,377	0,370	0,079	4,782***
RIP3 -> RIP	0,331	0,334	0,074	4,466***
RIP5 -> RIP	0,627	0,629	0,053	11,730***
RIP6 -> RIP	0,425	0,421	0,058	7,284***
RIP7 -> RIP	0,434	0,435	0,065	6,695***

** p < 0,01; *** p < 0,001

Tablica 6.44 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer (nastavak)

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
SGR3 -> SGR	0,376	0,374	0,085	4,421***
SGR4 -> SGR	0,476	0,474	0,073	6,500***
SGR5 -> SGR	0,492	0,484	0,080	6,133***
SGR6 -> SGR	0,472	0,466	0,067	7,087***
SGR10 -> SGR	0,409	0,396	0,083	4,904***
SPO1 -> SPO	0,741	0,709	0,103	7,223***
SPO3 -> SPO	0,523	0,524	0,122	4,300***
SPO4 -> SPO	0,421	0,432	0,135	3,121**
SVK1 -> SVK	0,533	0,527	0,144	3,711***
SVK2 -> SVK	0,561	0,548	0,119	4,702***
SVK3 -> SVK	0,634	0,616	0,122	5,190***
UPA2 -> UPA	0,428	0,431	0,078	5,473***
UPA3 -> UPA	0,424	0,421	0,071	6,006***
UPA4 -> UPA	0,301	0,290	0,074	4,101***
UPA5 -> UPA	0,484	0,482	0,063	7,645***
UPA7 -> UPA	0,559	0,553	0,070	7,941***
UPR1 -> UPR	0,697	0,688	0,080	8,727***
UPR3 -> UPR	0,483	0,473	0,112	4,331***
UPR4 -> UPR	0,233	0,235	0,106	2,197*
UPR5 -> UPR	0,294	0,293	0,112	2,618**
UPR6 -> UPR	0,375	0,359	0,107	3,495***
ZAS1 -> ZAS	0,702	0,698	0,046	15,367***
ZAS3 -> ZAS	0,427	0,427	0,070	6,128***
ZAS4 -> ZAS	0,570	0,572	0,050	11,515***
ZVO2 -> ZVO	0,621	0,612	0,055	11,384***
ZVO3 -> ZVO	0,584	0,587	0,082	7,127***
ZVO4 -> ZVO	0,524	0,522	0,085	6,151***

* $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$

Tablica 6.45 Apsolutna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DST -> DHV	0,934	0,932	0,026	35,606***
INT -> OTV	0,764	0,748	0,098	7,828***
MIN -> FUP	0,893	0,894	0,037	24,482***
PIN -> POK	0,850	0,848	0,033	25,956***
PNS -> OTV	0,814	0,816	0,083	9,812***
PST -> DHV	0,635	0,633	0,053	12,087***
RIP -> POK	0,831	0,832	0,031	27,024***
SGR -> KVS	0,803	0,750	0,126	6,361***
UPA -> FUP	0,808	0,796	0,061	13,195***
ZAS -> RAU	0,894	0,892	0,070	12,715***
ZVO -> RAU	0,735	0,717	0,104	7,058***

*** $p < 0,001$

Tablica 6.46 Apsolutna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DHV -> KVS	0,789	0,776	0,126	6,258***
FUP -> KVU	0,787	0,761	0,131	6,025***
OTV -> KVS	0,721	0,685	0,146	4,938***
POK -> KVU	0,890	0,878	0,090	9,855***

*** $p < 0,001$

Tablica 6.47 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DST1 -> DST	0,826	0,827	0,039	21,413***
DST4 -> DST	0,447	0,447	0,042	10,594***
DST5 -> DST	0,343	0,343	0,031	11,020***
INT1 -> INT	0,675	0,673	0,073	9,226***
INT2 -> INT	0,488	0,479	0,094	5,187***
INT3 -> INT	0,553	0,555	0,088	6,306***
IRO1 -> IRO	0,475	0,471	0,074	6,434***
IRO2 -> IRO	0,567	0,562	0,072	7,845***
IRO3 -> IRO	0,448	0,441	0,082	5,480***
IRO4 -> IRO	0,503	0,498	0,087	5,766***
MIN1 -> MIN	0,414	0,416	0,041	10,232***
MIN2 -> MIN	0,333	0,329	0,042	7,946***
MIN5 -> MIN	0,500	0,498	0,041	12,064***
MIN7 -> MIN	0,601	0,599	0,048	12,480***
MIN8 -> MIN	0,328	0,330	0,038	8,636***
MOP1 -> MOP	0,486	0,467	0,160	3,046**
MOP2 -> MOP	0,503	0,485	0,163	3,088**
MOP4 -> MOP	0,714	0,695	0,136	5,249***
MPR1 -> MPR	0,737	0,723	0,120	6,153***
MPR2 -> MPR	0,430	0,402	0,149	2,886**
MPR3 -> MPR	0,521	0,514	0,150	3,474***
PIN1 -> PIN	0,395	0,393	0,043	9,292***
PIN2 -> PIN	0,291	0,287	0,041	7,188***
PIN3 -> PIN	0,618	0,618	0,052	11,903***
PIN4 -> PIN	0,420	0,419	0,058	7,221***
PIN6 -> PIN	0,440	0,436	0,043	10,164***
PNS1 -> PNS	0,505	0,504	0,050	10,098***
PNS2 -> PNS	0,610	0,609	0,053	11,447***
PNS3 -> PNS	0,611	0,612	0,047	12,941***
PST1 -> PST	0,612	0,613	0,070	8,700***
PST4 -> PST	0,454	0,451	0,075	6,077***
PST6 -> PST	0,648	0,644	0,060	10,796***
RIP1 -> RIP	0,398	0,399	0,046	8,628***
RIP3 -> RIP	0,313	0,312	0,053	5,958***
RIP5 -> RIP	0,613	0,613	0,043	14,258***
RIP6 -> RIP	0,402	0,397	0,044	9,174***
RIP7 -> RIP	0,442	0,437	0,045	9,844***

** $p < 0,01$; *** $p < 0,001$

Tablica 6.47 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer (nastavak)

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
SGR3 -> SGR	0,376	0,375	0,071	5,319***
SGR4 -> SGR	0,476	0,478	0,069	6,945***
SGR5 -> SGR	0,492	0,492	0,059	8,323***
SGR6 -> SGR	0,472	0,469	0,065	7,287***
SGR10 -> SGR	0,409	0,407	0,066	6,195***
SPO1 -> SPO	0,741	0,708	0,104	7,151***
SPO3 -> SPO	0,523	0,524	0,121	4,334***
SPO4 -> SPO	0,421	0,431	0,123	3,430***
SVK1 -> SVK	0,533	0,527	0,145	3,690***
SVK2 -> SVK	0,561	0,548	0,112	5,007***
SVK3 -> SVK	0,634	0,617	0,109	5,826***
UPA2 -> UPA	0,428	0,430	0,055	7,822***
UPA3 -> UPA	0,424	0,422	0,054	7,802***
UPA4 -> UPA	0,301	0,299	0,056	5,412***
UPA5 -> UPA	0,484	0,479	0,061	7,958***
UPA7 -> UPA	0,559	0,560	0,064	8,705***
UPR1 -> UPR	0,697	0,690	0,071	9,872***
UPR3 -> UPR	0,483	0,474	0,084	5,763***
UPR4 -> UPR	0,233	0,235	0,090	2,587**
UPR5 -> UPR	0,294	0,291	0,088	3,350***
UPR6 -> UPR	0,375	0,362	0,078	4,804***
ZAS1 -> ZAS	0,702	0,700	0,040	17,586***
ZAS3 -> ZAS	0,427	0,426	0,038	11,388***
ZAS4 -> ZAS	0,570	0,574	0,047	12,021***
ZVO2 -> ZVO	0,621	0,610	0,058	10,689***
ZVO3 -> ZVO	0,584	0,585	0,075	7,741***
ZVO4 -> ZVO	0,524	0,525	0,071	7,388***

** $p < 0,01$; *** $p < 0,001$

Tablica 6.48 Relativna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DST -> DHV	0,815	0,814	0,042	19,386***
INT -> OTV	0,600	0,579	0,117	5,142***
MIN -> FUP	0,662	0,670	0,077	8,592***
PIN -> POK	0,611	0,609	0,045	13,734***
PNS -> OTV	0,666	0,672	0,098	6,776***
PST -> DHV	0,377	0,376	0,066	5,737***
RIP -> POK	0,578	0,580	0,049	11,782***
SGR -> KVS	0,450	0,400	0,215	2,097*
UPA -> FUP	0,506	0,495	0,083	6,106***
ZAS -> RAU	0,725	0,731	0,119	6,098***
ZVO -> RAU	0,478	0,454	0,148	3,243**

* p < 0,05; ** p < 0,01; *** p < 0,001

Tablica 6.49 Relativna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DHV -> KVS	0,450	0,474	0,204	2,202*
FUP -> KVU	0,502	0,482	0,190	2,644**
OTV -> KVS	0,395	0,377	0,198	1,991*
POK -> KVU	0,680	0,677	0,172	3,955***

* p < 0,05; ** p < 0,01; *** p < 0,001

U sljedećem je koraku provedena analiza pouzdanosti latentnih konstrukata. Pouzdanost reflektivnih latentnih konstrukata vrjednovana je izračunom vrijednosti koeficijenta unutarnje dosljednosti dok se vrjednovanje pouzdanosti formativnih latentnih konstrukata sastojalo od testiranja multikolinearnosti formativnih manifestnih varijabli.

Tablica 6.50 sadrži rezultate vrjednovanja pouzdanosti reflektivnih latentnih konstrukata na svim razinama u višedimenzionalnom konceptualnom modelu. Iz navedene je tablice evidentno da na prvoj razini modela najmanju razinu unutarnje dosljednosti ima reflektivni latentni konstrukt kojim je mjerena mogućnost kontrole ($\rho_c = 0{,}847$) aplikacijom Zoho Writer, a najveću reflektivni latentni konstrukt pomoću kojeg je vrjednovana lakoća učenja korištenja ($\rho_c = 0{,}959$) aplikacijom Zoho Writer. Na drugoj je razini modela utvrđeno da od dva reflektivna latentna konstrukta veći stupanj unutarnje dosljednosti ($\rho_c = 0{,}909$) ima onaj primjenom kojeg je vrjednovana operabilnost aplikacije Zoho Writer. Konačno, kriterij vrjednovanja unutarnje dosljednosti je u slučaju reflektivnog latentnog konstrukta treće razine kojim je mjerena količina napora potrebnog za dovršetak reprezentativnih koraka scenarija upotrebom aplikacije Zoho Writer poprimio vrijednost $\rho_c = 0{,}859$ što predstavlja prihvatljivu razinu pouzdanosti. Shodno tome, reflektivni latentni konstrukti koji se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer su pouzdani. Iz tablice 6.51 je vidljivo da se vrijednosti koeficijenta inflacije varijance (VIF) nalaze u rasponu od 1,012 do 3,619, a vrijednosti koeficijenta tolerancije u intervalu od 0,276 do 0,988. Navedeno implicira da je razina multikolinearnosti između formativnih manifestnih varijabli koje su pridružene istom temeljnom latentnom konstruktu prihvatljiva. Prema tome, svi su formativni latentni konstrukti u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer pouzdani.

Nakon što je utvrđena pouzdanost latentnih konstrukata, pristupilo se vrjednovanju njihove valjanosti. Konvergentna valjanost reflektivnih latentnih konstrukata vrjednovana je analizom vrijednosti prosječnih ekstrahiranih varijanci. Iz tablice 6.50 je vidljivo da se vrijednosti prosječne ekstrahirane varijance (AVE) nalaze u intervalu od 0,650 do 0,886 što znači da reflektivni latentni konstrukti objašnjavaju više od 50% varijance pridruženih manifestnih varijabli. Prema tome, svi latentni konstrukti koji su u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer operacionalizirani reflektivno udovoljavaju kriteriju konvergentne valjanosti. Vrjednovanje nomološke valjanosti formativnih latentnih konstrukata provedeno je analizom vrijednosti koeficijenata puta koji su od istih odaslani prema reflektivnim latentnim konstruktima. U tablici 6.57 se može vidjeti da je 81,82% vrijednosti koeficijenata puta odaslanih od formativnih latentnih konstrukata prema reflektivnim latentnim konstruktima značajno na razini $\alpha = 0{,}001$ dok je preostalih 18,18% vrijednosti koeficijenata puta značajno na razini $\alpha = 0{,}01$. Navedeno implicira da su formativni latentni konstrukti u

konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer nomološki valjani.

Tablica 6.50 Vrijednosti kriterija vrjednovanja pouzdanosti i konvergentne valjanosti reflektivnih latentnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

REFLEKTIVNE LATENTNE VARIJABLE	Kompozitna pouzdanost ρ	AVE
Latentne varijable prve razine		
Dosljednost (DSD)	0,899	0,747
Estetika (EST)	0,902	0,753
Familijarnost (FML)	0,893	0,736
Jedinstvenost (JDN)	0,916	0,785
Korisnost (KRS)	0,947	0,855
Lakoća korištenja (LAK)	0,954	0,874
Lojalnost (LOJ)	0,944	0,849
Lakoća učenja korištenja (LUK)	0,959	0,886
Mogućnost kontrole (MOK)	0,847	0,650
Pamtljivost (PMT)	0,952	0,868
Pouzdanost (PZD)	0,921	0,797
Razigranost (RZG)	0,896	0,743
Razumljivost (RZM)	0,931	0,818
Stav prema korištenju (SPK)	0,952	0,870
Užitak (UTK)	0,941	0,842
Zamijećena djelotvornost (ZAD)	0,898	0,747
Zamijećena učinkovitost (ZAU)	0,870	0,690
Zadovoljstvo (ZDV)	0,940	0,840
Zamijećeno radno opterećenje (ZRO)	0,921	0,795
Latentne varijable druge razine		
Operabilnost (OPR)	0,909	0,770
Produktivnost (PDK)	0,929	0,867
Latentna varijabla treće razine		
Napor (NPR)	0,859	0,752

* Referentne vrijednosti: $\rho \geq 0{,}707$; AVE $\geq 0{,}500$

Tablica 6.51 Rezultati analize multikolinearnosti formativnih manifestnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

MV	VIF	Koeficijent tolerancije	MV	VIF	Koeficijent tolerancije
DST1	1,080	0,926	**PST6**	1,173	0,853
DST4	1,111	0,900	**RIP1**	1,522	0,657
DST5	1,039	0,962	**RIP3**	1,506	0,664
INT1	1,303	0,767	**RIP5**	2,332	0,429
INT2	1,200	0,833	**RIP6**	2,507	0,399
INT3	1,111	0,900	**RIP7**	2,590	0,386
IRO1	1,601	0,625	**SGR3**	1,102	0,908
IRO2	3,354	0,298	**SGR4**	1,021	0,979
IRO3	3,619	0,276	**SGR5**	1,238	0,808
IRO4	1,552	0,644	**SGR6**	1,218	0,821
IZD1	1,012	0,988	**SGR10**	1,165	0,859
IZU1	1,022	0,979	**SPO1**	1,495	0,669
MIN1	1,319	0,758	**SPO3**	1,487	0,672
MIN2	1,133	0,883	**SPO4**	1,016	0,984
MIN5	1,193	0,838	**SVK1**	1,288	0,776
MIN7	1,374	0,728	**SVK2**	1,283	0,780
MIN8	1,332	0,751	**SVK3**	1,495	0,669
MOP1	1,977	0,506	**UPA2**	1,353	0,739
MOP2	2,050	0,488	**UPA3**	1,390	0,720
MOP4	1,425	0,702	**UPA4**	1,163	0,860
MPR1	1,072	0,933	**UPA5**	1,156	0,865
MPR2	1,121	0,892	**UPA7**	1,047	0,955
MPR3	1,116	0,896	**UPR1**	1,186	0,843
PIN1	1,202	0,832	**UPR3**	1,550	0,645
PIN2	1,530	0,653	**UPR4**	1,624	0,616
PIN3	2,341	0,427	**UPR5**	1,703	0,587
PIN4	2,308	0,433	**UPR6**	1,701	0,588
PIN6	1,203	0,831	**ZAS1**	1,387	0,721
PNS1	1,186	0,843	**ZAS3**	1,179	0,848
PNS2	1,217	0,822	**ZAS4**	1,382	0,724
PNS3	1,060	0,943	**ZVO2**	2,077	0,481
PST1	1,038	0,963	**ZVO3**	2,796	0,358
PST4	1,189	0,841	**ZVO4**	2,537	0,394

* Referentne vrijednosti: VIF < 5; koeficijent tolerancije > 0,2

Diskriminacijska valjanost reflektivnih latentnih konstrukata vrjednovana je usporedbom vrijednosti standardiziranih faktorskih i unakrsnih opterećenja te usporedbom vrijednosti prosječne ekstrahirane varijance pojedinog reflektivnog latentnog konstrukta i kvadriranih vrijednosti njegovih dvosmjernih korelacija sa preostalim reflektivnim latentnim konstruktima. S druge strane, diskriminacijska valjanost formativnih latentnih konstrukata vrjednovana je analizom vrijednosti njihovih međukorelacija.

Rezultati vrjednovanja diskriminacijske valjanosti reflektivnih latentnih konstrukata prve razine prikazani su u tablicama 6.41 i 6.52 dok se rezultati vrjednovanja diskriminacijske valjanosti reflektivnih latentnih konstrukata druge razine nalaze u tablicama 6.42 i 6.53. Iz tablica 6.41 i 6.42 je vidljivo da su vrijednosti standardiziranih faktorskih opterećenja svih reflektivnih manifestnih varijabli sa temeljnim latentnim konstruktom veće od unakrsnih opterećenja sa preostalim reflektivnim latentnim konstruktima u modelu. Pored navedenog, tablice 6.52 i 6.53 jasno prikazuju da su vrijednosti prosječnih ekstrahiranih varijanci reflektivnih latentnih konstrukata veće od kvadriranih vrijednosti njihovih dvosmjernih korelacija sa preostalim reflektivnim latentnim konstruktima. Prema tome, svi reflektivni latentni konstrukti u višedimenzionalnom konceptualnom modelu zadovoljavaju oba kriterija diskriminacijske valjanosti.

Tablice 6.54–6.56 sadrže rezultate vrjednovanja diskriminacijske valjanosti formativnih latentnih konstrukata. Iz međukorelacija formativnih latentnih konstrukata je vidljivo da isti dijele između 0,04% i 26,11% zajedničke varijance na prvoj razini, između 8,46% i 29,92% varijance na drugoj te 27,46% varijance na trećoj razini višedimenzionalnog konceptualnog modela. Prema tome, formativni latentni konstrukti na svim razinama višedimenzionalnog konceptualnog modela udovoljavaju kriteriju diskriminacijske valjanosti. Uzimajući u obzir podatke sadržane u tablicama 6.41–6.57, moguće je zaključiti da su vanjski reflektivni model i vanjski formativni model u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer pouzdani i valjani.

Tablica 6.52 Diskriminacijska valjanost reflektivnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
DSD	**0,747**																		
EST	0,045	**0,753**																	
FML	0,188	0,053	**0,736**																
JDN	0,002	0,066	0,000	**0,785**															
KRS	0,045	0,087	0,103	0,158	**0,855**														
LAK	0,206	0,096	0,276	0,003	0,254	**0,874**													
LOJ	0,009	0,082	0,045	0,188	0,282	0,140	**0,849**												
LUK	0,293	0,052	0,382	0,000	0,135	0,366	0,071	**0,886**											
MOK	0,134	0,054	0,133	0,038	0,184	0,334	0,053	0,214	**0,650**										
PMT	0,123	0,029	0,264	0,001	0,158	0,410	0,107	0,512	0,197	**0,868**									
PZD	0,135	0,054	0,250	0,027	0,187	0,227	0,043	0,272	0,215	0,266	**0,797**								
RZG	0,018	0,042	0,056	0,200	0,246	0,062	0,243	0,069	0,101	0,087	0,107	**0,743**							
RZM	0,202	0,068	0,375	0,020	0,241	0,274	0,049	0,326	0,270	0,291	0,372	0,093	**0,818**						
SPK	0,024	0,136	0,050	0,094	0,178	0,112	0,255	0,059	0,131	0,064	0,064	0,125	0,070	**0,870**					
UTK	0,029	0,120	0,081	0,219	0,378	0,184	0,399	0,124	0,098	0,130	0,105	0,387	0,140	0,240	**0,842**				
ZAD	0,130	0,068	0,161	0,092	0,350	0,329	0,213	0,171	0,305	0,134	0,163	0,230	0,226	0,210	0,251	**0,747**			
ZAU	0,179	0,080	0,194	0,061	0,409	0,410	0,224	0,236	0,320	0,214	0,204	0,208	0,291	0,246	0,256	0,538	**0,690**		
ZDV	0,147	0,112	0,231	0,097	0,473	0,461	0,313	0,336	0,270	0,372	0,368	0,260	0,368	0,197	0,470	0,402	0,472	**0,840**	
ZRO	0,047	0,030	0,104	0,002	0,071	0,179	0,023	0,215	0,046	0,201	0,090	0,015	0,184	0,065	0,104	0,042	0,090	0,143	**0,795**

Tablica 6.53 Diskriminacijska valjanost reflektivnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	OPR	PDK
OPR	**0,770**	
PDK	0,357	**0,867**

Tablica 6.54 Diskriminacijska valjanost formativnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	DST	INT	IRO	IZD	IZU	MIN	MOP	MPR	PIN	PNS	PST	RIP	SGR	SPO	SVK	UPA	UPR	ZAS	ZVO
DST	1,000																		
INT	0,193	1,000																	
IRO	-0,030	-0,071	1,000																
IZD	0,079	0,319	-0,111	1,000															
IZU	-0,131	-0,235	0,267	-0,354	1,000														
MIN	0,263	0,353	-0,186	0,309	-0,235	1,000													
MOP	0,241	0,380	-0,043	0,254	-0,306	0,352	1,000												
MPR	0,204	0,347	-0,169	0,305	-0,222	0,389	0,308	1,000											
PIN	0,244	0,340	-0,121	0,361	-0,304	0,323	0,317	0,289	1,000										
PNS	0,321	0,249	-0,047	0,068	-0,165	0,311	0,156	0,194	0,204	1,000									
PST	0,318	0,138	-0,062	0,065	-0,062	0,202	0,120	0,188	0,207	0,186	1,000								
RIP	0,197	0,247	-0,060	0,288	-0,374	0,301	0,305	0,292	0,419	0,211	0,172	1,000							
SGR	0,414	0,322	-0,127	0,182	-0,108	0,348	0,175	0,264	0,253	0,285	0,281	0,176	1,000						
SPO	0,169	0,311	-0,162	0,384	-0,303	0,427	0,360	0,391	0,331	0,209	0,148	0,314	0,302	1,000					
SVK	0,200	0,366	-0,021	0,437	-0,263	0,366	0,324	0,399	0,216	0,242	0,110	0,307	0,344	0,316	1,000				
UPA	0,215	0,288	-0,061	0,297	-0,214	0,461	0,207	0,383	0,264	0,202	0,128	0,269	0,328	0,364	0,337	1,000			
UPR	0,171	0,315	-0,220	0,374	-0,496	0,335	0,338	0,262	0,357	0,260	0,074	0,406	0,220	0,315	0,245	0,326	1,000		
ZAS	0,229	0,370	-0,121	0,443	-0,358	0,511	0,363	0,371	0,407	0,187	0,173	0,414	0,265	0,455	0,393	0,471	0,438	1,000	
ZVO	0,221	0,308	-0,123	0,320	-0,203	0,283	0,304	0,264	0,255	0,146	0,152	0,273	0,210	0,303	0,268	0,196	0,223	0,358	1,000

Tablica 6.55 Diskriminacijska valjanost formativnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	DHV	FUP	OTV	POK	RAU
DHV	1,000				
FUP	0,309	1,000			
OTV	0,348	0,436	1,000		
POK	0,302	0,411	0,381	1,000	
RAU	0,294	0,547	0,388	0,509	1,000

Tablica 6.56 Diskriminacijska valjanost formativnih latentnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	KVS	KVU
KVS	1,000	
KVU	0,524	1,000

Nakon što je utvrđeno da vanjski reflektivni i vanjski formativni model udovoljavaju kriterijima valjanosti i pouzdanosti, provedeno je vrjednovanje metrijskih karakteristika unutarnjeg modela. Iz slike 6.23 je vidljivo da se vrijednosti koeficijenta determinacije R^2 zavisnih latentnih varijabli nalaze u rasponu od 0,157 do 0,618. Formativni latentni konstrukti treće razine pomoću kojih su mjerene dimenzije kvalitete sustava i kvalitete usluge aplikacije Zoho Writer su objasnili 15,7% varijance u reflektivnom latentnom konstruktu prve razine kojim je vrjednovan stav prema korištenju aplikacijom Zoho Writer. Atributi kvalitete u korištenju primjenom kojih su vrjednovani aspekti dosljednosti i mogućnosti prilagodbe aplikacije Zoho Writer su objasnili 20,2% varijance u atributu kojim je mjerena pamtljivost aplikacije Zoho Writer. Formativni latentni konstrukt pomoću kojeg se provjeravalo da li Zoho Writer sprječava nastanak pogrješaka u radu i formativni latentni konstrukt kojim je utvrđeno do koje se mjere Zoho Writer može oporaviti od pogrješaka ili prekida u radu su objasnili 21,1% varijance u reflektivnom latentnom konstruktu kojim je mjerena pouzdanost aplikacije Zoho Writer.

Reflektivni latentni konstrukti pomoću kojih je vrjednovana korisnost aplikacije Zoho Writer, zadovoljstvo korisnika i stav prema korištenju aplikacijom Zoho Writer su objasnili 41,8% varijance u konstruktu kojim je vrjednovana lojalnost korisnika. Indikator kojim je mjeren broj reprezentativnih koraka scenarija koje su korisnici uspjeli dovršiti upotrebom aplikacije Zoho Writer i formativni latentni konstrukt pomoću kojeg se provjeravalo da li se Zoho Writer može upotrebljavati i izvan konteksta za koji je originalno namijenjen su zajedno objasnili 42,3% varijance u reflektivnom latentnom konstruktu kojim je vrjednovana zamijećena djelotvornost

korisnika. Indikatori pomoću kojih je mjeren broj pritisnutih tipaka na tipkovnici, udaljenost prijeđena pomicanjem miša, broj klikova mišem i broj pomicanja klizača na mišu za vrijeme izvršavanja reprezentativnih koraka scenarija upotrebom aplikacije Zoho Writer su objasnili 43,0% varijance u atributu kojim je vrjednovano zamijećeno radno opterećenje korisnika. Atributi kvalitete u korištenju pomoću kojih je vrjednovana familijarnost i razumljivost aplikacije Zoho Writer su objasnili 44,1% varijance u atributu primjenom kojeg je mjerena lakoća učenja korištenja aplikacijom Zoho Writer.

Reflektivni latentni konstrukt prve razine pomoću kojeg je mjerena pouzdanost aplikacije Zoho Writer i reflektivni latentni konstrukt druge razine kojim je vrjednovana produktivnost aplikacije Zoho Writer su objasnili 45,9% varijance u reflektivnom latentnom konstruktu prve razine pomoću kojeg je vrjednovana korisnost aplikacije Zoho Writer. Atributi korisničkog iskustva pomoću kojih su vrjednovane dimenzije estetike i jedinstvenosti aplikacije Zoho Writer te aspekti razigranosti korisnika su objasnili 46,7% varijance u atributu kojim je mjeren užitak u interakciji sa aplikacijom Zoho Writer. Formativni latentni konstrukt druge razine kojim je vrjednovan radni učinak aplikacije Zoho Writer i indikator pomoću kojeg je mjerena količina vremena potrebna za dovršetak scenarija interakcije sa aplikacijom Zoho Writer su zajedno objasnili 49,4% varijance u reflektivnom latentnom konstruktu pomoću kojeg je vrjednovana zamijećena učinkovitost korisnika.

Reflektivni latentni konstrukt primjenom kojeg se provjeravalo da li korisnici mogu kontrolirati interakciju sa aplikacijom Zoho Writer i formativni latentni konstrukt čijim su manifestnim varijablama vrjednovani aspekti upravljivosti aplikacijom Zoho Writer su objasnili 49,7% varijance u reflektivnom latentnom konstruktu pomoću kojeg je vrjednovana lakoća korištenja aplikacijom Zoho Writer. Konačno, latentni konstrukt kojim je mjeren užitak kojeg upotreba aplikacije Zoho Writer pruža korisnicima i latentni konstrukt pomoću kojeg je utvrđeno koliko su napora korisnici trebali uložiti u izvršavanje reprezentativnih zadataka pomoću aplikacije Zoho Writer su objasnili 61,8% varijance u atributu pomoću kojeg je vrjednovano zadovoljstvo korisnika.

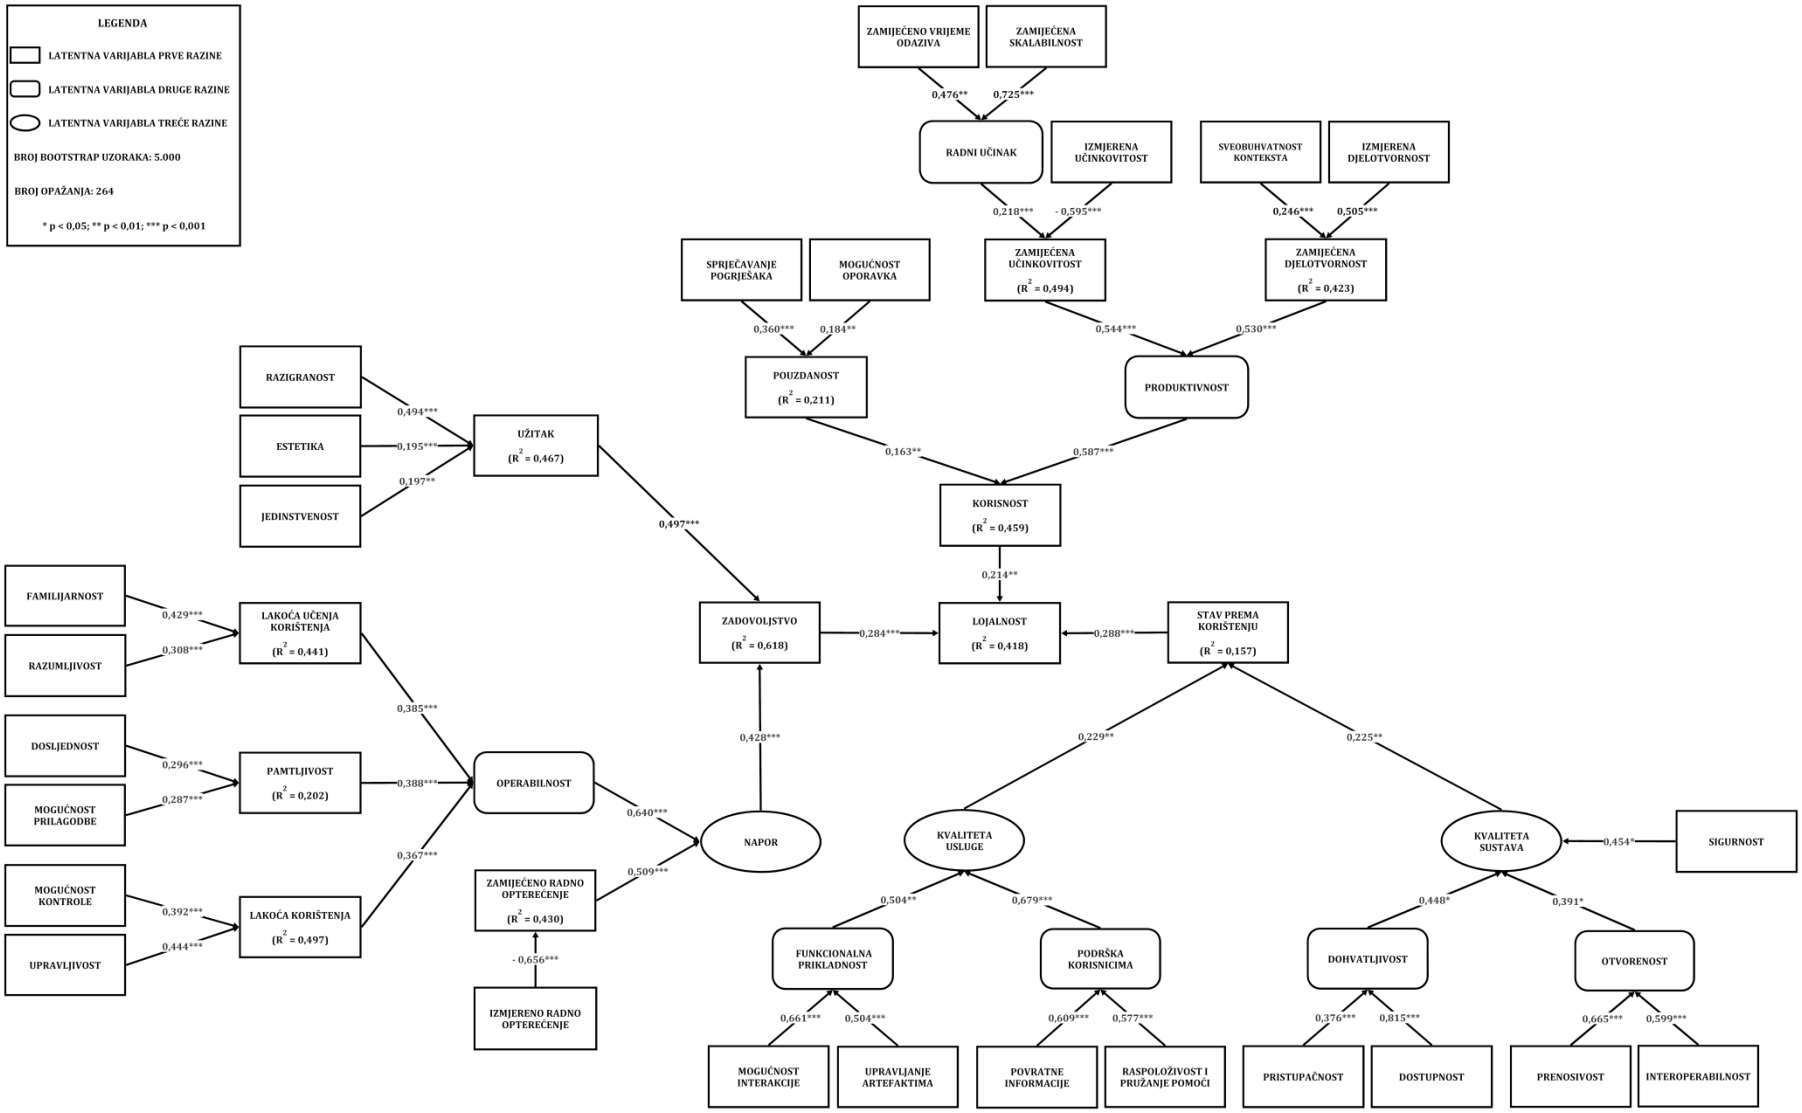

Slika 6.23 Rezultati analize metrijskih karakteristika unutarnjeg modela u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer

Struktura koeficijenata puta sa naznačenim razinama značajnosti prikazana je u tablici 6.57 i na slici 6.23. Analizom navedene strukture utvrđeno je da je većina (76,60%) koeficijenata puta značajna na razini $\alpha = 0{,}001$, 17,02% koeficijenata puta je značajno na razini $\alpha = 0{,}01$ dok je 6,38% koeficijenata puta značajno na razini $\alpha = 0{,}05$. Iz navedenog proizlazi da su u kontekstu konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer sve pothipoteze $H_{1.1}$-$H_{1.25}$ potvrđene.

Promatrajući konceptualni model u cjelini, iz skupa nezavisnih latentnih varijabli na prvoj razini potrebno je izdvojiti reflektivni latentni konstrukt kojim je vrjednovana razigranost korisnika tijekom korištenja aplikacijom Zoho Writer zbog toga što je isti najznačajniji ($\beta = 0{,}494$; $p < 0{,}001$) prediktor konstrukta pomoću kojega je mjeren užitak interakcije sa aplikacijom Zoho Writer. Osim toga, na prvoj je razini potrebno još izdvojiti i formativni latentni konstrukt kojim se provjeravalo do koje mjere Zoho Writer sprječava nastanak pogrješaka u radu iz razloga što isti ima veću značajnost ($\beta = 0{,}360$; $p < 0{,}001$) u predikciji pouzdanosti aplikacije Zoho Writer od formativnog latentnog konstrukta kojim je vrjednovana mogućnost oporavka ($\beta = 0{,}184$; $p < 0{,}01$) aplikacije Zoho Wirter. U kontekstu povezanosti latentnih varijabli prve i druge razine potrebno je spomenuti da su aspekti radnog učinka aplikacije Zoho Writer u značajnijoj mjeri vrjednovani manifestnim varijablama kojima je mjerena zamijećena skalabilnost ($\beta = 0{,}725$; $p < 0{,}001$) od manifestnih varijabli pomoću kojih je mjereno zamijećeno vrijeme odaziva ($\beta = 0{,}476$; $p < 0{,}01$) aplikacije Zoho Writer. Isto tako, utvrđeno je da je reflektivni latentni konstrukt druge razine pomoću kojeg je vrjednovana produktivnost korisnika ($\beta = 0{,}587$; $p < 0{,}001$) značajniji prediktor korisnosti aplikacije Zoho Writer od reflektivnog latentnog konstrukta primjenom kojeg je mjerena pouzdanost aplikacije Zoho Writer ($\beta = 0{,}163$; $p < 0{,}01$). Konačno, manifestne varijable kojima su mjerene dimenzije dostupnosti ($\beta = 0{,}815$; $p < 0{,}001$) su imale značajniji doprinos u vrjednovanju dohvatljivosti od manifestnih varijabli pomoću kojih su mjereni aspekti pristupačnosti ($\beta = 0{,}376$; $p < 0{,}001$) aplikacije Zoho Writer.

Analizom koeficijenata puta koji povezuju latentne varijable pomoću kojih se mjere objektivni i subjektivni aspekti istovjetnog atributa kvalitete u korištenju utvrđeno je da povećanje broja pritisnutih tipaka na tipkovnici, udaljenosti prijeđene mišem, broja klikova mišem i broja pomicanja klizača na mišu dovodi do značajnog povećanja ($\beta = -0{,}656$; $p < 0{,}001$) zamijećenog radnog opterećenja korisnika tijekom interakcije sa aplikacijom Zoho Writer. Osim toga, pronađeno je da povećanje količine vremena potrebnog za dovršetak reprezentativnih koraka scenarija rezultira značajnim smanjenjem ($\beta = -0{,}595$; $p < 0{,}001$) zamijećene učinkovitosti korisnika u izvršavanju zadataka upotrebom aplikacije Zoho Writer. Konačno, povećanjem broja reprezentativnih koraka scenarija koje je moguće dovršiti primjenom

aplikacije Zoho Writer dolazi do značajnog povećanja ($\beta = 0{,}505$; $p < 0{,}001$) zamijećene djelotvornosti korisnika.

Tablica 6.57 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\lvert OU/\sigma \rvert$)**
DHV -> KVS	0,448	0,471	0,201	2,227*
DSD -> PMT	0,296	0,303	0,071	4,164***
DST -> DHV	0,815	0,812	0,042	19,295***
EST -> UTK	0,195	0,195	0,054	3,635***
FML -> LUK	0,429	0,429	0,065	6,633***
FUP -> KVU	0,504	0,482	0,189	2,667**
INT -> OTV	0,599	0,574	0,118	5,086***
IRO -> ZRO	-0,656	-0,662	0,040	16,486***
IZD -> ZAD	0,505	0,504	0,057	8,797***
IZU -> ZAU	-0,595	-0,595	0,054	11,048***
JDN -> UTK	0,197	0,197	0,061	3,253**
KRS -> LOJ	0,214	0,212	0,070	3,050**
KVS -> SPK	0,225	0,238	0,082	2,742**
KVU -> SPK	0,229	0,237	0,080	2,867**
LAK -> OPR	0,367	0,366	0,008	44,635***
LUK -> OPR	0,385	0,384	0,009	40,917***
MIN -> FUP	0,661	0,664	0,078	8,457***
MOK -> LAK	0,392	0,389	0,054	7,309***
MOP -> PZD	0,184	0,200	0,062	2,944**
MPR -> PMT	0,287	0,290	0,061	4,672***
NPR -> ZDV	0,428	0,431	0,044	9,723***
OPR -> NPR	0,640	0,639	0,022	28,599***
OTV -> KVS	0,391	0,371	0,197	1,990*
PDK -> KRS	0,587	0,588	0,054	10,875***
PIN -> POK	0,609	0,603	0,045	13,548***
PMT -> OPR	0,388	0,388	0,010	37,362***
PNS -> OTV	0,665	0,665	0,099	6,725***
POK -> KVU	0,679	0,675	0,171	3,976***
PST -> DHV	0,376	0,370	0,065	5,772***
PZD -> KRS	0,163	0,164	0,056	2,904**
RAU -> ZAU	0,218	0,219	0,054	4,013***
RIP -> POK	0,577	0,572	0,049	11,811***
RZG -> UTK	0,494	0,492	0,052	9,586***
RZM -> LUK	0,308	0,310	0,072	4,312***

* p < 0,05; ** p < 0,01; *** p < 0,001

Tablica 6.57 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer (nastavak)

	Originalan uzorak (OU)	Srednja vrijednost uzorka ($\bar{x}$)	Standardna pogrješka (σ)	T statistika ($\|OU/\sigma\|$)
SGR -> KVS	0,454	0,401	0,213	2,127*
SPK -> LOJ	0,288	0,293	0,063	4,565***
SPO -> PZD	0,360	0,365	0,061	5,885***
SVK -> ZAD	0,246	0,255	0,063	3,900***
UPA -> FUP	0,504	0,487	0,084	6,009***
UPR -> LAK	0,444	0,452	0,063	7,016***
UTK -> ZDV	0,497	0,494	0,043	11,499***
ZAD -> PDK	0,530	0,530	0,008	66,976***
ZAS -> RAU	0,725	0,728	0,120	6,049***
ZAU -> PDK	0,544	0,544	0,010	52,878***
ZDV -> LOJ	0,284	0,286	0,073	3,923***
ZRO -> NPR	0,509	0,509	0,010	53,149***
ZVO -> RAU	0,476	0,448	0,148	3,206**

** p < 0,01; *** p < 0,001

Rezultati vrjednovanja veličine utjecaja i prediktivne valjanosti nezavisnih varijabli u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer prikazani su u tablici 11.58. Analizom rezultata vrjednovanja utvrđeno je da 53,57% prediktora ima mali utjecaj, 25% prediktora ima srednji utjecaj, a 21,43% ima veliki utjecaj na zavisne varijable. Iz skupine prediktora sa malim utjecajem potrebno je izdvojiti konstrukte pomoću kojih su vrjednovani aspekti mogućnosti oporavka, pouzdanosti, korisnosti i kvalitete sustava aplikacije Zoho Writer jer imaju najmanju razinu utjecaja ($f^2 = 0{,}04$) u konceptualnom modelu. Potrebno je i istaknuti formativni latentni konstrukt kojim se provjeravalo da li Zoho Writer sprječava nastanak pogrješaka u radu jer isti ima najveći stupanj utjecaja ($f^2 = 0{,}14$) u skupini prediktora sa malim utjecajem u konceptualnom modelu. U skupini prediktora sa srednjim utjecajem najmanju razinu utjecaja ($f^2 = 0{,}15$) ima indikator kojim je mjereno koliko su klikova mišem napravili korisnici tijekom izvršavanja reprezentativnih koraka scenarija interakcije sa aplikacijom Zoho Writer dok najveći stupanj utjecaja ($f^2 = 0{,}32$) unutar te skupine ima formativni latentni konstrukt primjenom kojeg su vrjednovani aspekti upravljivosti aplikacijom Zoho Writer. Konačno, u skupini prediktora sa velikim utjecajem najmanju razinu istog ($f^2 = 0{,}35$) ima indikator kojim je mjeren broj reprezentativnih koraka scenarija koje su korisnici upotrebom aplikacije Zoho Writer uspjeli dovršiti dok najveći stupanj utjecaja ($f^2 = 0{,}61$) u konceptualnom modelu ima indikator pomoću kojeg je mjereno koliko je vremena korisnicima bilo potrebno da dovrše reprezentativne korake scenarija pomoću aplikacije Zoho Writer.

Od ukupno 28 nezavisnih varijabli u konceptualnom modelu, 64,29% ih ima malu prediktivnu valjanost, 32,14% ih ima srednju prediktivnu valjanost dok ih 3,57% ima veliku prediktivnu valjanost. U skupini nezavisnih varijabli sa malom prediktivnom valjanošću, najmanju razinu iste ($q^2 = 0{,}02$) ima reflektivni latentni konstrukt kojim je vrjednovana korisnost aplikacije Zoho Writer dok najveći stupanj prediktivne valjanosti ($q^2 = 0{,}12$) unutar ove skupine ima indikator pomoću kojeg je mjereno koliko će puta korisnici pomaknuti klizač na mišu tijekom dovršavanja reprezentativnih koraka scenarija pomoću aplikacije Zoho Writer. Indikator kojim je mjerena udaljenost koju su korisnici prošli pomicanjem miša za vrijeme dovršavanja scenarija interakcije sa aplikacijom Zoho Writer ima najmanji stupanj ($q^2 = 0{,}16$) prediktivne valjanosti u skupini nezavisnih varijabli sa srednjom prediktivnom valjanošću. S druge strane, reflektivni latentni konstrukt kojim su vrjednovani aspekti užitka korištenja aplikacijom Zoho Writer ima najveću razinu prediktivne valjanosti ($q^2 = 0{,}33$) u skupini nezavisnih varijabli sa srednjom prediktivnom valjanošću. Konačno, najveću prediktivnu valjanost ($q^2 = 0{,}37$) u konceptualnom modelu ima reflektivni latentni konstrukt pomoću kojeg su vrjednovane dimenzije produktivnosti korisnika.

Uzimajući u obzir sve rezultate vrjednovanja, konceptualni model vrjednovanja kvalitete u korištenju aplikacijom Zoho Writer je pouzdan i valjan.

Tablica 6.58 Rezultati analize veličine utjecaja i prediktivne valjanosti egzogenih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Zoho Writer

	R_u^2	R_i^2	f^2	Q_u^2	Q_i^2	q^2
DSD -> PMT	0,202	0,118	0,11	0,182	0,095	0,11
EST -> UTK	0,467	0,432	0,07	0,385	0,364	0,03
FML -> LUK	0,441	0,326	0,21	0,388	0,286	0,17
IRO1 -> ZRO	0,430	0,333	0,17	0,338	0,263	0,11
IRO2 -> ZRO	0,430	0,292	0,24	0,338	0,231	0,16
IRO3 -> ZRO	0,430	0,344	0,15	0,338	0,271	0,10
IRO4 -> ZRO	0,430	0,322	0,19	0,338	0,256	0,12
IZD -> ZAD	0,423	0,220	0,35	0,313	0,167	0,21
IZU -> ZAU	0,494	0,186	0,61	0,337	0,127	0,32
JDN -> UTK	0,467	0,437	0,06	0,385	0,369	0,03
KRS -> LOJ	0,418	0,395	0,04	0,344	0,333	0,02
KVS -> SPK	0,157	0,121	0,04	0,134	0,105	0,03
KVU -> SPK	0,157	0,119	0,05	0,134	0,102	0,04
MOK -> LAK	0,497	0,370	0,25	0,440	0,326	0,20
MOP -> PZD	0,211	0,182	0,04	0,163	0,142	0,03
MPR -> PMT	0,202	0,123	0,10	0,182	0,100	0,10
NPR -> ZDV	0,618	0,472	0,38	0,513	0,390	0,25
PDK -> KRS	0,459	0,187	0,50	0,386	0,158	0,37
PZD -> KRS	0,459	0,438	0,04	0,386	0,369	0,03
RAU -> ZAU	0,494	0,453	0,08	0,337	0,310	0,04
RZG -> UTK	0,467	0,274	0,36	0,385	0,231	0,25
RZM -> LUK	0,441	0,382	0,11	0,388	0,336	0,08
SPK -> LOJ	0,418	0,354	0,11	0,344	0,300	0,07
SPO -> PZD	0,211	0,098	0,14	0,163	0,076	0,10
SVK -> ZAD	0,423	0,377	0,08	0,313	0,276	0,05
UPR -> LAK	0,497	0,334	0,32	0,440	0,295	0,26
UTK -> ZDV	0,618	0,418	0,52	0,513	0,350	0,33
ZDV -> LOJ	0,418	0,378	0,07	0,344	0,315	0,04

R^2– koeficijent determinacije
f^2 – koeficijent veličine utjecaja
Q^2 – Stone-Geisserov indeks unakrsno validirane redundance
q^2 – koeficijent prediktivne valjanosti

6.3.3 Rezultati analize metrijskih karakteristika konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App

Vrjednovanjem pouzdanosti manifestnih varijabli započela je analiza metrijskih karakteristika višedimenzionalnog konceptualnog modela u kontekstu Web 2.0 aplikacije Microsoft Word Web App. Analizom vrijednosti standardiziranih faktorskih opterećenja utvrđena je pouzdanost reflektivnih manifestnih varijabli dok je vrjednovanjem značajnosti vrijednosti standardiziranih faktorskih opterećenja i težinskih vrijednosti provedena procjena pouzdanosti formativnih manifestnih varijabli. Rezultati vrjednovanja pouzdanosti reflektivnih manifestnih varijabli prve, druge i treće razine konceptualnog modela nalaze se u tablicama 6.59-6.61, respektivno. Spomenute tablice jasno prikazuju da se vrijednosti standardiziranih faktorskih opterećenja nalaze u rasponu od 0,709 do 0,947 što znači da reflektivne manifestne varijable objašnjavaju između 50,27% i 89,68% varijance u temeljnim latentnim konstruktima čija obilježja mjere. Iz navedenog je evidentno da su sve reflektivne manifestne varijable u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App pouzdane. Tablice 6.62-6.64 sadrže rezultate procjene značajnosti apsolutne važnosti formativnih manifestnih varijabli koje se u konceptualnom modelu nalaze na prvoj, drugoj i trećoj razini, respektivno. Iz tablice 6.62 je vidljivo da je 89,06% standardiziranih faktorskih opterećenja formativnih manifestnih varijabli prve razine značajno na razini $\alpha = 0{,}001$, 4,69% ih je značajno na razini $\alpha = 0{,}01$ dok ih je 6,25% značajno na razini $\alpha = 0{,}05$. S druge strane, tablice 6.63 i 6.64 jasno prikazuju da su vrijednosti standardiziranih faktorskih opterećenja formativnih manifestnih varijabli druge i treće razine u modelu značajne na razini $\alpha = 0{,}001$.

Stupnjevi značajnosti težinskih vrijednosti formativnih manifestnih varijabli prve, druge i treće razine u konceptualnom modelu naznačene su u tablicama 6.65-6.67, respektivno. Kao što se može vidjeti u tablici 6.65, većina (90,62%) težinskih vrijednosti formativnih manifestnih varijabli prve razine je značajna na razini $\alpha = 0{,}001$, dok ih je po 4,69% značajno na razinama $\alpha = 0{,}01$ i $\alpha = 0{,}05$. Većinski dio (90,91%) težinskih vrijednosti formativnih manifestnih varijabli druge razine je značajan na razini $\alpha = 0{,}001$ dok ih je 9,09% značajno na razini $\alpha = 0{,}01$ što je i vidljivo u tablici 6.66. Konačno, iz podataka prikazanih u tablici 6.67 je evidentno da je 50% težinskih vrijednosti formativnih manifestnih varijabli značajno na razini $\alpha = 0{,}001$, a preostalih 50% značajno na razini $\alpha = 0{,}01$. Iz rezultata vrjednovanja sadržanim u tablicama 6.62-6.67 moguće je zaključiti da su sve formativne manifestne varijable u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App pouzdane.

Tablica 6.59 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
DSD2	**0,830**	0,114	0,297	0,148	0,257	0,367	0,099	0,352	0,300	0,389	0,314	0,204	0,370	0,257	0,213	0,188	0,255	0,287	0,163
DSD3	**0,809**	0,136	0,271	0,050	0,036	0,328	0,065	0,314	0,322	0,254	0,214	0,116	0,246	0,124	0,103	0,152	0,237	0,130	0,070
DSD4	**0,776**	0,065	0,237	0,086	0,066	0,297	0,076	0,275	0,280	0,233	0,190	0,134	0,238	0,136	0,077	0,194	0,248	0,119	0,020
EST2	0,081	**0,709**	0,270	-0,045	0,111	0,247	0,105	0,301	0,193	0,261	0,167	0,019	0,265	0,101	0,143	0,098	0,154	0,199	0,157
EST4	0,170	**0,887**	0,123	0,241	0,201	0,233	0,211	0,091	0,221	0,160	0,172	0,177	0,161	0,267	0,238	0,183	0,191	0,315	-0,021
EST5	0,062	**0,892**	0,155	0,158	0,151	0,248	0,188	0,120	0,161	0,166	0,164	0,109	0,171	0,250	0,189	0,130	0,160	0,312	0,041
FML1	0,303	0,223	**0,842**	0,025	0,300	0,469	0,225	0,525	0,331	0,465	0,392	0,294	0,498	0,230	0,273	0,270	0,419	0,325	0,224
FML3	0,282	0,168	**0,875**	0,081	0,277	0,346	0,063	0,524	0,303	0,504	0,380	0,143	0,575	0,128	0,206	0,158	0,310	0,234	0,245
FML4	0,301	0,143	**0,908**	0,028	0,231	0,412	0,038	0,589	0,294	0,535	0,503	0,277	0,650	0,143	0,220	0,141	0,311	0,264	0,290
JDN1	0,143	0,210	0,057	**0,905**	0,464	0,220	0,508	0,052	0,309	0,160	0,182	0,439	0,087	0,416	0,474	0,435	0,325	0,509	-0,128
JDN2	0,071	0,093	0,049	**0,883**	0,404	0,109	0,403	-0,003	0,232	0,046	0,212	0,437	0,110	0,304	0,388	0,367	0,296	0,430	-0,088
JDN3	0,123	0,138	0,029	**0,915**	0,468	0,120	0,494	0,001	0,270	0,091	0,202	0,354	0,078	0,401	0,413	0,405	0,274	0,502	-0,130
KRS2	0,162	0,158	0,300	0,465	**0,934**	0,420	0,488	0,315	0,391	0,328	0,381	0,510	0,336	0,505	0,600	0,576	0,550	0,626	0,131
KRS3	0,144	0,182	0,258	0,445	**0,893**	0,390	0,453	0,323	0,328	0,315	0,352	0,462	0,362	0,378	0,574	0,443	0,517	0,581	0,112
KRS4	0,178	0,191	0,286	0,463	**0,942**	0,415	0,497	0,328	0,402	0,296	0,394	0,483	0,371	0,470	0,580	0,576	0,542	0,678	0,113
LAK1	0,345	0,264	0,368	0,250	0,483	**0,870**	0,394	0,458	0,630	0,479	0,454	0,359	0,351	0,433	0,505	0,508	0,634	0,528	0,303
LAK2	0,409	0,265	0,479	0,120	0,377	**0,936**	0,183	0,573	0,492	0,659	0,440	0,288	0,501	0,313	0,368	0,363	0,571	0,416	0,351
LAK3	0,387	0,258	0,431	0,105	0,361	**0,939**	0,257	0,550	0,499	0,625	0,387	0,230	0,464	0,339	0,383	0,356	0,576	0,410	0,389
LOJ1	0,104	0,216	0,140	0,490	0,474	0,304	**0,929**	0,181	0,264	0,186	0,197	0,394	0,110	0,590	0,573	0,507	0,410	0,588	0,009
LOJ2	0,101	0,194	0,116	0,473	0,507	0,264	**0,902**	0,173	0,289	0,179	0,181	0,367	0,137	0,562	0,542	0,521	0,411	0,595	-0,063
LOJ3	0,079	0,170	0,078	0,488	0,461	0,264	**0,944**	0,116	0,269	0,138	0,144	0,384	0,058	0,570	0,538	0,510	0,416	0,551	-0,067
LUK1	0,377	0,159	0,580	-0,017	0,294	0,533	0,141	**0,937**	0,368	0,631	0,433	0,185	0,548	0,207	0,272	0,287	0,454	0,325	0,354
LUK2	0,380	0,123	0,539	0,050	0,356	0,575	0,202	**0,927**	0,378	0,608	0,483	0,264	0,564	0,189	0,358	0,353	0,526	0,354	0,377
LUK3	0,345	0,221	0,620	0,025	0,319	0,500	0,133	**0,921**	0,327	0,698	0,481	0,196	0,629	0,154	0,285	0,250	0,404	0,326	0,428

Tablica 6.59 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App (nastavak)

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
MOK1	0,290	0,189	0,238	0,294	0,431	0,573	0,339	0,335	**0,829**	0,316	0,378	0,330	0,263	0,407	0,366	0,502	0,496	0,528	0,125
MOK2	0,329	0,122	0,299	0,159	0,138	0,340	0,151	0,287	**0,712**	0,266	0,264	0,136	0,297	0,231	0,166	0,294	0,308	0,269	0,057
MOK3	0,276	0,223	0,322	0,234	0,325	0,423	0,163	0,280	**0,813**	0,335	0,312	0,257	0,322	0,273	0,222	0,434	0,411	0,378	0,103
PMT1	0,322	0,225	0,557	0,109	0,306	0,618	0,194	0,674	0,354	**0,944**	0,476	0,288	0,555	0,238	0,303	0,170	0,395	0,380	0,372
PMT2	0,379	0,192	0,548	0,112	0,379	0,582	0,169	0,669	0,362	**0,947**	0,520	0,286	0,641	0,227	0,357	0,223	0,428	0,393	0,377
PMT3	0,376	0,211	0,518	0,104	0,272	0,625	0,152	0,630	0,385	**0,940**	0,454	0,237	0,539	0,210	0,276	0,202	0,407	0,351	0,378
PZD3	0,326	0,157	0,423	0,255	0,445	0,458	0,204	0,443	0,430	0,457	**0,937**	0,377	0,515	0,324	0,353	0,373	0,472	0,498	0,214
PZD4	0,290	0,181	0,528	0,183	0,338	0,430	0,137	0,480	0,391	0,521	**0,938**	0,321	0,582	0,241	0,272	0,270	0,419	0,421	0,265
PZD5	0,219	0,214	0,364	0,147	0,314	0,371	0,173	0,444	0,286	0,408	**0,836**	0,217	0,475	0,205	0,265	0,251	0,328	0,405	0,256
RZG1	0,179	0,219	0,285	0,345	0,385	0,260	0,345	0,239	0,298	0,327	0,305	**0,725**	0,306	0,330	0,457	0,432	0,382	0,432	0,098
RZG5	0,182	0,091	0,215	0,406	0,474	0,277	0,377	0,172	0,280	0,209	0,280	**0,938**	0,220	0,369	0,594	0,476	0,456	0,516	-0,004
RZG6	0,154	0,063	0,220	0,427	0,497	0,287	0,348	0,199	0,268	0,225	0,312	**0,911**	0,232	0,301	0,536	0,440	0,436	0,491	-0,033
RZM2	0,413	0,162	0,590	0,158	0,437	0,525	0,164	0,598	0,419	0,620	0,543	0,336	**0,876**	0,309	0,374	0,323	0,437	0,438	0,344
RZM3	0,296	0,240	0,598	0,076	0,308	0,382	0,079	0,518	0,252	0,513	0,514	0,204	**0,913**	0,152	0,265	0,212	0,326	0,351	0,238
RZM4	0,287	0,216	0,605	0,037	0,296	0,392	0,053	0,579	0,311	0,527	0,519	0,232	**0,931**	0,130	0,238	0,222	0,353	0,332	0,326
SPK1	0,211	0,245	0,179	0,389	0,456	0,360	0,584	0,183	0,372	0,195	0,273	0,351	0,206	**0,947**	0,452	0,530	0,451	0,554	0,063
SPK2	0,208	0,259	0,212	0,365	0,454	0,377	0,555	0,193	0,355	0,238	0,272	0,370	0,225	**0,945**	0,460	0,536	0,444	0,555	0,081
SPK3	0,231	0,233	0,148	0,426	0,476	0,374	0,613	0,180	0,408	0,240	0,267	0,370	0,193	**0,934**	0,486	0,553	0,469	0,591	0,102
UTK2	0,207	0,188	0,244	0,437	0,537	0,431	0,518	0,252	0,304	0,298	0,272	0,604	0,260	0,427	**0,918**	0,472	0,482	0,621	0,139
UTK4	0,122	0,178	0,206	0,453	0,549	0,355	0,568	0,269	0,266	0,222	0,245	0,545	0,255	0,428	**0,924**	0,494	0,451	0,624	0,122
UTK5	0,159	0,273	0,274	0,412	0,645	0,458	0,545	0,375	0,357	0,381	0,382	0,541	0,372	0,500	**0,897**	0,517	0,534	0,689	0,276
ZAD2	0,232	0,048	0,236	0,300	0,460	0,410	0,358	0,301	0,424	0,200	0,316	0,493	0,225	0,467	0,438	**0,778**	0,718	0,418	0,059
ZAD3	0,250	0,181	0,197	0,411	0,528	0,405	0,509	0,344	0,508	0,196	0,314	0,446	0,314	0,506	0,499	**0,913**	0,594	0,613	-0,008
ZAD4	0,097	0,203	0,127	0,441	0,507	0,338	0,554	0,184	0,458	0,151	0,234	0,412	0,188	0,508	0,462	**0,889**	0,534	0,596	-0,034

Tablica 6.59 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App (nastavak)

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
ZAU1	0,308	0,265	0,369	0,258	0,432	0,713	0,346	0,507	0,551	0,477	0,420	0,402	0,376	0,363	0,466	0,508	**0,819**	0,511	0,264
ZAU3	0,255	0,122	0,359	0,315	0,533	0,459	0,392	0,359	0,446	0,320	0,426	0,502	0,362	0,487	0,474	0,679	**0,862**	0,515	0,191
ZAU4	0,211	0,128	0,266	0,264	0,499	0,469	0,386	0,393	0,344	0,304	0,300	0,338	0,306	0,366	0,414	0,598	**0,844**	0,471	0,138
ZDV1	0,199	0,303	0,248	0,522	0,555	0,397	0,589	0,295	0,489	0,306	0,406	0,487	0,319	0,537	0,610	0,591	0,513	**0,924**	0,042
ZDV2	0,204	0,280	0,249	0,524	0,614	0,455	0,603	0,286	0,498	0,312	0,471	0,483	0,344	0,584	0,620	0,603	0,557	**0,933**	0,070
ZDV4	0,251	0,325	0,345	0,395	0,667	0,469	0,491	0,391	0,417	0,452	0,439	0,532	0,452	0,498	0,673	0,512	0,527	**0,835**	0,201
ZRO1	0,100	0,100	0,242	-0,029	0,231	0,453	0,074	0,416	0,147	0,363	0,295	0,072	0,285	0,165	0,253	0,133	0,315	0,208	**0,865**
ZRO2	0,083	0,021	0,263	-0,179	0,058	0,264	-0,099	0,351	0,037	0,348	0,226	-0,045	0,322	0,002	0,113	-0,074	0,137	0,037	**0,893**
ZRO3	0,136	0,015	0,258	-0,133	0,046	0,278	-0,093	0,326	0,149	0,334	0,180	0,019	0,278	0,061	0,151	-0,052	0,159	0,056	**0,869**

Tablica 6.60 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	OPR	PDK
LAK	**0,844**	0,590
LUK	**0,871**	0,441
PMT	**0,899**	0,349
ZAD	0,369	**0,925**
ZAU	0,600	**0,925**

Tablica 6.61 Vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	NPR
OPR	0,884
ZRO	0,820

Tablica 6.62 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\lvert OU/\sigma \rvert$)**
DST1 -> DST	0,672	0,670	0,042	15,888***
DST4 -> DST	0,606	0,602	0,052	11,612***
DST5 -> DST	0,433	0,431	0,055	7,830***
INT1 -> INT	0,856	0,853	0,027	31,280***
INT2 -> INT	0,302	0,300	0,075	4,015***
INT3 -> INT	0,421	0,424	0,074	5,651***
IRO1 -> IRO	0,453	0,457	0,071	6,409***
IRO2 -> IRO	0,589	0,583	0,079	7,420***
IRO3 -> IRO	0,401	0,394	0,080	4,995***
IRO4 -> IRO	0,535	0,532	0,081	6,645***
MIN1 -> MIN	0,332	0,333	0,062	5,384***
MIN2 -> MIN	0,551	0,548	0,048	11,457***
MIN5 -> MIN	0,580	0,577	0,050	11,667***
MIN7 -> MIN	0,471	0,472	0,054	8,749***
MIN8 -> MIN	0,445	0,444	0,057	7,772***
MOP1 -> MOP	0,551	0,535	0,123	4,476***
MOP2 -> MOP	0,456	0,452	0,136	3,357***
MOP4 -> MOP	0,700	0,683	0,107	6,525***
MPR1 -> MPR	0,482	0,454	0,232	2,075*
MPR2 -> MPR	0,675	0,615	0,223	3,034**
MPR3 -> MPR	0,559	0,510	0,243	2,298*
PIN1 -> PIN	0,493	0,491	0,088	5,581***
PIN2 -> PIN	0,428	0,415	0,069	6,237***
PIN3 -> PIN	0,460	0,457	0,081	5,698***
PIN4 -> PIN	0,532	0,531	0,075	7,120***
PIN6 -> PIN	0,283	0,279	0,096	2,944**
PNS1 -> PNS	0,540	0,537	0,055	9,881***
PNS2 -> PNS	0,627	0,626	0,057	10,972***
PNS3 -> PNS	0,562	0,565	0,060	9,380***
PST1 -> PST	0,658	0,654	0,078	8,429***
PST4 -> PST	0,546	0,546	0,084	6,539***
PST6 -> PST	0,519	0,514	0,075	6,955***
RIP1 -> RIP	0,481	0,481	0,051	9,394***
RIP3 -> RIP	0,446	0,448	0,057	7,776***
RIP5 -> RIP	0,424	0,422	0,066	6,441***
RIP6 -> RIP	0,513	0,513	0,056	9,141***
RIP7 -> RIP	0,357	0,355	0,072	4,954***

* p < 0,05; ** p < 0,01; *** p < 0,001

Tablica 6.62 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App (nastavak)

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\lvert OU/\sigma \rvert$)**
SGR3 -> SGR	0,412	0,411	0,084	4,906***
SGR4 -> SGR	0,609	0,604	0,055	11,041***
SGR5 -> SGR	0,408	0,404	0,085	4,801***
SGR6 -> SGR	0,509	0,498	0,061	8,329***
SGR10 -> SGR	0,510	0,506	0,078	6,519***
SPO1 -> SPO	0,561	0,537	0,134	4,189***
SPO3 -> SPO	0,727	0,721	0,101	7,172***
SPO4 -> SPO	0,397	0,390	0,118	3,364***
SVK1 -> SVK	0,345	0,342	0,149	2,311*
SVK2 -> SVK	0,684	0,673	0,113	6,031***
SVK3 -> SVK	0,643	0,627	0,108	5,935***
UPA2 -> UPA	0,427	0,420	0,090	4,727***
UPA3 -> UPA	0,444	0,435	0,091	4,870***
UPA4 -> UPA	0,482	0,469	0,086	5,584***
UPA5 -> UPA	0,381	0,376	0,091	4,193***
UPA7 -> UPA	0,493	0,494	0,093	5,329***
UPR1 -> UPR	0,587	0,572	0,095	6,185***
UPR3 -> UPR	0,607	0,593	0,085	7,147***
UPR4 -> UPR	0,319	0,306	0,119	2,667**
UPR5 -> UPR	0,357	0,347	0,105	3,391***
UPR6 -> UPR	0,241	0,242	0,111	2,181*
ZAS1 -> ZAS	0,568	0,567	0,062	9,163***
ZAS3 -> ZAS	0,453	0,449	0,082	5,496***
ZAS4 -> ZAS	0,687	0,685	0,047	14,498***
ZVO2 -> ZVO	0,439	0,444	0,083	5,272***
ZVO3 -> ZVO	0,688	0,688	0,063	10,939***
ZVO4 -> ZVO	0,578	0,575	0,058	9,967***

* $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$

Tablica 6.63 Apsolutna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika (|OU/σ|)**
DST -> DHV	0,898	0,899	0,042	21,591***
INT -> OTV	0,796	0,794	0,043	18,421***
MIN -> FUP	0,940	0,945	0,020	46,339***
PIN -> POK	0,711	0,703	0,064	11,114***
PNS -> OTV	0,816	0,813	0,039	20,983***
PST -> DHV	0,665	0,658	0,068	9,795***
RIP -> POK	0,938	0,938	0,029	31,886***
SGR -> KVS	0,810	0,790	0,081	10,039***
UPA -> FUP	0,676	0,660	0,070	9,642***
ZAS -> RAU	0,845	0,830	0,096	8,795***
ZVO -> RAU	0,783	0,774	0,102	7,656***

*** $p < 0,001$

Tablica 6.64 Apsolutna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika (|OU/σ|)**
DHV -> KVS	0,739	0,732	0,091	8,097***
FUP -> KVU	0,853	0,832	0,104	8,228***
OTV -> KVS	0,847	0,833	0,071	11,927***
POK -> KVU	0,833	0,823	0,104	8,048***

*** $p < 0,001$

Tablica 6.65 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\lvert OU/\sigma \rvert$)**
DST1 -> DST	0,647	0,650	0,044	14,809***
DST4 -> DST	0,628	0,629	0,043	14,508***
DST5 -> DST	0,427	0,429	0,039	11,003***
INT1 -> INT	0,856	0,854	0,042	20,367***
INT2 -> INT	0,302	0,299	0,048	6,290***
INT3 -> INT	0,421	0,421	0,044	9,636***
IRO1 -> IRO	0,453	0,454	0,070	6,451***
IRO2 -> IRO	0,589	0,588	0,063	9,355***
IRO3 -> IRO	0,401	0,393	0,073	5,474***
IRO4 -> IRO	0,535	0,529	0,083	6,490***
MIN1 -> MIN	0,322	0,324	0,030	10,645***
MIN2 -> MIN	0,501	0,501	0,034	14,691***
MIN5 -> MIN	0,496	0,494	0,034	14,651***
MIN7 -> MIN	0,360	0,360	0,034	10,666***
MIN8 -> MIN	0,361	0,363	0,034	10,744***
MOP1 -> MOP	0,551	0,536	0,123	4,475***
MOP2 -> MOP	0,456	0,460	0,119	3,815***
MOP4 -> MOP	0,700	0,686	0,115	6,078***
MPR1 -> MPR	0,482	0,453	0,227	2,119*
MPR2 -> MPR	0,675	0,614	0,224	3,021**
MPR3 -> MPR	0,559	0,513	0,241	2,319*
PIN1 -> PIN	0,493	0,490	0,069	7,105***
PIN2 -> PIN	0,428	0,418	0,062	6,889***
PIN3 -> PIN	0,460	0,457	0,058	7,975***
PIN4 -> PIN	0,532	0,533	0,071	7,444***
PIN6 -> PIN	0,283	0,282	0,056	5,053***
PNS1 -> PNS	0,540	0,537	0,050	10,851***
PNS2 -> PNS	0,627	0,626	0,052	12,014***
PNS3 -> PNS	0,562	0,560	0,048	11,619***
PST1 -> PST	0,658	0,651	0,072	9,113***
PST4 -> PST	0,546	0,546	0,072	7,584***
PST6 -> PST	0,519	0,514	0,071	7,323***
RIP1 -> RIP	0,481	0,482	0,036	13,240***
RIP3 -> RIP	0,446	0,445	0,038	11,732***
RIP5 -> RIP	0,424	0,423	0,034	12,558***
RIP6 -> RIP	0,513	0,511	0,035	14,717***
RIP7 -> RIP	0,357	0,356	0,030	11,810***

* p < 0,05; ** p < 0,01; *** p < 0,001

Tablica 6.65 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App (nastavak)

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\lvert OU/\sigma \rvert$)**
SGR3 -> SGR	0,279	0,283	0,055	5,088***
SGR4 -> SGR	0,505	0,506	0,066	7,701***
SGR5 -> SGR	0,322	0,320	0,060	5,371***
SGR6 -> SGR	0,434	0,428	0,064	6,806***
SGR10 -> SGR	0,443	0,447	0,058	7,687***
SPO1 -> SPO	0,561	0,541	0,130	4,330***
SPO3 -> SPO	0,727	0,722	0,112	6,505***
SPO4 -> SPO	0,397	0,391	0,110	3,618***
SVK1 -> SVK	0,345	0,337	0,129	2,668**
SVK2 -> SVK	0,684	0,674	0,109	6,305***
SVK3 -> SVK	0,643	0,627	0,105	6,139***
UPA2 -> UPA	0,427	0,423	0,081	5,282***
UPA3 -> UPA	0,444	0,442	0,068	6,501***
UPA4 -> UPA	0,482	0,468	0,084	5,768***
UPA5 -> UPA	0,381	0,380	0,075	5,122***
UPA7 -> UPA	0,493	0,493	0,072	6,867***
UPR1 -> UPR	0,587	0,581	0,108	5,431***
UPR3 -> UPR	0,607	0,598	0,104	5,864***
UPR4 -> UPR	0,319	0,310	0,108	2,949**
UPR5 -> UPR	0,357	0,347	0,097	3,685***
UPR6 -> UPR	0,241	0,244	0,100	2,409*
ZAS1 -> ZAS	0,568	0,570	0,048	11,777***
ZAS3 -> ZAS	0,453	0,451	0,056	8,036***
ZAS4 -> ZAS	0,687	0,687	0,051	13,454***
ZVO2 -> ZVO	0,439	0,438	0,064	6,895***
ZVO3 -> ZVO	0,688	0,687	0,052	13,342***
ZVO4 -> ZVO	0,578	0,571	0,054	10,800***

* $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$

Tablica 6.66 Relativna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika (|OU/σ|)**
DST -> DHV	0,776	0,779	0,060	12,952***
INT -> OTV	0,606	0,607	0,053	11,367***
MIN -> FUP	0,799	0,810	0,050	16,071***
PIN -> POK	0,383	0,376	0,066	5,786***
PNS -> OTV	0,635	0,633	0,051	12,361***
PST -> DHV	0,456	0,446	0,081	5,657***
RIP -> POK	0,776	0,780	0,059	13,088***
SGR -> KVS	0,380	0,362	0,146	2,602**
UPA -> FUP	0,369	0,349	0,071	5,196***
ZAS -> RAU	0,658	0,648	0,137	4,814***
ZVO -> RAU	0,566	0,563	0,145	3,915***

** p < 0,01; *** p < 0,001

Tablica 6.67 Relativna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika (|OU/σ|)**
DHV -> KVS	0,368	0,375	0,134	2,744**
FUP -> KVU	0,610	0,594	0,168	3,632***
OTV -> KVS	0,496	0,490	0,150	3,302**
POK -> KVU	0,576	0,574	0,174	3,316***

** p < 0,01; *** p < 0,001

Nakon što je utvrđena razina pouzdanosti manifestnih varijabli, pristupilo se vrjednovanju pouzdanosti latentnih konstrukata. Kao kriterij analize pouzdanosti reflektivnih latentnih konstrukata korišten je koeficijent unutarnje dosljednosti dok se analiza pouzdanosti formativnih latentnih konstrukata sastojala od vrjednovanja multikolinearnosti formativnih manifestnih varijabli. Rezultati vrjednovanja pouzdanosti reflektivnih latentnih konstrukata sadržanih na različitim razinama konceptualnog modela nalaze se u tablici 11.68. Iz spomenutih je rezultata vidljivo da najveći stupanj unutarnje dosljednosti ($\rho_c = 0{,}961$) na prvoj razini ima reflektivni latentni konstrukt kojim je vrjednovana pamtljivost aplikacije Microsoft Word Web App dok je najmanja razina unutarnje dosljednosti ($\rho_c = 0{,}829$) utvrđena za reflektivni latentni konstrukt pomoću kojeg je provjeravano do koje mjere korisnici mogu kontrolirati interakciju sa aplikacijom Microsoft Word Web App. Na drugoj razini višedimenzionalnog modela veću razinu pouzdanosti ($\rho_c = 0{,}922$) ima reflektivni latentni konstrukt primjenom kojeg je vrjednovana produktivnost korisnika tijekom upotrebe aplikacije Microsoft Word Web App dok je nešto manji stupanj pouzdanosti ($\rho_c = 0{,}905$) utvrđen za reflektivni latentni konstrukt kojim je mjerena operabilnost aplikacije Microsoft Word Web App. Konačno, koeficijent unutarnje dosljednosti je u slučaju reflektivnog latentnog konstrukta treće razine pomoću kojeg se provjeravalo koliku je količinu napora potrebno uložiti u korištenje aplikacijom Microsoft Word Web App poprimio vrijednost $\rho_c = 0{,}842$ što implicira dostatnu razinu pouzdanosti. Iz navedenog je moguće zaključiti da su reflektivni latentni konstrukti koji se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App pouzdani. Tablica 6.69 jasno prikazuje da se vrijednosti koeficijenta inflacije varijance (VIF) nalaze u intervalu od 1,017 do 3,389, a vrijednosti koeficijenta tolerancije u rasponu od 0,295 do 0,984 što ukazuje na prihvatljivu razinu multikolineranosti među formativnim manifestnim varijablama pridruženim istom temeljnom latentnom konstruktu. Prema tome, formativni latentni konstrukti sadržani u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App su pouzdani.

Po završetku vrjednovanju pouzdanosti latentnih konstrukata, započela je analiza njihove valjanosti. Vrjednovanje konvergentne valjanosti reflektivnih latentnih konstrukata provedeno je analizom vrijednosti prosječnih ekstrahiranih varijanci. Iz podataka koji se nalaze u tablici 6.68 je vidljivo da su reflektivni latentni konstrukti objasnili između 78,68% i 94,34% varijance pridruženih manifestnih varijabli. Prema tome, svi reflektivni latentni konstrukti su konvergentno valjani. Rezultati vrjednovanja nomološke valjanosti formativnih latentnih konstrukata nalaze se u tablici 6.75. Spomenuta tablica jasno prikazuje da je 81,82% koeficijenata puta koji su odaslani od formativnih latentnih konstrukata prema reflektivnim latentnim konstruktima značajno na razini $\alpha = 0{,}001$ dok je preostalih 18,18% vrijednosti koeficijenata puta značajno na razini $\alpha = 0{,}05$. Iz navedenog je moguće zaključiti da su

formativni latentni kontrukti u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App nomološki valjani.

Tablica 6.68 Vrijednosti kriterija vrjednovanja pouzdanosti i konvergentne valjanosti reflektivnih latentnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

REFLEKTIVNE LATENTNE VARIJABLE	Kompozitna pouzdanost ρ	AVE
Latentne varijable prve razine		
Dosljednost (DSD)	0,847	0,649
Estetika (EST)	0,871	0,695
Familijarnost (FML)	0,908	0,766
Jedinstvenost (JDN)	0,928	0,812
Korisnost (KRS)	0,945	0,852
Lakoća korištenja (LAK)	0,940	0,838
Lojalnost (LOJ)	0,947	0,857
Lakoća učenja korištenja (LUK)	0,949	0,862
Mogućnost kontrole (MOK)	0,829	0,619
Pamtljivost (PMT)	0,961	0,890
Pouzdanost (PZD)	0,931	0,819
Razigranost (RZG)	0,897	0,745
Razumljivost (RZM)	0,933	0,823
Stav prema korištenju (SPK)	0,959	0,887
Užitak (UTK)	0,938	0,834
Zamijećena djelotvornost (ZAD)	0,896	0,743
Zamijećena učinkovitost (ZAU)	0,879	0,708
Zadovoljstvo (ZDV)	0,926	0,807
Zamijećeno radno opterećenje (ZRO)	0,908	0,767
Latentne varijable druge razine		
Operabilnost (OPR)	0,905	0,760
Produktivnost (PDK)	0,922	0,855
Latentna varijabla treće razine		
Napor (NPR)	0,842	0,727

* Referentne vrijednosti: $\rho \geq 0{,}707$; AVE $\geq 0{,}500$

Tablica 6.69 Rezultati analize multikolinearnosti formativnih manifestnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

MV	VIF	Koeficijent tolerancije	MV	VIF	Koeficijent tolerancije
DST1	1,070	0,934	**PST6**	1,279	0,782
DST4	1,070	0,935	**RIP1**	1,410	0,709
DST5	1,017	0,984	**RIP3**	1,427	0,701
INT1	1,261	0,793	**RIP5**	2,125	0,471
INT2	1,511	0,662	**RIP6**	2,582	0,387
INT3	1,266	0,790	**RIP7**	2,463	0,406
IRO1	1,509	0,663	**SGR3**	1,325	0,755
IRO2	1,813	0,552	**SGR4**	1,209	0,827
IRO3	2,538	0,394	**SGR5**	1,518	0,659
IRO4	1,300	0,769	**SGR6**	1,423	0,703
IZD1	1,032	0,969	**SGR10**	1,154	0,866
IZU1	1,026	0,975	**SPO1**	1,434	0,697
MIN1	1,264	0,791	**SPO3**	1,486	0,673
MIN2	1,199	0,834	**SPO4**	1,088	0,919
MIN5	1,228	0,815	**SVK1**	1,456	0,687
MIN7	1,203	0,831	**SVK2**	1,281	0,781
MIN8	1,219	0,820	**SVK3**	1,632	0,613
MOP1	1,925	0,519	**UPA2**	1,342	0,745
MOP2	1,841	0,543	**UPA3**	1,314	0,761
MOP4	1,479	0,676	**UPA4**	1,257	0,795
MPR1	1,043	0,959	**UPA5**	1,161	0,861
MPR2	1,329	0,752	**UPA7**	1,291	0,775
MPR3	1,299	0,770	**UPR1**	1,107	0,904
PIN1	1,241	0,806	**UPR3**	1,430	0,699
PIN2	1,539	0,650	**UPR4**	1,497	0,668
PIN3	2,452	0,408	**UPR5**	1,397	0,716
PIN4	2,250	0,445	**UPR6**	1,580	0,633
PIN6	1,377	0,726	**ZAS1**	1,110	0,901
PNS1	1,196	0,836	**ZAS3**	1,201	0,832
PNS2	1,249	0,801	**ZAS4**	1,148	0,871
PNS3	1,077	0,929	**ZVO2**	2,202	0,454
PST1	1,037	0,965	**ZVO3**	3,139	0,319
PST4	1,298	0,771	**ZVO4**	3,389	0,295

* Referentne vrijednosti: VIF < 5; koeficijent tolerancije > 0,2

Komparacijom vrijednosti standardiziranih faktorskih i unakrsnih opterećenja te komparacijom prosječne ekstrahirane varijance pojedinog reflektivnog latentnog konstrukta i kvadriranih vrijednosti njegovih dvosmjernih korelacija sa preostalim reflektivnim latentnim konstruktima u modelu provedeno je vrjednovanje diskriminacijske valjanosti reflektivnih latentnih konstrukata. Tablice 6.59 i 6.60 zorno prikazuju da su vrijednosti standardiziranih faktorskih opterećenja svih reflektivnih manifestnih varijabli prve i druge razine sa temeljnim latentnim konstruktom veće od njihovih unakrsnih opterećenja sa preostalim reflektivnim latentnim konstruktima u modelu. Osim toga, iz tablica 6.70 i 6.71 je vidljivo da svaki reflektivni latentni konstrukt dijeli više varijance sa pridruženim manifestnim varijablama nego sa preostalim reflektivnim latentnim konstruktima u modelu. Shodno tome, reflektivni latentni konstrukti konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App udovoljavaju kriterijima diskriminacijske valjanosti.

Vrjednovanje diskriminacijske valjanosti formativnih latentnih konstrukata provedeno je analizom vrijednosti njihovih međukorelacija. U tablicama 6.72-6.74 se može vidjeti da formativni latentni konstrukti prve razine dijele između 0% i 22,47% zajedničke varijance, formativni latentni konstrukti druge razine dijele između 8,41% i 20,98% zajedničke varijance, a formativni latentni konstrukti treće razine dijele 29,59% zajedničke varijance, respektivno. Shodno tome, formativni latentni konstrukti svih razina u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App udovoljavaju kriteriju diskriminacijske valjanosti. Temeljem rezultata vrjednovanja metrijskih karakteristika koji se nalaze u tablicama 6.59-6.75 moguće je zaključiti da su reflektivno i formativno operacionalizirani vanjski modeli u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App pouzdani i valjani.

Tablica 6.70 Diskriminacijska valjanost reflektivnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
DSD	**0,649**																		
EST	0,017	**0,695**																	
FML	0,114	0,041	**0,766**																
JDN	0,016	0,028	0,003	**0,812**															
KRS	0,031	0,037	0,093	0,246	**0,852**														
LAK	0,173	0,082	0,218	0,029	0,196	**0,838**													
LOJ	0,011	0,044	0,015	0,274	0,270	0,090	**0,857**												
LUK	0,156	0,033	0,391	0,000	0,121	0,333	0,029	**0,862**											
MOK	0,138	0,053	0,124	0,092	0,165	0,345	0,088	0,148	**0,619**										
PMT	0,145	0,049	0,328	0,013	0,114	0,415	0,033	0,485	0,152	**0,890**									
PZD	0,097	0,040	0,239	0,048	0,166	0,217	0,036	0,252	0,171	0,263	**0,819**								
RZG	0,039	0,018	0,075	0,208	0,276	0,101	0,170	0,053	0,105	0,082	0,118	**0,745**							
RZM	0,136	0,051	0,434	0,010	0,149	0,232	0,012	0,392	0,134	0,376	0,337	0,082	**0,823**						
SPK	0,053	0,068	0,036	0,175	0,241	0,154	0,385	0,039	0,162	0,057	0,083	0,149	0,049	**0,887**					
UTK	0,032	0,055	0,070	0,225	0,401	0,207	0,355	0,108	0,115	0,109	0,109	0,380	0,105	0,246	**0,834**				
ZAD	0,049	0,029	0,046	0,201	0,335	0,197	0,307	0,102	0,290	0,044	0,111	0,270	0,079	0,328	0,293	**0,743**			
ZAU	0,094	0,041	0,155	0,110	0,337	0,418	0,199	0,246	0,281	0,189	0,206	0,243	0,171	0,233	0,288	0,502	**0,708**		
ZDV	0,059	0,114	0,098	0,287	0,465	0,241	0,391	0,130	0,272	0,158	0,239	0,311	0,171	0,362	0,500	0,402	0,352	**0,807**	
ZRO	0,015	0,003	0,084	0,017	0,017	0,145	0,002	0,174	0,016	0,159	0,072	0,000	0,114	0,008	0,039	0,000	0,055	0,013	**0,767**

Tablica 6.71 Diskriminacijska valjanost reflektivnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	OPR	PDK
OPR	**0,760**	
PDK	0,275	**0,855**

Tablica 6.72 Diskriminacijska valjanost formativnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	DST	INT	IRO	IZD	IZU	MIN	MOP	MPR	PIN	PNS	PST	RIP	SGR	SPO	SVK	UPA	UPR	ZAS	ZVO
DST	1,000																		
INT	0,204	1,000																	
IRO	-0,013	-0,017	1,000																
IZD	0,188	0,345	0,171	1,000															
IZU	-0,238	-0,242	0,273	-0,131	1,000														
MIN	0,283	0,257	0,084	0,154	-0,075	1,000													
MOP	0,124	0,200	0,004	0,100	-0,244	0,138	1,000												
MPR	0,233	0,109	0,028	0,247	-0,169	0,319	0,195	1,000											
PIN	0,269	0,185	-0,152	0,081	-0,356	0,310	0,238	0,161	1,000										
PNS	0,328	0,311	0,031	0,233	-0,248	0,265	0,181	0,165	0,257	1,000									
PST	0,272	0,267	-0,246	0,175	-0,372	0,204	0,184	0,162	0,361	0,251	1,000								
RIP	0,207	0,300	0,057	0,174	-0,333	0,333	0,326	0,267	0,440	0,271	0,364	1,000							
SGR	0,408	0,401	0,064	0,343	-0,247	0,298	0,178	0,272	0,104	0,419	0,283	0,279	1,000						
SPO	0,344	0,326	-0,139	0,190	-0,348	0,252	0,283	0,220	0,434	0,261	0,413	0,380	0,280	1,000					
SVK	0,118	0,289	0,194	0,422	-0,197	0,293	0,178	0,300	0,275	0,208	0,284	0,269	0,292	0,289	1,000				
UPA	0,256	0,294	0,159	0,319	-0,171	0,394	0,300	0,351	0,147	0,262	0,198	0,240	0,373	0,244	0,389	1,000			
UPR	0,235	0,267	-0,278	0,082	-0,474	0,122	0,285	0,127	0,437	0,241	0,352	0,455	0,190	0,411	0,164	0,130	1,000		
ZAS	0,182	0,339	0,072	0,383	-0,264	0,171	0,259	0,251	0,332	0,317	0,325	0,382	0,300	0,308	0,444	0,370	0,263	1,000	
ZVO	0,306	0,226	0,001	0,277	-0,257	0,126	0,332	0,085	0,251	0,268	0,271	0,274	0,250	0,336	0,179	0,251	0,347	0,331	1,000

Tablica 6.73 Diskriminacijska valjanost formativnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	DHV	FUP	OTV	POK	RAU
DHV	1,000				
FUP	0,357	1,000			
OTV	0,406	0,390	1,000		
POK	0,400	0,405	0,386	1,000	
RAU	0,394	0,290	0,441	0,458	1,000

Tablica 6.74 Diskriminacijska valjanost formativnih latentnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	KVS	KVU
KVS	1,000	
KVU	0,544	1,000

Vrjednovanje metrijskih karakteristika unutarnjeg modela započelo je analizom vrijednosti koeficijenta determinacije R^2 zavisnih latentnih konstrukata. Na slici 6.24 je moguće uočiti da se vrijednosti koeficijenta determinacije nalaze u intervalu od 0,159 do 0,512. Atributi kvalitete u korištenju pomoću kojih su mjerene dimenzije dosljednosti i mogućnosti prilagodbe aplikacije Microsoft Word Web App su objasnili 15,9% varijance u atributu kojim je vrjednovana pamtljivost aplikacije Microsoft Word Web App. Formativni latentni konstrukti primjenom kojih su mjereni različiti aspekti kvalitete sustava i kvalitete usluge aplikacije Microsoft Word Web App su objasnili 25,5% varijance u reflektivnom latentnom konstruktu pomoću kojeg je vrjednovan stav prema korištenju aplikacijom Microsoft Word Web App. Atribut primjenom kojeg se provjeravalo da li Microsoft Word Web App sprječava nastanak pogrješaka u radu i atribut pomoću kojeg je utvrđeno do koje se mjere Microsoft Word Web App može oporaviti od pogrješaka ili prekida u radu su objasnili 27,4% varijance u atributu kojim je vrjednovana zamijećena pouzdanost aplikacije Microsoft Word Web App. Latentni konstrukti primjenom kojih su mjerene pouzdanost i produktivnost aplikacije Microsoft Word Web App su objasnili 41,8% varijance u latentnom konstruktu pomoću kojeg je vrjednovana korisnost aplikacije Microsoft Word Web App.

Formativne manifestne varijable primjenom kojih su objektivno mjereni aspekti radnog opterećenja korisnika su objasnili 42,2% varijance u reflektivnom latentnom konstruktu pomoću kojeg je vrjednovana zamijećena razina iscrpljenosti i umora nakon interakcije sa aplikacijom Microsoft Word Web App. Atributi korisničkog iskustva primjenom kojih je

vrjednovana razigranost korisnika te jedinstvenost i estetika aplikacije Microsoft Word Web App su objasnili 44,4% varijance u atributu kojim je mjeren užitak kojeg je upotreba aplikacije Microsoft Word Web App pružila korisnicima. Indikator pomoću kojeg je mjereno koliko reprezentativnih koraka scenarija korisnici mogu dovršiti koristeći se aplikacijom Microsoft Word Web App i atribut kojim se provjeravalo do koje je razine aplikaciju Microsoft Word Web App moguće upotrebljavati izvan inicijalno definiranog konteksta korištenja su zajedno objasnili 46% varijance u atributu kojim je vrjednovana zamijećena djelotvornost korisnika. Reflektivni latentni konstrukti temeljem kojih su vrjednovane dimenzije familijarnosti i razumljivosti aplikacije Microsoft Word Web App su objasnili 47,2% varijance u atributu primjenom kojeg je mjerena lakoća učenja korištenja aplikacijom Microsoft Word Web App. Atributi kvalitete u korištenju pomoću kojih su vrjednovani različiti aspekti mogućnosti kontrole i upravljivosti aplikacijom Microsoft Word Web App su objasnili 47,6% varijance u atributu čijim je manifestnim varijablama mjerena lakoća korištenja aplikacijom Microsoft Word Web App.

Indikator primjenom kojeg je mjerena količina vremena potrebnog za dovršetak reprezentativnih koraka scenarija interakcije sa aplikacijom Microsoft Word Web App i formativni latentni konstrukt druge razine pomoću kojeg je vrjednovan radni učinak aplikacije Microsoft Word Web App su zajedno objasnili 48,6% varijance u reflektivnom latentnom konstruktu kojim je vrjednovana zamijećena učinkovitost korisnika. Korisnost, stav prema korištenju i zadovoljstvo su atributi kvalitete u korištenju koji su objasnili 49,2% varijance u atributu čijim je manifestnim varijablama vrjednovana lojalnost korisnika. Naposljetku, reflektivni latentni konstrukt treće razine pomoću kojeg je utvrđeno koliku je količinu napora potrebno uložiti u dovršavanje reprezentativnih koraka scenarija upotrebom aplikacije Microsoft Word Web App i reflektivni latentni konstrukt prve razine kojim je mjeren užitak interakcije sa aplikacijom Microsoft Word Web App su objasnili 51,2% varijance u reflektivnom latentnom konstruktu pomoću kojeg je vrjednovano zadovoljstvo korisnika.

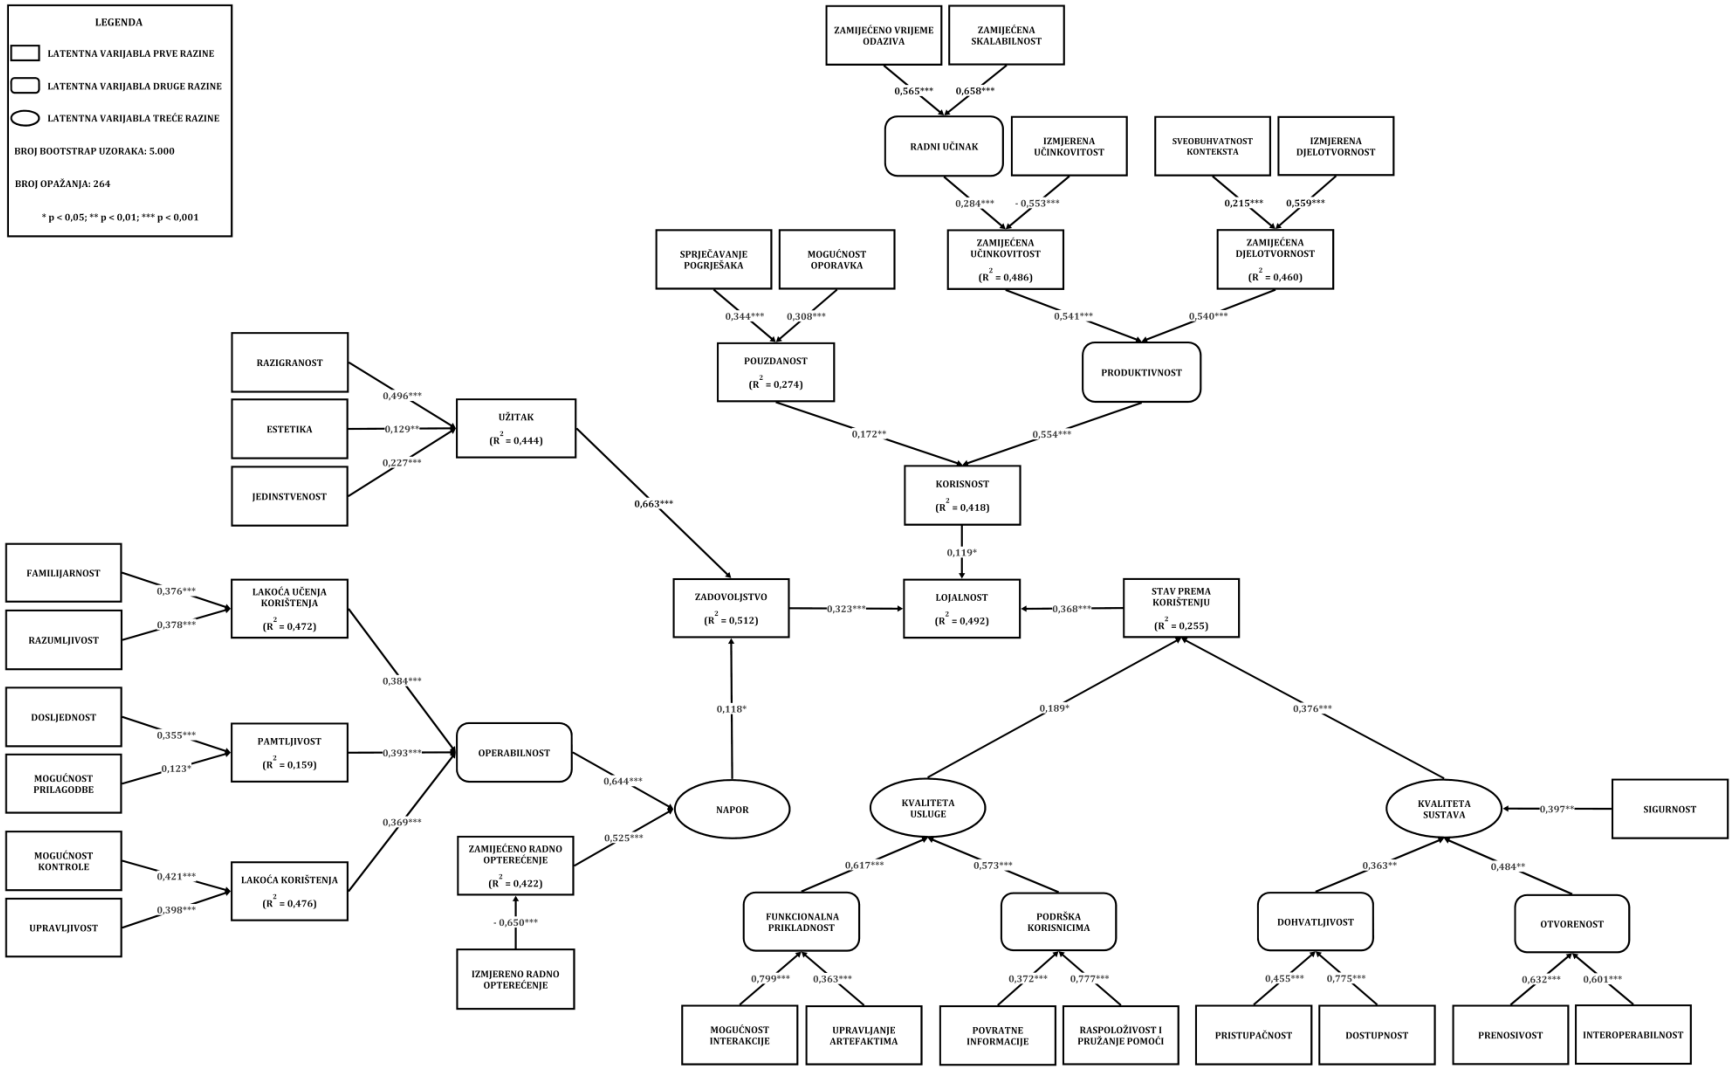

Slika 6.24 Rezultati analize metrijskih karakteristika unutarnjeg modela u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App

Sljedeći korak u vrjednovanju metrijskih karakteristika unutarnjeg modela je bila analiza značajnosti koeficijenata puta čiji su rezultati prikazani u tablici 6.75. Iz spomenute je tablice vidljivo da je 80,85% vrijednosti koeficijenata puta značajno na razini $\alpha = 0{,}001$, 10,64% ih je značajno na razini $\alpha = 0{,}01$ dok je 8,51% vrijednosti koeficijenata puta značajno na razini $\alpha = 0{,}05$. Iz navedenog proizlazi da su sve pothipoteze $H_{1.1}$-$H_{1.25}$ u kontekstu konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App potvrđene.

Uzimajući u obzir razlike u vrijednostima koeficijenata puta među latentnim konstruktima koji pripadaju prvoj razini konceptualnog modela potrebno je izdvojiti atribut pomoću kojeg je vrjednovana dosljednost aplikacije Microsoft Word Web App ($\beta = 0{,}355$; $p < 0{,}001$) iz razloga što je isti značajniji prediktor pamtljivosti aplikacije Microsoft Word Web App od atributa kojim je vrjednovana mogućnost prilagodbe aplikacije Microsoft Word Web App ($\beta = 0{,}123$; $p < 0{,}05$). Na istoj je razini u modelu potrebno još istaknuti atribut kojim je vrjednovana korisnost aplikacije Microsoft Word Web App ($\beta = 0{,}119$; $p < 0{,}05$) zbog toga što ima manju značajnost u oblikovanju lojalnosti korisnika od atributa pomoću kojeg je mjereno zadovoljstvo korisnika ($\beta = 0{,}323$; $p < 0{,}001$) i atributa primjenom kojeg je vrjednovan stav prema korištenju aplikacijom Microsoft Word Web App ($\beta = 0{,}368$; $p < 0{,}001$).

U skupini koeficijenata puta koji odražavaju povezanost latentnih konstrukata na različitim razinama potrebno je spomenuti reflektivni latentni konstrukt druge razine kojim su vrjednovane dimenzije produktivnosti korisnika ($\beta = 0{,}554$; $p < 0{,}001$) jer je značajniji u predikciji korisnosti aplikacije Microsoft Word Web App od reflektivnog latentnog konstrukta pomoću kojeg je mjerena pouzdanost aplikacije Microsoft Word Web App ($\beta = 0{,}172$; $p < 0{,}01$). Pored toga, potrebno je još izdvojiti formativni latentni konstrukt treće razine pomoću kojeg je vrjednovana kvaliteta sustava aplikacije Microsoft Word Web App ($\beta = 0{,}376$; $p < 0{,}001$) iz razloga što isti ima veću značajnost u oblikovanju stava prema korištenju aplikacijom Microsoft Word Web App od formativnog latentnog konstrukta treće razine kojim su mjereni aspekti kvalitete usluge aplikacije Microsoft Word Web App ($\beta = 0{,}189$; $p < 0{,}05$).

Analizom vrijednosti koeficijenata puta još je pronađeno da povećanje broja pomicanja klizača na mišu, broja klikova mišem, broja pritisnutih tipaka na tipkovnici i udaljenosti prijeđene mišem tijekom dovršavanja reprezentativnih koraka scenarija upotrebom aplikacije Microsoft Word Web App rezultira značajnim povećanjem ($\beta = -0{,}650$; $p < 0{,}001$) zamijećenog radnog opterećenja korisnika. Nadalje, utvrđeno je da povećanje broja reprezentativnih koraka scenarija koje je moguće dovršiti tijekom interakcije sa aplikacijom Microsoft Word Web App utječe na značajno povećanje ($\beta = 0{,}559$; $p < 0{,}001$) zamijećene djelotvornosti korisnika. Konačno, pronađeno je i da povećanje količine vremena potrebnog za dovršetak

reprezentativnih koraka scenarija pomoću aplikacije Microsoft Word Web App ima za posljedicu značajno smanjenje ($\beta = -0{,}553;\ p < 0{,}001$) zamijećene učinkovitosti korisnika.

Tablica 6.75 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DHV -> KVS	0,363	0,367	0,133	2,730**
DSD -> PMT	0,355	0,354	0,066	5,368***
DST -> DHV	0,775	0,775	0,060	12,863***
EST -> UTK	0,129	0,129	0,048	2,699**
FML -> LUK	0,376	0,375	0,079	4,796***
FUP -> KVU	0,617	0,600	0,165	3,743***
INT -> OTV	0,601	0,598	0,054	11,111***
IRO -> ZRO	-0,650	-0,657	0,042	15,473***
IZD -> ZAD	0,559	0,558	0,062	9,091***
IZU -> ZAU	-0,553	-0,553	0,059	9,324***
JDN -> UTK	0,227	0,233	0,064	3,533***
KRS -> LOJ	0,119	0,124	0,056	2,118*
KVS -> SPK	0,376	0,379	0,074	5,118***
KVU -> SPK	0,189	0,197	0,074	2,556*
LAK -> OPR	0,369	0,370	0,010	37,456***
LUK -> OPR	0,384	0,384	0,009	42,096***
MIN -> FUP	0,799	0,808	0,050	16,036***
MOK -> LAK	0,421	0,417	0,052	8,088***
MOP -> PZD	0,308	0,313	0,065	4,743***
MPR -> PMT	0,123	0,143	0,056	2,199*
NPR -> ZDV	0,118	0,117	0,047	2,485*
OPR -> NPR	0,644	0,645	0,028	23,033***
OTV -> KVS	0,484	0,477	0,148	3,268**
PDK -> KRS	0,554	0,552	0,067	8,241***
PIN -> POK	0,372	0,358	0,067	5,592***
PMT -> OPR	0,393	0,393	0,011	35,083***
PNS -> OTV	0,632	0,627	0,051	12,293***
POK -> KVU	0,573	0,569	0,172	3,334***
PST -> DHV	0,455	0,440	0,081	5,634***
PZD -> KRS	0,172	0,172	0,064	2,662**
RAU -> ZAU	0,284	0,286	0,057	5,010***
RIP -> POK	0,777	0,778	0,060	13,017***
RZG -> UTK	0,496	0,495	0,057	8,640***
RZM -> LUK	0,378	0,375	0,072	5,219***

* p < 0,05; ** p < 0,01; *** p < 0,001

Tablica 6.75 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App (nastavak)

	Originalan uzorak (OU)	Srednja vrijednost uzorka ($\bar{x}$)	Standardna pogrješka (σ)	T statistika ($\|OU/\sigma\|$)
SGR -> KVS	0,397	0,376	0,145	2,735**
SPK -> LOJ	0,368	0,367	0,064	5,766***
SPO -> PZD	0,344	0,353	0,057	6,046***
SVK -> ZAD	0,215	0,223	0,057	3,777***
UPA -> FUP	0,363	0,336	0,070	5,159***
UPR -> LAK	0,398	0,409	0,058	6,880***
UTK -> ZDV	0,663	0,665	0,042	15,737***
ZAD -> PDK	0,540	0,541	0,008	64,079***
ZAS -> RAU	0,658	0,645	0,138	4,781***
ZAU -> PDK	0,541	0,541	0,009	58,839***
ZDV -> LOJ	0,323	0,319	0,073	4,443***
ZRO -> NPR	0,525	0,524	0,012	42,456***
ZVO -> RAU	0,565	0,559	0,145	3,893***

** p < 0,01; *** p < 0,001

Posljednji korak u vrjednovanju unutarnjeg modela se sastojao od analize veličine utjecaja i prediktivne valjanosti nezavisnih varijabli. Rezultati vrjednovanja maločas spomenutih metrijskih karakteristika unutarnjeg modela nalaze se u tablici 6.76. Analizom rezultata vrjednovanja pronađeno je da 50% nezavisnih varijabli ima mali utjecaj, 32,14% ih ima srednji utjecaj dok ih 17,86% ima veliki utjecaj na zavisne varijable konceptualnog modela.

Najmanju razinu utjecaja ($f^2 = 0{,}02$) u konceptualnom modelu imaju atributi kvalitete u korištenju pomoću kojih su vrjednovani aspekti mogućnosti prilagodbe i korisnosti aplikacije Microsoft Word Web App. U skupini prediktora sa malim utjecajem najveću razinu istog ($f^2 = 0{,}14$) ima formativni latentni konstrukt druge razine primjenom kojeg je mjeren radni učinak aplikacije Microsoft Word Web App. Najmanji stupanj utjecaja ($f^2 = 0{,}15$) u skupini prediktora sa srednjim utjecajem u modelu ima indikator pomoću kojeg je mjereno koliko su tipaka na tipkovnici pritisnuli korisnici tijekom interakcije sa aplikacijom Microsoft Word Web App, formativni latentni konstrukt kojim se provjeravalo da li aplikacija Microsoft Word Web App sprječava nastanak pogrješaka u radu te reflektivni latentni konstrukti primjenom kojih su vrjednovani aspekti familijarnosti i razumljivosti aplikacije Microsoft Word Web App. S druge strane, najveći stupanj utjecaja ($f^2 = 0{,}28$) u skupini prediktora sa srednjim utjecajem ima atribut pomoću kojeg je utvrđeno do koje razine korisnici mogu kontrolirati interakciju sa aplikacijom Microsoft Word Web App. U skupini prediktora sa velikim utjecajem u modelu najmanju razinu istog ($f^2 = 0{,}35$) ima atribut kojim je mjerena razina razigranosti korisnika tijekom upotrebe aplikacije Microsoft Word Web App. Konačno, najveću razinu utjecaja

($f^2 = 0{,}77$) u konceptualnom modelu ima reflektivni latentni konstrukt kojim je mjeren užitak korištenja aplikacijom Microsoft Word Web App.

Od ukupnog broja nezavisnih varijabli u konceptualnom modelu, 71,43% ih ima malu prediktivnu valjanost, 25% ih ima srednju prediktivnu valjanost dok ih 3,57% ima veliku prediktivnu valjanost. Najmanju razinu prediktivne valjanosti ($q^2 = 0{,}02$) u konceptualnom modelu imaju reflektivni latentni konstrukti prve razine primjenom kojih su vrjednovane dimenzije korisnosti i estetike aplikacije Microsoft Word Web App, reflektivni latentni konstrukt druge razine kojim je mjerena količina napora kojeg je potrebno uložiti u interakciju sa aplikacijom Microsoft Word Web App i formativni latentni konstrukt treće razine pomoću kojeg su mjereni različiti aspekti kvalitete usluge aplikacije Microsoft Word Web App. U skupini prediktora male prediktivne valjanosti najveću razinu iste ($q^2 = 0{,}14$) ima reflektivni latentni konstrukt kojim je vrjednovana dosljednost aplikacije Microsoft Word Web App. Nadalje, utvrđeno je da indikator pomoću kojeg je mjerana udaljenost koju su korisnici prošli pomicanjem miša tijekom izvršavanja reprezentativnih koraka scenarija upotrebom aplikacije Microsoft Word Web App ima u skupini nezavisnih varijabli srednje prediktivne valjanosti najmanju razinu iste ($q^2 = 0{,}17$) dok reflektivni latentni konstrukt druge razine pomoću kojeg je vrjednovana produktivnost aplikacije Microsoft Word Web App ima najveću razinu prediktivne valjanosti ($q^2 = 0{,}32$) unutar ove skupine. Naposljetku, najveću razinu prediktivne valjanosti ($q^2 = 0{,}50$) u konceptualnom modelu ima reflektivni latentni konstrukt prve razine kojim je vrjednovan užitak interakcije sa aplikacijom Microsoft Word Web App.

Uzimajući u obzir sve rezultate vrjednovanja metrijskih karakteristika sadržane u tablicama 6.59-6.76, konceptualni model vrjednovanja kvalitete u korištenju aplikacijom Microsoft Word Web App je pouzdan i valjan.

Tablica 6.76 Rezultati analize veličine utjecaja i prediktivne valjanosti egzogenih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Microsoft Word Web App

	R_u^2	R_i^2	f^2	Q_u^2	Q_i^2	q^2
DSD -> PMT	0,159	0,039	0,14	0,146	0,027	0,14
EST -> UTK	0,444	0,428	0,03	0,363	0,353	0,02
FML -> LUK	0,472	0,392	0,15	0,404	0,334	0,12
IRO1 -> ZRO	0,422	0,336	0,15	0,323	0,258	0,10
IRO2 -> ZRO	0,422	0,277	0,25	0,323	0,211	0,17
IRO3 -> ZRO	0,422	0,355	0,12	0,323	0,269	0,08
IRO4 -> ZRO	0,422	0,302	0,21	0,323	0,233	0,13
IZD -> ZAD	0,460	0,206	0,47	0,339	0,152	0,28
IZU -> ZAU	0,486	0,213	0,53	0,342	0,150	0,29
JDN -> UTK	0,444	0,404	0,07	0,363	0,337	0,04
KRS -> LOJ	0,492	0,483	0,02	0,416	0,407	0,02
KVS -> SPK	0,255	0,155	0,13	0,220	0,137	0,11
KVU -> SPK	0,255	0,229	0,03	0,220	0,202	0,02
MOK -> LAK	0,476	0,330	0,28	0,399	0,279	0,20
MOP -> PZD	0,274	0,186	0,12	0,220	0,149	0,09
MPR -> PMT	0,159	0,145	0,02	0,146	0,122	0,03
NPR -> ZDV	0,512	0,499	0,03	0,406	0,395	0,02
PDK -> KRS	0,418	0,166	0,43	0,349	0,139	0,32
PZD -> KRS	0,418	0,394	0,04	0,349	0,328	0,03
RAU -> ZAU	0,486	0,415	0,14	0,342	0,292	0,08
RZG -> UTK	0,444	0,250	0,35	0,363	0,208	0,24
RZM -> LUK	0,472	0,391	0,15	0,404	0,337	0,11
SPK -> LOJ	0,492	0,408	0,17	0,413	0,346	0,11
SPO -> PZD	0,274	0,165	0,15	0,220	0,132	0,11
SVK -> ZAD	0,460	0,424	0,07	0,339	0,315	0,04
UPR -> LAK	0,476	0,347	0,25	0,399	0,289	0,18
UTK -> ZDV	0,512	0,134	0,77	0,406	0,108	0,50
ZDV -> LOJ	0,492	0,446	0,09	0,413	0,378	0,06

R^2– koeficijent determinacije
f^2 – koeficijent veličine utjecaja
Q^2 – Stone-Geisserov indeks unakrsno validirane redundance
q^2 – koeficijent prediktivne valjanosti

6.3.4 Rezultati vrjednovanja kvalitete u korištenju Web 2.0 aplikacija za kolaborativno uređivanje teksta

Procedura izračuna elementarnih i globalnih preferencija Web 2.0 aplikacija namijenjenih kolaborativnom uređivanju teksta prikazana je u tablici 6.77. Premda su preferencije izražene vrijednostima u intervalu [0,1] iste se interpretiraju kao postotci zadovoljenja pojedinog kriterija u stablu zahtjeva. Iz vrijednosti globalnih preferencija je evidentno da Zoho Writer zadovoljava 54,66%, a Microsoft Word Web App 49,73% svih zahtjeva kvalitete u korištenju. U nastavku slijedi pregled podsustava varijabli performansi koji su u značajnoj mjeri doprinijeli razlici među vrijednostima kompozitnih indeksa kvalitete u korištenju (KUK) vrjednovanih Web 2.0 aplikacija za kolaborativno uređivanje teksta.

Analizom rezultata vrjednovanja ustanovljeno je da najveća razlika (40,36%) između vrjednovanih Web 2.0 aplikacija egzistira na razini zadovoljenja zahtjeva izmjerene učinkovitosti (IZU). Naime, korisnicima je prosječno bilo potrebno 80 sekundi da dovrše pojedini reprezentativan korak scenarija kada su upotrebljavali Web 2.0 aplikaciju Microsoft Word Web App čime je ista zadovoljila 68,06% zahtjeva izmjerene učinkovitosti. S druge strane, korisnicima je za provedbu jednog reprezentativnog koraka scenarija u prosjeku bilo potrebno 110 sekundi kada su se koristili Web 2.0 aplikacijom Zoho Writer čime je ista zadovoljila 27,70% zahtjeva izmjerene učinkovitosti. Sljedeći podsustav varijabli performansi u zadovoljenju čijih zahtjeva se Zoho Writer i Microsoft Word Web App razlikuju u velikoj mjeri (28,34%) je izmjereno radno opterećenje (IRO). Naime, korisnici su za vrijeme izvršavanja reprezentativnih koraka scenarija pomoću Web 2.0 aplikacije Zoho Writer u prosjeku pomaknuli klizač na mišu 34,28% veći broj puta (IRO4), pomicanjem miša prošli 32,68% veću udaljenost (IRO2), napravili 27,62% više klikova mišem (IRO3) i pritisnuli 17,37% više tipaka na tipkovnici (IRO1) nego kada su reprezentativne korake scenarija dovršavali upotrebom Web 2.0 aplikacije Microsoft Word Web App. Premda je razlika među vrjednovanim Web 2.0 aplikacijama sa aspekta zadovoljenja zahtjeva varijabli performansi kojima se neposredno vrjednuju dimenzije zamijećenog radnog opterećenja (ZRO) bila vrlo mala (0,62%), spomenuta razlika u stupnju zadovoljenja zahtjeva izmjerenog radnog opterećenja (IRO) rezultirala je značajnom razlikom (14,70%) na razini zadovoljenja podsustava varijabli performansi pomoću kojih se mjeri radno opterećenje (ROP).

Velika razlika (21,43%) između dvije vrjednovane Web 2.0 aplikacije za kolaborativno uređivanje teksta utvrđena je i u kontekstu zadovoljenja zahtjeva izmjerene djelotvornosti (IZD) iz razloga što su korisnici primjenom Web 2.0 aplikacije Zoho Writer uspjeli u prosjeku dovršiti 33, a upotrebom Web 2.0 aplikacije Microsoft Word Web App prosječno 27 od 45

reprezentativnih koraka scenarija. Web 2.0 aplikacije za kolaborativno uređivanje teksta se znatno (17,83%) razlikuju i u razini zadovoljenja varijabli performansi kojima se mjeri interoperabilnost (INT). Konkretnije, razina zadovoljenja zahtjeva pomoću kojeg se provjerava da li je kreirane artefakte moguće pohraniti u formatima datoteka koji su korisnicima potrebni (INT3) je bila 20,36% veća kada su korisnici upotrebljavali Web 2.0 aplikaciju Zoho Writer, stupanj zadovoljenja zahtjeva kojim se utvrđuje da li kod kopiranja kreiranog artefakta između Web 2.0 aplikacije i aplikacija koje korisnici inače upotrebljavaju dolazi do promjene u strukturi artefakta (INT2) je bio 12,97% manji u kontekstu korištenja Web 2.0 aplikacijom Microsoft Word Web App dok je razina zadovoljenja zahtjeva primjenom kojeg se provjerava da li kod prijenosa kreiranog artefakta između Web 2.0 aplikacije i aplikacija koje korisnici redovito upotrebljavaju dolazi do promjene u strukturi artefakta (INT1) je bila 5,68% veća u korist Web 2.0 aplikacije Zoho Writer.

Značajna razlika (10,23%) među vrjednovanim Web 2.0 aplikacijama za kolaborativno uređivanje teksta postoji i na razini zadovoljenja zahtjeva varijabli performansi kojima se mjeri mogućnost interakcije (MIN). Naime, razina zadovoljenja zahtjeva kojim su utvrđuje da li Web 2.0 aplikacija omogućava sinkronu komunikaciju između korisnika (MIN7) je bila 24,43% veća kada su korisnici upotrebljavali Zoho Writer, stupanj zadovoljenja zahtjeva pomoću kojeg se provjerava da li Web 2.0 aplikacija podržava asinkronu komunikaciju među korisnicima (MIN8) je bio 16,57% manji u slučaju upotrebe Web 2.0 aplikacije Microsoft Word Web App, razina zadovoljenja zahtjeva kojim se utvrđuje da li Web 2.0 aplikacija podržava rad većeg broja korisnika u izradi artefakata (MIN5) je bila 4,83% veća u kontekstu upotrebe Web 2.0 aplikacije Zoho Writer, stupanj zadovoljenja zahtjeva kojim se provjerava da li Web 2.0 aplikacija omogućava dodjelu pristupa kreiranom artefaktu preko liste kontakata (MIN1) je bio 3,03% manji u slučaju upotrebe Web 2.0 aplikacije Microsoft Word Web App dok je razina zadovoljenja zahtjeva primjenom kojeg se utvrđuje da li Web 2.0 aplikacija podržava dodjelu pristupa kreiranom artefaktu preko direktne poveznice (MIN2) bila 2,37% veća u korist Web 2.0 aplikacije Zoho Writer.

Uzimajući u obzir rezultate vrjednovanja, razina zadovoljenja zahtjeva definiranih varijablama performansi pomoću kojih se vrjednuje zadovoljstvo (ZDV) je bila 9,63% veća kada su korisnici upotrebljavali Web 2.0 aplikaciju Zoho Writer. Konkretnije, stupanj zadovoljenja zahtjeva kojim se provjerava da li su korisnici generalno zadovoljni upotrebom Web 2.0 aplikacije (ZDV2) je bio 11,84% veći u slučaju korištenja Web 2.0 aplikacijom Zoho Writer, razina zadovoljenja zahtjeva pomoću kojeg se utvrđuje da li je Web 2.0 aplikacija ispunila očekivanja korisnika (ZDV1) je bila 11,74% manja u slučaju upotrebe Web 2.0 aplikacije Microsoft Word Web App dok je stupanj zadovoljenja zahtjeva temeljem kojeg se provjerava do koje je razine Web 2.0 aplikacija na

korisnike ostavila pozitivan dojam (ZDV3) bio 3,50% veći u korist Web 2.0 aplikacije Zoho Writer. Nadalje, stupanj zamijećene djelotvornosti (ZAD) je bio 9,43% manji tijekom interakcije sa Web 2.0 aplikacijom Microsoft Word Web App. Naime, razina zadovoljenja zahtjeva kojim se provjerava da li Web 2.0 aplikacija ima sve funkcionalnosti potrebne za izvršavanje zadatka (ZAD4) je bila 15,91% veća kada su korisnici upotrebljavali Zoho Writer, stupanj zadovoljenja zahtjeva pomoću kojeg se utvrđuje da li je upotrebom Web 2.0 aplikacije zadatke moguće izvršiti točno i u potpunosti (ZAD3) je bio 8,05% manji u kontekstu interakcije sa Web 2.0 aplikacijom Microsoft Word Web App dok je razina zadovoljenja zahtjeva primjenom kojeg se provjerava da li upotreba Web 2.0 aplikacije utječe na povećanje djelotvornosti korisnika u izvršavanju zadataka (ZAD2) bila 2,84% veća u korist Web 2.0 aplikacije Zoho Writer.

Vrjednovane Web 2.0 aplikacije se dostatno (9,16%) razlikuju i sa aspekta zadovoljenja zahtjeva definiranih atributom kvalitete u korištenju kojim se vrjednuje upravljanje artefaktima (UPA). Konkretnije, razina zadovoljenja zahtjeva kojim se provjerava da li Web 2.0 aplikacija sadrži funkcionalnost automatske pohrane artefakta (UPA5) je bila 15,63% veća u slučaju korištenja Web 2.0 aplikacijom Zoho Writer, stupanj zadovoljenja zahtjeva primjenom kojeg se utvrđuje da li Web 2.0 aplikacija omogućuje označavanje kreiranih artefakata pomoću tagova (UPA4) je bila 15,44% manja u kontekstu upotrebe Web 2.0 aplikacije Microsoft Word Web App, razina zadovoljenja zahtjeva pomoću kojeg se provjerava da li Web 2.0 aplikacija sadrži funkcionalnost slanja obavijesti o promjenama nad artefaktom (UPA7) je bila 8,90% veća kada se upotrebljavao Zoho Writer, stupanj zadovoljenja zahtjeva kojim se provjerava da li Web 2.0 aplikacija sadrži funkcionalnost dodjele razina vidljivosti kreiranom artefaktu (UPA2) je bio 4,07% manji kada se upotrebljavao Microsoft Word Web App dok je razina zadovoljenja zahtjeva primjenom kojeg se utvrđuje da li Web 2.0 aplikacija sadrži funkcionalnost za dodjeljivanje dozvola nad kreiranim artefaktom (UPA3) bila 3,03% veća u korist upotrebe Web 2.0 aplikacije Zoho Writer. Razlike u zadovoljenju zahtjeva atributa kvalitete u korištenju kojima se vrjednuje mogućnost interakcije (MIN) i upravljanje artefaktima (UPA) rezultirale su dostatnom razlikom (9,68%) među vrjednovanim Web 2.0 aplikacijama u kontekstu zadovoljenja zahtjeva podsustava varijabli performansi kojima se mjeri funkcionalna prikladnost (FUP).

Zoho Writer i Microsoft Word Web App se značajno (6,44%) razlikuju i u stupnju zadovoljenja zahtjeva definiranih varijablama performansi kojima se vrjednuje stav prema korištenju (SPK). Naime, razina zadovoljenja zahtjeva kojim se provjerava da li korisnici smatraju da je upotreba Web 2.0 aplikacije dobra ideja (SPK1) je bila 6,91% veća u slučaju upotrebe Web 2.0 aplikacije Zoho Writer, stupanj zadovoljenja zahtjeva primjenom kojeg se utvrđuje da li se korisnicima sviđa ideja o upotrebi Web 2.0 aplikacije (SPK3) je bila 6,63% manja u kontekstu korištenja Web 2.0 aplikacijom Microsoft Word Web App dok je razina zadovoljenja zahtjeva pomoću kojeg se

provjera da li korisnici smatraju da je korištenje Web 2.0 aplikacijom mudra ideja (SPK2) bila 5,78% veća u korist Web 2.0 aplikacije Zoho Writer. Od preostalih atributa kvalitete u korištenju sa aspekta kojih među vrjednovanim Web 2.0 aplikacijama postoji zamjetna razlika (6,02%) potrebno je još spomenuti zamijećenu skalabilnost (ZAS). Konkretnije, stupanj zadovoljenja zahtjeva definiranog varijablom kojom se provjerava mogućnost izvršavanja kompleksnih zadataka upotrebom Web 2.0 aplikacije (ZAS4) je bio 10,42% veći kada su korisnici upotrebljavali Zoho Writer, razina zadovoljenja zahtjeva definiranog varijablom kojom se utvrđuje da li Web 2.0 aplikacija omogućuje istovremeni rad na većem broju zadataka (ZAS3) je bila 9,56% manja kada su korisnici upotrebljavali Microsoft Word Web App, a stupanj zadovoljenja zahtjeva definiranog varijablom primjenom koje se ustanovljuje da li Web 2.0 aplikacija omogućuje pohranu velike količine artefakata (ZAS1) je bio 1,61% veći u korist Web 2.0 aplikacije Microsoft Word Web App.

U suprotnosti sa dosad navedenim, vrjednovane Web 2.0 aplikacije za kolaborativno uređivanje teksta se vrlo malo razlikuju sa aspekta zadovoljenja zahtjeva kojima se mjere sljedeći podsustavi varijabli performansi: prenosivost (PNS; 0,06%), razumljivost (RZM; 0,21%), zamijećena lakoća korištenja (ZLK*; 0,24%), sveobuhvatnost konteksta (SVK; 0,25%); mogućnost prilagodbe (MPR; 0,31%), produktivnost (PDK; 0,61%), zamijećeno radno opterećenje (ZRO; 0,62%), povratne informacije (PIN; 0,81%), operabilnost (OPR; 0,83%) i lakoća učenja korištenja (LUK; 1,00%).

Tablica 6.77 Elementarne i globalne preferencije Web 2.0 aplikacija za kolaborativno uređivanje teksta

X_i	W_i	Zoho Writer		Microsoft Word Web App	
		E_i	E	E_i	E
Familijarnost (FML)			0,7236		0,7678
FML1	0,3141	0,6875		0,7311	
FML3	0,3362	0,7386		0,7784	
FML4	0,3497	0,7415		0,7907	
Razumljivost (RZM)			0,7475		0,7454
RZM2	0,3276	0,7197		0,7102	
RZM3	0,3363	0,7604		0,7746	
RZM4	0,3361	0,7652		0,7566	
Lakoća učenja korištenja (LUK)			0,7045		0,7145
LUK1	0,2961	0,7008		0,7121	
LUK2	0,3627	0,6960		0,7045	
LUK3	0,3412	0,7169		0,7273	
Dosljednost (DSD)			0,6903		0,6673
DSD2	0,3192	0,6847		0,6496	
DSD3	0,3609	0,7083		0,6913	
DSD4	0,3199	0,6761		0,6544	
Mogućnost prilagodbe (MPR)			0,5572		0,5541
MPR1	0,3665	0,5369		0,5587	
MPR2	0,3645	0,5568		0,5369	
MPR3	0,2690	0,5852		0,5710	
Pamtljivost (PMT)			0,6938		0,7224
PMT1	0,3721	0,7027		0,7282	
PMT2	0,3224	0,7083		0,7330	
PMT3	0,3055	0,6686		0,7045	
Mogućnost kontrole (MOK)			0,6738		0,6398
MOK1	0,3773	0,6468		0,6061	
MOK2	0,2911	0,6733		0,6544	
MOK3	0,3316	0,7074		0,6733	
Upravljivost (UPR)			0,6763		0,6488
UPR1	0,1912	0,6563		0,6212	
UPR3	0,2271	0,6610		0,6250	
UPR4	0,1768	0,7282		0,7244	
UPR5	0,1705	0,6922		0,6326	
UPR6	0,2344	0,6638		0,6638	
Lakoća korištenja (LAK)			0,6364		0,6601
LAK1	0,3316	0,6184		0,6430	
LAK2	0,3562	0,6553		0,6761	
LAK3	0,3122	0,6364		0,6619	

Tablica 6.77 Elementarne i globalne preferencije Web 2.0 aplikacija za kolaborativno uređivanje teksta (nastavak)

X_i	W_i	Zoho Writer		Microsoft Word Web App	
		E_i	E	E_i	E
Zamijećena lakoća učenja korištenja (ZLU*)			0,7169		0,7291
FML	0,1692	0,7236		0,7678	
RZM	0,2280	0,7475		0,7454	
LUK	0,6028	0,7045		0,7145	
Zamijećena pamtljivost (ZPM*)			0,6735		0,6854
DSD	0,2202	0,6903		0,6673	
MPR	0,1717	0,5572		0,5541	
PMT	0,6081	0,6938		0,7224	
Zamijećena lakoća korištenja (ZLK*)			0,6509		0,6534
MOK	0,2151	0,6738		0,6398	
UPR	0,1906	0,6763		0,6488	
LAK	0,5943	0,6364		0,6601	
Operabilnost (OPR)			0,6787		0,6870
ZLU*	0,3298	0,7169		0,7291	
ZPM*	0,3099	0,6735		0,6854	
ZLK*	0,3603	0,6509		0,6534	

* kompozitne varijable

Tablica 6.77 Elementarne i globalne preferencije Web 2.0 aplikacija za kolaborativno uređivanje teksta (nastavak)

X_i	W_i	Zoho Writer		Microsoft Word Web App	
		E_i	E	E_i	E
Razigranost (RZG)			0,4972		0,4754
RZG1	0,3630	0,5739		0,5549	
RZG5	0,3364	0,4678		0,4403	
RZG6	0,3006	0,4375		0,4186	
Estetika (EST)			0,6739		0,6959
EST2	0,3592	0,7273		0,7443	
EST4	0,3454	0,6269		0,6477	
EST5	0,2954	0,6638		0,6932	
Jedinstvenost (JDN)			0,5080		0,4702
JDN1	0,3632	0,4915		0,4489	
JDN2	0,2863	0,5085		0,4792	
JDN3	0,3505	0,5246		0,4848	
Užitak (UTK)			0,4641		0,4309
UTK2	0,3139	0,4886		0,4564	
UTK4	0,3596	0,4100		0,3854	
UTK5	0,3265	0,5000		0,4564	
Zadovoljstvo (ZDV)			0,6029		0,5065
ZDV1	0,3832	0,6136		0,4962	
ZDV2	0,3609	0,6193		0,5009	
ZDV4	0,2559	0,5663		0,5313	
Izmjereno radno opterećenje (IRO)			0,3078		0,5912
IRO1	0,2234	0,3069		0,4806	
IRO2	0,2697	0,2906		0,6174	
IRO3	0,2592	0,3213		0,5975	
IRO4	0,2477	0,3131		0,6559	
Zamijećeno radno opterećenje (ZRO)			0,5524		0,5586
ZRO1	0,3712	0,5047		0,5095	
ZRO2	0,3204	0,5360		0,5426	
ZRO3	0,3084	0,6269		0,6345	

Tablica 6.77 Elementarne i globalne preferencije Web 2.0 aplikacija za kolaborativno uređivanje teksta (nastavak)

X_i	W_i	Zoho Writer		Microsoft Word Web App	
		E_i	E	E_i	E
Zamijećen užitak (ZUT*)			0,5167		0,4952
RZG	0,1773	0,4972		0,4754	
EST	0,1881	0,6739		0,6959	
JDN	0,1668	0,5080		0,4702	
UTK	0,4678	0,4641		0,4309	
Radno opterećenje (ROP*)			0,4282		0,5752
IRO	0,5078	0,3078		0,5912	
ZRO	0,4922	0,5524		0,5586	
Napor (NPR)			0,6142		0,6589
OPR	0,5597	0,6787		0,6870	
ROP*	0,4403	0,4282		0,5752	
Zamijećeno zadovoljstvo (ZAZ*)			0,5915		0,5366
NPR	0,2205	0,6142		0,6589	
ZUT*	0,2026	0,5167		0,4952	
ZDV	0,5769	0,6029		0,5065	

* kompozitne varijable

Tablica 6.77 Elementarne i globalne preferencije Web 2.0 aplikacija za kolaborativno uređivanje teksta (nastavak)

X_i	W_i	Zoho Writer		Microsoft Word Web App	
		E_i	E	E_i	E
Zamijećeno vrijeme odaziva (ZVO)			0,7570		0,7197
ZVO2	0,3357	0,7566		0,7074	
ZVO3	0,3227	0,7509		0,7169	
ZVO4	0,3416	0,7633		0,7358	
Zamijećena skalabilnost (ZAS)			0,6599		0,5998
ZAS1	0,3425	0,6648		0,6809	
ZAS3	0,3312	0,6894		0,5938	
ZAS4	0,3263	0,6250		0,5208	
Zamijećena učinkovitost (ZAU)			0,5678		0,5793
ZAU1	0,3329	0,5947		0,6108	
ZAU3	0,3448	0,5843		0,5985	
ZAU4	0,3223	0,5256		0,5303	
Sveobuhvatnost konteksta (SVK)			0,6945		0,6920
SVK1	0,3327	0,7273		0,7206	
SVK2	0,3235	0,7235		0,7206	
SVK3	0,3438	0,6354		0,6373	
Zamijećena djelotvornost (ZAD)			0,6164		0,5222
ZAD2	0,3220	0,5985		0,5701	
ZAD3	0,3374	0,6193		0,5388	
ZAD4	0,3406	0,6316		0,4725	
Sprječavanje pogrješaka (SPO)			0,6874		0,7274
SPO1	0,3420	0,7604		0,7528	
SPO3	0,3337	0,8239		0,8087	
SPO4	0,3243	0,5767		0,6534	
Mogućnost oporavka (MOP)			0,6520		0,6041
MOP1	0,3238	0,6591		0,6080	
MOP2	0,3510	0,6610		0,5909	
MOP4	0,3252	0,6364		0,6155	
Pouzdanost (PZD)			0,7374		0,7080
PZD3	0,3128	0,7197		0,6960	
PZD4	0,3613	0,7386		0,7197	
PZD5	0,3259	0,7547		0,7074	
Korisnost (KRS)			0,6090		0,5589
KRS2	0,3508	0,6307		0,5720	
KRS3	0,3079	0,5710		0,5417	
KRS4	0,3413	0,6231		0,5616	

Tablica 6.77 Elementarne i globalne preferencije Web 2.0 aplikacija za kolaborativno uređivanje teksta (nastavak)

X_i	W_i	Zoho Writer		Microsoft Word Web App	
		E_i	E	E_i	E
Radni učinak (RAU)			0,7323		0,6890
ZVO	0,5395	0,7570		0,7197	
ZAS	0,4605	0,6599		0,5998	
Učinkovitost (UNK*)			0,4944		0,6188
RAU	0,2042	0,7323		0,6890	
IZU	0,2045	0,2770		0,6806	
ZAU	0,5913	0,5678		0,5793	
Djelotvornost (DTV*)			0,6169		0,4950
SVK	0,1706	0,6945		0,6920	
IZD	0,2091	0,5714		0,3571	
ZAD	0,6203	0,6164		0,5222	
Zamijećena pouzdanost (ZPD*)			0,7053		0,6833
SPO	0,2094	0,6874		0,7274	
MOP	0,2090	0,6520		0,6041	
PZD	0,5816	0,7374		0,7080	
Produktivnost (PDK)			0,5554		0,5493
UNK*	0,4706	0,4944		0,6188	
DTV*	0,5294	0,6169		0,4950	
Zamijećena korisnost (ZKS*)			0,6142		0,5801
ZPD*	0,2180	0,7053		0,6833	
PDK	0,2295	0,5554		0,5493	
KRS	0,5525	0,6090		0,5589	

* kompozitne varijable

Tablica 6.77 Elementarne i globalne preferencije Web 2.0 aplikacija za kolaborativno uređivanje teksta (nastavak)

X_i	W_i	Zoho Writer		Microsoft Word Web App	
		E_i	E	E_i	E
Mogućnost interakcije (MIN)			0,6952		0,5929
MIN1	0,1793	0,7027		0,6723	
MIN2	0,1978	0,7585		0,7348	
MIN5	0,2232	0,5938		0,5455	
MIN7	0,1928	0,7519		0,5076	
MIN8	0,2069	0,6847		0,5189	
Upravljanje artefaktima (UPA)			0,6850		0,5934
UPA2	0,2254	0,7178		0,6771	
UPA3	0,2094	0,7216		0,6913	
UPA4	0,1779	0,6430		0,4886	
UPA5	0,2102	0,7064		0,5502	
UPA7	0,1771	0,6165		0,5275	
Povratne informacije (PIN)			0,6245		0,6326
PIN1	0,1998	0,5881		0,5890	
PIN2	0,2050	0,6098		0,6051	
PIN3	0,1795	0,7093		0,7131	
PIN4	0,1847	0,6553		0,6619	
PIN6	0,2310	0,6032		0,6335	
Raspoloživost i pružanje pomoći (RIP)			0,6247		0,5914
RIP1	0,1990	0,6780		0,6326	
RIP3	0,1882	0,6506		0,5985	
RIP5	0,1987	0,6383		0,6080	
RIP6	0,2115	0,5994		0,5710	
RIP7	0,2026	0,6023		0,5748	
Funkcionalna prikladnost (FUP)			0,6900		0,5931
MIN	0,4903	0,6952		0,5929	
UPA	0,5097	0,6850		0,5934	
Podrška korisnicima (POK)			0,6246		0,6127
PIN	0,5308	0,6245		0,6326	
RIP	0,4692	0,6247		0,5914	
Kvaliteta usluge (KVU)			0,6407		0,6078
FUP	0,4817	0,6900		0,5931	
POK	0,5183	0,6246		0,6127	

Tablica 6.77 Elementarne i globalne preferencije Web 2.0 aplikacija za kolaborativno uređivanje teksta (nastavak)

X_i	W_i	Zoho Writer		Microsoft Word Web App	
		E_i	E	E_i	E
Pristupačnost (PST)			0,7649		0,7420
PST1	0,3411	0,7708		0,5956	
PST4	0,3395	0,7746		0,7784	
PST6	0,3194	0,7500		0,7936	
Dostupnost (DST)			0,8146		0,7727
DST1	0,3999	0,8068		0,8030	
DST4	0,3201	0,8930		0,8144	
DST5	0,2800	0,7027		0,6345	
Prenosivost (PNS)			0,6124		0,6130
PNS1	0,3243	0,6979		0,6742	
PNS2	0,3483	0,5833		0,5956	
PNS3	0,3274	0,5455		0,5530	
Interoperabilnost (INT)			0,7534		0,5751
INT1	0,3336	0,6922		0,6354	
INT2	0,3280	0,6610		0,5313	
INT3	0,3384	0,7765		0,5729	
Sigurnost (SGR)			0,6548		0,6752
SGR3	0,1657	0,6241		0,6146	
SGR4	0,1652	0,3561		0,5000	
SGR5	0,2093	0,7547		0,7585	
SGR6	0,2038	0,6420		0,6591	
SGR10	0,2560	0,7244		0,7169	
Dohvatljivost (DHV)			0,7909		0,7581
PST	0,4691	0,7649		0,7420	
DST	0,5309	0,8146		0,7727	
Otvorenost (OTV)			0,6459		0,6034
PNS	0,4951	0,6124		0,6130	
INT	0,5049	0,7534		0,5751	
Kvaliteta sustava (KVS)			0,6921		0,6774
DHV	0,3190	0,7909		0,7581	
OTV	0,2924	0,6459		0,6034	
SGR	0,3886	0,6548		0,6752	

Tablica 6.77 Elementarne i globalne preferencije Web 2.0 aplikacija za kolaborativno uređivanje teksta (nastavak)

X_i	W_i	Zoho Writer		Microsoft Word Web App	
		E_i	E	E_i	E
Stav prema korištenju (SPK)			0,6709		0,6065
SPK1	0,3231	0,7045		0,6354	
SPK2	0,3314	0,6657		0,6080	
SPK3	0,3455	0,6458		0,5795	
Lojalnost (LOJ)			0,4052		0,3577
LOJ1	0,3552	0,4044		0,3617	
LOJ2	0,3305	0,4366		0,3731	
LOJ3	0,3143	0,3759		0,3381	
Stav korisnika (STK*)			0,6679		0,6220
KVU	0,2452	0,6407		0,6078	
KVS	0,2301	0,6921		0,6774	
SPK	0,5247	0,6709		0,6065	
Kvaliteta u korištenju (KUK)			0,5466		0,4973
STK*	0,2336	0,6679		0,6220	
ZKS*	0,2591	0,6142		0,5801	
ZAZ*	0,2710	0,5915		0,5366	
LOJ	0,2363	0,4052		0,3577	

* kompozitne varijable

6.3.4.1 Prednosti Web 2.0 aplikacije Zoho Writer

Analizom rezultata vrjednovanja Web 2.0 aplikacije Zoho Writer utvrđeno je da ista u najvećoj mjeri (81,46%) udovoljava zahtjevima atributa kvalitete u korištenju kojim se mjeri dostupnost (DST). Naime, aplikacija Zoho Writer je zadovoljila 89,30% zahtjeva vezanog uz lakoću pronalaska Web 2.0 aplikacija putem web tražilice (DST4), 80,68% zahtjeva koji se odnosi na mogućnost upotrebe Web 2.0 aplikacije svaki put kada je korisniku to potrebno (DST1) i 70,27% zahtjeva vezanog uz mogućnost prijave sa postojećim (npr. Google) korisničkim računom (DST5). Nadalje, aplikacija Zoho Writer je u velikoj mjeri (76,49%) udovoljila i podsustavu varijabli pomoću kojih se vrjednuje pristupačnost (PST). Prema podacima prikupljenima od korisnika, zahtjev kojim se utvrđuje da li je tekst koji opisuje funkcionalnost pojedinih elemenata sučelja Web 2.0 aplikacije dovoljno velik za čitanje (PST4) je zadovoljen 77,46%, zahtjev primjenom kojeg se provjerava da li Web 2.0 aplikacija sadrži popis tipkovničkih kratica za pokretanje često korištenih elemenata sučelja (PST1) je zadovoljen 77,08%, a zahtjev kojim se utvrđuje da li su elementi sučelja Web 2.0 aplikacije dovoljno veliki (PST6) je zadovoljen 75,00%. Ukoliko se u obzir uzmu razine zadovoljenja zahtjeva definiranih atributima dostupnost

(DST) i pristupačnost (PST), Zoho Writer je zadovoljio 79,09% svih zahtjeva kojima se vrjednuje dohvatljivost (DHV) Web 2.0 aplikacije.

Sljedeći atribut kvalitete u korištenju čijim je zahtjevima aplikacija Zoho Writer udovoljila u dostatnoj mjeri (75,70%) je zamijećeno vrijeme odaziva (ZVO). Konkretnije, aplikacija Zoho Writer je zadovoljila 76,33% zahtjeva definiranog varijablom kojom se mjeri razina do koje je zamijećeno vrijeme odaziva korisnicima prihvatljivo (ZVO4), 75,66% zahtjeva definiranog varijablom kojom se vrjednuje stupanj zamijećene brzine učitavanja radnog prostora i elemenata sučelja Web 2.0 aplikacije u web pregledniku (ZVO2) te 75,09% zahtjeva definiranog varijablom kojom se mjeri zamijećeno vrijeme čekanja do pokretanja i izvršavanja odabranih funkcionalnosti sučelja Web 2.0 aplikacije (ZVO3). Obzirom da je aplikacija Zoho Writer uz spomenuto zadovoljenje zahtjeva zamijećenog vremena odaziva (ZVO) u relativno velikoj mjeri (65,99%) udovoljila i zahtjevima zamijećene skalabilnosti (ZAS), ista je zadovoljila 73,23% svih zahtjeva definiranih podsustavom varijabli performansi pomoću kojih se mjeri radni učinak (RAU).

Interoperabilnost (INT) je atribut kvalitete u korištenju čija elementarna preferencija u kontekstu vrjednovanja Web 2.0 aplikacije Zoho Writer iznosi 75,34%. Naime, aplikacija Zoho Writer je zadovoljila 77,65% zahtjeva primjenom kojeg se utvrđuje da li Web 2.0 aplikacija omogućava pohranu kreiranih artefakata u formatima datoteka koje su korisnicima potrebni (INT3), 69,22% zahtjeva pomoću kojeg se provjerava da li kod prijenosa artefakta između Web 2.0 aplikacije i aplikacije koje korisnici svakodnevno upotrebljavaju dolazi do promjene u strukturi artefakta (INT1) i 66,10% zahtjeva kojim se utvrđuje da li prilikom kopiranja artefakta između Web 2.0 aplikacije i aplikacije koju korisnici redovito upotrebljavaju dolazi do promjene u strukturi artefakta (INT2). Uzimajući u obzir rezultate vrjednovanja, elementi korisničkog sučelja Web 2.0 aplikacije Zoho Writer su korisnicima bili u dostatnoj mjeri (74,75%) razumljivi (RZM). Naime, aplikacija Zoho Writer je zadovoljila 76,52% zahtjeva kojim se provjerava da li naziv funkcionalnih elemenata sučelja Web 2.0 aplikacije odgovara kontekstu njihove upotrebe (RZM4), 76,04% zahtjeva pomoću kojeg se utvrđuje da li je izgled ikona usklađen sa njihovom namjenom (RZM3) i 71,97% zahtjeva primjenom kojeg se mjeri razina zamijećene razumljivosti funkcionalnih elemenata sučelja Web 2.0 aplikacije (RZM2).

Prihvatljiva je i razina (73,74%) na kojoj je aplikacija Zoho Writer udovoljila varijablama performansi kojima se vrjednuje pouzdanost (PZD) pri čemu je zahtjev kojim se utvrđuje da li Web 2.0 aplikacija ima softverskih pogrješaka (PZD5) zadovoljen 75,47%, zahtjev pomoću kojeg se vrjednuje stupanj zamijećene stabilnosti Web 2.0 aplikacije (PZD4) je zadovoljen 73,86% dok je zahtjev kojim se mjeri razina zamijećene pouzdanosti (PZD3) zadovoljen 71,97%. Kako je aplikacija Zoho Writer u nešto manjoj mjeri zadovoljila zahtjeve varijabli performansi kojima se

vrjednuju sprječavanje pogrješaka (SPO; 68,74) i mogućnost oporavka (MOP; 65,20%) od maločas navedenih stupnjeva zadovoljenja zahtjeva kojima se neposredno mjere dimenzije pouzdanosti (PZD), ista je u konačnici zadovoljila 70,53% svih zahtjeva definiranih kompozitnim podsustavom varijabli performansi primjenom kojih se mjeri zamijećena pouzdanost (ZPD*).

Iz rezultata vrjednovanja je također vidljivo da su korisnici u prihvatljivoj mjeri (72,36%) upoznati (FML) sa načinom upotrebe Web 2.0 aplikacije Zoho Writer. Naime, zahtjev koji se odnosi na razinu do koje Web 2.0 aplikacija upotrebljava slične ikone za pokretanje pojedinih funkcionalnosti sučelja kao i aplikacije kojima se korisnici svakodnevno koriste (FML4) je zadovoljen 74,15%, zahtjev vezan uz stupanj do kojeg Web 2.0 aplikacija upotrebljava jednake nazive za pojedine funkcionalnosti sučelja kao i aplikacije kojima se korisnici inače koriste (FML3) je zadovoljen 73,86% dok je zahtjev koji se odnosi na mjeru do koje je raspored funkcionalnosti na korisničkom sučelju sličan rasporedu funkcionalnosti u aplikacijama koje korisnici redovito upotrebljavaju (FML1) zadovoljen 68,75%. Osim navedenog, Web 2.0 aplikacija Zoho Writer je u dostatnoj mjeri (70,45%) udovoljila i zahtjevima atributa kvalitete u korištenju kojim se vrjednuje lakoća učenja korištenja (LUK). Konkretnije, aplikacija Zoho Writer je zadovoljila 71,69% zahtjeva varijable kojom se mjeri zamijećena brzina učenja korištenja funkcionalnostima sučelja Web 2.0 aplikacije (LUK3), 71,21% zahtjeva varijable kojom se vrjednuje zamijećena jednostavnost razvoja vještine korištenja Web 2.0 aplikacijom (LUK1) i 69,60% zahtjeva varijable kojom se mjeri zamijećena lakoća učenja izvršavanja zadataka pomoću Web 2.0 aplikacije (LUK2). Maločas spomenuti stupnjevi zadovoljenja varijabli performansi kojima se neposredno vrjednuju dimenzije lakoće učenja korištenja (LUK) su zajedno sa prije navedenim razinama zadovoljenja zahtjeva definiranih atributima razumljivost (RZM) i familijarnost (FML) rezultirali visokim stupnjem (71,69%) zadovoljenja svih zahtjeva kompozitnog podsustava varijabli performansi kojima se mjeri zamijećena lakoća učenja korištenja (ZLU*) Web 2.0 aplikacije Zoho Writer.

Atribut kvalitete u korištenju čija je vrijednost elementarne preferencije u kontekstu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijom Zoho Writer poprimila vrijednost 69,52% nosi naziv mogućnost interakcije (MIN). Prema rezultatima vrjednovanja ovog podsustava varijabli performansi, aplikacija Zoho Writer je zadovoljila 75,85% zahtjeva varijable kojom se mjeri razina do koje korisnici mogu dodijeliti pristup kreiranom artefaktu preko direktne poveznice (MIN2), 75,19% zahtjeva varijable pomoću koje se vrjednuje stupanj do kojeg Web 2.0 aplikacija omogućava sinkronu komunikaciju sa ostalim korisnicima (MIN7), 70,27% zahtjeva varijable kojom se mjeri razina do koje korisnici mogu dodijeliti pristup kreiranom artefaktu preko liste kontakata (MIN1), 68,47% zahtjeva pomoću kojeg se vrjednuje stupanj do kojeg Web 2.0 aplikacija omogućava asinkronu komunikaciju među korisnicima

(MIN8) i 59,38% zahtjeva varijable kojom se mjeri razina do koje Web 2.0 aplikacija podržava rad većeg broja korisnika na izradi artefakta (MIN5). Od preostalih atributa kvalitete u korištenju čijim je zahtjevima aplikacija Zoho Writer udovoljila u dostatnoj mjeri (69,45%) potrebno je još izdvojiti sveobuhvatnost konteksta (SVK). Naime, zahtjev koji se odnosi na razinu do koje Web 2.0 aplikacija omogućava izradu raznovrsnih artefakata (SVK1) je zadovoljen 72,73%, zahtjev vezan uz stupanj do kojeg je Web 2.0 aplikaciju moguće upotrebljavati i izvan konteksta za koji je inicijalno namijenjena (SVK2) je zadovoljen 72,35% dok je zahtjev koji se odnosi na razinu do koje Web 2.0 aplikacija ima široku mogućnost primjene (SVK3) zadovoljen 63,54%.

6.3.4.2 Nedostatci Web 2.0 aplikacije Zoho Writer

Nasuprot dosad interpretiranim rezultatima vrjednovanja, aplikacija Zoho Writer je u najmanjoj mjeri (27,70%) udovoljila zahtjevu izmjerene učinkovitosti (IZU) iz razloga što je korisnicima za dovršavanje svih reprezentativnih koraka scenarija u prosjeku bilo potrebno 110 sekundi. Osim toga, aplikacija Zoho Writer je u vrlo maloj mjeri (30,78%) udovoljila i zahtjevima izmjerenog radnog opterećenja (IRO) pri čemu je zahtjev varijable namijenjene mjerenju udaljenosti prijeđene pomicanjem miša (IRO2) zadovoljen 29,06%, zahtjev varijable kojom se mjeri broj pritisnutih tipaka na tipkovnici (IRO1) je zadovoljen 30,69%. zahtjev varijable pomoću koje se mjeri broj pomicanja klizača na mišu (IRO4) je zadovoljen 31,31%, dok je zahtjev varijable primjenom koje se mjeri broj klikova mišem (IRO3) zadovoljen 32,13%. Sljedeći atribut kvalitete u korištenju čija je elementarna preferencija poprimila relativno nisu vrijednost (40,52%) je lojalnost (LOJ). Naime, aplikacija Zoho Writer je zadovoljila 37,59% zahtjeva koji se odnosi na namjeru buduće česte upotrebe Web 2.0 aplikacije (LOJ3), 40,44% zahtjeva vezanog uz namjeru daljnjeg korištenja Web 2.0 aplikacijom (LOJ1) i 43,66% zahtjeva koji se odnosi na namjeru korisnika da preporuče Web 2.0 aplikaciju (LOJ2).

Zahtjevi atributa kvalitete u korištenju namijenjenog neposrednom vrjednovanju aspekata užitka (UTK) tijekom interakcije sa Web 2.0 aplikacijom Zoho Writer su također zadovoljeni u manjoj mjeri (46,41%). Detaljnije, zahtjev varijable kojom se mjeri razina do koje je korisnicima ugodno upotrebljavati Web 2.0 aplikaciju (UTK4) je zadovoljen 41,00%, zahtjev varijable namijenjene vrjednovanju stupnja do koje je korisnicima zanimljivo upotrebljavati Web 2.0 aplikaciju (UTK2) je zadovoljen 48,86% dok je zahtjev varijable kojom se mjeri razina sviđanja načina izvršavanja zadataka pomoću funkcionalnosti sučelja Web 2.0 aplikacije (UTK5) zadovoljen 50,00%. Nadalje, elementarna preferencija podsustava varijabli performansi pomoću kojih se mjerila razina razigranosti (RZG) korisnika za vrijeme upotrebe Web 2.0 aplikacije Zoho Writer je poprimila vrijednost 49,72% iz razloga što je zahtjev koji se odnosi na mjerenje razine

do koje interakcija sa Web 2.0 aplikacijom potiče stvaralačku maštu korisnika (RZG6) zadovoljen 43,75%, zahtjev vezan uz mjerenje stupnja do kojeg interakcija sa Web 2.0 aplikacijom potiče kreativnost korisnika (RZG5) zadovoljen 46,78%, a zahtjev koji se odnosi na razinu do koje interakcija sa Web 2.0 aplikacijom uspješno zadržava pažnju korisnika dulje vrijeme (RZG1) zadovoljen 57,39%.

Relativno slaba razina (50,80%) jedinstvenosti (JDN) u skupini aplikacija namijenjenih uređivanju teksta je još jedan od nedostataka Web 2.0 aplikacije Zoho Writer. Naime, ista je zadovoljila 49,15% zahtjeva pomoću kojeg se provjerava do kojeg stupnja Web 2.0 aplikacija ima ono nešto što je čini drugačijom od ostalih aplikacija (JDN1), 50,85% zahtjeva kojim se mjeri zamijećena razina generalne jedinstvenosti Web 2.0 aplikacije (JDN2) i 52,46% zahtjeva kojim se vrjednuje do koje se mjere Web 2.0 aplikacija ističe u skupini istovrsnih aplikacija (JDN3). Obzirom da je aplikacija Zoho Writer nisko zadovoljenje zahtjeva kojima se vrjednuju dimenzije užitka (UTK), razigranosti (RZG) i jedinstvenosti (JDN) uspjela kompenzirati umjerenim zadovoljenjem zahtjeva estetike (EST; 67,39%), ista je zadovoljila 51,67% svih zahtjeva kompozitnog podsustava varijabli performansi pomoću kojih se vrjednuje zamijećen užitak (ZUT*).

Nadalje, Web 2.0 aplikacija Zoho Writer je zadovoljila 55,24% zahtjeva varijabli performansi pomoću kojih se vrjednuju različiti aspekti zamijećenog radnog opterećenja (ZRO) gdje je zahtjev koji se odnosi na količinu zamijećene iscrpljenosti nakon korištenja Web 2.0 aplikacijom (ZRO1) zadovoljen 50,47%, zahtjev vezan uz razinu zamijećenog umora u očima nakon upotrebe Web 2.0 aplikacije (ZRO2) zadovoljen 53,60%, a zahtjev koji se odnosi na stupanj zamijećenog umora u prstima, zglobovima i mišićima ruku nakon korištenja Web 2.0 aplikacijom (ZRO3) zadovoljen 62,69%. Uzimajući u obzir razine na kojima je aplikacija Zoho Writer udovoljila zahtjevima varijabli performansi namijenjenih vrjednovanju izmjerenog radnog opterećenja (IRO) i dimenzija zamijećenog radnog opterećenja (ZRO), ista je zadovoljila 42,82% svih zahtjeva kompozitnog podsustava varijabli performansi pomoću kojih se mjeri radno opterećenje korisnika (ROP*).

Iz rezultata vrjednovanja je također očigledno da su mogućnosti prilagodbe (MPR) pojedinih elemenata sučelja Web 2.0 aplikacije Zoho Writer na osrednjoj razini (55,72%). Konkretnije, aplikacija Zoho Writer je zadovoljila 53,69% zahtjeva varijable kojom se mjeri razina do koje Web 2.0 aplikacija pruža mogućnost prilagodbe radnog prostora (MPR1), 55,68% zahtjeva varijable namijenjene mjerenju razine do koje Web 2.0 aplikacija omogućava prilagodbu jezika prikaza (MPR2) i 58,52% zahtjeva varijable primjenom koje se mjeri razina do koje Web 2.0 aplikacija podržava prilagodbu prikaza formata datuma i vremena (MPR3). Elementarna preferencija atributa kvalitete u korištenju kojim se neposredno vrjednuju aspekti zamijećene

učinkovitosti (ZAU) je u kontekstu vrjednovanja Web 2.0 aplikacije Zoho Writer poprimila vrijednost 56,78% iz razloga što je zahtjev koji se odnosi na zamijećenu uštedu vremena kao rezultat izvršavanja zadataka pomoću Web 2.0 aplikacije (ZAU4) zadovoljen 52,56%, zahtjev vezan uz zamijećeno povećanje učinkovitosti u izvršavanju zadataka kao rezultat upotrebe Web 2.0 aplikacije (ZAU3) zadovoljen 58,43%, a zahtjev koji se odnosi na zamijećenu brzinu dovršavanja zadataka kao rezultat korištenja Web 2.0 aplikacijom (ZAU1) zadovoljen 59,47%. Uzimajući u obzir vrijednosti elementarnih preferencija koje odražavaju razinu zadovoljenja zahtjeva varijabli performansi kojima se vrjednuju dimenzije izmjerene učinkovitosti (IZU) i zamijećene učinkovitosti (ZAU), aplikacija Zoho Writer je zadovoljila 49,44% svih zahtjeva kompozitnog podsustava varijabli performansi kojima se vrjednuje učinkovitost (UNK*). Od preostalih atributa kvalitete u korištenju čije je zahtjeve aplikacija Zoho Writer zadovoljila u manjoj mjeri potrebno je još spomenuti izmjerenu djelotvornost (IZD). Naime, korisnici su primjenom Web 2.0 aplikacije Zoho Writer dovršili prosječno 33 od ukupno 45 reprezentativnih koraka scenarija čime je zahtjev izmjerene djelotvornosti zadovoljen 57,14%. Konačno, potrebno je napomenuti da je aplikacija Zoho Writer nisko zadovoljenje zahtjeva kompozitnog podsustava varijabli performansi kojima se mjeri učinkovitost (UNK*) kompenzirala osrednjim zadovoljenjem zahtjeva kompozitnog podsustava varijabli performansi pomoću kojih se vrjednuje djelotvornost (DTV*; 61,69%) te na taj način uspjela zadovoljiti 55,54% zahtjeva varijabli performansi kojima se mjeri produktivnost (PDK).

6.3.4.3 Prednosti Web 2.0 aplikacije Microsoft Word Web App

Uzimajući u obzir sve atribute kvalitete u korištenju, Web 2.0 aplikacija Microsoft Word Web App je u najvećoj mjeri (77,27%) udovoljila zahtjevima dostupnosti (DST). Naime, zahtjev prema kojem je jednostavno pronaći Web 2.0 aplikaciju putem web tražilice (DST4) je zadovoljen 81,44%, zahtjev prema kojem je Web 2.0 aplikacija dostupna svaki put kada je korisnicima to potrebno (DST1) je zadovoljen 80,30%, a zahtjev prema kojem Web 2.0 omogućava prijavu sa postojećim (npr. Facebook) korisničkim računom (DST5) je zadovoljen 63,45%. Sljedeći atribut kvalitete u korištenju čijim je zahtjevima aplikacija Microsoft Word Web App udovoljila u značajnoj mjeri (76,78%) jest familijarnost (FML). Konkretnije, aplikacija Microsoft Word Web App je zadovoljila 79,07% zahtjeva vezanog uz razinu do koje Web 2.0 aplikacija upotrebljava slične ikone za pokretanje određenih funkcionalnosti sučelja kao i aplikacije kojima se korisnici redovito koriste (FML4), 77,84% zahtjeva koji se odnosi na razinu do koje Web 2.0 aplikacija upotrebljava jednake nazive za pojedine funkcionalnosti sučelja kao i aplikacije kojima se korisnici svakodnevno koriste (FML3) te 73,11% zahtjeva vezanog uz razinu do koje je raspored elemenata na korisničkom sučelju Web 2.0 aplikacije sličan rasporedu u aplikacijama koje

korisnici inače upotrebljavaju (FML1). Nadalje, aplikacija Microsoft Word Web App je zadovoljila 74,54% zahtjeva definiranih varijablama performansi kojima se vrjednuje razumljivost (RZM) Web 2.0 aplikacije. Detaljnije, aplikacija Microsoft Word Web App je zadovoljila 77,46% zahtjeva prema kojem izgled ikona treba odgovarati njihovoj namjeni (RZM3), 75,66% zahtjeva prema kojem naziv funkcionalnih elemenata sučelja treba biti usklađen sa kontekstom njihove upotrebe (RZM4) i 73,11% zahtjeva prema kojem funkcionalnost elemenata sučelja treba biti razumljiva (RZM2).

Elementarna preferencija atributa kvalitete u korištenju čijim se varijablama performansi mjeri pristupačnost (PST) je u kontekstu Web 2.0 aplikacije Microsoft Word Web App poprimila vrijednost 74,20% iz razloga što je zahtjev kojim se utvrđuje da li su objekti smješteni na sučelju Web 2.0 aplikacije dovoljno veliki (PST6) zadovoljen 79,36%, zahtjev prema kojem tekst koji opisuje funkcionalnost elemenata sučelja treba biti dovoljno velik za čitanje (PST4) zadovoljen 77,84%, a zahtjev kojim se provjerava da li Web 2.0 aplikacija sadrži popis tipkovničkih kratica za pokretanje često korištenih elemenata sučelja (PST1) zadovoljen 59,56%. Uzimajući u obzir stupnjeve zadovoljenja zahtjeva kojima se vrjednuju atributi dostupnost (DST) i pristupačnost (PST), Web 2.0 aplikacija Microsoft Word Web App je zadovoljila 75,81% svih zahtjeva podsustava varijabli performansi kojima se mjeri dohvatljivost (DHV).

Uz navedeno, aplikacija Microsoft Word Web App je zadovoljila i 72,74% zahtjeva definiranih varijablama performansi pomoću kojih se provjerava do koje mjere Web 2.0 aplikacija sprječava nastanak pogrješaka (SPO). Prema rezultatima vrjednovanja, aplikacija Microsoft Word Web App je zadovoljila 80,87% zahtjeva pomoću kojeg se utvrđuje da li Web 2.0 aplikacija omogućuje da korisnici ponište i ponove promjene na artefaktu (SPO3), 75,28% zahtjeva kojim se provjerava da li Web 2.0 aplikacija omogućava brzo i jednostavno ispravljanje počinjenih pogrješaka (SPO1) i 65,34% zahtjeva primjenom kojeg se utvrđuje da li Web 2.0 aplikacije prije provedbe destruktivnih operacija traži potvrdu od korisnika (SPO4).

Pamtljivost (PMT) je atribut kvalitete u korištenju čijim je zahtjevima aplikacija Microsoft Word Web App također udovoljila u dostatnoj mjeri (72,24%). Naime, zahtjev kojim se mjeri razina do koje je lako zapamtiti gdje se nalaze pojedine funkcionalnosti sučelja Web 2.0 aplikacije (PMT2) je zadovoljen 73,30%, zahtjev pomoću kojeg se provjerava do koje je mjere jednostavno zapamtiti kako se upotrebljava Web 2.0 aplikacija (PMT1) je zadovoljen 72,82% dok je zahtjev kojim se utvrđuje razina do koje je nakon duljeg nekorištenja Web 2.0 aplikacijom jednostavno prisjetiti se kako se ona upotrebljava i gdje su smještene pojedine funkcionalnosti njena sučelja (PMT3) zadovoljen 70,45%. Sudeći prema vrijednostima elementarnih preferencija koje su poprimile varijable performansi, Web 2.0 aplikacija Microsoft Word Web App je u dostatno velikoj mjeri (71,97%) udovoljila zahtjevima kojima se vrjednuje zamijećeno vrijeme odaziva

(ZVO). Detaljnije, aplikacija Microsoft Word Web App je zadovoljila 73,58% zahtjeva koji se odnosi na prihvatljivu razinu zamijećenog vremena odaziva (ZVO4), 71,69% zahtjeva kojim se mjeri zamijećeno vrijeme čekanja do pokretanja i izvršavanja odabranih funkcionalnosti sučelja Web 2.0 aplikacije (ZVO3) i 70,74% zahtjeva pomoću kojeg se vrjednuje zamijećena brzina učitavanja radnog prostora Web 2.0 aplikacije i njenih elemenata sučelja u web pregledniku (ZVO2).

Web 2.0 aplikacija Microsoft Word Web App je u prihvatljivoj mjeri (71,45%) udovoljila i varijablama performansi kojima se neposredno vrjednuju aspekti lakoće učenja korištenja (LUK). Naime, zahtjev varijable kojom se mjeri zamijećena brzina učenja korištenja funkcionalnostima sučelja Web 2.0 aplikacije (LUK3) je zadovoljen 72,73%, zahtjev varijable kojom se vrjednuje zamijećena jednostavnost razvoja vještine korištenja Web 2.0 aplikacijom (LUK1) je zadovoljen 71,21%, a zahtjev varijable kojom se mjeri zamijećena lakoća kojom je moguće naučiti izvršavati zadatke pomoću Web 2.0 aplikacije (LUK2) je zadovoljen 70,45%. Obzirom da su u kontekstu vrjednovanja Web 2.0 aplikacije Microsoft Word Web App zahtjevi varijabli performansi kojima se vrjednuju aspekti familijarnosti (FML), razumljivosti (RZM) i lakoće učenja korištenja (LUK) zadovoljeni u visokoj mjeri, ista je zadovoljila 71,69% svih zahtjeva kompozitnog podsustava varijabli performansi kojima se mjeri zamijećena lakoća učenja korištenja (ZLU*).

Sljedeći atribut kvalitete u korištenju čijim je zahtjevima varijabli performansi aplikacija Microsoft Word Web App udovoljila u dovoljno velikoj mjeri (70,80%) je pouzdanost (PZD). Konkretnije, aplikacija Microsoft Word Web App je zadovoljila 71,97% zahtjeva varijable kojom se mjeri razina zamijećene stabilnosti Web 2.0 aplikacije (PZD4), 70,74% zahtjeva varijable kojom se provjerava da li Web 2.0 aplikacija ima softverskih pogrješaka (PZD5) i 69,60% zahtjeva varijable primjenom koje se vrjednuje razina zamijećene pouzdanosti Web 2.0 aplikacije (PZD3). Potrebno je napomenuti kako je vrijednost elementarne preferencije kompozitnog podsustava varijabli performansi kojima se vrjednuje zamijećena pouzdanost (ZPD*) iznosila 68,33% iz razloga što je aplikacija Microsoft Word Web App osrednje (60,41%) zadovoljila zahtjeve namijenjene mjerenju mogućnosti oporavka (MOP). Od preostalih atributa kvalitete u korištenju koji odražavaju prednosti Web 2.0 aplikacije Microsoft Word Web App potrebno je još spomenuti estetiku (EST). Naime, aplikacija Microsoft Word Web App je u kontekstu estetike zadovoljila 69,59% zahtjeva varijabli performansi pri čemu je zahtjev kojim se utvrđuje razina zamijećene usklađenosti boja koje prevladavaju na sučelju Web 2.0 aplikacije (EST2) zadovoljen 74,43%, zahtjev pomoću kojeg se mjeri razina do koje korisnici smatraju da Web 2.0 aplikacija lijepo izgleda (EST5) je zadovoljen 69,32%, a zahtjev pomoću kojeg se

vrjednuje razina zamijećene atraktivnosti sučelja Web 2.0 aplikacije (EST4) je zadovoljen 64,77%.

6.3.4.4 Nedostatci Web 2.0 aplikacije Microsoft Word Web App

Prema rezultatima vrjednovanja kvalitete u korištenju Web 2.0 aplikacijom Microsoft Word Web App, ista je u najmanjoj mjeri (35,71%) zadovoljila zahtjev izmjerene djelotvornosti (IZD) iz razloga što su korisnici njenom primjenom uspjeli u prosjeku dovršiti 27 reprezentativnih koraka scenarija. Sljedeći atribut kvalitete u korištenju čijim zahtjevima aplikacija Microsoft Word Web App nije udovoljila u dostatnoj mjeri (35,77%) jest lojalnost (LOJ). Naime, zahtjev kojim se utvrđuje da li korisnici namjeravaju Web 2.0 aplikaciju ubuduće često upotrebljavati (LOJ2) je zadovoljen 33,81%, zahtjev kojim se provjerava da li korisnici namjeravaju nastaviti upotrebljavati Web 2.0 aplikaciju (LOJ1) je zadovoljen 36,17% dok je zahtjev kojim se utvrđuje da li su korisnici voljni preporučiti Web 2.0 aplikaciju svakome tko namjerava kolaborativno uređivati tekst (LOJ2) je zadovoljen 37,31%. Sudeći prema rezultatima vrjednovanja, korisnici nisu u dovoljno velikoj mjeri (43,09%) uživali (UTK) u korištenju Web 2.0 aplikacijom Microsoft Word Web App iz razloga što je ista zadovoljila 38,54% zahtjeva kojim se mjeri razina zamijećene ugode u korištenju Web 2.0 aplikacijom (UTK4), 45,64% zahtjeva kojim se provjerava do kojeg je stupnja upotreba Web 2.0 aplikacije korisnicima zanimljiva (UTK2) i 45,64% zahtjeva kojim se vrjednuje razina do koje se korisnicima sviđa način izvršavanja zadataka pomoću funkcionalnosti sučelja Web 2.0 aplikacije (UTK5).

Nadalje, aplikacija Microsoft Word Web App nije u dostatnoj mjeri (47,02%) udovoljila varijablama performansi kojima se vrjednuje jedinstvenost (JDN) Web 2.0 aplikacije iz razloga što je zahtjev pomoću kojeg se utvrđuje da li Web 2.0 aplikacija raspolaže nečime što je razlikuje od drugih aplikacija (JDN1) zadovoljen 44,89%, zahtjev primjenom kojeg se mjeri razina zamijećene jedinstvenosti Web 2.0 aplikacije (JDN2) je zadovoljen 47,92%, a zahtjev kojim se provjerava da li se Web 2.0 aplikacija ističe u skupini aplikacija iste namjene (JDN3) je zadovoljen 48,48%. Varijable performansi kojima se vrjednuje zamijećena razigranost (RZG) su u kontekstu interakcije sa Web 2.0 aplikacijom Microsoft Word Web App zadovoljene 47,54%. Naime, aplikacija Microsoft Word Web App je zadovoljila 41,86% zahtjeva varijable kojom se mjeri razina do koje upotreba Web 2.0 aplikacije potiče stvaralačku maštu korisnika (RZG6), 44,03% zahtjeva varijable kojom se vrjednuje stupanj do kojeg upotreba Web 2.0 aplikacije potiče kreativnost korisnika (RZG5) i 55,49% zahtjeva varijable kojom se mjeri razina do koje upotreba Web 2.0 aplikacije uspješno zadržava pažnju korisnika dulje vrijeme (RZG1). Obzirom da je aplikacija Microsoft Word Web App u relativno niskoj mjeri udovoljila zahtjevima varijabli performansi kojima se mjere dimenzije užitka (UTK), jedinstvenosti (JDN) i razigranosti (RZG) te

u relativno visokoj mjeri (69,59%) zadovoljila zahtjeve kojima se vrjednuje estetika (EST), ista je zadovoljila 49,52% svih zahtjeva definiranih kompozitnim podsustavom varijabli performansi kojima se mjeri zamijećen užitak (ZUT*).

Prema podacima prikupljenima od korisnika, razina zadovoljstva (ZDV) upotrebom Web 2.0 aplikacije Microsoft Word Web App iznosi 50,65%. Konkretnije, aplikacija Microsoft Word Web App je zadovoljila 49,62% zahtjeva kojim se mjeri razina do koje je upotreba Web 2.0 aplikacije udovoljila očekivanjima korisnika (ZDV1), 50,09% zahtjeva pomoću kojeg se vrjednuje razina generalnog zadovoljstva korištenja Web 2.0 aplikacijom (ZDV2) i 53,13% zahtjeva primjenom kojeg se mjeri razina do koje je upotreba Web 2.0 aplikacije na korisnike ostavila dobar dojam (ZDV4). Uzimajući u obzir niske razine zadovoljenja zahtjeva definiranih kompozitnim podsustavom varijabli performansi pomoću kojih se vrjednuje zamijećen užitak (ZUT*) i zahtjeva kojima se mjere različiti aspekti zadovoljstva korisnika (ZDV) te relativno visoka razina (65,89%) zadovoljenja zahtjeva primjenom kojih se mjeri količina napora (NPR) uloženog u korištenje, aplikacija Microsoft Word Web App je zadovoljila 53,66% zahtjeva definiranih kompozitnim podsustavom varijabli performansi kojima se vrjednuje zamijećeno zadovoljstvo korisnika (ZAZ*).

Web 2.0 aplikacija Microsoft Word Web App je u osrednjoj mjeri (52,22%) zadovoljila zahtjeve varijabli performansi pomoću kojih se vrjednuje zamijećena djelotvornost (ZAD). Konkretnije, aplikacija Microsoft Word Web App je zadovoljila 47,25% zahtjeva kojim se provjerava da li Web 2.0 aplikacija raspolaže sa svim funkcionalnostima koje su potrebne za izvršavanje zadataka (ZAD4), 53,88% zahtjeva kojim se mjeri razina do koje je zadatke primjenom Web 2.0 aplikacije moguće izvršiti točno i u potpunosti (ZAD3) i 57,01% zahtjeva kojim se vrjednuje stupanj do kojeg se upotrebom Web 2.0 aplikacije povećava zamijećena djelotvornost korisnika u izvršavanju zadataka (ZAD2). Obzirom da je aplikacija Microsoft Word Web App u manjoj mjeri udovoljila zahtjevima kojima se vrjednuje izmjerena djelotvornost (IZD), osrednje udovoljila zahtjevima kojima se mjere dimenzije zamijećene djelotvornosti (ZAD) i u velikoj mjeri udovoljila zahtjevima kojima se vrjednuje sveobuhvatnost konteksta, vrijednost elementarne preferencije kompozitnog podsustava varijabli performansi pomoću kojih se mjerila djelotvornost (DTV*) je poprimila vrijednost 49,50%. Međutim, aplikacija Microsoft Word Web App je navedenu nisku razinu zadovoljenja zahtjeva kompozitnog podsustava varijabli performansi kojima se vrjednuje djelotvornost (DTV*) kompenzirala osrednjim (61,88%) zadovoljenjem zahtjeva kompozitnog podsustava varijabli performansi namijenjenih mjerenju učinkovitosti (UNK*) te na taj način zadovoljila 54,93% zahtjeva definiranih podsustavom varijabli performansi koje služe vrjednovanju produktivnosti (PDK) korisnika.

Iz rezultata vrjednovanja je također evidentno da su mogućnosti prilagodbe (MPR) pojedinih funkcionalnosti sučelja Web 2.0 aplikacije Microsoft Word Web App osrednje (55,41%). Naime, zahtjev kojim se utvrđuje da li je moguće promijeniti jezik na kojem se prikazuju elementi korisničkog sučelja (MPR2) je zadovoljen 53,69%, zahtjev kojim se provjerava da li je moguće prilagoditi radni prostor (MPR1) je zadovoljen 55,87% dok je zahtjev kojim se utvrđuje da li je moguće prilagoditi prikaz datuma i vremena (MPR3) zadovoljen 57,10%. Razina zadovoljenja podsustava varijabli performansi kojima se mjeri zamijećeno radno opterećenje (ZRO) korisnika u slučaju vrjednovanja kvalitete u korištenju Web 2.0 aplikacijom Microsoft Word Web App iznosi 55,86%. Detaljnije, aplikacija Microsoft Word Web App je zadovoljila 50,95% zahtjeva definiranog varijablom kojom se mjeri razina zamijećene iscrpljenosti nakon upotrebe Web 2.0 aplikacije (ZRO1), 54,26% zahtjeva definiranog varijablom pomoću koje se vrjednuje stupanj zamijećenog umora u očima nakon upotrebe Web 2.0 aplikacije (ZRO2) i 63,45% zahtjeva definiranog varijablom primjenom koje se mjeri razina zamijećenog umora u prstima, zglobovima i mišićima ruku nakon upotrebe Web 2.0 aplikacije (ZRO3). Obzirom da je aplikacija Microsoft Word u osrednjoj mjeri udovoljila zahtjevima varijabli performansi kojima se mjere dimenzije zamijećenog radnog opterećenja (ZRO) i izmjerenog radnog opterećenja (IRO), ista je zadovoljila 57,52% svih zahtjeva definiranih kompozitnim podsustavom varijabli performansi primjenom kojih se mjeri radno opterećenje (ROP*).

Od preostalih atributa kvalitete u korištenju koji odražavaju nedostatke Web 2.0 aplikacije Microsoft Word Web App potrebno je još spomenuti korisnost (KRS). Naime, aplikacija Microsoft Word Web App je zadovoljila 55,89% varijabli performansi namijenjenih vrjednovanju temeljnih aspekata korisnosti pri čemu je zahtjev kojim se mjeri razina zamijećene korisnosti Web 2.0 aplikacije za izvršavanje zadataka (KRS3) zadovoljen 54,17%, zahtjev kojim se vrjednuje stupanj prikladnosti Web 2.0 aplikacije za izvršavanje zadataka (KRS4) je zadovoljen 56,16%, a zahtjev kojim se mjeri razina zamijećenog povećanja performansi korisnika u izvršavanju zadataka kao posljedica upotrebe Web 2.0 aplikacije (KRS2) je zadovoljen 57,20%. Uzimajući u obzir vrijednosti elementarnih preferencija kompozitnih podsustava varijabli performansi namijenjenih mjerenju zamijećene pouzdanosti (ZPD*) i produktivnosti (PDK) kao i vrijednost elementarne preferencije atributa kojim se vrjednuju aspekti korisnosti (KRS), Web 2.0 aplikacija Microsoft Word Web App je zadovoljila 58,01% svih zahtjeva kompozitnog podsustava varijabli performansi kojima se vrjednuje zamijećena korisnost (ZKS*).

6.4 Drugi eksperiment

Za vrijeme drugog eksperimenta sudionici su izvršavali 48 koraka scenarija (nalazi se u Prilogu G) od čega je jedan bio uvodni, četiri završna, dok su 43 bila reprezentativna u kontekstu Web 2.0 aplikacija za izradu mentalnih mapa. Svi sudionici su kroz isti scenarij prolazili dva puta – prvi put su se koristili Web 2.0 aplikacijom Mindomo[12] (ilustrirana na slici 6.25) dok su drugi put upotrebljavali Web 2.0 aplikaciju Wise Mapping[13] (prikazana na slici 6.26).

Iz podataka prikazanih u tablici 6.78 je vidljivo da su sudionici u drugom eksperimentu upotrebljavali sve najpopularnije web preglednike. Daleko najveći broj sudionika (94,42%) je upotrebljavao Google Chrome kao dominantan web preglednik dok ih se 60,59% koristilo Mozillom Firefox kao alternativnim web preglednikom za izvršavanje četiri specifična koraka scenarija.

Tablica 6.78 Struktura sudionika u drugom eksperimentu prema učestalosti upotrebe web preglednika tijekom izvršavanja koraka scenarija interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa

Naziv web preglednika	**Dominantan web preglednik**		**Alternativan web preglednik**	
	Frekvencija	**%**	**Frekvencija**	**%**
Apple Safari	8	2,97	0	0,00
Google Chrome	254	94,42	8	2,97
Microsoft Internet Explorer	7	2,60	37	13,75
Mozilla Firefox	0	0,00	163	60,59
Opera	0	0,00	61	22,68
Ukupno	269	100,00	269	100,00

[12] http://www.mindomo.com/
[13] http://www.wisemapping.com/

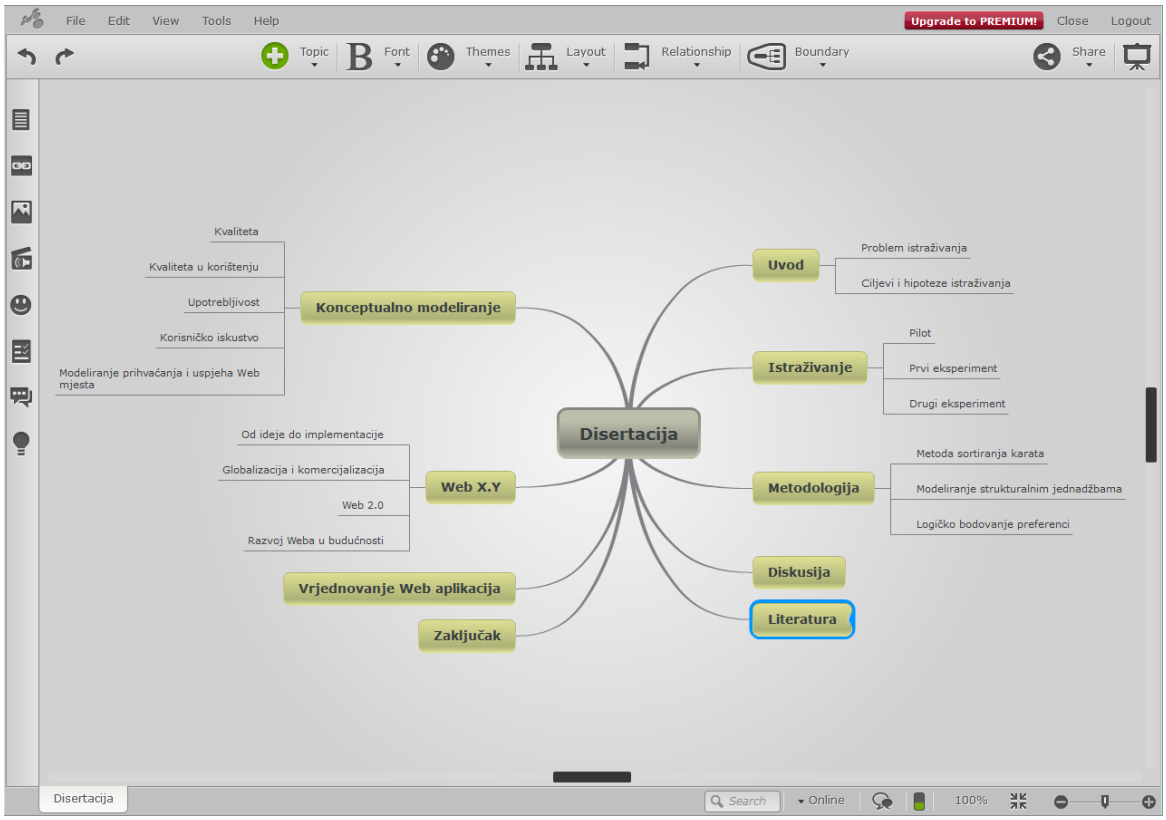

Slika 6.25 Radno okruženje Web 2.0 aplikacije Mindomo

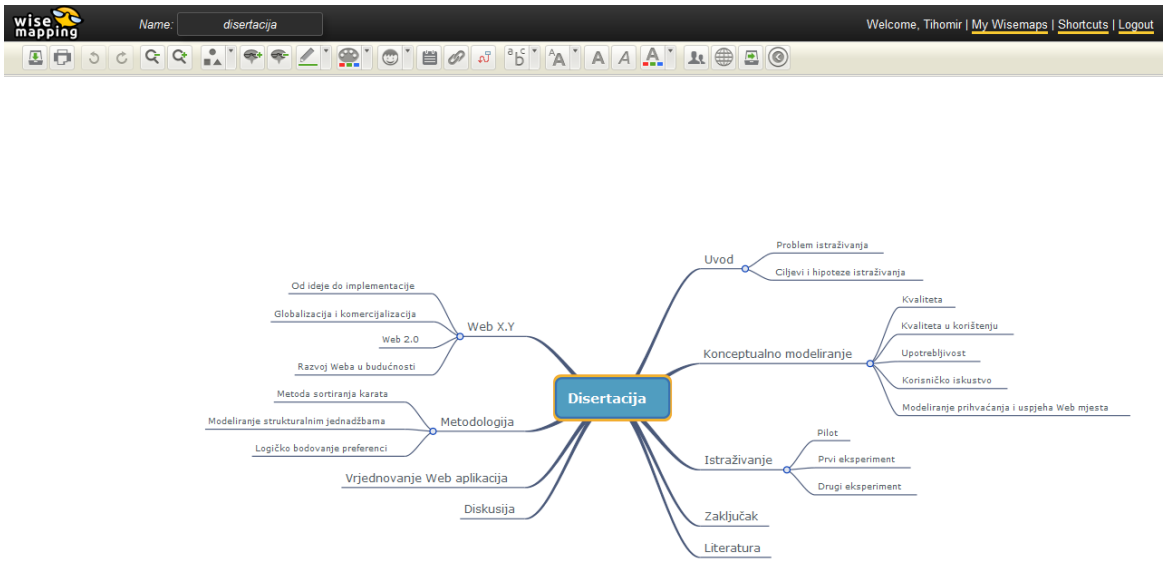

Slika 6.26 Radno okruženje Web 2.0 aplikacije Wise Mapping

6.4.1 Karakteristike sudionika

Za vrijeme provedbe drugog eksperimenta prikupljeno je ukupno 269 ispravno popunjenih upitnika, Mousotron izvještaja te obrazaca sa reprezentativnim koracima scenarija interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa. Struktura sudionika u drugom eksperimentu prema spolu, visokoškolskoj ustanovi i godini studija koju pohađaju nalazi se u tablicama 6.79-6.81, respektivno. Pored toga, grafikoni 6.4-6.6 prikazuju distribuciju sudionika prema starosnoj dobi te godinama iskustva u radu sa računalom i korištenju Internetom, respektivno. Od ukupnog broja sudionika u prvom eksperimentu, njih 54,65% je bilo muškog, a 45,35% ženskog spola.

Tablica 6.79 Struktura sudionika u drugom eksperimentu prema spolu

Spol	Frekvencija	%
Muški	147	54,65
Ženski	122	45,35
Ukupno	269	100,00

Starosna dob sudionika je u prosjeku iznosila 20,38 godina ($\sigma = 1{,}909$) gdje su najmlađi sudionici imali 18, a najstariji 32 godine. Obzirom da je uzorak sudionika bio sačinjen od studenata, većina (69,15%) ih je imala između 19 i 21 godine.

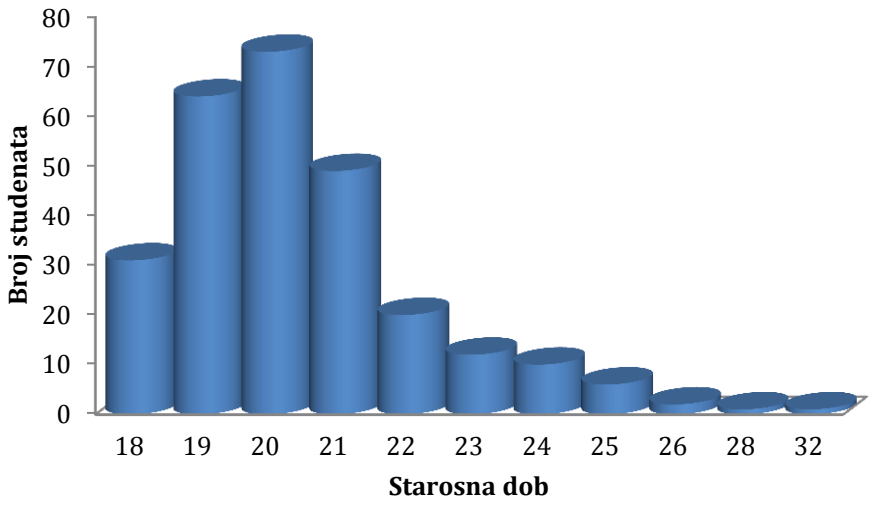

Grafikon 6.4 Struktura sudionika u drugom eksperimentu prema starosnoj dobi

Većina sudionika drugog eksperimenta su studenti hrvatskih visokoškolskih ustanova od čega ih je 35,69% sa Veleučilišta u Rijeci, 33,83% sa Fakulteta organizacije i informatike u Varaždinu, 16,36% sa Filozofskog fakulteta u Osijeku te 9,67% sa Ekonomskog fakulteta u Splitu. Preostali studenti su polaznici sveučilišta u Kolumbiji (2,60%) i Španjolskoj (1,86%).

Tablica 6.80 Struktura sudionika u drugom eksperimentu prema visokoškolskoj ustanovi koju pohađaju

Naziv visokoškolske ustanove	Grad	Država	Frekvencija	%
Ekonomski fakultet	Split	Hrvatska	26	9,67
Fakultet organizacije i informatike	Varaždin	Hrvatska	91	33,83
Filozofski fakultet	Osijek	Hrvatska	44	16,36
Veleučilište u Rijeci	Rijeka	Hrvatska	96	35,69
Escola Politècnica Superior	Lleida	Španjolska	5	1,86
Universidad del Quindío	Armenia	Kolumbija	6	2,23
Universidad del Cauca	Popayán	Kolumbija	1	0,37
Ukupno			269	100,00

Sudionici drugog eksperimenta su većinom polaznici preddiplomskog studija pri čemu ih je u trenutku provedbe istraživanja 43,12% bilo na prvoj, 34,57% na drugoj, a 10,78% na trećoj godini studija.

Tablica 6.81 Struktura sudionika u drugom eksperimentu prema godini studija koju pohađaju

Godina studija	Frekvencija	%
Prva godina preddiplomskog studija	116	43,12
Druga godina preddiplomskog studija	93	34,57
Treća godina preddiplomskog studija	29	10,78
Prva godina diplomskog studija	20	7,43
Druga godina diplomskog studija	11	4,09
Ukupno	269	100,00

U trenutku provedbe drugog eksperimenta, sudionici su imali prosječno 9,87 godina iskustva ($\sigma = 2{,}527$) u radu sa računalom. Od ukupno 269 sudionika, 2,23% ih se koristilo računalom manje od šest godina dok ih je 1,49% upotrebljavalo računalo više od petnaest godina.

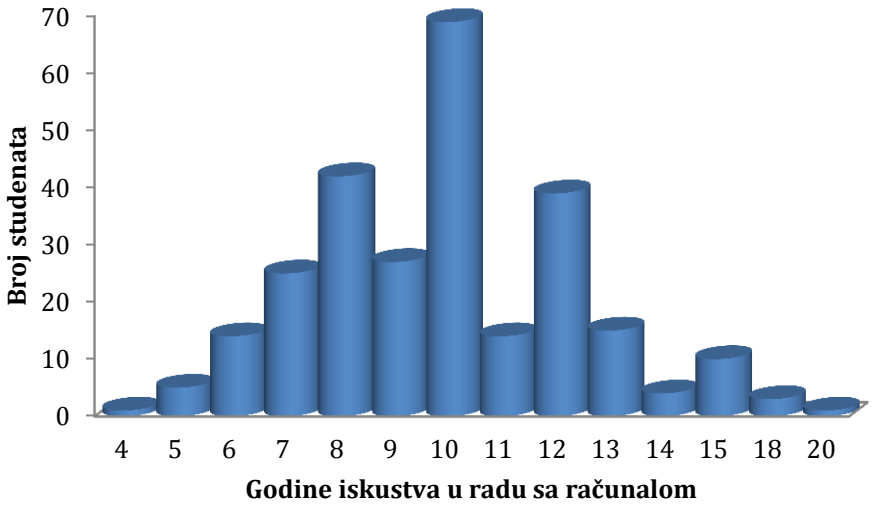

Grafikon 6.5 Struktura sudionika u drugom eksperimentu prema godinama iskustva u radu sa računalom

Prosječno vrijeme korištenja Internetom za sudionike drugog eksperimenta iznosi 7,69 godina ($\sigma = 2.316$). Svega 5,58% ih ima manje od pet godina iskustva u interakciji sa Internetom dok ih 2,23% upotrebljava Internet više od dvanaest godina.

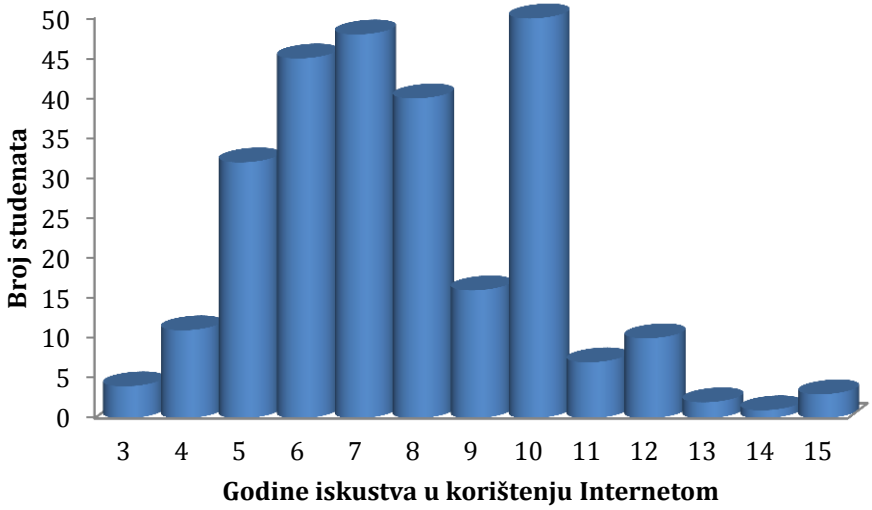

Grafikon 6.6 Struktura sudionika u drugom eksperimentu prema godinama iskustva u korištenju Internetom

Iz podataka prikazanih u tablici 6.82 je vidljivo da većina sudionika drugog eksperimenta upotrebljava Internet najmanje jednom dnevno radi komunikacije (75,84%), zabave (61,34%) ili obrazovanja (54,27%). Obzirom da je riječ o populaciji studenata, 43,87% ih nije nikad

upotrebljavalo Internet u poslovne svrhe. Struktura sudionika u drugom eksperimentu prema učestalosti i svrsi korištenja Internetom prikazana je tablicom 6.83. Najveći dio uzorka sudionika na korištenje Internetom utroši najmanje četiri sata tjedno od čega njih 79,55% iz potrebe za komunikacijom, 74,72% radi zabave te 66,92% u obrazovne svrhe.

Zbirni podaci u tablici 6.84 impliciraju da u kontekstu dvanaest različitih vrsta Web 2.0 aplikacija, najveći broj sudionika drugog eksperimenta najčešće upotrebljava društvene mreže i video podcasting servise. Od ukupno 269 sudionika, 51,67% ih se koristi Facebookom barem tri puta dnevno dok ih 71,01% upotrebljava YouTube najmanje jednom dnevno. Uz navedeno, potrebno je još spomenuti da 53,17% sudionika upotrebljava Gmail barem tri puta tjedno, dok ih se 60,23% koristi Wikipedijom najmanje jednom tjedno.

Rezultati samoprocjene sudionika u drugom istraživanju vezane uz poznavanje rada na računalu te upotrebu Interneta i Web 2.0 aplikacija prikazani su u tablici 6.85. Gotovo pola uzorka sudionika vjeruje da vrlo dobro poznaje rad na računalu (47,21%) te se vrlo dobro služi Internetom (47,96%) dok ih podjednaki broj (30,11%) smatra da je njihovo poznavanje interakcije sa Web 2.0 aplikacijama dobro odnosno slabo.

Tablica 6.82 Struktura sudionika u drugom eksperimentu prema intenzitetu i svrsi korištenja Internetom

Intenzitet korištenja	Komunikacija		Obrazovanje		Zabava		Posao	
	Frekvencija	%	Frekvencija	%	Frekvencija	%	Frekvencija	%
Ne koristim	1	0,37	2	0,74	3	1,12	118	43,87
Manje od jednom tjedno	6	2,23	12	4,46	14	5,20	36	13,38
1-2 puta tjedno	21	7,81	45	16,73	27	10,04	39	14,50
3-6 puta tjedno	37	13,75	64	23,79	60	22,30	27	10,04
1-2 puta dnevno	67	24,91	99	36,80	69	25,65	30	11,15
3 i više puta dnevno	137	50,93	47	17,47	96	35,69	19	7,06
Ukupno	269	100,00	269	100,00	269	100,00	269	100,00

Tablica 6.83 Struktura sudionika u drugom eksperimentu prema učestalosti i svrsi korištenja Internetom

Učestalost korištenja	Komunikacija		Obrazovanje		Zabava		Posao	
	Frekvencija	%	Frekvencija	%	Frekvencija	%	Frekvencija	%
Ne koristim	1	0,37	2	0,74	3	1,12	118	43,87
Manje od sata tjedno	10	3,72	16	5,95	21	7,81	45	16,73
1-3 sata tjedno	44	16,36	71	26,39	44	16,36	40	14,87
4-10 sati tjedno	62	23,05	89	33,09	67	24,91	26	9,67
11-20 sati tjedno	59	21,93	49	18,22	55	20,45	20	7,43
21-40 sati tjedno	51	18,96	30	11,15	42	15,61	13	4,83
Više od 40 sati tjedno	42	15,61	12	4,46	37	13,75	7	2,60
Ukupno	269	100,00	269	100,00	269	100,00	269	100,00

Tablica 6.84 Struktura sudionika u drugom eksperimentu prema učestalosti korištenja Web 2.0 aplikacijama

Web 2.0 aplikacije	Ne koristim		Manje od jednom tjedno		1-2 puta tjedno		3-6 puta tjedno		1-2 puta dnevno		3 i više puta dnevno		Ukupno	
	Frek.	%	Frek.	%	Frek.	%	Frek.	%	Frek.	%	Frek.	%	Frek.	%
Digg	259	96,28	10	3,72	0	0,00	0	0,00	0	0,00	0	0,00	269	100,00
Facebook	19	7,06	6	2,23	8	2,97	29	10,78	68	25,28	139	51,67	269	100,00
Flickr	236	87,73	18	6,69	4	1,49	3	1,12	4	1,49	4	1,49	269	100,00
Gmail	53	19,70	34	12,64	39	14,50	44	16,36	49	18,22	50	18,59	269	100,00
Last.fm	230	85,50	7	2,60	9	3,35	11	4,09	8	2,97	4	1,49	269	100,00
Mahara	254	94,42	13	4,83	1	0,37	1	0,37	0	0,00	0	0,00	269	100,00
Second Life	264	98,14	3	1,12	0	0,00	0	0,00	1	0,37	1	0,37	269	100,00
Skype	89	33,09	54	20,07	43	15,99	19	7,06	19	7,06	45	16,73	269	100,00
Twitter	233	86,62	11	4,09	11	4,09	5	1,86	5	1,86	4	1,49	269	100,00
YouTube	4	1,49	6	2,23	17	6,32	51	18,96	62	23,05	129	47,96	269	100,00
WordPress	237	88,10	16	5,95	4	1,49	5	1,86	2	0,74	5	1,86	269	100,00
Wikipedia	26	9,67	81	30,11	80	29,74	49	18,22	18	6,69	15	5,58	269	100,00

Tablica 6.85 Struktura sudionika u drugom eksperimentu prema samoprocjeni poznavanja rada na računalu te korištenja Internetom i Web 2.0 aplikacijama

Razina poznavanja	**Rad na računalu**		**Upotreba Interneta**		**Korištenje Web 2.0 aplikacijama**	
	Frekvencija	**%**	**Frekvencija**	**%**	**Frekvencija**	**%**
Odlično	56	20,82	80	29,74	23	8,55
Vrlo dobro	127	47,21	129	47,96	68	25,28
Dobro	80	29,74	55	20,45	81	30,11
Slabo	6	2,23	5	1,86	81	30,11
Vrlo slabo	0	0,00	0	0,00	16	5,95
Ukupno	269	100,00	269	100,00	269	100,00

6.4.2 Rezultati analize metrijskih karakteristika konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Mindomo

Analizom pouzdanosti manifestnih varijabli započela je procedura vrjednovanja metrijskih karakteristika višedimenzionalnog konceptualnog modela u kontekstu aplikacije Mindomo. Pouzdanost reflektivnih manifestnih varijabli vrjednovana je analizom vrijednosti koje su poprimila njihova standardizirana faktorska opterećenja dok se vrjednovanje pouzdanosti formativnih manifestnih varijabli sastojalo od analize značajnosti vrijednosti njihovih standardiziranih faktorskih opterećenja i težinskih vrijednosti.

Rezultati vrjednovanja pouzdanosti reflektivnih manifestnih varijabli prve, druge i treće razine konceptualnog modela nalaze se u tablicama 6.86-6.88, respektivno. Iz spomenutih se rezultata može vidjeti da su standardizirana faktorska opterećenja reflektivnih manifestnih varijabli poprimila vrijednosti u intervalu od 0,707 do 0,962 što znači da iste objašnjavaju između 50% i 92,54% varijance temeljnih latentnih konstrukata čija obilježja mjere. Shodno tome, sve reflektivne manifestne varijable koje se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Mindomo su pouzdane. Tablice 6.89-6.91 sadrže rezultate analize značajnosti apsolutnog doprinosa formativnih manifestnih varijabli prve, druge i treće razine u konceptualnom modelu, respektivno. Iz tablice 6.89 je vidljivo da je većina (92,19%) vrijednosti standardiziranih faktorskih opterećenja formativnih manifestnih varijabli značajna na razini $\alpha = 0{,}001$, 3,12% ih je značajno na razini $\alpha = 0{,}01$ dok ih je 4,69% značajno na razini $\alpha = 0{,}05$. Vrijednosti standardiziranih faktorskih opterećenja formativnih manifestnih varijabli druge i treće razine su značajne na razini $\alpha = 0{,}001$ što je i vidljivo u tablicama 6.90 i 6.91, respektivno.

U tablicama 6.92-6.94 se nalaze rezultati analize značajnosti relativnog doprinosa formativnih manifestnih varijabli koje se u konceptualnom modelu nalaze na prvoj, drugoj i trećoj razini, respektivno. Iz tablice 6.92 je vidljivo da je 93,75% težinskih vrijednosti formativnih manifestnih varijabli prve razine značajno na razini $\alpha = 0{,}001$, 1,56% ih je značajno na razini $\alpha = 0{,}01$, dok ih je 4,69% značajno na razini $\alpha = 0{,}05$. Tablica 6.93 jasno prikazuje da je 90,91% težinskih vrijednosti formativnih manifestnih varijabli značajno na razini $\alpha = 0{,}001$, a preostalih 9,09% značajno na razini $\alpha = 0{,}05$. Konačno, 75% težinskih vrijednosti formativnih varijabli treće razine je značajno na razini $\alpha = 0{,}001$ dok ih je 25% značajno na razini $\alpha = 0{,}05$ kao što je i prikazano u tablici 6.94. Temeljem rezultata koji se nalaze u tablicama 6.86-6.94 može se zaključiti da su sve manifestne varijable koje se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Mindomo pouzdane.

Tablica 6.86 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
DSD2	**0,860**	0,423	0,403	0,244	0,364	0,424	0,174	0,351	0,410	0,349	0,333	0,320	0,505	0,236	0,263	0,433	0,384	0,421	0,152
DSD3	**0,922**	0,381	0,369	0,244	0,376	0,479	0,188	0,456	0,386	0,432	0,358	0,290	0,504	0,291	0,239	0,424	0,385	0,423	0,147
DSD4	**0,870**	0,375	0,289	0,314	0,424	0,346	0,195	0,344	0,410	0,296	0,348	0,297	0,495	0,270	0,216	0,443	0,409	0,423	0,160
EST2	0,366	**0,887**	0,357	0,211	0,336	0,423	0,197	0,323	0,407	0,324	0,400	0,249	0,350	0,395	0,314	0,335	0,276	0,391	0,222
EST4	0,431	**0,907**	0,319	0,277	0,369	0,443	0,226	0,363	0,386	0,311	0,373	0,307	0,312	0,395	0,339	0,375	0,316	0,439	0,126
EST5	0,398	**0,911**	0,336	0,270	0,302	0,361	0,222	0,305	0,392	0,267	0,344	0,228	0,300	0,443	0,287	0,357	0,262	0,422	0,182
FML1	0,290	0,214	**0,767**	0,156	0,243	0,341	0,259	0,281	0,251	0,294	0,132	0,253	0,228	0,251	0,280	0,349	0,346	0,346	0,200
FML3	0,386	0,381	**0,903**	0,256	0,402	0,495	0,202	0,403	0,426	0,413	0,308	0,322	0,418	0,297	0,319	0,401	0,406	0,401	0,272
FML4	0,331	0,325	**0,847**	0,277	0,391	0,451	0,220	0,334	0,386	0,429	0,284	0,306	0,401	0,265	0,340	0,378	0,427	0,395	0,204
JDN1	0,317	0,326	0,299	**0,918**	0,570	0,309	0,479	0,343	0,339	0,307	0,243	0,510	0,447	0,373	0,552	0,447	0,405	0,565	0,126
JDN2	0,179	0,195	0,125	**0,858**	0,387	0,165	0,315	0,239	0,205	0,198	0,123	0,370	0,266	0,324	0,390	0,253	0,305	0,358	0,031
JDN3	0,272	0,201	0,290	**0,879**	0,467	0,242	0,345	0,231	0,263	0,224	0,174	0,405	0,387	0,330	0,433	0,346	0,335	0,389	0,077
KRS2	0,329	0,238	0,313	0,509	**0,847**	0,345	0,512	0,371	0,318	0,342	0,379	0,485	0,434	0,480	0,530	0,539	0,567	0,523	0,191
KRS3	0,437	0,386	0,440	0,467	**0,930**	0,564	0,452	0,477	0,514	0,465	0,453	0,521	0,538	0,403	0,577	0,535	0,574	0,665	0,257
KRS4	0,405	0,388	0,376	0,494	**0,916**	0,569	0,476	0,510	0,468	0,525	0,395	0,511	0,531	0,416	0,578	0,499	0,543	0,662	0,281
LAK1	0,484	0,465	0,513	0,276	0,517	**0,910**	0,384	0,620	0,592	0,663	0,405	0,457	0,486	0,465	0,488	0,596	0,515	0,581	0,341
LAK2	0,436	0,424	0,483	0,264	0,522	**0,960**	0,373	0,662	0,593	0,732	0,463	0,445	0,530	0,394	0,472	0,553	0,514	0,610	0,361
LAK3	0,427	0,394	0,459	0,242	0,499	**0,939**	0,396	0,617	0,557	0,696	0,432	0,441	0,500	0,359	0,493	0,520	0,538	0,588	0,347
LOJ1	0,239	0,233	0,237	0,408	0,500	0,383	**0,919**	0,375	0,321	0,409	0,280	0,518	0,240	0,495	0,645	0,475	0,448	0,581	0,194
LOJ2	0,157	0,217	0,247	0,402	0,518	0,421	**0,883**	0,385	0,314	0,438	0,285	0,499	0,247	0,533	0,659	0,479	0,484	0,551	0,212
LOJ3	0,164	0,190	0,226	0,370	0,414	0,290	**0,896**	0,272	0,264	0,327	0,179	0,432	0,165	0,436	0,552	0,395	0,389	0,474	0,088
LUK1	0,405	0,316	0,377	0,287	0,483	0,620	0,367	**0,961**	0,412	0,736	0,446	0,428	0,547	0,343	0,476	0,435	0,516	0,564	0,336
LUK2	0,446	0,390	0,374	0,308	0,467	0,686	0,384	**0,930**	0,485	0,761	0,443	0,476	0,496	0,372	0,463	0,508	0,516	0,622	0,376
LUK3	0,408	0,344	0,415	0,298	0,487	0,624	0,354	**0,962**	0,429	0,751	0,454	0,428	0,565	0,334	0,449	0,414	0,496	0,569	0,325

Tablica 6.86 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo (nastavak)

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
MOK1	0,441	0,398	0,399	0,267	0,425	0,612	0,320	0,462	**0,866**	0,478	0,439	0,379	0,397	0,326	0,414	0,543	0,435	0,526	0,208
MOK2	0,291	0,311	0,312	0,215	0,364	0,447	0,250	0,341	**0,807**	0,394	0,355	0,370	0,371	0,278	0,351	0,439	0,393	0,362	0,123
MOK3	0,360	0,363	0,340	0,287	0,395	0,439	0,243	0,318	**0,790**	0,417	0,325	0,360	0,381	0,354	0,380	0,508	0,405	0,458	0,096
PMT1	0,397	0,353	0,403	0,286	0,471	0,700	0,452	0,791	0,499	**0,931**	0,425	0,469	0,517	0,450	0,529	0,440	0,565	0,584	0,299
PMT2	0,351	0,281	0,428	0,220	0,448	0,710	0,369	0,712	0,459	**0,934**	0,442	0,447	0,556	0,443	0,452	0,438	0,466	0,563	0,299
PMT3	0,406	0,296	0,439	0,276	0,454	0,665	0,401	0,690	0,508	**0,920**	0,410	0,465	0,557	0,383	0,472	0,410	0,505	0,579	0,329
PZD3	0,386	0,394	0,311	0,221	0,471	0,490	0,318	0,490	0,477	0,483	**0,924**	0,397	0,516	0,433	0,403	0,479	0,384	0,542	0,173
PZD4	0,371	0,416	0,284	0,212	0,446	0,408	0,236	0,413	0,402	0,395	**0,933**	0,316	0,483	0,314	0,330	0,422	0,344	0,513	0,138
PZD5	0,276	0,281	0,180	0,111	0,270	0,321	0,175	0,341	0,340	0,333	**0,823**	0,259	0,401	0,253	0,258	0,306	0,207	0,398	0,196
RZG1	0,159	0,140	0,261	0,330	0,391	0,377	0,410	0,374	0,347	0,424	0,180	**0,707**	0,278	0,366	0,531	0,368	0,428	0,466	0,168
RZG5	0,347	0,293	0,347	0,474	0,562	0,446	0,511	0,423	0,399	0,456	0,400	**0,936**	0,461	0,428	0,701	0,524	0,517	0,637	0,242
RZG6	0,345	0,301	0,292	0,450	0,484	0,407	0,466	0,406	0,409	0,404	0,346	**0,914**	0,398	0,380	0,667	0,480	0,443	0,597	0,204
RZM2	0,510	0,286	0,383	0,386	0,543	0,573	0,283	0,534	0,473	0,579	0,494	0,439	**0,850**	0,335	0,425	0,482	0,452	0,562	0,244
RZM3	0,470	0,287	0,362	0,387	0,473	0,422	0,205	0,480	0,357	0,458	0,426	0,353	**0,881**	0,340	0,318	0,415	0,406	0,446	0,232
RZM4	0,502	0,367	0,368	0,336	0,439	0,407	0,145	0,459	0,383	0,489	0,457	0,379	**0,896**	0,351	0,322	0,376	0,401	0,428	0,208
SPK1	0,255	0,420	0,332	0,357	0,448	0,414	0,468	0,328	0,351	0,442	0,377	0,393	0,370	**0,926**	0,474	0,493	0,403	0,515	0,110
SPK2	0,291	0,429	0,288	0,356	0,455	0,383	0,473	0,315	0,366	0,409	0,363	0,389	0,384	**0,935**	0,468	0,514	0,451	0,508	0,087
SPK3	0,290	0,416	0,280	0,367	0,441	0,404	0,569	0,374	0,359	0,422	0,326	0,478	0,335	**0,919**	0,534	0,537	0,435	0,535	0,203
UTK2	0,233	0,308	0,324	0,501	0,568	0,464	0,648	0,425	0,393	0,468	0,342	0,706	0,386	0,512	**0,949**	0,473	0,474	0,649	0,326
UTK4	0,272	0,349	0,315	0,507	0,562	0,441	0,647	0,412	0,428	0,441	0,321	0,709	0,331	0,494	**0,921**	0,504	0,456	0,669	0,307
UTK5	0,246	0,311	0,397	0,454	0,607	0,531	0,625	0,516	0,474	0,543	0,385	0,643	0,421	0,473	**0,905**	0,468	0,511	0,671	0,337
ZAD2	0,287	0,257	0,325	0,361	0,494	0,394	0,537	0,355	0,434	0,381	0,352	0,516	0,360	0,570	0,547	**0,770**	0,647	0,529	0,156
ZAD3	0,453	0,336	0,379	0,327	0,505	0,549	0,403	0,445	0,559	0,421	0,433	0,444	0,446	0,453	0,412	**0,897**	0,579	0,556	0,200
ZAD4	0,489	0,408	0,433	0,351	0,496	0,562	0,359	0,410	0,550	0,378	0,386	0,423	0,437	0,411	0,386	**0,880**	0,518	0,532	0,156

Tablica 6.86 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo (nastavak)

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
ZAU1	0,463	0,322	0,432	0,301	0,495	0,563	0,389	0,533	0,457	0,524	0,350	0,483	0,445	0,327	0,428	0,596	**0,818**	0,538	0,234
ZAU3	0,323	0,253	0,415	0,387	0,581	0,449	0,451	0,445	0,431	0,487	0,334	0,496	0,438	0,461	0,498	0,626	**0,870**	0,492	0,189
ZAU4	0,359	0,248	0,367	0,345	0,543	0,435	0,435	0,412	0,411	0,422	0,252	0,419	0,367	0,411	0,417	0,538	**0,902**	0,484	0,225
ZDV1	0,488	0,456	0,417	0,456	0,572	0,554	0,514	0,523	0,551	0,569	0,517	0,561	0,481	0,460	0,586	0,535	0,507	**0,895**	0,184
ZDV2	0,413	0,442	0,441	0,464	0,619	0,582	0,563	0,562	0,499	0,570	0,519	0,590	0,488	0,562	0,646	0,615	0,556	**0,936**	0,254
ZDV4	0,403	0,370	0,380	0,462	0,672	0,589	0,553	0,587	0,465	0,552	0,463	0,657	0,532	0,503	0,713	0,572	0,526	**0,895**	0,251
ZRO1	0,183	0,174	0,306	0,071	0,268	0,394	0,187	0,356	0,182	0,368	0,145	0,221	0,256	0,144	0,308	0,231	0,269	0,274	**0,920**
ZRO2	0,187	0,230	0,252	0,071	0,250	0,378	0,170	0,355	0,199	0,292	0,206	0,223	0,256	0,131	0,343	0,208	0,219	0,241	**0,953**
ZRO3	0,093	0,125	0,178	0,122	0,222	0,242	0,159	0,281	0,111	0,248	0,155	0,219	0,203	0,129	0,310	0,101	0,196	0,176	**0,877**

Tablica 6.87 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	OPR	PDK
LAK	**0,887**	0,627
LUK	**0,905**	0,551
PMT	**0,931**	0,553
ZAD	0,562	**0,914**
ZAU	0,602	**0,918**

Tablica 6.88 Vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	NPR
OPR	0,892
ZRO	0,765

Tablica 6.89 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DST1 -> DST	0,754	0,751	0,036	20,897***
DST4 -> DST	0,487	0,488	0,042	11,516***
DST5 -> DST	0,440	0,441	0,057	7,673***
INT1 -> INT	0,508	0,504	0,057	8,878***
INT2 -> INT	0,443	0,439	0,065	6,817***
INT3 -> INT	0,739	0,739	0,037	19,863***
IRO1 -> IRO	0,407	0,393	0,102	3,995***
IRO2 -> IRO	0,550	0,544	0,102	5,372***
IRO3 -> IRO	0,592	0,575	0,101	5,837***
IRO4 -> IRO	0,548	0,542	0,095	5,745***
MIN1 -> MIN	0,359	0,365	0,058	6,157***
MIN2 -> MIN	0,611	0,611	0,040	15,236***
MIN5 -> MIN	0,476	0,483	0,056	8,454***
MIN7 -> MIN	0,528	0,523	0,053	9,938***
MIN8 -> MIN	0,535	0,535	0,050	10,663***
MOP1 -> MOP	0,606	0,613	0,096	6,316***
MOP2 -> MOP	0,509	0,510	0,114	4,468***
MOP4 -> MOP	0,612	0,589	0,103	5,959***
MPR1 -> MPR	0,832	0,821	0,066	12,573***
MPR2 -> MPR	0,308	0,301	0,124	2,477*
MPR3 -> MPR	0,461	0,455	0,119	3,887***
PIN1 -> PIN	0,501	0,502	0,061	8,267***
PIN2 -> PIN	0,364	0,360	0,070	5,179***
PIN3 -> PIN	0,488	0,489	0,057	8,552***
PIN4 -> PIN	0,498	0,500	0,044	11,301***
PIN6 -> PIN	0,361	0,355	0,060	6,046***
PNS1 -> PNS	0,471	0,471	0,074	6,382***
PNS2 -> PNS	0,723	0,721	0,049	14,918***
PNS3 -> PNS	0,506	0,504	0,069	7,355***
PST1 -> PST	0,535	0,536	0,087	6,139***
PST4 -> PST	0,653	0,651	0,077	8,455***
PST6 -> PST	0,536	0,522	0,087	6,181***
RIP1 -> RIP	0,450	0,446	0,081	5,572***
RIP3 -> RIP	0,505	0,502	0,069	7,369***
RIP5 -> RIP	0,386	0,387	0,151	2,552*
RIP6 -> RIP	0,398	0,394	0,062	6,428***
RIP7 -> RIP	0,484	0,481	0,076	6,353***

* $p < 0,05$; *** $p < 0,001$

Tablica 6.89 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo (nastavak)

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
SGR3 -> SGR	0,283	0,276	0,092	3,085**
SGR4 -> SGR	0,621	0,622	0,059	10,516***
SGR5 -> SGR	0,328	0,315	0,094	3,497***
SGR6 -> SGR	0,547	0,539	0,077	7,071***
SGR10 -> SGR	0,357	0,353	0,078	4,574***
SPO1 -> SPO	0,645	0,649	0,111	5,805***
SPO3 -> SPO	0,675	0,663	0,090	7,484***
SPO4 -> SPO	0,359	0,351	0,103	3,488***
SVK1 -> SVK	0,696	0,683	0,111	6,254***
SVK2 -> SVK	0,599	0,588	0,122	4,906***
SVK3 -> SVK	0,397	0,380	0,136	2,916**
UPA2 -> UPA	0,468	0,468	0,051	9,104***
UPA3 -> UPA	0,474	0,476	0,059	7,986***
UPA4 -> UPA	0,478	0,480	0,050	9,478***
UPA5 -> UPA	0,416	0,415	0,066	6,292***
UPA7 -> UPA	0,394	0,395	0,059	6,683***
UPR1 -> UPR	0,632	0,617	0,094	6,758***
UPR3 -> UPR	0,469	0,450	0,106	4,431***
UPR4 -> UPR	0,412	0,416	0,124	3,316***
UPR5 -> UPR	0,250	0,251	0,114	2,182*
UPR6 -> UPR	0,386	0,379	0,114	3,397***
ZAS1 -> ZAS	0,577	0,573	0,086	6,707***
ZAS3 -> ZAS	0,649	0,646	0,067	9,634***
ZAS4 -> ZAS	0,495	0,487	0,103	4,795***
ZVO2 -> ZVO	0,477	0,476	0,077	6,217***
ZVO3 -> ZVO	0,704	0,705	0,061	11,486***
ZVO4 -> ZVO	0,526	0,533	0,061	8,612***

* $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$

Tablica 6.90 Apsolutna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika (|OU/σ|)**
DST -> DHV	0,920	0,923	0,022	41,632***
INT -> OTV	0,883	0,880	0,030	29,547***
MIN -> FUP	0,889	0,889	0,024	36,721***
PIN -> POK	0,960	0,959	0,018	54,377***
PNS -> OTV	0,754	0,752	0,053	14,348***
PST -> DHV	0,608	0,595	0,069	8,870***
RIP -> POK	0,765	0,760	0,048	15,997***
SGR -> KVS	0,651	0,627	0,103	6,304***
UPA -> FUP	0,871	0,871	0,028	31,147***
ZAS -> RAU	0,718	0,682	0,150	4,787***
ZVO -> RAU	0,818	0,814	0,123	6,672***

*** p < 0,001

Tablica 6.91 Apsolutna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika (|OU/σ|)**
DHV -> KVS	0,848	0,840	0,062	13,740***
FUP -> KVU	0,950	0,939	0,050	18,858***
OTV -> KVS	0,789	0,784	0,068	11,614***
POK -> KVU	0,782	0,777	0,098	8,013***

*** p < 0,001

Tablica 6.92 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\lvert OU/\sigma \rvert$)**
DST1 -> DST	0,754	0,753	0,035	21,681***
DST4 -> DST	0,487	0,490	0,038	12,769***
DST5 -> DST	0,440	0,442	0,036	12,145***
INT1 -> INT	0,508	0,508	0,035	14,600***
INT2 -> INT	0,443	0,443	0,045	9,894***
INT3 -> INT	0,739	0,743	0,044	16,863***
IRO1 -> IRO	0,222	0,212	0,101	2,198*
IRO2 -> IRO	0,532	0,527	0,106	5,019***
IRO3 -> IRO	0,561	0,555	0,094	5,962***
IRO4 -> IRO	0,521	0,516	0,102	5,116***
MIN1 -> MIN	0,292	0,295	0,036	8,024***
MIN2 -> MIN	0,460	0,460	0,035	13,098***
MIN5 -> MIN	0,431	0,431	0,037	11,601***
MIN7 -> MIN	0,430	0,423	0,041	10,520***
MIN8 -> MIN	0,340	0,337	0,038	9,014***
MOP1 -> MOP	0,606	0,609	0,092	6,554***
MOP2 -> MOP	0,509	0,506	0,092	5,553***
MOP4 -> MOP	0,612	0,587	0,107	5,739***
MPR1 -> MPR	0,832	0,821	0,079	10,608***
MPR2 -> MPR	0,308	0,301	0,125	2,457*
MPR3 -> MPR	0,461	0,456	0,103	4,493***
PIN1 -> PIN	0,501	0,504	0,034	14,755***
PIN2 -> PIN	0,364	0,365	0,031	11,714***
PIN3 -> PIN	0,488	0,490	0,035	13,816***
PIN4 -> PIN	0,498	0,498	0,042	11,748***
PIN6 -> PIN	0,361	0,359	0,035	10,313***
PNS1 -> PNS	0,471	0,472	0,056	8,349***
PNS2 -> PNS	0,723	0,720	0,047	15,498***
PNS3 -> PNS	0,506	0,504	0,052	9,710***
PST1 -> PST	0,535	0,535	0,102	5,227***
PST4 -> PST	0,653	0,654	0,075	8,711***
PST6 -> PST	0,536	0,520	0,085	6,306***
RIP1 -> RIP	0,450	0,446	0,059	7,684***
RIP3 -> RIP	0,505	0,497	0,060	8,415***
RIP5 -> RIP	0,386	0,384	0,084	4,609***
RIP6 -> RIP	0,398	0,390	0,060	6,604***
RIP7 -> RIP	0,484	0,480	0,060	8,091***

* $p < 0,05$; *** $p < 0,001$

Tablica 6.92 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo (nastavak)

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\lvert OU/\sigma \rvert$)**
SGR3 -> SGR	0,281	0,275	0,079	3,535***
SGR4 -> SGR	0,634	0,633	0,064	9,881***
SGR5 -> SGR	0,329	0,321	0,073	4,503***
SGR6 -> SGR	0,541	0,536	0,065	8,323***
SGR10 -> SGR	0,346	0,341	0,070	4,917***
SPO1 -> SPO	0,645	0,647	0,087	7,388***
SPO3 -> SPO	0,675	0,660	0,101	6,682***
SPO4 -> SPO	0,359	0,348	0,084	4,287***
SVK1 -> SVK	0,696	0,683	0,119	5,828***
SVK2 -> SVK	0,599	0,589	0,120	5,002***
SVK3 -> SVK	0,397	0,385	0,129	3,067**
UPA2 -> UPA	0,468	0,465	0,044	10,556***
UPA3 -> UPA	0,474	0,470	0,048	9,912***
UPA4 -> UPA	0,478	0,478	0,043	11,081***
UPA5 -> UPA	0,416	0,412	0,049	8,456***
UPA7 -> UPA	0,394	0,395	0,041	9,534***
UPR1 -> UPR	0,632	0,621	0,086	7,368***
UPR3 -> UPR	0,469	0,442	0,116	4,044***
UPR4 -> UPR	0,412	0,408	0,110	3,758***
UPR5 -> UPR	0,250	0,243	0,098	2,537*
UPR6 -> UPR	0,386	0,379	0,104	3,700***
ZAS1 -> ZAS	0,577	0,573	0,085	6,775***
ZAS3 -> ZAS	0,649	0,645	0,082	7,958***
ZAS4 -> ZAS	0,495	0,491	0,084	5,914***
ZVO2 -> ZVO	0,477	0,471	0,067	7,076***
ZVO3 -> ZVO	0,704	0,700	0,056	12,500***
ZVO4 -> ZVO	0,526	0,520	0,075	7,017***

* $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$

Tablica 6.93 Relativna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika (|OU/σ|)**
DST -> DHV	0,819	0,826	0,041	19,838***
INT -> OTV	0,703	0,702	0,052	13,405***
MIN -> FUP	0,587	0,587	0,050	11,869***
PIN -> POK	0,773	0,776	0,057	13,474***
PNS -> OTV	0,503	0,505	0,057	8,898***
PST -> DHV	0,406	0,395	0,053	7,609***
RIP -> POK	0,338	0,332	0,068	4,996***
SGR -> KVS	0,307	0,285	0,119	2,579*
UPA -> FUP	0,549	0,548	0,047	11,655***
ZAS -> RAU	0,585	0,552	0,172	3,409***
ZVO -> RAU	0,709	0,715	0,146	4,857***

* p < 0,05; *** p < 0,001

Tablica 6.94 Relativna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika (|OU/σ|)**
DHV -> KVS	0,561	0,559	0,108	5,213***
FUP -> KVU	0,744	0,732	0,138	5,388***
OTV -> KVS	0,412	0,420	0,107	3,847***
POK -> KVU	0,375	0,376	0,160	2,344*

* p < 0,05; *** p < 0,001

Sljedeći korak u analizi metrijskih karakteristika konceptualnog modela je bilo vrjednovanje pouzdanosti latentnih konstrukata. U slučaju reflektivnih latentnih konstrukata pouzdanost je vrjednovana koeficijentom unutarnje dosljednosti dok se u kontekstu formativnih latentnih konstrukata vrjednovanje pouzdanosti sastojalo od analize multikolinearnosti.

Rezultati vrjednovanja pouzdanosti reflektivnih latentnih konstrukata nalaze se u tablici 6.95. U spomenutoj se tablici može vidjeti da na prvoj razini konceptualnog modela najmanju razinu kompozitne pouzdanosti ($\rho_c = 0{,}862$) ima reflektivni latentni konstrukt pomoću kojeg je utvrđeno do koje mjere korisnici mogu kontrolirati interakciju sa aplikacijom Mindomo, a najveću ($\rho_c = 0{,}966$) reflektivni latentni konstrukt pomoću kojeg je vrjednovana lakoća učenja korištenja aplikacijom Mindomo. Na drugoj razini modela manju razinu ($\rho_c = 0{,}912$) kompozitne pouzdanosti ima reflektivni latentni konstrukt primjenom kojeg je mjerena produktivnost korisnika, a veću ($\rho_c = 0{,}934$) reflektivni latentni konstrukt pomoću kojeg je mjerena operabilnost aplikacije Mindomo. Naposljetku, koeficijent kompozitne pouzdanosti je u slučaju napora kao jedinog reflektivnog latentnog konstrukta treće razina poprimio vrijednost $\rho_c = 0{,}816$ što implicira prihvatljivu razinu unutarnje dosljednosti. Iz navedenog je evidentno da su svi reflektivni latentni konstrukti u kontekstu konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Mindomo pouzdani. Tablica 6.96 zorno prikazuje da se vrijednosti koeficijenta inflacije varijance (VIF) nalaze u rasponu od 1,003 do 4,703, a vrijednosti koeficijenta tolerancije u intervalu od 0,213 do 0,997 što znači da je razina multikolinearnosti između formativnih manifestnih varijabli koje mjere dimenzije istog latentnog konstrukta prihvatljiva. Prema tome, svi formativni latentni konstrukti koji se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Mindomo su pouzdani.

U nastavku procedure testiranja metrijskih karakteristika konceptualnog modela, provedena je analiza valjanosti latentnih konstrukata. Vrjednovanje konvergentne valjanosti reflektivnih latentnih konstrukata sastojalo se od analize vrijednosti prosječnih ekstrahiranih varijanci. Kao što se može vidjeti u tablici 6.95, vrijednosti prosječnih ekstrahiranih varijanci se nalaze u intervalu od 0,675 do 0,904 što implicira da reflektivni latentni konstrukti objašnjavaju više od od 50% varijance pridruženih manifestnih varijabli. Nomološka valjanost formativnih latentnih konstrukata vrjednovana je analizom značajnosti koeficijenata puta koji su od istih odaslani prema reflektivnim latentnim konstruktima. Iz tablice 6.102 je vidljivo da je 81,82% vrijednosti koeficijenata puta odaslanih od formativnih latentnih konstrukata prema reflektivnim latentnim konstruktima značajno na razini $\alpha = 0{,}001$ dok ih je 18,18% značajno na razini $\alpha = 0{,}01$. Prema tome, svi formativni latentni konstrukti koji se nalaze u konceptualnom modelu udovoljavaju metrijskom kriteriju nomološke valjanosti.

Tablica 6.95 Vrijednosti kriterija vrjednovanja pouzdanosti i konvergentne valjanosti reflektivnih latentnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

REFLEKTIVNE LATENTNE VARIJABLE	Kompozitna pouzdanost ρ	AVE
Latentne varijable prve razine		
Dosljednost (DSD)	0,915	0,782
Estetika (EST)	0,929	0,813
Familijarnost (FML)	0,878	0,707
Jedinstvenost (JDN)	0,916	0,784
Korisnost (KRS)	0,926	0,808
Lakoća korištenja (LAK)	0,955	0,877
Lojalnost (LOJ)	0,927	0,809
Lakoća učenja korištenja (LUK)	0,966	0,904
Mogućnost kontrole (MOK)	0,862	0,675
Pamtljivost (PMT)	0,949	0,862
Pouzdanost (PZD)	0,923	0,801
Razigranost (RZG)	0,893	0,737
Razumljivost (RZM)	0,908	0,767
Stav prema korištenju (SPK)	0,948	0,859
Užitak (UTK)	0,947	0,856
Zamijećena djelotvornost (ZAD)	0,887	0,724
Zamijećena učinkovitost (ZAU)	0,898	0,746
Zadovoljstvo (ZDV)	0,934	0,826
Zamijećeno radno opterećenje (ZRO)	0,941	0,841
Latentne varijable druge razine		
Operabilnost (OPR)	0,934	0,824
Produktivnost (PDK)	0,912	0,839
Latentna varijabla treće razine		
Napor (NPR)	0,816	0,690

* Referentne vrijednosti: $\rho \geq 0{,}707$; AVE $\geq 0{,}500$

Tablica 6.96 Rezultati analize multikolinearnosti formativnih manifestnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

MV	VIF	Koeficijent tolerancije	MV	VIF	Koeficijent tolerancije
DST1	1,321	0,757	**PST6**	1,333	0,750
DST4	1,448	0,691	**RIP1**	1,758	0,569
DST5	1,189	0,841	**RIP3**	1,498	0,668
INT1	1,245	0,803	**RIP5**	3,398	0,294
INT2	1,193	0,838	**RIP6**	3,373	0,296
INT3	1,181	0,847	**RIP7**	2,795	0,358
IRO1	1,470	0,680	**SGR3**	1,254	0,798
IRO2	2,525	0,396	**SGR4**	1,317	0,760
IRO3	2,507	0,399	**SGR5**	1,356	0,737
IRO4	1,164	0,859	**SGR6**	1,223	0,818
IZD1	1,003	0,997	**SGR10**	1,099	0,910
IZU1	1,034	0,968	**SPO1**	1,630	0,614
MIN1	1,113	0,898	**SPO3**	1,646	0,607
MIN2	1,271	0,787	**SPO4**	1,014	0,986
MIN5	1,127	0,888	**SVK1**	1,560	0,641
MIN7	1,346	0,743	**SVK2**	1,234	0,810
MIN8	1,538	0,650	**SVK3**	1,720	0,581
MOP1	1,724	0,580	**UPA2**	1,954	0,512
MOP2	1,616	0,619	**UPA3**	1,868	0,535
MOP4	1,519	0,658	**UPA4**	1,046	0,956
MPR1	1,014	0,986	**UPA5**	1,310	0,763
MPR2	1,166	0,858	**UPA7**	1,185	0,844
MPR3	1,178	0,849	**UPR1**	1,300	0,769
PIN1	1,541	0,649	**UPR3**	1,676	0,597
PIN2	1,746	0,573	**UPR4**	2,007	0,498
PIN3	1,931	0,518	**UPR5**	2,542	0,393
PIN4	1,948	0,513	**UPR6**	1,998	0,501
PIN6	1,396	0,717	**ZAS1**	1,157	0,864
PNS1	1,290	0,775	**ZAS3**	1,380	0,725
PNS2	1,261	0,793	**ZAS4**	1,284	0,779
PNS3	1,043	0,959	**ZVO2**	4,107	0,243
PST1	1,076	0,929	**ZVO3**	4,703	0,213
PST4	1,297	0,771	**ZVO4**	3,913	0,256

* Referentne vrijednosti: VIF < 5; koeficijent tolerancije > 0,2

Vrjednovanje diskriminacijske valjanosti reflektivnih latentnih konstrukata obuhvaćalo je usporedbu vrijednosti standardiziranih faktorskih i unakrsnih opterećenja kao i usporedbu vrijednosti prosječne ekstrahirane varijance pojedinog reflektivnog latentnog konstrukta i kvadriranih vrijednosti njegovih dvosmjernih korelacija sa preostalim reflektivnim latentnim konstruktima. S druge strane, vrjednovanje diskriminacijske valjanosti formativnih latentnih konstrukata se sastojalo od analize vrijednosti njihovih međukorelacija.

Tablice 6.86 i 6.97 sadrže rezultate vrjednovanja diskriminacijske valjanosti reflektivnih latentnih konstrukata prve razine dok se u tablicama 6.87 i 6.98 nalaze rezultati vrjednovanja diskriminacijske valjanosti reflektivnih latentnih konstrukata druge razine. Iz tablica 6.86 i 6.87 je vidljivo da su vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli prve i druge razine sa temeljnim latentnim konstruktom veće od unakrsnih opterećenja sa preostalim reflektivnim latentnim konstruktima iste razine. Osim toga, u tablicama 6.97 i 6.98 se može vidjeti da su vrijednosti prosječnih ekstrahiranih varijanci reflektivnih latentnih konstrukata prve i druge razine veće od kvadriranih vrijednosti njihovih dvosmjernih korelacija sa preostalim reflektivnim latentnim konstruktima na istoj razini. Iz navedenog je moguće zaključiti da svi reflektivni latentni konstrukti koji se nalaze u konceptualnom modelu udovoljavaju kriterijima diskriminacijske valjanosti.

Rezultati vrjednovanja diskriminacijske valjanosti formativnih latentnih konstrukata prve, druge i treće razine nalaze se u tablicama 6.99-6.101, respektivno. Iz spomenutih je tablica vidljivo da formativni latentni konstrukti dijele između 0% i 31,70% zajedničke varijance na prvoj razini, između 15,60% i 29,38% varijance na drugoj razini te 39,82% varijance na trećoj razini u konceptualnom modelu. Navedeno implicira da formativni latentni konstrukti svih razina u konceptualnom modelu udovoljavaju kriteriju diskriminacijske valjanosti. Iz rezultata vrjednovanja metrijskih karakteristika prezentiranim u tablicama 6.86-6.102 moguće je zaključiti da su vanjski reflektivni i formativni model u kontekstu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijom Mindomo pouzdani i valjani.

Tablica 6.97 Diskriminacijska valjanost reflektivnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
DSD	**0,782**																		
EST	0,196	**0,813**																	
FML	0,163	0,140	**0,707**																
JDN	0,088	0,079	0,077	**0,784**															
KRS	0,189	0,140	0,175	0,298	**0,808**														
LAK	0,229	0,208	0,268	0,077	0,299	**0,877**													
LOJ	0,044	0,057	0,070	0,193	0,286	0,168	**0,809**												
LUK	0,195	0,135	0,167	0,098	0,253	0,457	0,150	**0,904**											
MOK	0,203	0,192	0,186	0,097	0,232	0,384	0,112	0,216	**0,675**										
PMT	0,172	0,112	0,207	0,079	0,243	0,555	0,193	0,621	0,277	**0,862**									
PZD	0,153	0,171	0,088	0,044	0,208	0,214	0,078	0,222	0,212	0,210	**0,801**								
RZG	0,115	0,085	0,123	0,242	0,317	0,228	0,292	0,218	0,201	0,246	0,136	**0,737**							
RZM	0,320	0,127	0,180	0,180	0,311	0,291	0,060	0,318	0,217	0,342	0,277	0,201	**0,767**						
SPK	0,091	0,206	0,104	0,151	0,233	0,187	0,298	0,135	0,150	0,210	0,146	0,208	0,153	**0,859**					
UTK	0,073	0,122	0,138	0,278	0,391	0,267	0,479	0,236	0,217	0,273	0,142	0,551	0,168	0,284	**0,856**				
ZAD	0,237	0,156	0,200	0,165	0,342	0,352	0,253	0,226	0,369	0,214	0,211	0,289	0,238	0,310	0,271	**0,724**			
ZAU	0,194	0,100	0,219	0,159	0,391	0,311	0,243	0,287	0,251	0,305	0,130	0,291	0,232	0,215	0,269	0,461	**0,746**		
ZDV	0,226	0,215	0,205	0,257	0,470	0,401	0,359	0,378	0,306	0,384	0,301	0,443	0,304	0,315	0,514	0,401	0,340	**0,826**	
ZRO	0,029	0,038	0,074	0,009	0,073	0,139	0,035	0,132	0,033	0,111	0,034	0,058	0,068	0,022	0,122	0,040	0,063	0,065	**0,841**

Tablica 6.98 Diskriminacijska valjanost reflektivnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	OPR	PDK
OPR	**0,824**	
PDK	0,404	**0,839**

Tablica 6.99 Diskriminacijska valjanost formativnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	DST	INT	IRO	IZD	IZU	MIN	MOP	MPR	PIN	PNS	PST	RIP	SGR	SPO	SVK	UPA	UPR	ZAS	ZVO
DST	1,000																		
INT	0,423	1,000																	
IRO	0,006	0,003	1,000																
IZD	0,329	0,344	-0,021	1,000															
IZU	-0,174	-0,321	0,191	-0,268	1,000														
MIN	0,305	0,369	0,006	0,313	-0,220	1,000													
MOP	0,309	0,312	-0,127	0,239	-0,263	0,386	1,000												
MPR	0,353	0,349	-0,104	0,334	-0,216	0,429	0,419	1,000											
PIN	0,331	0,434	-0,129	0,410	-0,272	0,417	0,357	0,332	1,000										
PNS	0,302	0,359	0,054	0,169	-0,248	0,326	0,297	0,370	0,261	1,000									
PST	0,249	0,183	-0,203	0,265	-0,083	0,303	0,183	0,298	0,265	0,159	1,000								
RIP	0,229	0,311	-0,122	0,270	-0,204	0,303	0,355	0,305	0,563	0,264	0,238	1,000							
SGR	0,251	0,308	-0,034	0,242	-0,243	0,341	0,373	0,434	0,306	0,334	0,320	0,348	1,000						
SPO	0,337	0,368	-0,230	0,349	-0,252	0,401	0,400	0,510	0,523	0,288	0,501	0,388	0,405	1,000					
SVK	0,278	0,352	-0,007	0,369	-0,224	0,402	0,301	0,442	0,379	0,312	0,186	0,266	0,358	0,340	1,000				
UPA	0,322	0,428	-0,164	0,348	-0,306	0,553	0,474	0,529	0,482	0,397	0,337	0,441	0,390	0,556	0,368	1,000			
UPR	0,296	0,359	-0,246	0,312	-0,411	0,307	0,385	0,407	0,344	0,288	0,242	0,295	0,315	0,371	0,225	0,416	1,000		
ZAS	0,356	0,260	0,118	0,298	-0,178	0,288	0,216	0,215	0,246	0,116	0,164	0,176	0,134	0,177	0,267	0,176	0,215	1,000	
ZVO	0,336	0,325	-0,058	0,377	-0,313	0,327	0,333	0,383	0,321	0,219	0,259	0,285	0,306	0,433	0,282	0,388	0,352	0,193	1,000

Tablica 6.100 Diskriminacijska valjanost formativnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	DHV	FUP	OTV	POK	RAU
DHV	1,000				
FUP	0,437	1,000			
OTV	0,455	0,525	1,000		
POK	0,395	0,542	0,460	1,000	
RAU	0,476	0,446	0,380	0,398	1,000

Tablica 6.101 Diskriminacijska valjanost formativnih latentnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	KVS	KVU
KVS	1,000	
KVU	0,631	1,000

Nakon što je dovršeno vrjednovanje vanjskih modela, uslijedila je analiza metrijskih karakteristika unutarnjeg modela. Slika 6.27 jasno prikazuje da se vrijednosti koeficijenta determinacije R^2 endogenih latentnih konstrukata nalaze u rasponu od 0,279 do 0,597. Formativni latentni konstrukti treće razine primjenom kojih su mjerene dimenzije kvalitete sustava i kvalitete usluge aplikacije Mindomo su objasnili 27,9% varijance u reflektivnom latentnom konstruktu prve razine pomoću kojeg je vrjednovan stav prema korištenju aplikacijom Mindomo. Indikatori primjenom kojih je mjeren broj pritisnutih tipaka na tipkovnici, broj klikova mišem, broj pomicanja klizača na mišu i udaljenost prijeđena pomicanjem miša tijekom interakcije sa aplikacijom Mindomo su objasnili 28,3% varijance u reflektivnom latentnom konstruktu kojim je vrjednovano zamijećeno radno opterećenje korisnika. Atributi kvalitete u korištenju pomoću kojih su vrjednovani aspekti mogućnosti prilagodbe i dosljednosti aplikacije Mindomo su objasnili 29,6% varijance u atributu kojim se vrjednovala pamtljivost aplikacije Mindomo. Formativni latentni konstrukt pomoću kojeg je mjerena razina do koje Mindomo sprječava nastanak pogrješaka i formativni latentni konstrukt kojim je utvrđeno do kojeg se stupnja Mindomo može oporaviti od pogrješaka i prekida u radu su objasnili 35% varijance u reflektivnom latentnom konstruktu primjenom kojeg je vrjednovana pouzdanost aplikacije Mindomo.

Konstrukti čije su manifestne varijable korištene u vrjednovanju familijarnosti i razumljivosti aplikacije Mindomo su objasnili 35,3% varijance u konstruktu kojim je mjerena lakoća učenja korištenja aplikacijom Mindomo. Indikator kojim je utvrđen broj reprezentativnih koraka

scenarija koje su korisnici uspjeli dovršiti primjenom aplikacije Mindomo i formativni latentni konstrukt pomoću kojeg se provjeravalo do koje je razine aplikaciju Mindomo moguće upotrebljavati i izvan konteksta za koji je originalno namijenjena su zajedno objasnili 42,5% varijance u reflektivnom latentnom konstruktu kojim je vrjednovana zamijećena djelotvornost korisnika. Atributi primjenom kojih su vrjednovani aspekti korisnosti, stava prema korištenju i zadovoljstva korisnika su objasnili 44% varijance u atributu kojim je vrjednovana lojalnost korisnika. Reflektivni latentni konstrukt druge razine pomoću kojeg je vrjednovana produktivnost korisnika i reflektivni latentni konstrukt prve razine primjenom kojeg je mjerena pouzdanost aplikacije Mindomo su zajedno objasnili 46,9% varijance u atributu pomoću kojeg je vrjednovana korisnost aplikacije Mindomo.

Indikator pomoću kojeg je utvrđeno koliko je vremena korisnicima potrebno da upotrebom aplikacije Mindomo dovrše reprezentativne koraka scenarija i formativni latentni konstrukt druge razine primjenom kojeg je mjeren radni učinak aplikacije Mindomo su objasnili 50,6% varijance u reflektivnom latentnom konstruktu prve razine kojim je vrjednovana zamijećena učinkovitost korisnika. Atribut kvalitete u korištenju primjenom kojeg se provjeravalo do koje mjere korisnici mogu kontrolirati način izvršavanja zadataka pomoću aplikacije Mindomo i atribut pomoću kojeg su mjereni aspekti upravljivosti aplikacijom Mindomo su objasnili 51,6% varijance u atributu kojim je vrjednovana lakoća korištenja aplikacijom Mindomo. Reflektivni latentni konstrukt druge razine primjenom kojeg je utvrđeno koliku količinu napora trebaju korisnici uložiti u interakciju sa aplikacijom Mindomo i reflektivni latentni konstrukt prve razine pomoću kojeg je vrjednovan užitak interakcije sa aplikacijom Mindomo su zajedno objasnili 57,3% varijance u atributu kojim je vrjednovano zadovoljstvo korisnika. Konačno, atributi korisničkog iskustva čijim su manifestnim varijablama vrjednovani različiti aspekti razigranosti korisnika te jedinstvenosti i estetike aplikacije Mindomo su objasnili 59,7% varijance u atributu pomoću kojeg je izmjereno do koje su razine korisnici uživali u korištenju aplikacijom Mindomo.

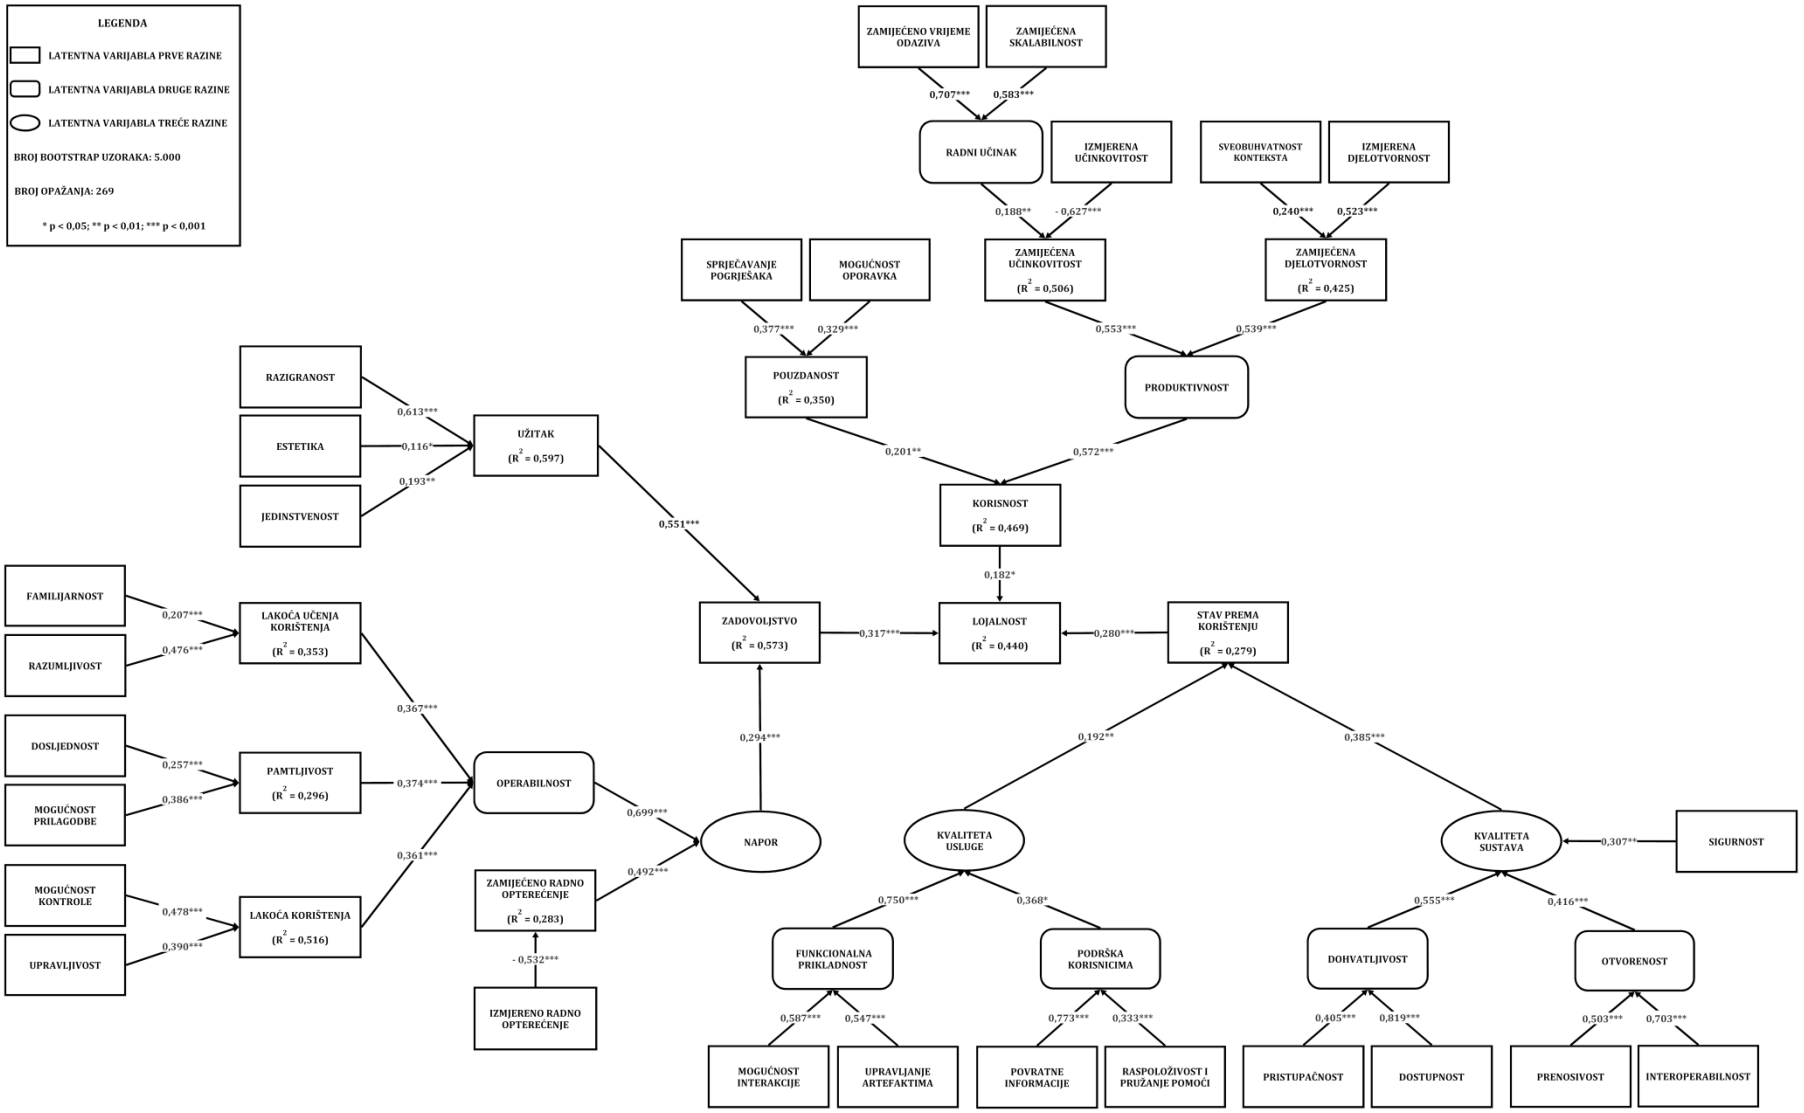

Slika 6.27 Rezultati analize metrijskih karakteristika unutarnjeg modela u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Mindomo

Rezultati vrjednovanja značajnosti koeficijenata puta u unutarnjem modelu nalaze se na slici 6.27 i u tablici 6.102. Iz navedene je tablice vidljivo da je 82,98% vrijednosti koeficijenata puta značajno na razini $\alpha = 0{,}001$, 10,64% ih je značajno na razini $\alpha = 0{,}01$ dok ih je 6,38% značajno na razini $\alpha = 0{,}05$. Prema tome, sve su pothipoteze $H_{1.1}$-$H_{1.25}$ u kontekstu konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Mindomo potvrđene.

Uzimajući u obzir vrijednosti koeficijenata puta odaslanih od latentnih konstrukata na prvoj razini u konceptualnom modelu potrebno je istaknuti atribut kojim je vrjednovana razigranost korisnika ($\beta = 0{,}613$; $p < 0{,}001$) jer ima veću značajnost u predikciji užitka u korištenju aplikacijom Mindomo od atributa pomoću kojeg je vrjednovana jedinstvenost ($\beta = 0{,}193$; $p < 0{,}01$) odnosno estetika ($\beta = 0{,}116$; $p < 0{,}05$) aplikacije Mindomo. Pored toga, na ovoj je razini potrebno još spomenuti atribut pomoću kojeg je vrjednovana korisnost aplikacije Mindomo ($\beta = 0{,}182$; $p < 0{,}05$) zbog toga što je njegova značajnost u oblikovanju lojalnosti korisnika manja od značajnosti atributa pomoću kojih je vrjednovan stav prema korištenju aplikacijom Mindomo ($\beta = 0{,}280$; $p < 0{,}001$) i značajnosti atributa kojim je vrjednovano zadovoljstvo korisnika ($\beta = 0{,}317$; $p < 0{,}001$). Iz skupine koeficijenata puta odaslanih od latentnih konstrukata nižih razina prema latentnim konstruktima viših razina u konceptualnom modelu potrebno je izdvojiti formativni latentni konstrukt druge razine kojim su vrjednovane dimenzije funkcionalne prikladnosti aplikacije Mindomo ($\beta = 0{,}750$; $p < 0{,}001$) iz razloga što isti ima veću značajnost u predikciji kvalitete usluge aplikacije Mindomo od formativnog latentnog konstrukta druge razine kojim su mjereni aspekti podrške koju aplikacija Mindomo pruža korisnicima ($\beta = 0{,}368$; $p < 0{,}05$). Jednako tako, potrebno je spomenuti i formativni latentni konstrukt treće razine pomoću kojeg su mjerene dimenzije kvalitete sustava aplikacije Mindomo ($\beta = 0{,}385$; $p < 0{,}001$) jer ima veću značajnost u oblikovanju stava prema korištenju aplikacijom Mindomo od formativnog latentnog konstrukta treće razine pomoću kojeg su mjereni različiti aspekti kvalitete usluge aplikacije Mindomo ($\beta = 0{,}192$; $p < 0{,}01$).

Promatrajući koeficijente puta sa aspekta povezanosti latentnih konstrukata kojima se vrjednuju objektivne i subjektivne dimenzije istog atributa kvalitete u korištenju pronađeno je da povećanje količine vremena potrebnog za dovršetak reprezentativnih koraka scenarija upotrebom aplikacije Mindomo dovodi do značajnog smanjenja ($\beta = -0{,}627$; $p < 0{,}001$) zamijećene učinkovitosti korisnika. Osim navedenog, utvrđeno je i da povećanje broja reprezentativnih koraka scenarija koje je moguće dovršiti primjenom aplikacije Mindomo rezultira značajnim povećanjem ($\beta = 0{,}523$; $p < 0{,}001$) zamijećene djelotvornosti korisnika. Konačno, ustanovljeno je da povećanje broja klikova mišem, broja pritisnutih tipaka na tipkovnici, broja pomicanja klizača na mišu i udaljenosti prijeđene pomicanjem miša tijekom

dovršavanja koraka scenarija pomoću aplikacije Mindomo dolazi do značajnog povećanja ($\beta = -0{,}532;\ p < 0{,}001$) zamijećenog radnog opterećenja korisnika.

Tablica 6.102 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\lvert OU/\sigma \rvert$)**
DHV -> KVS	0,555	0,551	0,107	5,167***
DSD -> PMT	0,257	0,257	0,068	3,760***
DST -> DHV	0,819	0,823	0,041	20,024***
EST -> UTK	0,116	0,116	0,050	2,334*
FML -> LUK	0,207	0,211	0,057	3,659***
FUP -> KVU	0,750	0,738	0,136	5,523***
INT -> OTV	0,703	0,699	0,052	13,431***
IRO -> ZRO	-0,532	-0,541	0,049	10,771***
IZD -> ZAD	0,523	0,521	0,061	8,603***
IZU -> ZAU	-0,627	-0,626	0,052	12,085***
JDN -> UTK	0,193	0,194	0,058	3,303**
KRS -> LOJ	0,182	0,180	0,084	2,160*
KVS -> SPK	0,385	0,388	0,074	5,187***
KVU -> SPK	0,192	0,199	0,074	2,591**
LAK -> OPR	0,361	0,361	0,006	65,245***
LUK -> OPR	0,367	0,367	0,006	58,276***
MIN -> FUP	0,587	0,584	0,050	11,742***
MOK -> LAK	0,478	0,467	0,055	8,741***
MOP -> PZD	0,329	0,332	0,075	4,398***
MPR -> PMT	0,386	0,395	0,061	6,386***
NPR -> ZDV	0,294	0,295	0,061	4,814***
OPR -> NPR	0,699	0,701	0,038	18,404***
OTV -> KVS	0,416	0,420	0,104	4,001***
PDK -> KRS	0,572	0,569	0,058	9,889***
PIN -> POK	0,773	0,774	0,057	13,511***
PMT -> OPR	0,374	0,373	0,007	56,038***
PNS -> OTV	0,503	0,501	0,057	8,876***
POK -> KVU	0,368	0,368	0,157	2,341*
PST -> DHV	0,405	0,389	0,054	7,477***
PZD -> KRS	0,201	0,202	0,064	3,138**
RAU -> ZAU	0,188	0,188	0,058	3,259**
RIP -> POK	0,333	0,323	0,067	4,946***
RZG -> UTK	0,613	0,611	0,050	12,230***
RZM -> LUK	0,476	0,477	0,052	9,243***

* p < 0,05; ** p < 0,01; *** p < 0,001

Tablica 6.102 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo (nastavak)

	Originalan uzorak (OU)	Srednja vrijednost uzorka ($\bar{x}$)	Standardna pogrješka (σ)	T statistika ($\lvert OU/\sigma \rvert$)
SGR -> KVS	0,307	0,284	0,116	2,646**
SPK -> LOJ	0,280	0,284	0,057	4,930***
SPO -> PZD	0,377	0,383	0,074	5,096***
SVK -> ZAD	0,240	0,253	0,058	4,160***
UPA -> FUP	0,547	0,542	0,048	11,354***
UPR -> LAK	0,390	0,402	0,059	6,593***
UTK -> ZDV	0,551	0,551	0,061	8,996***
ZAD -> PDK	0,539	0,539	0,010	54,565***
ZAS -> RAU	0,583	0,546	0,173	3,372***
ZAU -> PDK	0,553	0,553	0,011	50,957***
ZDV -> LOJ	0,317	0,315	0,083	3,836***
ZRO -> NPR	0,492	0,489	0,022	22,643***
ZVO -> RAU	0,707	0,709	0,148	4,793***

** p < 0,01; *** p < 0,001

U tablici 6.103 su prikazani rezultati analize veličine utjecaja i prediktivne valjanosti nezavisnih varijabli koje se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Mindomo. Iz navedene je tablice vidljivo da 64,29% nezavisnih varijabli ima mali utjecaj, 14,28% ih ima srednji utjecaj dok ih 21,43% ima veliki utjecaj na zavisne latentne konstrukte u konceptualnom modelu. Najmanju razinu utjecaja ($f^2 = 0{,}02$) u konceptualnom modelu ima indikator pomoću kojeg je izmjereno koliko su ukupno tipaka na tipkovnici korisnici pritisnuli tijekom izvršavanja reprezentativnih koraka scenarija primjenom aplikacije Mindomo. S druge strane, najveći stupanj utjecaja ($f^2 = 0{,}14$) u skupini nezavisnih varijabli sa malim utjecajem ima atribut pomoću kojeg je utvrđeno koliko su napora trebali korisnici uložiti kako bi upotrebom aplikacije Mindomo dovršili reprezentativne korake scenarija.

U skupini nezavisnih varijabli sa srednjim utjecajem najmanju razinu ($f^2 = 0{,}18$) istog ima atribut pomoću kojeg su vrjednovane mogućnosti prilagodbe aplikacije Mindomo i atribut primjenom kojeg je izmjerena razina do koje Mindomo sprječava nastanak pogrješaka u radu. Najveći stupanj utjecaja ($f^2 = 0{,}29$) unutar skupine nezavisnih varijabli sa srednjim utjecajem ima atribut pomoću kojeg je vrjednovana razumljivost aplikacije Mindomo. U skupini konstrukata sa velikim utjecajem, najmanju razinu istog ($f^2 = 0{,}41$) ima atribut primjenom kojeg je utvrđeno do koje mjere korisnici kontroliraju interakciju sa aplikacijom Mindomo i indikator pomoću kojeg je izmjereno koliko reprezentativnih koraka scenarija korisnici mogu dovršiti upotrebom aplikacije Mindomo. Najveću razinu utjecaja ($f^2 = 0{,}71$) u konceptualnom

modelu ima indikator primjenom kojeg je izmjereno koliko je vremena korisnicima potrebno za dovršetak reprezentativnih koraka scenarija.

Od ukupno 28 nezavisnih latentnih varijabli u konceptualnom modelu, 67,86% ih ima malu prediktivnu valjanost, 25% ih ima srednju prediktivnu valjanost dok ih 7,14% ima veliku prediktivnu valjanost. Najmanju razinu prediktivne valjanosti ($q^2 = 0{,}02$) u konceptualnom modelu ima reflektivni latentni konstrukt pomoću kojeg je vrjednovana estetika aplikacije Mindomo, reflektivni latentni konstrukt primjenom kojeg su vrjednovani različiti aspekti korisnosti aplikacije Mindomo i indikator kojim je izmjereno koliko su klikova mišem korisnici napravili tijekom interakcije sa aplikacijom Mindomo. U skupini nezavisnih varijabli sa malom prediktivnom valjanošću najveću razinu iste ($q^2 = 0{,}12$) ima formativni latentni konstrukt pomoću kojeg se provjeravalo da li Mindomo sprječava nastanak pogrješaka u radu. Iz skupine nezavisnih varijabli sa srednjom prediktivnom valjanošću potrebno je izdvojiti konstrukt pomoću kojeg je utvrđeno do koje je mjere moguće prilagoditi aplikaciju Mindomo jer ima najmanji stupanj prediktivne valjanosti ($q^2 = 0{,}15$) unutar ove skupine i konstrukt primjenom kojeg su vrjednovani različiti aspekti produktivnosti korisnika zbog toga što ima najveću razinu prediktivne valjanosti ($q^2 = 0{,}33$) u ovoj skupini. Od dva latentna konstrukta koji imaju veliku prediktivnu valjanost u konceptualnom modelu, manju razinu iste ($q^2 = 0{,}41$) ima konstrukt pomoću kojeg je utvrđeno koliko je vremena korisnicima bilo potrebno da dovrše reprezentativne korake scenarija interakcije sa aplikacijom Mindomo. Naposljetku, najveću razinu prediktivne valjanosti ($q^2 = 0{,}46$) u konceptualnom modelu ima reflektivni konstrukt pomoću kojeg su vrjednovani aspekti razigranosti korisnika tijekom korištenja aplikacijom Mindomo.

Uzimajući u obzir sve rezultate vrjednovanja metrijskih karakteristika, konceptualni model vrjednovanja kvalitete u korištenju aplikacijom Mindomo je pouzdan i valjan.

Tablica 6.103 Rezultati analize veličine utjecaja i prediktivne valjanosti egzogenih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Mindomo

	R_u^2	R_i^2	f^2	Q_u^2	Q_i^2	q^2
DSD -> PMT	0,296	0,241	0,08	0,255	0,202	0,07
EST -> UTK	0,597	0,585	0,03	0,503	0,495	0,02
FML -> LUK	0,353	0,318	0,05	0,318	0,285	0,05
IRO1 -> ZRO	0,283	0,270	0,02	0,237	0,225	0,02
IRO2 -> ZRO	0,283	0,204	0,11	0,237	0,171	0,09
IRO3 -> ZRO	0,283	0,196	0,12	0,237	0,165	0,09
IRO4 -> ZRO	0,283	0,208	0,11	0,237	0,177	0,08
IZD -> ZAD	0,425	0,187	0,41	0,308	0,137	0,25
IZU -> ZAU	0,506	0,156	0,71	0,375	0,116	0,41
JDN -> UTK	0,597	0,570	0,07	0,503	0,486	0,03
KRS -> LOJ	0,440	0,423	0,03	0,344	0,334	0,02
KVS -> SPK	0,279	0,189	0,12	0,238	0,161	0,10
KVU -> SPK	0,279	0,257	0,03	0,238	0,219	0,03
MOK -> LAK	0,516	0,318	0,41	0,450	0,278	0,31
MOP -> PZD	0,350	0,259	0,14	0,268	0,205	0,09
MPR -> PMT	0,296	0,172	0,18	0,255	0,146	0,15
NPR -> ZDV	0,573	0,514	0,14	0,467	0,420	0,09
PDK -> KRS	0,469	0,208	0,49	0,371	0,166	0,33
PZD -> KRS	0,469	0,437	0,06	0,371	0,344	0,04
RAU -> ZAU	0,506	0,475	0,06	0,375	0,353	0,04
RZG -> UTK	0,597	0,322	0,68	0,503	0,275	0,46
RZM -> LUK	0,353	0,167	0,29	0,318	0,151	0,25
SPK -> LOJ	0,440	0,388	0,09	0,344	0,308	0,05
SPO -> PZD	0,350	0,232	0,18	0,268	0,179	0,12
SVK -> ZAD	0,425	0,375	0,09	0,308	0,271	0,05
UPR -> LAK	0,516	0,384	0,27	0,450	0,335	0,21
UTK -> ZDV	0,573	0,365	0,49	0,467	0,298	0,32
ZDV -> LOJ	0,440	0,395	0,08	0,344	0,313	0,05

R^2– koeficijent determinacije
f^2 – koeficijent veličine utjecaja
Q^2 – Stone-Geisserov indeks unakrsno validirane redundance
q^2 – koeficijent prediktivne valjanosti

6.4.3 Rezultati analize metrijskih karakteristika konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping

Prvi korak u analizi metrijskih karakteristika konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping je bilo vrjednovanje pouzdanosti manifestnih varijabli. Kao kriterij vrjednovanja pouzdanosti reflektivnih manifestnih varijabli korištena je analiza vrijednosti njihovih standardiziranih faktorskih opterećenja. S druge strane, vrjednovanje pouzdanosti formativnih manifestnih varijabli se sastojalo od analize značajnosti njihovih težinskih vrijednosti i standardiziranih faktorskih opterećenja

U tablicama 6.104-6.106 se nalaze vrijednosti standardiziranih faktorskih opterećenja koje su poprimile reflektivne manifestne varijable na prvoj, drugoj i trećoj razini u konceptualnom modelu, respektivno. Spomenute tablice jasno prikazuju da se standardizirana faktorska opterećenja reflektivnih manifestnih varijabli nalaze u rasponu od 0,782 do 0,952 što implicira da iste objašnjavaju između 61,15% i 90,63% varijance u temeljnom latentnom konstruktu. Iz navedenog je evidentno da su reflektivne manifestne varijable na svim razinama u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping pouzdane.

Tablice 6.107-6.109 sadrže rezultate vrjednovanja značajnosti apsolutne važnosti formativnih manifestnih varijabli. Iz tablice 6.107 je vidljivo da je većina (89,06%) standardiziranih faktorskih opterećenja formativnih manifestnih varijabli značajna na razini $\alpha = 0{,}001$, 6,25% ih je značajno na razini $\alpha = 0{,}01$ dok ih je 4,69% značajno na razini $\alpha = 0{,}05$. Tablice 6.108 i 6.109 jasno prikazuju da su standardizirana faktorska opterećenja formativnih manifestnih varijabli druge i treće razine značajna na razini $\alpha = 0{,}001$, respektivno. Rezultati vrjednovanja značajnosti relativnog doprinosa formativnih manifestnih varijabli prve, druge i treće razine višedimenzionalnog modela nalaze se u tablicama 6.110–6.112, respektivno. Iz tablice 6.110 je vidljivo da je 93,75% težinskih vrijednosti formativnih manifestnih varijabli prve razine značajno na razini $\alpha = 0{,}001$, 4,69% ih je značajno na razini $\alpha = 0{,}01$ dok ih je 1,56% značajno na razini $\alpha = 0{,}05$. Kao što se može vidjeti u tablici 6.111, 81,82% težinskih vrijednosti manifestnih varijabli druge razine je značajno na razini $\alpha = 0{,}001$ dok ih je preostalih 18,18% značajno na razini $\alpha = 0{,}05$. Konačno, tablica 6.112 zorno prikazuje da je 50% težinskih vrijednosti formativnih manifestnih varijabli značajno na razini $\alpha = 0{,}001$ dok ih je po 25% značajno na razinama $\alpha = 0{,}01$ i $\alpha = 0{,}05$. Uzimajući u obzir rezultate vrjednovanja koji se nalaze u tablicama 6.107-6.112, može se zaključiti da su formativne manifestne varijable na svim razinama konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping pouzdane.

Tablica 6.104 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
DSD2	**0,875**	0,165	0,394	0,108	0,241	0,471	0,164	0,405	0,426	0,398	0,293	0,249	0,526	0,249	0,296	0,387	0,339	0,241	0,121
DSD3	**0,880**	0,052	0,338	-0,049	0,156	0,380	-0,051	0,384	0,349	0,390	0,320	0,142	0,476	0,182	0,189	0,315	0,265	0,107	0,138
DSD4	**0,863**	0,123	0,275	0,056	0,208	0,325	0,095	0,318	0,353	0,299	0,284	0,181	0,429	0,212	0,194	0,412	0,293	0,144	0,128
EST2	0,189	**0,817**	0,242	0,154	0,368	0,300	0,239	0,171	0,315	0,208	0,153	0,253	0,299	0,399	0,349	0,262	0,287	0,350	0,206
EST4	0,060	**0,887**	0,018	0,266	0,281	0,174	0,435	0,087	0,200	0,050	-0,042	0,244	0,080	0,384	0,334	0,250	0,260	0,333	0,064
EST5	0,090	**0,916**	0,135	0,215	0,314	0,206	0,367	0,083	0,225	0,062	0,052	0,212	0,152	0,401	0,378	0,265	0,255	0,337	0,067
FML1	0,347	0,180	**0,820**	0,119	0,310	0,412	0,243	0,329	0,369	0,369	0,241	0,297	0,338	0,245	0,352	0,438	0,457	0,334	0,193
FML3	0,338	0,123	**0,871**	0,053	0,296	0,382	0,052	0,355	0,361	0,367	0,257	0,236	0,412	0,217	0,285	0,319	0,331	0,254	0,193
FML4	0,313	0,088	**0,861**	0,060	0,290	0,388	0,050	0,336	0,373	0,399	0,228	0,241	0,443	0,174	0,252	0,313	0,385	0,259	0,155
JDN1	0,066	0,256	0,085	**0,908**	0,423	0,192	0,522	0,106	0,249	0,127	0,023	0,487	0,167	0,351	0,528	0,380	0,331	0,534	-0,003
JDN2	0,022	0,145	0,047	**0,848**	0,298	0,091	0,317	0,058	0,183	0,064	0,040	0,354	0,187	0,313	0,385	0,268	0,220	0,323	-0,092
JDN3	0,015	0,216	0,101	**0,860**	0,328	0,065	0,396	-0,020	0,193	-0,002	0,034	0,387	0,185	0,264	0,404	0,347	0,186	0,384	-0,087
KRS2	0,265	0,356	0,369	0,366	**0,923**	0,468	0,406	0,397	0,453	0,345	0,307	0,463	0,445	0,383	0,596	0,486	0,539	0,492	0,114
KRS3	0,160	0,311	0,266	0,379	**0,904**	0,428	0,429	0,440	0,327	0,393	0,319	0,476	0,406	0,369	0,568	0,461	0,547	0,516	0,116
KRS4	0,215	0,352	0,338	0,386	**0,946**	0,445	0,452	0,452	0,415	0,385	0,291	0,504	0,451	0,384	0,615	0,496	0,533	0,542	0,129
LAK1	0,454	0,279	0,454	0,188	0,459	**0,908**	0,202	0,584	0,602	0,591	0,409	0,429	0,508	0,361	0,505	0,602	0,519	0,455	0,316
LAK2	0,412	0,226	0,423	0,105	0,459	**0,953**	0,196	0,618	0,556	0,666	0,444	0,395	0,518	0,352	0,460	0,490	0,493	0,443	0,319
LAK3	0,409	0,220	0,415	0,101	0,433	**0,934**	0,203	0,608	0,507	0,625	0,415	0,351	0,523	0,299	0,442	0,439	0,518	0,402	0,270
LOJ1	0,119	0,339	0,130	0,456	0,405	0,211	**0,917**	0,199	0,172	0,174	0,038	0,371	0,123	0,368	0,532	0,361	0,361	0,587	0,075
LOJ2	0,068	0,408	0,142	0,435	0,479	0,233	**0,891**	0,239	0,215	0,197	0,042	0,381	0,152	0,435	0,536	0,375	0,404	0,563	0,038
LOJ3	0,015	0,319	0,081	0,418	0,367	0,128	**0,905**	0,156	0,097	0,095	-0,060	0,311	0,035	0,338	0,438	0,323	0,283	0,475	-0,017
LUK1	0,365	0,133	0,392	0,082	0,455	0,570	0,227	**0,949**	0,400	0,732	0,377	0,361	0,554	0,209	0,395	0,381	0,549	0,328	0,285
LUK2	0,457	0,138	0,365	0,069	0,410	0,630	0,188	**0,922**	0,410	0,701	0,377	0,356	0,519	0,201	0,411	0,424	0,472	0,316	0,320
LUK3	0,388	0,095	0,370	0,021	0,448	0,631	0,211	**0,952**	0,419	0,731	0,387	0,358	0,512	0,155	0,373	0,385	0,493	0,326	0,312

Tablica 6.104 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping (nastavak)

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
MOK1	0,390	0,267	0,386	0,253	0,384	0,584	0,213	0,430	**0,851**	0,439	0,335	0,369	0,402	0,344	0,457	0,548	0,499	0,421	0,170
MOK2	0,306	0,141	0,292	0,126	0,280	0,373	0,105	0,314	**0,782**	0,358	0,255	0,291	0,369	0,308	0,270	0,367	0,343	0,247	0,135
MOK3	0,364	0,267	0,377	0,198	0,387	0,481	0,115	0,315	**0,843**	0,374	0,350	0,381	0,427	0,446	0,410	0,553	0,460	0,324	0,108
PMT1	0,368	0,127	0,412	0,098	0,384	0,629	0,187	0,735	0,429	**0,927**	0,446	0,391	0,531	0,224	0,388	0,376	0,501	0,358	0,297
PMT2	0,406	0,131	0,443	0,075	0,398	0,625	0,160	0,726	0,439	**0,927**	0,435	0,381	0,560	0,260	0,370	0,395	0,459	0,318	0,281
PMT3	0,393	0,079	0,376	0,045	0,341	0,615	0,140	0,662	0,455	**0,918**	0,405	0,385	0,495	0,189	0,337	0,347	0,462	0,352	0,338
PZD3	0,373	0,121	0,289	0,083	0,390	0,476	0,121	0,416	0,392	0,465	**0,925**	0,365	0,470	0,348	0,388	0,422	0,307	0,349	0,128
PZD4	0,299	0,044	0,249	0,093	0,314	0,416	0,016	0,364	0,381	0,417	**0,927**	0,297	0,493	0,288	0,353	0,310	0,259	0,297	0,088
PZD5	0,228	-0,017	0,215	-0,115	0,143	0,296	-0,148	0,283	0,233	0,344	**0,813**	0,107	0,358	0,191	0,160	0,196	0,155	0,141	0,083
RZG1	0,175	0,228	0,286	0,406	0,417	0,346	0,326	0,324	0,345	0,402	0,236	**0,783**	0,274	0,274	0,523	0,382	0,404	0,565	0,156
RZG5	0,177	0,247	0,256	0,418	0,480	0,376	0,379	0,317	0,376	0,352	0,279	**0,917**	0,330	0,387	0,542	0,493	0,486	0,642	0,193
RZG6	0,219	0,222	0,241	0,412	0,452	0,367	0,316	0,346	0,379	0,325	0,267	**0,891**	0,317	0,360	0,501	0,436	0,434	0,606	0,221
RZM2	0,452	0,195	0,448	0,243	0,485	0,543	0,228	0,533	0,503	0,548	0,435	0,364	**0,831**	0,311	0,474	0,427	0,475	0,393	0,191
RZM3	0,467	0,188	0,340	0,161	0,370	0,417	0,053	0,454	0,351	0,438	0,446	0,283	**0,871**	0,299	0,316	0,346	0,344	0,264	0,144
RZM4	0,487	0,129	0,396	0,099	0,321	0,438	-0,005	0,430	0,360	0,461	0,387	0,244	**0,848**	0,250	0,252	0,311	0,372	0,207	0,132
SPK1	0,229	0,419	0,266	0,287	0,382	0,363	0,331	0,200	0,426	0,271	0,372	0,345	0,355	**0,934**	0,467	0,461	0,330	0,454	0,040
SPK2	0,255	0,418	0,244	0,325	0,373	0,334	0,363	0,144	0,404	0,208	0,292	0,323	0,340	**0,945**	0,495	0,446	0,355	0,457	0,027
SPK3	0,199	0,417	0,184	0,379	0,382	0,311	0,477	0,210	0,404	0,197	0,221	0,423	0,253	**0,899**	0,497	0,514	0,361	0,522	0,077
UTK2	0,248	0,344	0,307	0,496	0,544	0,433	0,488	0,343	0,452	0,320	0,328	0,526	0,380	0,452	**0,905**	0,506	0,434	0,616	-0,007
UTK4	0,238	0,412	0,312	0,464	0,613	0,455	0,554	0,374	0,415	0,355	0,300	0,559	0,380	0,518	**0,937**	0,533	0,461	0,690	0,062
UTK5	0,235	0,352	0,332	0,444	0,598	0,489	0,488	0,424	0,431	0,406	0,332	0,571	0,388	0,467	**0,897**	0,523	0,470	0,681	0,106
ZAD2	0,305	0,298	0,340	0,300	0,416	0,392	0,400	0,337	0,481	0,317	0,228	0,460	0,334	0,517	0,472	**0,811**	0,605	0,440	0,093
ZAD3	0,393	0,227	0,370	0,272	0,459	0,533	0,254	0,391	0,558	0,349	0,396	0,387	0,400	0,362	0,457	**0,876**	0,547	0,336	0,133
ZAD4	0,370	0,224	0,346	0,402	0,442	0,462	0,338	0,338	0,492	0,355	0,283	0,436	0,357	0,416	0,514	**0,843**	0,493	0,377	0,068

Tablica 6.104 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping (nastavak)

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
ZAU1	0,340	0,283	0,430	0,208	0,532	0,572	0,343	0,546	0,491	0,488	0,260	0,402	0,450	0,261	0,464	0,539	**0,837**	0,401	0,180
ZAU3	0,283	0,284	0,398	0,323	0,509	0,414	0,334	0,416	0,499	0,411	0,217	0,468	0,405	0,422	0,445	0,608	**0,854**	0,398	0,126
ZAU4	0,257	0,215	0,344	0,212	0,455	0,416	0,327	0,412	0,385	0,417	0,235	0,442	0,359	0,283	0,370	0,521	**0,875**	0,349	0,190
ZDV1	0,141	0,359	0,276	0,460	0,512	0,392	0,527	0,274	0,346	0,312	0,297	0,629	0,339	0,476	0,651	0,411	0,370	**0,920**	0,225
ZDV2	0,196	0,377	0,278	0,486	0,506	0,427	0,578	0,323	0,398	0,344	0,238	0,689	0,263	0,461	0,679	0,449	0,401	**0,924**	0,305
ZDV4	0,187	0,337	0,359	0,401	0,529	0,465	0,562	0,351	0,397	0,366	0,313	0,616	0,361	0,492	0,678	0,400	0,464	**0,921**	0,277
ZRO1	0,122	0,148	0,195	0,003	0,185	0,350	0,107	0,320	0,190	0,342	0,130	0,258	0,194	0,096	0,162	0,151	0,232	0,325	**0,898**
ZRO2	0,152	0,138	0,179	-0,047	0,124	0,329	0,044	0,293	0,194	0,285	0,091	0,189	0,149	0,037	0,074	0,133	0,172	0,273	**0,929**
ZRO3	0,116	0,041	0,190	-0,138	0,019	0,160	-0,069	0,243	0,047	0,240	0,077	0,124	0,149	-0,002	-0,106	0,008	0,096	0,164	**0,822**

Tablica 6.105 Vrijednosti standardiziranih faktorskih i unakrsnih opterećenja reflektivnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	OPR	PDK
LAK	**0,862**	0,602
LUK	**0,903**	0,528
PMT	**0,913**	0,506
ZAD	0,510	**0,905**
ZAU	0,595	**0,912**

Tablica 6.106 Vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	NPR
OPR	0,846
ZRO	0,806

Tablica 6.107 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DST1 -> DST	0,729	0,727	0,037	20,000***
DST4 -> DST	0,546	0,541	0,066	8,219***
DST5 -> DST	0,474	0,473	0,055	8,672***
INT1 -> INT	0,535	0,530	0,055	9,812***
INT2 -> INT	0,503	0,506	0,067	7,481***
INT3 -> INT	0,679	0,679	0,051	13,258***
IRO1 -> IRO	0,371	0,359	0,115	3,218**
IRO2 -> IRO	0,519	0,507	0,115	4,509***
IRO3 -> IRO	0,644	0,632	0,094	6,823***
IRO4 -> IRO	0,423	0,413	0,111	3,801***
MIN1 -> MIN	0,448	0,447	0,062	7,229***
MIN2 -> MIN	0,437	0,437	0,060	7,246***
MIN5 -> MIN	0,440	0,439	0,070	6,277***
MIN7 -> MIN	0,460	0,457	0,060	7,715***
MIN8 -> MIN	0,450	0,449	0,063	7,157***
MOP1 -> MOP	0,591	0,582	0,087	6,821***
MOP2 -> MOP	0,548	0,544	0,098	5,617***
MOP4 -> MOP	0,592	0,592	0,102	5,784***
MPR1 -> MPR	0,501	0,471	0,185	2,707**
MPR2 -> MPR	0,743	0,710	0,147	5,049***
MPR3 -> MPR	0,444	0,423	0,206	2,157*
PIN1 -> PIN	0,475	0,473	0,077	6,204***
PIN2 -> PIN	0,361	0,359	0,077	4,725***
PIN3 -> PIN	0,515	0,516	0,058	8,813***
PIN4 -> PIN	0,568	0,559	0,056	10,168***
PIN6 -> PIN	0,236	0,239	0,094	2,514*
PNS1 -> PNS	0,444	0,448	0,058	7,660***
PNS2 -> PNS	0,502	0,503	0,060	8,355***
PNS3 -> PNS	0,806	0,803	0,028	28,884***
PST1 -> PST	0,609	0,604	0,058	10,454***
PST4 -> PST	0,537	0,531	0,068	7,932***
PST6 -> PST	0,584	0,585	0,064	9,088***
RIP1 -> RIP	0,534	0,532	0,054	9,866***
RIP3 -> RIP	0,429	0,425	0,076	5,683***
RIP5 -> RIP	0,381	0,386	0,084	4,555***
RIP6 -> RIP	0,440	0,434	0,069	6,402***
RIP7 -> RIP	0,506	0,505	0,064	7,908***

* p < 0,05; ** p < 0,01; *** p < 0,001

Tablica 6.107 Apsolutna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping (nastavak)

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\lvert OU/\sigma \rvert$)**
SGR3 -> SGR	0,197	0,194	0,089	2,211*
SGR4 -> SGR	0,613	0,614	0,064	9,653***
SGR5 -> SGR	0,473	0,465	0,078	6,062***
SGR6 -> SGR	0,484	0,481	0,079	6,158***
SGR10 -> SGR	0,326	0,320	0,082	3,957***
SPO1 -> SPO	0,677	0,671	0,092	7,326***
SPO3 -> SPO	0,638	0,626	0,117	5,468***
SPO4 -> SPO	0,367	0,358	0,133	2,758**
SVK1 -> SVK	0,477	0,468	0,142	3,363***
SVK2 -> SVK	0,554	0,539	0,135	4,123***
SVK3 -> SVK	0,682	0,667	0,109	6,253***
UPA2 -> UPA	0,420	0,420	0,079	5,315***
UPA3 -> UPA	0,711	0,710	0,048	14,873***
UPA4 -> UPA	0,352	0,345	0,063	5,610***
UPA5 -> UPA	0,352	0,345	0,069	5,109***
UPA7 -> UPA	0,266	0,267	0,070	3,825***
UPR1 -> UPR	0,709	0,701	0,064	11,151***
UPR3 -> UPR	0,430	0,429	0,100	4,283***
UPR4 -> UPR	0,350	0,347	0,098	3,573***
UPR5 -> UPR	0,247	0,244	0,095	2,588**
UPR6 -> UPR	0,359	0,351	0,103	3,468***
ZAS1 -> ZAS	0,625	0,621	0,045	13,875***
ZAS3 -> ZAS	0,319	0,325	0,066	4,825***
ZAS4 -> ZAS	0,713	0,712	0,029	24,839***
ZVO2 -> ZVO	0,618	0,627	0,101	6,112***
ZVO3 -> ZVO	0,510	0,508	0,117	4,348***
ZVO4 -> ZVO	0,599	0,582	0,092	6,483***

* $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$

Tablica 6.108 Apsolutna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DST -> DHV	0,891	0,892	0,028	31,370***
INT -> OTV	0,849	0,852	0,036	23,888***
MIN -> FUP	0,858	0,854	0,037	23,075***
PIN -> POK	0,883	0,880	0,035	25,323***
PNS -> OTV	0,883	0,878	0,031	28,159***
PST -> DHV	0,701	0,695	0,051	13,715***
RIP -> POK	0,850	0,846	0,042	20,435***
SGR -> KVS	0,781	0,744	0,094	8,341***
UPA -> FUP	0,867	0,866	0,034	25,869***
ZAS -> RAU	0,958	0,956	0,044	22,049***
ZVO -> RAU	0,562	0,533	0,129	4,365***

*** $p < 0,001$

Tablica 6.109 Apsolutna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DHV -> KVS	0,812	0,803	0,098	8,320***
FUP -> KVU	0,891	0,881	0,071	12,501***
OTV -> KVS	0,800	0,785	0,093	8,621***
POK -> KVU	0,783	0,767	0,110	7,139***

*** $p < 0,001$

Tablica 6.110 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
DST1 -> DST	0,699	0,699	0,046	15,228***
DST4 -> DST	0,540	0,541	0,042	12,729***
DST5 -> DST	0,414	0,416	0,039	10,666***
INT1 -> INT	0,535	0,534	0,047	11,299***
INT2 -> INT	0,503	0,503	0,050	10,044***
INT3 -> INT	0,679	0,680	0,043	15,749***
IRO1 -> IRO	0,371	0,367	0,111	3,346***
IRO2 -> IRO	0,519	0,506	0,124	4,183***
IRO3 -> IRO	0,644	0,635	0,107	6,024***
IRO4 -> IRO	0,423	0,413	0,124	3,416***
MIN1 -> MIN	0,448	0,447	0,049	9,214***
MIN2 -> MIN	0,437	0,441	0,040	10,939***
MIN5 -> MIN	0,440	0,439	0,044	9,963***
MIN7 -> MIN	0,460	0,457	0,046	9,993***
MIN8 -> MIN	0,450	0,446	0,043	10,382***
MOP1 -> MOP	0,591	0,577	0,092	6,435***
MOP2 -> MOP	0,548	0,542	0,088	6,255***
MOP4 -> MOP	0,592	0,593	0,099	6,010***
MPR1 -> MPR	0,501	0,472	0,188	2,669**
MPR2 -> MPR	0,743	0,712	0,144	5,171***
MPR3 -> MPR	0,444	0,424	0,206	2,154*
PIN1 -> PIN	0,475	0,476	0,047	10,016***
PIN2 -> PIN	0,361	0,361	0,040	8,998***
PIN3 -> PIN	0,515	0,516	0,045	11,455***
PIN4 -> PIN	0,568	0,566	0,044	13,030***
PIN6 -> PIN	0,236	0,238	0,041	5,746***
PNS1 -> PNS	0,434	0,436	0,037	11,799***
PNS2 -> PNS	0,394	0,394	0,035	11,127***
PNS3 -> PNS	0,756	0,754	0,036	20,741***
PST1 -> PST	0,609	0,609	0,053	11,511***
PST4 -> PST	0,537	0,533	0,059	9,116***
PST6 -> PST	0,584	0,586	0,064	9,118***
RIP1 -> RIP	0,506	0,502	0,056	8,984***
RIP3 -> RIP	0,351	0,352	0,048	7,271***
RIP5 -> RIP	0,349	0,348	0,040	8,825***
RIP6 -> RIP	0,428	0,424	0,047	9,022***
RIP7 -> RIP	0,511	0,511	0,051	10,090***

* $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$

Tablica 6.110 Relativna važnost formativnih manifestnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping (nastavak)

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\|OU/\sigma\|$)**
SGR3 -> SGR	0,248	0,244	0,077	3,225**
SGR4 -> SGR	0,604	0,603	0,064	9,436***
SGR5 -> SGR	0,470	0,464	0,063	7,471***
SGR6 -> SGR	0,510	0,505	0,060	8,500***
SGR10 -> SGR	0,343	0,333	0,070	4,871***
SPO1 -> SPO	0,677	0,667	0,096	7,026***
SPO3 -> SPO	0,638	0,625	0,117	5,467***
SPO4 -> SPO	0,367	0,360	0,117	3,146**
SVK1 -> SVK	0,477	0,473	0,124	3,846***
SVK2 -> SVK	0,554	0,540	0,133	4,167***
SVK3 -> SVK	0,682	0,668	0,115	5,946***
UPA2 -> UPA	0,420	0,420	0,038	11,173***
UPA3 -> UPA	0,711	0,714	0,042	17,141***
UPA4 -> UPA	0,352	0,351	0,044	8,083***
UPA5 -> UPA	0,352	0,348	0,044	8,104***
UPA7 -> UPA	0,266	0,265	0,038	7,101***
UPR1 -> UPR	0,709	0,702	0,063	11,198***
UPR3 -> UPR	0,430	0,426	0,078	5,491***
UPR4 -> UPR	0,350	0,346	0,071	4,942***
UPR5 -> UPR	0,247	0,243	0,071	3,501***
UPR6 -> UPR	0,359	0,351	0,085	4,230***
ZAS1 -> ZAS	0,625	0,623	0,030	20,776***
ZAS3 -> ZAS	0,319	0,322	0,031	10,310***
ZAS4 -> ZAS	0,713	0,716	0,037	19,302***
ZVO2 -> ZVO	0,618	0,621	0,087	7,121***
ZVO3 -> ZVO	0,510	0,506	0,090	5,695***
ZVO4 -> ZVO	0,599	0,577	0,099	6,039***

** p < 0,01; *** p < 0,001

Tablica 6.111 Relativna važnost formativnih manifestnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	Originalan uzorak (OU)	Srednja vrijednost uzorka ($\bar{x}$)	Standardna pogrješka (σ)	T statistika ($\|OU/\sigma\|$)
DST -> DHV	0,748	0,752	0,044	16,930***
INT -> OTV	0,543	0,550	0,060	8,990***
MIN -> FUP	0,571	0,568	0,065	8,843***
PIN -> POK	0,610	0,610	0,070	8,776***
PNS -> OTV	0,611	0,602	0,062	9,893***
PST -> DHV	0,475	0,470	0,057	8,385***
RIP -> POK	0,543	0,543	0,071	7,621***
SGR -> KVS	0,377	0,333	0,159	2,368*
UPA -> FUP	0,588	0,591	0,059	9,975***
ZAS -> RAU	0,868	0,874	0,086	10,056***
ZVO -> RAU	0,300	0,272	0,137	2,183*

* p < 0,05; *** p < 0,001

Tablica 6.112 Relativna važnost formativnih manifestnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	Originalan uzorak (OU)	Srednja vrijednost uzorka ($\bar{x}$)	Standardna pogrješka (σ)	T statistika ($\|OU/\sigma\|$)
DHV -> KVS	0,478	0,491	0,157	3,039**
FUP -> KVU	0,684	0,677	0,139	4,917***
OTV -> KVS	0,397	0,402	0,163	2,429*
POK -> KVU	0,499	0,494	0,150	3,325***

* p < 0,05; ** p < 0,01; *** p < 0,001

U sljedećem je koraku vrjednovana pouzdanost latentnih konstrukata. Vrjednovanje pouzdanosti reflektivnih latentnih konstrukata sastojalo se od analize vrijednosti koeficijenata unutarnje dosljednosti dok je testiranjem multikolinearnosti formativnih manifestnih varijabli utvrđena pouzdanost formativnih latentnih konstrukata.

Rezultati vrjednovanja pouzdanosti reflektivnih latentnih konstrukata sažeti su u tablici 6.113. Iz spomenutih je rezultata evidentno da u skupu reflektivnih manifestnih varijabli prve razine najmanju pouzdanost ima atribut pomoću kojeg je utvrđeno do koje mjere korisnici mogu kontrolirati interakciju sa aplikacijom Wise Mapping ($\rho_c = 0{,}865$), a najveću atribut pomoću kojeg je vrjednovana lakoća učenja korištenja aplikacijom Wise Mapping ($\rho_c = 0{,}959$). Na drugoj razini višedimenzionalnog modela veći je stupanj pouzdanosti utvrđen za konstrukt kojim je mjerena operabilnost aplikacije Wise Mapping ($\rho_c = 0{,}922$), a manji za konstrukt primjenom kojeg su vrjednovane dimenzije produktivnosti korisnika ($\rho_c = 0{,}904$). Konačno, koeficijent unutarnje dosljednosti je u slučaju reflektivnog latentnog konstrukta treće razine pomoću kojeg je utvrđeno koliku je količinu napora potrebno uložiti kako bi se primjenom aplikacije Wise Mapping dovršili reprezentativni koraci scenarija poprimio vrijednost $\rho_c = 0{,}812$ koja označava prihvatljivu razinu pouzdanosti. Prema tome, svi reflektivni latentni konstrukti koji se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping su pouzdani.

Kao što se može vidjeti u tablici 6.114, vrijednosti koeficijenta inflacije varijance (VIF) se nalaze u intervalu od 1,002 do 3,527 dok se vrijednosti koeficijenta tolerancije kreću u rasponu od 0,284 do 0,998 što znači da je utvrđena razina multikolinearnosti među formativnim manifestnim varijablama pridruženima istom temeljnom latentnom konstruktu prihvatljiva. Iz navedenog je evidentno da su svi formativni latentni konstrukti u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping pouzdani.

Po završetku vrjednovanja pouzdanosti latentnih konstrukata, pristupilo se analizi njihove valjanosti. Kao kriterij vrjednovanja konvergentne valjanosti reflektivnih latentnih konstrukata korištena je analiza vrijednosti prosječnih ekstrahiranih varijanci. Iz tablice 6.113 je vidljivo da se vrijednosti prosječnih ekstrahiranih varijanci nalaze u rasponu od 0,682 do 0,886 što implicira da reflektivni latentni konstrukti objašnjavaju između 82,58% i 94,13% varijance manifestnih varijabli koje mjere njihova obilježja. Prema tome, svi reflektivni latentni konstrukti koji se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping su konvergentno valjani. Nomološka valjanost formativnih latentnih konstrukata vrjednovana je analizom značajnosti koeficijenata puta koji su u konceptualnom modelu od njih odaslani prema reflektivnim latentnim konstruktima. Tablica 6.120 jasno prikazuje da su

vrijednosti svih koeficijenata puta odaslanih od formativnih latentnih konstrukata prema reflektivnim latentnim konstruktima značajne na razini $\alpha = 0{,}001$. Shodno tome, svi formativni latentni konstrukti koji se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping udovoljavaju kriteriju nomološke valjanosti.

Tablica 6.113 Vrijednosti kriterija vrjednovanja pouzdanosti i konvergentne valjanosti reflektivnih latentnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

REFLEKTIVNE LATENTNE VARIJABLE	**Kompozitna pouzdanost ρ**	**AVE**
Latentne varijable prve razine		
Dosljednost (DSD)	0,905	0,761
Estetika (EST)	0,907	0,765
Familijarnost (FML)	0,887	0,724
Jedinstvenost (JDN)	0,905	0,761
Korisnost (KRS)	0,946	0,854
Lakoća korištenja (LAK)	0,952	0,868
Lojalnost (LOJ)	0,931	0,818
Lakoća učenja korištenja (LUK)	0,959	0,886
Mogućnost kontrole (MOK)	0,865	0,682
Pamtljivost (PMT)	0,946	0,854
Pouzdanost (PZD)	0,919	0,792
Razigranost (RZG)	0,899	0,749
Razumljivost (RZM)	0,886	0,722
Stav prema korištenju (SPK)	0,948	0,858
Užitak (UTK)	0,938	0,834
Zamijećena djelotvornost (ZAD)	0,881	0,712
Zamijećena učinkovitost (ZAU)	0,891	0,731
Zadovoljstvo (ZDV)	0,944	0,849
Zamijećeno radno opterećenje (ZRO)	0,915	0,782
Latentne varijable druge razine		
Operabilnost (OPR)	0,922	0,798
Produktivnost (PDK)	0,904	0,825
Latentna varijabla treće razine		
Napor (NPR)	0,812	0,683

* Referentne vrijednosti: $\rho \geq 0{,}707$; AVE ≥ 0,500

Tablica 6.114 Rezultati analize multikolinearnosti formativnih manifestnih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

MV	VIF	Koeficijent tolerancije	MV	VIF	Koeficijent tolerancije
DST1	1,397	0,716	**PST6**	1,393	0,718
DST4	1,388	0,721	**RIP1**	1,459	0,685
DST5	1,012	0,988	**RIP3**	1,628	0,614
INT1	1,304	0,767	**RIP5**	3,053	0,327
INT2	1,112	0,900	**RIP6**	3,527	0,284
INT3	1,185	0,844	**RIP7**	2,661	0,376
IRO1	1,506	0,664	**SGR3**	1,098	0,911
IRO2	1,848	0,541	**SGR4**	1,251	0,800
IRO3	2,002	0,499	**SGR5**	1,418	0,705
IRO4	1,313	0,762	**SGR6**	1,273	0,786
IZD1	1,004	0,996	**SGR10**	1,151	0,869
IZU1	1,022	0,979	**SPO1**	1,436	0,697
MIN1	1,173	0,852	**SPO3**	1,434	0,698
MIN2	1,147	0,872	**SPO4**	1,002	0,998
MIN5	1,123	0,890	**SVK1**	1,352	0,740
MIN7	1,227	0,815	**SVK2**	1,199	0,834
MIN8	1,268	0,789	**SVK3**	1,504	0,665
MOP1	2,104	0,475	**UPA2**	2,018	0,496
MOP2	2,034	0,492	**UPA3**	1,728	0,579
MOP4	1,857	0,539	**UPA4**	1,419	0,705
MPR1	1,021	0,980	**UPA5**	1,161	0,861
MPR2	1,257	0,795	**UPA7**	1,046	0,956
MPR3	1,274	0,785	**UPR1**	1,161	0,861
PIN1	1,440	0,694	**UPR3**	1,637	0,611
PIN2	1,544	0,648	**UPR4**	1,765	0,567
PIN3	1,821	0,549	**UPR5**	1,716	0,583
PIN4	1,890	0,529	**UPR6**	2,038	0,491
PIN6	1,379	0,725	**ZAS1**	1,270	0,787
PNS1	1,214	0,824	**ZAS3**	1,306	0,766
PNS2	1,222	0,818	**ZAS4**	1,445	0,692
PNS3	1,075	0,930	**ZVO2**	2,758	0,363
PST1	1,020	0,980	**ZVO3**	2,872	0,348
PST4	1,384	0,723	**ZVO4**	3,273	0,306

* Referentne vrijednosti: VIF < 5; koeficijent tolerancije > 0,2

Vrjednovanje diskriminacijske valjanosti reflektivnih latentnih konstrukata obuhvaćalo je komparaciju vrijednosti standardiziranih faktorskih i unakrsnih opterećenja kao i komparaciju vrijednosti prosječne ekstrahirane varijance određenog reflektivnog latentnog konstrukta i kvadriranih vrijednosti njegovih dvosmjernih korelacija sa preostalim reflektivnim latentnim konstruktima. S druge strane, kao kriterij vrjednovanja diskriminacijske valjanosti formativnih latentnih konstrukata korištena je analiza vrijednosti njihovih međukorelacija.

Rezultati vrjednovanja diskriminacijske valjanosti reflektivnih latentnih konstrukata prve razine prikazani su u tablicama 6.104 i 6.115 dok se rezultati vrjednovanja diskriminacijske valjanosti druge razine nalaze u tablicama 6.105 i 6.116. Tablice 6.104 i 6.105 jasno prikazuju da su vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli sa temeljnim latentnim konstruktom veće od unakrsnih opterećenja sa preostalim reflektivnim latentnim konstruktima u modelu. Osim toga, iz tablica 6.115 i 6.116 je vidljivo da svaki reflektivni latentni konstrukt dijeli više varijance sa pridruženim manifestnim varijablama nego sa preostalim reflektivnim latentnim konstruktima u modelu. Shodno tome, svi reflektivni latentni konstrukti u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping udovoljavaju kriterijima diskriminacijske valjanosti.

U tablicama 6.117-6.119 se nalaze međukorelacije formativnih latentnih konstrukata na prvoj, drugoj i trećoj razini u konceptualnom modelu, respektivno. Iz navedenih je tablica evidentno da formativni latentni konstrukti dijele između 0% i 28,20% zajedničke varijance na prvoj razini, između 3,31% i 19,80% varijance na drugoj razini i 21,07% varijance na trećoj razini konceptualnog modela što znači da isti udovoljavaju kriteriju diskriminacijske valjanosti. Ukoliko se uzmu u obzir rezultati vrjednovanja metrijskih karakteristika koji se nalaze u tablicama 6.104-6.120, može se zaključiti da su vanjski reflektivni i formativni model u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping pouzdani i valjani.

Tablica 6.115 Diskriminacijska valjanost reflektivnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	DSD	EST	FML	JDN	KRS	LAK	LOJ	LUK	MOK	PMT	PZD	RZG	RZM	SPK	UTK	ZAD	ZAU	ZDV	ZRO
DSD	**0,761**																		
EST	0,017	**0,765**																	
FML	0,152	0,023	**0,724**																
JDN	0,002	0,058	0,008	**0,761**															
KRS	0,053	0,135	0,123	0,166	**0,854**														
LAK	0,208	0,067	0,214	0,020	0,234	**0,868**													
LOJ	0,006	0,157	0,018	0,234	0,216	0,046	**0,818**												
LUK	0,183	0,017	0,160	0,004	0,216	0,420	0,049	**0,886**											
MOK	0,187	0,080	0,186	0,059	0,186	0,355	0,034	0,189	**0,682**										
PMT	0,177	0,015	0,198	0,006	0,164	0,454	0,031	0,587	0,228	**0,854**									
PZD	0,118	0,004	0,081	0,001	0,109	0,206	0,000	0,163	0,148	0,215	**0,792**								
RZG	0,048	0,073	0,091	0,228	0,271	0,177	0,156	0,145	0,180	0,174	0,091	**0,749**							
RZM	0,304	0,041	0,219	0,042	0,220	0,307	0,014	0,315	0,234	0,328	0,250	0,126	**0,722**						
SPK	0,060	0,204	0,062	0,128	0,168	0,131	0,179	0,040	0,197	0,059	0,101	0,155	0,116	**0,858**					
UTK	0,069	0,164	0,121	0,262	0,412	0,253	0,313	0,174	0,224	0,156	0,123	0,366	0,176	0,276	**0,834**				
ZAD	0,178	0,088	0,174	0,148	0,271	0,300	0,154	0,177	0,367	0,163	0,128	0,257	0,186	0,263	0,325	**0,712**			
ZAU	0,118	0,093	0,209	0,084	0,341	0,299	0,153	0,288	0,288	0,263	0,077	0,262	0,224	0,142	0,249	0,423	**0,731**		
ZDV	0,036	0,151	0,109	0,237	0,313	0,216	0,364	0,118	0,171	0,137	0,094	0,490	0,121	0,267	0,528	0,208	0,200	**0,849**	
ZRO	0,022	0,016	0,045	0,004	0,017	0,105	0,001	0,105	0,028	0,109	0,013	0,048	0,035	0,003	0,004	0,013	0,037	0,086	**0,782**

Tablica 6.116 Diskriminacijska valjanost reflektivnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	OPR	PDK
OPR	**0,798**	
PDK	0,371	**0,825**

Tablica 6.117 Diskriminacijska valjanost formativnih latentnih varijabli prve razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	DST	INT	IRO	IZD	IZU	MIN	MOP	MPR	PIN	PNS	PST	RIP	SGR	SPO	SVK	UPA	UPR	ZAS	ZVO
DST	1,000																		
INT	0,391	1,000																	
IRO	0,018	-0,072	1,000																
IZD	0,240	0,269	0,139	1,000															
IZU	-0,156	-0,269	0,230	-0,243	1,000														
MIN	0,230	0,287	-0,028	0,252	-0,158	1,000													
MOP	0,316	0,422	-0,066	0,183	-0,237	0,316	1,000												
MPR	0,196	0,193	0,046	0,332	-0,145	0,234	0,155	1,000											
PIN	0,098	0,205	0,019	0,217	-0,216	0,260	0,148	0,339	1,000										
PNS	0,322	0,505	-0,088	0,240	-0,277	0,267	0,326	0,157	0,090	1,000									
PST	0,305	0,255	-0,080	0,150	-0,104	0,231	0,200	0,260	0,154	0,260	1,000								
RIP	0,142	0,224	0,035	0,327	-0,131	0,250	0,227	0,199	0,507	0,182	0,128	1,000							
SGR	0,364	0,403	-0,028	0,266	-0,206	0,311	0,349	0,189	0,215	0,484	0,290	0,290	1,000						
SPO	0,428	0,466	-0,185	0,233	-0,229	0,303	0,374	0,178	0,151	0,326	0,307	0,230	0,429	1,000					
SVK	0,133	0,164	0,080	0,317	-0,214	0,214	0,105	0,414	0,367	0,087	0,075	0,177	0,159	0,113	1,000				
UPA	0,264	0,316	-0,031	0,185	-0,167	0,504	0,226	0,297	0,333	0,287	0,131	0,329	0,390	0,301	0,244	1,000			
UPR	0,193	0,324	-0,225	0,164	-0,345	0,197	0,236	0,152	0,212	0,348	0,206	0,135	0,347	0,286	0,147	0,184	1,000		
ZAS	0,268	0,344	0,087	0,459	-0,278	0,312	0,291	0,381	0,333	0,201	0,232	0,258	0,322	0,280	0,390	0,333	0,257	1,000	
ZVO	0,515	0,450	-0,096	0,318	-0,204	0,283	0,460	0,176	0,011	0,305	0,297	0,156	0,450	0,531	0,080	0,282	0,306	0,304	1,000

Tablica 6.118 Diskriminacijska valjanost formativnih latentnih varijabli druge razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	DHV	FUP	OTV	POK	RAU
DHV	1,000				
FUP	0,312	1,000			
OTV	0,445	0,381	1,000		
POK	0,182	0,403	0,238	1,000	
RAU	0,426	0,424	0,399	0,329	1,000

Tablica 6.119 Diskriminacijska valjanost formativnih latentnih varijabli treće razine u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	KVS	KVU
KVS	1,000	
KVU	0,459	1,000

Nakon što je utvrđeno da vanjski modeli udovoljavaju kriterijima pouzdanosti i valjanosti, izvršena je analiza metrijskih karakteristika unutarnjeg modela. Iz slike 6.28 je vidljivo da se vrijednosti koeficijenta determinacije R^2 zavisnih varijabli nalaze u rasponu od 0,221 do 0,571. Atributi kvalitete u korištenju pomoću kojih su vrjednovani aspekti dosljednosti i mogućnosti prilagodbe aplikacije Wise Mapping su objasnili 22,1% varijance u atributu kojim je vrjednovana pamtljivost aplikacije Wise Mapping. Formativni latentni konstrukti treće razine primjenom kojih su mjerene različite dimenzije kvalitete sustava i kvalitete usluge aplikacije Wise Mapping su objasnili 24,5% varijance u reflektivnom latentnom konstruktu pomoću kojeg je vrjednovan stav prema korištenju aplikacijom Wise Mapping. Indikatori primjenom kojih je mjeren broj pritisnutih tipaka na tipkovnici, udaljenost prijeđena mišem, broj klikova mišem i broj pomicanja klizača na mišu tijekom izvršavanja reprezentativnih koraka scenarija pomoću aplikacije Wise Mapping su objasnili 25,8% varijance u reflektivnom latentnom konstruktu kojim je vrjednovano zamijećeno radno opterećenje korisnika. Atributi pomoću kojih je utvrđena razina familijarnosti i razumljivosti aplikacije Wise Mapping su objasnili 33,9% varijance u atributu kojim je vrjednovana lakoća učenja korištenja aplikacijom Wise Mapping.

Formativni latentni konstrukt primjenom kojeg je tvrđeno do koje mjere aplikacija Wise Mapping sprječava nastanak pogrješaka tijekom upotrebe i formativni latentni konstrukt pomoću kojeg se provjeravalo da li se Wise Mapping može oporaviti od prekida i pogrješaka u radu su objasnili 37,8% varijance u reflektivnom latentnom konstruktu kojim je vrjednovana pouzdanost aplikacije Wise Mapping. Reflektivni latentni konstrukt druge razine kojim je

vrjednovana produktivnost korisnika i reflektivni latentni konstrukt čije su manifestne varijable korištene u vrjednovanju pouzdanosti aplikacije Wise Mapping su objasnili 38,6% varijance u reflektivnom latentnom konstruktu pomoću kojeg je vrjednovana korisnost aplikacije Wise Mapping. Atributi pomoću kojih je vrjednovano zadovoljstvo korisnika, stav prema korištenju i korisnost aplikacije Wise Mapping su objasnili 39,9% varijance u atributu kojim je vrjednovana lojalnost korisnika. Indikator pomoću kojeg je izmjeren broj reprezentativnih koraka scenarija koje su korisnici uspjeli dovršiti primjenom aplikacije Wise Mapping i formativni latentni konstrukt kojim je izmjerena razina do koje se aplikacija Wise Mapping može upotrebljavati i izvan konteksta za koji je inicijalno osmišljena su objasnili 44,5% varijance u reflektivnom latentnom konstruktu primjenom kojeg je vrjednovana zamijećena djelotvornost korisnika.

Formativni latentni konstrukt druge razine kojim je vrjednovan radni učinak aplikacije Wise Mapping i indikator primjenom kojeg je utvrđeno koliko je vremena korisnicima bilo potrebno da dovrše reprezentativne korake scenarija korištenja aplikacijom Wise Mapping su objasnili 46,4% varijance u atributu kojim je vrjednovana zamijećena učinkovitost korisnika. Reflektivni latentni konstrukti pomoću kojih su vrjednovani aspekti razigranosti korisnika te estetike i jedinstvenosti aplikacije Wise Mapping su objasnili 47,9% varijance u konstruktu čijim je manifestnim varijablama izmjereno koliko su korisnici uživali u korištenju aplikacijom Wise Mapping. Atribut primjenom kojeg je utvrđeno do koje mjere korisnici mogu kontrolirati interakciju sa aplikacijom Wise Mapping i atribut kojim su vrjednovani aspekti upravljivosti aplikacijom Wise Mapping su objasnili 56,4% varijance u atributu pomoću kojeg je vrjednovana lakoća korištenja aplikacijom Wise Mapping. Konačno, reflektivni latentni konstrukt druge razine kojim je izmjerena količina napora potrebnog za dovršetak reprezentativnih koraka scenarija primjenom aplikacije Wise Mapping i reflektivni latentni konstrukt prve razine pomoću kojeg je vrjednovan užitak interakcije sa aplikacijom Wise Mapping su objasnili 57,1% varijance u reflektivnom latentnom konstruktu primjenom kojeg je vrjednovano zadovoljstvo korisnika.

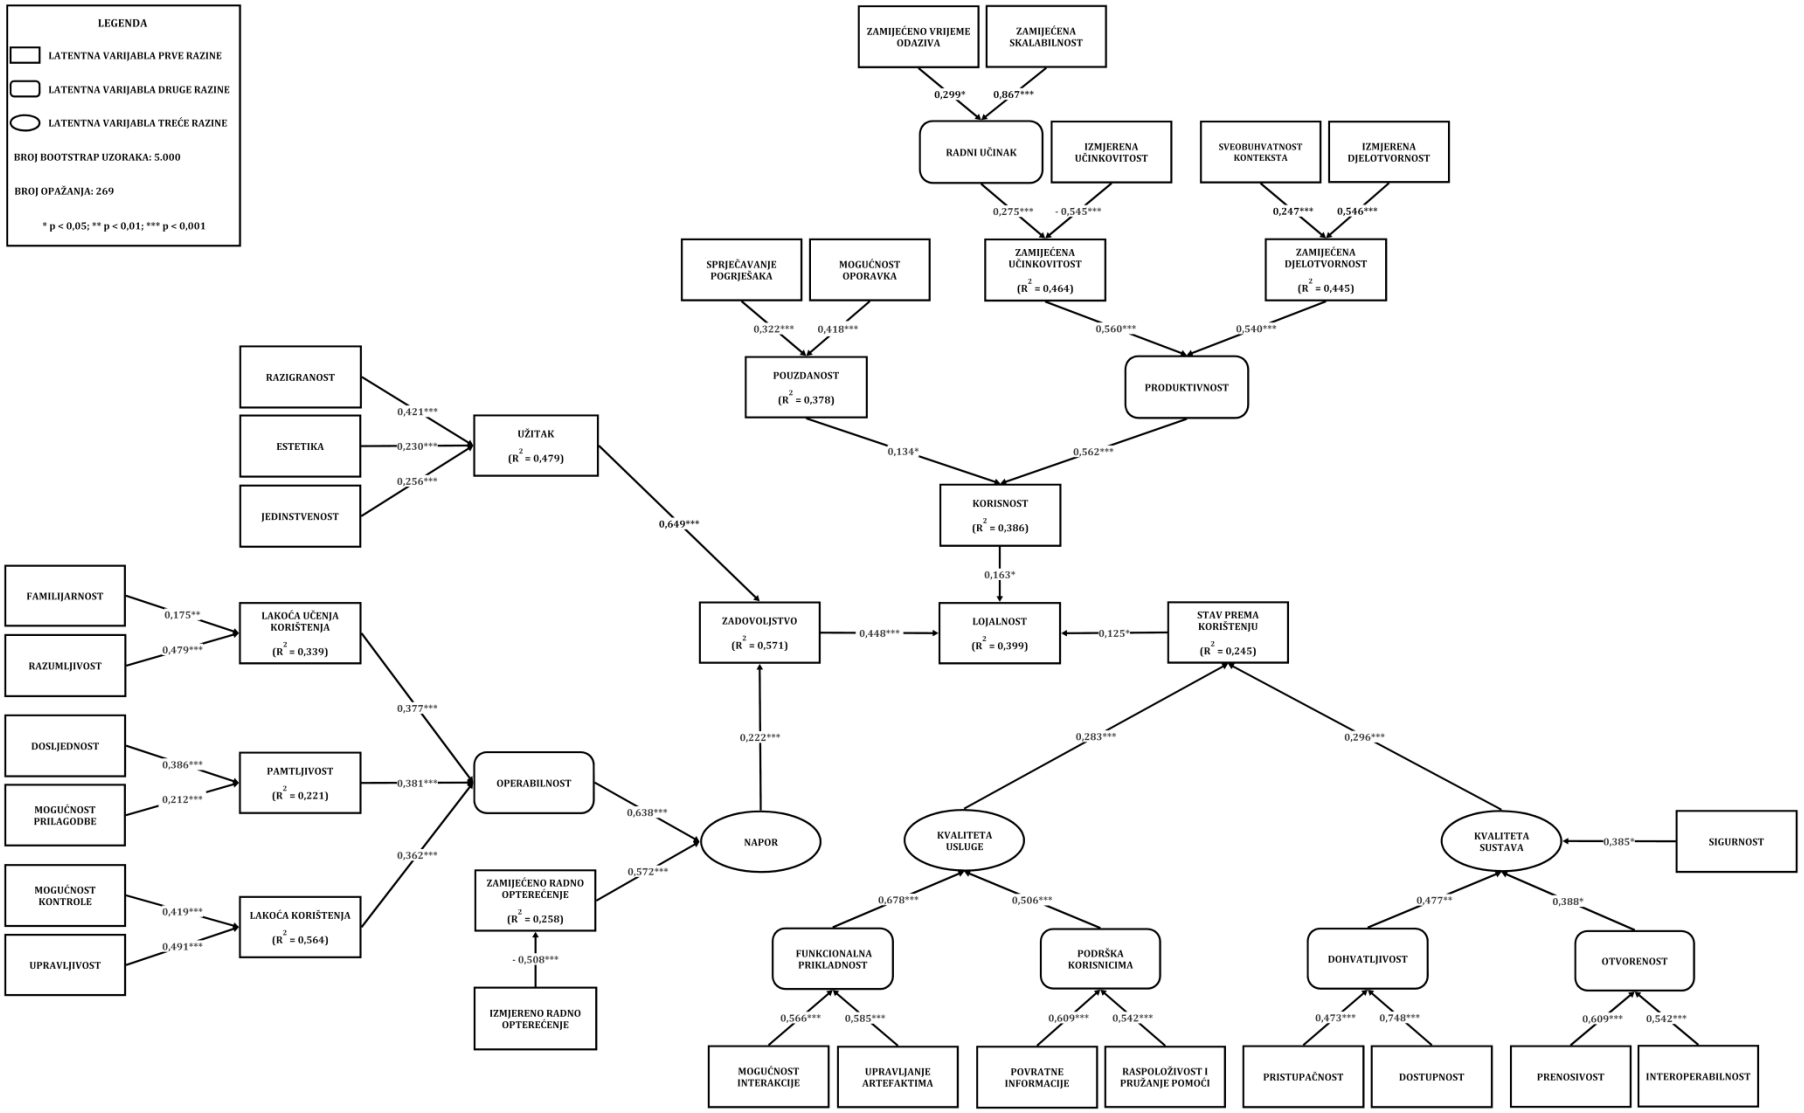

Slika 6.28 Rezultati analize metrijskih karakteristika unutarnjeg modela u kontekstu vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping

U tablici 6.120 i na slici 6.28 je prikazana struktura koeficijenata puta sa naznačenim razinama značajnosti. Kroz analizu spomenute strukture utvrđeno je da je 82,98% vrijednosti koeficijenata puta značajno na razini $\alpha = 0{,}001$, 4,25% ih je značajno na razini $\alpha = 0{,}01$ dok je 12,77% vrijednosti koeficijenata puta značajno na razini $\alpha = 0{,}05$. Shodno tome, sve su pothipoteze $H_{1.1}$-$H_{1.25}$ u kontekstu konceptualnog modela vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping potvrđene.

Ukoliko se višedimenzionalni konceptualni model promotri u cjelini tada je na prvoj razini nezavisnih latentnih konstrukata potrebno izdvojiti atribut pomoću kojeg je vrjednovana razumljivost aplikacije Wise Mapping ($\beta = 0{,}479$; $p < 0{,}001$) jer isti ima značajniji utjecaj na lakoću učenja korištenja aplikacijom Wise Mapping od atributa kojim je vrjednovana familijarnost aplikacije Wise Mapping ($\beta = 0{,}175$; $p < 0{,}01$). Osim toga, na prvoj je razini potrebno još spomenuti reflektivni latentni konstrukt kojim je vrjednovano zadovoljstvo korisnika ($\beta = 0{,}447$; $p < 0{,}001$) zbog toga što ima veću značajnost u oblikovanju lojalnosti korisnika od konstrukta pomoću kojeg su vrjednovani aspekti korisnosti aplikacije Wise Mapping ($\beta = 0{,}163$; $p < 0{,}05$) ili konstrukta primjenom kojeg je vrjednovan stav prema korištenju aplikacijom Wise Mapping ($\beta = 0{,}125$; $p < 0{,}05$). U kontekstu povezanosti latentnih konstrukata nižih i viših razina konceptualnog modela potrebno je spomenuti formativni latentni konstrukt druge razine pomoću kojeg su vrjednovane različite dimenzije dohvatljivosti aplikacije Wise Mapping ($\beta = 0{,}477$; $p < 0{,}01$) iz razloga što isti u značajnijoj mjeri doprinosi kvaliteti sustava aplikacije Wise Mapping od konstrukata primjenom kojih su mjereni aspekti otvorenosti ($\beta = 0{,}388$; $p < 0{,}05$) i sigurnosti ($\beta = 0{,}385$; $p < 0{,}05$) aplikacije Wise Mapping. Pored navedenog, potrebno je još napomenuti da atribut kojim je vrjednovana zamijećena skalabilnost ($\beta = 0{,}867$; $p < 0{,}001$) u značajnijoj mjeri doprinosi mjerenju radnog učinka od atributa kojim je vrjednovano zamijećeno vrijeme odaziva ($\beta = 0{,}299$; $p < 0{,}05$) aplikacije Wise Mapping. Naposljetku, reflektivni latentni konstrukt kojim je vrjednovana produktivnost korisnika ($\beta = 0{,}562$; $p < 0{,}001$) je značajniji prediktor korisnosti aplikacije Wise Mapping od atributa pomoću kojeg je mjerena pouzdanost ($\beta = 0{,}134$; $p < 0{,}05$) aplikacije Wise Mapping.

Rezultati analize koeficijenata puta koji povezuju latentne konstrukte namijenjene vrjednovanju objektivnih i subjektivnih dimenzija identičnog atributa kvalitete u korištenju pokazali su da povećanjem broja reprezentativnih koraka koje je moguće dovršiti primjenom aplikacije Wise Mapping dolazi do značajnog povećanja ($\beta = 0{,}546$; $p < 0{,}001$) zamijećene djelotvornosti korisnika. Pored toga utvrđeno je da povećanje količine vremena potrebnog za dovršavanje reprezentativnih koraka scenarija interakcije sa aplikacijom Wise Mapping dovodi do značajnog smanjenja ($\beta = -0{,}545$; $p < 0{,}001$) zamijećene učinkovitosti korisnika. Konačno, pronađeno je da povećanje broja klikova mišem, broja pritisnutih tipaka na tipkovnici, udaljenosti prijeđene

pomicanjem miša i broja pomicanja klizača na mišu kod dovršavanja reprezentativnih koraka scenarija upotrebom aplikacije Wise Mapping rezultira značajnim povećanjem ($\beta = -0{,}508;\ p < 0{,}001$) zamijećenog radnog opterećenja korisnika.

Tablica 6.120 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	Originalan uzorak (OU)	**Srednja vrijednost uzorka ($\bar{x}$)**	**Standardna pogrješka (σ)**	**T statistika ($\lvert OU/\sigma \rvert$)**
DHV -> KVS	0,477	0,486	0,155	3,089**
DSD -> PMT	0,386	0,388	0,064	6,049***
DST -> DHV	0,748	0,749	0,044	16,893***
EST -> UTK	0,230	0,232	0,050	4,650***
FML -> LUK	0,175	0,178	0,060	2,934**
FUP -> KVU	0,678	0,670	0,138	4,903***
INT -> OTV	0,542	0,548	0,061	8,968***
IRO -> ZRO	-0,508	-0,523	0,054	9,467***
IZD -> ZAD	0,546	0,546	0,051	10,711***
IZU -> ZAU	-0,545	-0,545	0,057	9,570***
JDN -> UTK	0,256	0,253	0,055	4,670***
KRS -> LOJ	0,163	0,163	0,064	2,544*
KVS -> SPK	0,296	0,300	0,066	4,506***
KVU -> SPK	0,283	0,290	0,068	4,158***
LAK -> OPR	0,362	0,362	0,006	56,234***
LUK -> OPR	0,377	0,377	0,007	52,047***
MIN -> FUP	0,566	0,559	0,065	8,682***
MOK -> LAK	0,419	0,417	0,045	9,292***
MOP -> PZD	0,418	0,419	0,059	7,076***
MPR -> PMT	0,212	0,223	0,053	4,013***
NPR -> ZDV	0,222	0,218	0,050	4,401***
OPR -> NPR	0,638	0,637	0,028	23,115***
OTV -> KVS	0,388	0,394	0,161	2,417*
PDK -> KRS	0,562	0,563	0,051	11,015***
PIN -> POK	0,609	0,604	0,070	8,648***
PMT -> OPR	0,381	0,381	0,008	50,674***
PNS -> OTV	0,609	0,598	0,062	9,888***
POK -> KVU	0,506	0,499	0,148	3,414***
PST -> DHV	0,473	0,463	0,056	8,406***
PZD -> KRS	0,134	0,134	0,057	2,366*
RAU -> ZAU	0,275	0,277	0,056	4,906***
RIP -> POK	0,542	0,537	0,073	7,479***
RZG -> UTK	0,421	0,421	0,062	6,817***
RZM -> LUK	0,479	0,478	0,054	8,833***

* p < 0,05; ** p < 0,01; *** p < 0,001

Tablica 6.120 Značajnost standardiziranih koeficijenata puta u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping (nastavak)

	Originalan uzorak (OU)	Srednja vrijednost uzorka ($\bar{x}$)	Standardna pogrješka (σ)	T statistika ($\|OU/\sigma\|$)
SGR -> KVS	0,385	0,339	0,159	2,415*
SPK -> LOJ	0,125	0,127	0,056	2,256*
SPO -> PZD	0,322	0,326	0,056	5,735***
SVK -> ZAD	0,247	0,255	0,054	4,558***
UPA -> FUP	0,585	0,583	0,060	9,764***
UPR -> LAK	0,491	0,497	0,047	10,373***
UTK -> ZDV	0,649	0,648	0,045	14,425***
ZAD -> PDK	0,540	0,540	0,010	53,930***
ZAS -> RAU	0,867	0,873	0,087	9,978***
ZAU -> PDK	0,560	0,559	0,012	47,433***
ZDV -> LOJ	0,448	0,451	0,074	6,044***
ZRO -> NPR	0,572	0,572	0,018	32,326***
ZVO -> RAU	0,299	0,268	0,137	2,191*

* p < 0,05; *** p < 0,001

Rezultati vrjednovanja veličine utjecaja i prediktivne valjanosti nezavisnih varijabli u konceptualnom modelu vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping nalaze se u tablici 6.121. Iz spomenute je tablice vidljivo da 60,71% nezavisnih varijabli ima mali utjecaj, 17,86% ih ima srednji utjecaj, a 21,43% ih ima veliki utjecaj na zavisne varijable. U skupini nezavisnih varijabli sa malim utjecajem najmanju razinu ($f^2 = 0{,}02$) istog ima reflektivni latentni konstrukt kojim je vrjednovan stav prema korištenju aplikacijom Wise Mapping dok najveći stupanj utjecaja ($f^2 = 0{,}14$) unutar skupine ima formativni latentni konstrukt kojim se provjeravalo do koje razine Wise Mapping sprječava nastanak pogrješaka u radu i indikator pomoću kojeg je izmjereno koliko su klikova mišem napravili korisnici tijekom dovršavanja reprezentativnih koraka scenarija interakcije sa aplikacijom Wise Mapping. Najmanju razinu utjecaja ($f^2 = 0{,}19$) u skupini nezavisnih varijabli sa srednjim utjecajem u konceptualnom modelu imaju atributi pomoću kojih su mjereni različiti aspekti dosljednosti aplikacije Wise Mapping i zadovoljstva korisnika dok najveći stupanj utjecaja ($f^2 = 0{,}27$) unutar skupine ima atribut kojim je vrjednovana razumljivost aplikacije Wise Mapping. Od nezavisnih varijabli sa velikim utjecajem u konceptualnom modelu potrebno je spomenuti atribut kojim je utvrđeno do koje mjere korisnici imaju kontrolu nad načinom upotrebe aplikacije Wise Mapping jer ima najmanji stupanj utjecaja ($f^2 = 0{,}35$) u skupini i atribut čijim je manifestnim varijablama mjeren užitak korištenja aplikacijom Wise Mapping iz razloga što ima najveću razinu utjecaja ($f^2 = 0{,}86$) u konceptualnom modelu.

Od ukupnog broja nezavisnih varijabli, 64,29% ih ima malu prediktivnu valjanost, 25% ih ima srednju prediktivnu valjanost, a 10,71% ih ima veliku prediktivnu valjanost. Najmanji stupanj prediktivne valjanosti ($q^2 = 0{,}01$) u skupini atributa sa malom prediktivnom valjanošću ima atribut kojim je vrjednovan stav prema korištenju aplikacijom Wise Mapping dok najveću razinu prediktivne valjanosti ($q^2 = 013$) unutar ove skupine ima atribut pomoću kojeg je mjereno zadovoljstvo korisnika. U skupini nezavisnih varijabli sa srednjom prediktivnom valjanošću, najmanju razinu ($q^2 = 0{,}16$) iste ima atribut kojim je vrjednovana dosljednost aplikacije Wise Mapping dok najveći stupanj ($q^2 = 0{,}29$) prediktivne valjanosti unutar ove skupine ima indikator pomoću kojeg je izmjereno koliko je vremena bilo potrebno korisnicima da dovrše reprezentativne korake scenarija interakcije sa aplikacijom Wise Mapping. Formativni latentni konstrukt pomoću kojeg su vrjednovane dimenzije produktivnosti korisnika ima najmanji stupanj ($q^2 = 0{,}35$) prediktivne valjanosti u skupini nezavisnih varijabli sa velikom prediktivnom valjanošću. Naposljetku, reflektivni latentni konstrukt primjenom kojeg je izmjeren užitak korištenja aplikacijom Wise Mapping ima najveću razinu ($q^2 = 0{,}60$) prediktivne valjanosti u konceptualnom modelu.

Uzimajući u obzir rezultate vrjednovanja metrijskih karakteristika koje se nalaze u tablicama 6.104-6.121, konceptualni model vrjednovanja kvalitete u korištenju aplikacijom Wise Mapping je pouzdan i valjan.

Tablica 6.121 Rezultati analize veličine utjecaja i prediktivne valjanosti egzogenih varijabli u kontekstu modeliranja kvalitete u korištenju aplikacijom Wise Mapping

	R_u^2	R_i^2	f^2	Q_u^2	Q_i^2	q^2
DSD -> PMT	0,221	0,076	0,19	0,189	0,061	0,16
EST -> UTK	0,479	0,431	0,09	0,392	0,359	0,05
FML -> LUK	0,339	0,315	0,04	0,301	0,276	0,04
IRO1 -> ZRO	0,258	0,222	0,05	0,201	0,174	0,03
IRO2 -> ZRO	0,258	0,189	0,09	0,201	0,147	0,07
IRO3 -> ZRO	0,258	0,151	0,14	0,201	0,117	0,10
IRO4 -> ZRO	0,258	0,212	0,06	0,201	0,167	0,04
IZD -> ZAD	0,445	0,177	0,48	0,315	0,125	0,28
IZU -> ZAU	0,464	0,198	0,50	0,334	0,141	0,29
JDN -> UTK	0,479	0,430	0,09	0,392	0,358	0,06
KRS -> LOJ	0,399	0,381	0,03	0,317	0,306	0,02
KVS -> SPK	0,245	0,175	0,09	0,206	0,151	0,07
KVU -> SPK	0,245	0,182	0,08	0,206	0,156	0,06
MOK -> LAK	0,564	0,411	0,35	0,487	0,354	0,26
MOP -> PZD	0,378	0,228	0,24	0,297	0,181	0,17
MPR -> PMT	0,221	0,177	0,06	0,189	0,148	0,05
NPR -> ZDV	0,571	0,528	0,10	0,480	0,445	0,07
PDK -> KRS	0,386	0,109	0,45	0,326	0,092	0,35
PZD -> KRS	0,386	0,370	0,03	0,326	0,314	0,02
RAU -> ZAU	0,464	0,397	0,13	0,334	0,287	0,07
RZG -> UTK	0,479	0,347	0,25	0,392	0,290	0,17
RZM -> LUK	0,339	0,160	0,27	0,301	0,142	0,23
SPK -> LOJ	0,399	0,388	0,02	0,317	0,312	0,01
SPO -> PZD	0,378	0,289	0,14	0,297	0,228	0,10
SVK -> ZAD	0,445	0,390	0,10	0,315	0,276	0,06
UPR -> LAK	0,564	0,355	0,48	0,487	0,307	0,35
UTK -> ZDV	0,571	0,201	0,86	0,480	0,170	0,60
ZDV -> LOJ	0,399	0,284	0,19	0,317	0,225	0,13

R^2– koeficijent determinacije
f^2 – koeficijent veličine utjecaja
Q^2 – Stone-Geisserov indeks unakrsno validirane redundance
q^2 – koeficijent prediktivne valjanosti

6.4.4 Rezultati vrjednovanja kvalitete u korištenju Web 2.0 aplikacija za izradu mentalnih mapa

Postupak izračuna vrijednosti elementarnih i globalnih preferencija kvalitete u korištenju Web 2.0 aplikacijama za izradu mentalnih mapa prikazan je u tablici 6.122. Iz vrijednosti globalnih preferencija je evidentno da Mindomo zadovoljava 62,98%, a Wise Mapping 49,02% svih zahtjeva vezanih uz kvalitetu u korištenju. Najveći doprinos (28,50%) razlici u vrijednostima kompozitnih indeksa kvalitete u korištenju među vrjednovanim Web 2.0 aplikacijama za izradu mentalnih mapa je dao podsustav varijabli performansi kojima se mjeri estetika (EST). Prema mišljenju korisnika Web 2.0 aplikacija Mindomo ima 33,55% ljepši izgled, 32,16% atraktivnije sučelje i 20,82% bolju usklađenost boja na sučelju od Web 2.0 aplikacije Wise Mapping. Sljedeći podsustav kvalitete u korištenju prema kojem se vrjednovane Web 2.0 aplikacije za izradu mentalnih mapa znatno (27,18%) razlikuju jest izmjerena učinkovitost (IZU). Naime, kada su korisnici upotrebljavali Mindomo bila im je u prosjeku potrebna 81 sekunda za dovršetak jednog reprezentativnog koraka scenarija čime je isti zadovoljio 62,29% zahtjeva izmjerene učinkovitosti. S druge strane, korisnicima je za dovršetak pojedinog reprezentativnog koraka scenarija bilo potrebno prosječno 98 sekundi kada su upotrebljavali Wise Mapping zbog čega je isti zadovoljio 35,11% zahtjeva izmjerene učinkovitosti. Nadalje, među Web 2.0 aplikacijama namijenjenih izradi mentalnih mapa utvrđena je velika razlika (24,80%) u razini zadovoljenja podsustava varijabli kojima se mjeri radno opterećenje (IRO). Konkretnije, tijekom interakcije sa Web 2.0 aplikacijom Mindomo korisnici su u prosjeku pomaknuli klizač na mišu 34,58% manji broj puta (IRO4), pritisnuli 29,81% manje tipaka na tipkovnici (IRO1), pomicanjem miša prošli 19,93% manju udaljenost (IRO2) i napravili 16,19% manje klikova mišem (IRO3) nego kada su upotrebljavali Web 2.0 aplikaciju Wise Mapping.

Kako su korisnici upotrebom Web 2.0 aplikacije Mindomo uspjeli u prosjeku dovršiti 31, a pomoću Web 2.0 aplikacije Wise Mapping prosječno 24 reprezentativna koraka scenarija, Mindomo je za 23,33% superiorniji od Wise Mapping u kontekstu zadovoljenja zahtjeva izmjerene djelotvornosti (IZD). Mindomo je također u većoj mjeri (16,82%) udovoljio zahtjevima podsustava varijabli performansi kojima se vrjednuju aspekti zadovoljstva korisnika. Prema mišljenju korisnika, Web 2.0 aplikacija Mindomo je za 18,49% bolje ispunila njihova očekivanja (ZDV1), za 16,92% bolje zadovoljila njihove potrebe (ZDV2) te ih se za 14,31% bolje dojmila (ZDV4) od Web 2.0 aplikacije Wise Mapping. Vrjednovane se Web 2.0 aplikacije za izradu mentalnih mapa međusobno značajno (16,54%) razlikuju i sa aspekta zadovoljenja podsustava varijabli performansi kojima se mjeri mogućnost interakcije (MIN). Naime, razina zadovoljenja zahtjeva kojim se utvrđuje da li Web 2.0 aplikacija raspolaže sa funkcionalnostima

koje omogućuju sinkronu komunikaciju među korisnicima (MIN7) je bila 36,99% veća kada su korisnici upotrebljavali Mindomo, stupanj zadovoljenja zahtjeva pomoću kojeg se provjerava da li Web 2.0 aplikacija ima implementirane funkcionalnosti asinkrone komunikacije među korisnicima (MIN8) je bio 19,52% manji kada su korisnici upotrebljavali Wise Mapping, razina zadovoljenja zahtjeva primjenom kojeg se utvrđuje da li Web 2.0 aplikacija omogućuje korisnicima da dodijele pristup kreiranim artefaktima preko liste kontakta (MIN1) je bila 13,29% veća u korist Web 2.0 aplikacije Mindomo, stupanj zadovoljenja zahtjeva kojim se provjerava da li Web 2.0 aplikacija podržava rad većeg broja korisnika na izradi artefakta (MIN2) je bio 8,36% manji u slučaju upotrebe Web 2.0 aplikacije Wise Mapping dok je razina zadovoljenja zahtjeva kojim se utvrđuje da li Web 2.0 omogućava dodjelu pristupa kreiranim artefaktima preko direktne poveznice bila 5,67% veća u kontekstu upotrebe Web 2.0 aplikacije Mindomo.

Velika razlika (15,19%) u vrijednostima elementarnih preferencija između vrjednovanih Web 2.0 aplikacija za izradu mentalnih mapa je identificirana i na razini podsustava varijabli performansi kojima se vrjednuje lojalnost (LOJ) korisnika. Naime, razina zadovoljenja zahtjeva koji se odnosi na namjeru daljnje upotrebe (LOJ1) je bila 17,29% veća u korist Web 2.0 aplikacije Mindomo, stupanj zadovoljenja zahtjeva vezanog uz namjeru davanja preporuke svakome kome je potreban programski proizvod namijenjen izradi mentalnih mapa (LOJ2) je bio 16,17% manji u kontekstu Web 2.0 aplikacije Wise Mapping, a razina zadovoljenja zahtjeva koji se odnosi na namjeru budućeg učestalog korištenja (LOJ3) je bila 12,17% veća u slučaju Web 2.0 aplikacije Mindomo. Analizom rezultata utvrđeno je i da su korisnici 14,67% više uživali (UTK) u interakciji sa Web 2.0 aplikacijom Mindomo od korištenja Web 2.0 aplikacijom Wise Mapping. Detaljnije, razina zadovoljenja zahtjeva kojim se mjeri zamijećena ugoda korištenja Web 2.0 aplikacijom (UTK4) je bila 12,36% manja kada su korisnici upotrebljavali Wise Mapping, stupanj zadovoljenja zahtjeva pomoću kojeg se utvrđuje razina do koje se korisnicima sviđa način izvršavanja zadataka pomoću funkcionalnih elemenata sučelja Web 2.0 aplikacije (UTK5) je bio 11,71% veći u korist Web 2.0 aplikacije Mindomo dok je razina zadovoljenja zahtjeva primjenom kojeg se mjeri razina do koje je korištenje Web 2.0 aplikacijom korisnicima zanimljivo (UTK2) bila 11,15% manja u slučaju upotrebe Web 2.0 aplikacije Wise Mapping. Spomenute znatne razlike u stupnjevima zadovoljenja zahtjeva kojima se vrjednuju dimenzije zadovoljstva (ZDV) i užitka (UTK) kao i nešto manja razlika (9,29%) u razini zadovoljenja zahtjeva pomoću kojih se vrjednuje napor (NPR) rezultirale su značajnom (14,76%) razlikom u stupnju zadovoljenja podsustava varijabli performansi primjenom kojih se mjeri zamijećeno zadovoljstvo (ZAZ*).

Razlika u razini zadovoljenja podsustava varijabli performansi kojima se vrjednuje pristupačnost (PST) Web 2.0 aplikacije je iznosila 14,45% pri čemu je stupanj zadovoljenja

zahtjeva kojim se provjerava da li Web 2.0 aplikacija sadrži popis tipkovničkih kratica za pokretanje često korištenih funkcionalnosti sučelja (PST1) bio 17,47% veći u korist Web 2.0 aplikacije Mindomo, razina zadovoljenja zahtjeva pomoću kojeg se utvrđuje da li su objekti sučelja Web 2.0 aplikacije dovoljno veliki (PST6) je bila 14,96% manja u kontekstu vrjednovanja Web 2.0 aplikacije Wise Mapping dok je stupanj zadovoljenja zahtjeva primjenom kojeg se utvrđuje da li je tekst koji opisuje funkcionalnosti pojedinih elemenata sučelja Web 2.0 aplikacije dovoljno velik za čitanje (PST4) bio 12,27% veći u slučaju interakcije sa Web 2.0 aplikacijom Mindomo. Od preostalih podsustava varijabli performansi u zadovoljenju čijih se zahtjeva vrjednovane Web 2.0 aplikacije za izradu mentalnih mapa uvelike razlikuju potrebno je još izdvojiti atribut kvalitete u korištenju kojim se vrjednuje raspoloživost i pružanje pomoći (RIP). Naime, razina zadovoljenja zahtjeva spomenutog atributa kvalitete u korištenju je bila 14,20% veća u korist Web 2.0 aplikacije Mindomo iz razloga što ista raspolaže sa sadržajima online pomoći koji su 16,64% pregledniji (RIP7), 14,78% jasniji (RIP5), 13,57% jednostavniji za pretraživanje (RIP6), 12,27% raznovrsniji (RIP1) i 11,34% dostupniji (RIP3) od sadržaja online pomoći koje nudi Web 2.0 aplikacija Wise Mapping. U suprotnosti sa dosad navedenim, vrjednovane Web 2.0 aplikacije za izradu mentalnih mapa se najmanje razlikuju u zadovoljenju zahtjeva definiranih sljedećim podsustavima varijabli performansi: sigurnost (SGR; 0,08%), zamijećena skalabilnost (ZAS; 0,17%), prenosivost (PNS; 1,27%), radni učinak (RAU; 1,57%), otvorenost (OTV; 1,96%), zamijećeno vrijeme odaziva (ZVO; 2,09%), sprječavanje pogrješaka (SPO; 2,70%), zamijećeno radno opterećenje (ZRO; 2,94%) i pouzdanost (PZD; 3,27%).

Ukoliko se u obzir uzmu svi podsustavi varijabli performansi namijenjeni vrjednovanju kvalitete u korištenju, Web 2.0 aplikacija Wise Mapping je bila bolja od Web 2.0 aplikacije Mindomo jedino u razini zadovoljenja tri zahtjeva. Naime, stupanj zadovoljenja zahtjeva prema kojem je tijekom izrade korisničkog računa potrebno unijeti CAPTCHA znakove (SGR3) je bio 16,82% veći kada su korisnici upotrebljavali Wise Mapping, razina zadovoljenja zahtjeva pomoću kojeg se provjerava da li Web 2.0 aplikacija podržava označavanje kreiranih artefakata pomoću tagova (UPA4) je bila 10,13% manja kada su korisnici upotrebljavali Mindomo dok je stupanj zadovoljenja zahtjeva pomoću kojeg se mjeri zamijećena količina artefakata koje je moguće pohraniti na Web 2.0 aplikaciji (ZAS1) bio 9,48% veći u korist Web 2.0 aplikacije Wise Mapping.

Tablica 6.122 Elementarne i globalne preferencije Web 2.0 aplikacija za izradu mentalnih mapa

X_i	W_i	Mindomo		Wise Mapping	
		E_i	E	E_i	E
Familijarnost (FML)			0,6648		0,6247
FML1	0,3141	0,6162		0,5567	
FML3	0,3362	0,6998		0,6691	
FML4	0,3497	0,6747		0,6431	
Razumljivost (RZM)			0,7568		0,7153
RZM2	0,3276	0,7398		0,6933	
RZM3	0,3363	0,7714		0,7230	
RZM4	0,3361	0,7602		0,7314	
Lakoća učenja korištenja (LUK)			0,7571		0,6974
LUK1	0,2961	0,7593		0,7017	
LUK2	0,3627	0,7472		0,6840	
LUK3	0,3412	0,7658		0,7082	
Dosljednost (DSD)			0,6997		0,6501
DSD2	0,3192	0,7026		0,6320	
DSD3	0,3609	0,7165		0,6738	
DSD4	0,3199	0,6822		0,6375	
Mogućnost prilagodbe (MPR)			0,6500		0,5646
MPR1	0,3665	0,8783		0,7407	
MPR2	0,3645	0,4749		0,4229	
MPR3	0,2690	0,5762		0,5167	
Pamtljivost (PMT)			0,7377		0,6756
PMT1	0,3721	0,7556		0,6803	
PMT2	0,3224	0,7509		0,7035	
PMT3	0,3055	0,7035		0,6422	
Mogućnost kontrole (MOK)			0,7189		0,6450
MOK1	0,3773	0,7333		0,6199	
MOK2	0,2911	0,6905		0,6608	
MOK3	0,3316	0,7184		0,6664	
Upravljivost (UPR)			0,6861		0,6037
UPR1	0,1912	0,6710		0,5260	
UPR3	0,2271	0,6682		0,6004	
UPR4	0,1768	0,7138		0,6831	
UPR5	0,1705	0,7017		0,6301	
UPR6	0,2344	0,6868		0,6236	
Lakoća korištenja (LAK)			0,7377		0,6155
LAK1	0,3316	0,7398		0,6190	
LAK2	0,3562	0,7398		0,6134	
LAK3	0,3122	0,7333		0,6143	

Tablica 6.122 Elementarne i globalne preferencije Web 2.0 aplikacija za izradu mentalnih mapa (nastavak)

X_i	W_i	Mindomo		Wise Mapping	
		E_i	E	E_i	E
Zamijećena lakoća učenja korištenja (ZLU*)			0,7440		0,6913
FML	0,1692	0,6648		0,6247	
RZM	0,2280	0,7568		0,7153	
LUK	0,6028	0,7571		0,6974	
Zamijećena pamtljivost (ZPM*)			0,7164		0,6539
DSD	0,2202	0,6997		0,6501	
MPR	0,1717	0,6500		0,5646	
PMT	0,6081	0,7377		0,6756	
Zamijećena lakoća korištenja (ZLK*)			0,7227		0,6190
MOK	0,2151	0,7189		0,6450	
UPR	0,1906	0,6861		0,6037	
LAK	0,5943	0,7377		0,6155	
Operabilnost (OPR)			0,7276		0,6524
ZLU*	0,3298	0,7440		0,6913	
ZPM*	0,3099	0,7164		0,6539	
ZLK*	0,3603	0,7227		0,6190	

* kompozitne varijable

Tablica 6.122 Elementarne i globalne preferencije Web 2.0 aplikacija za izradu mentalnih mapa (nastavak)

X_i	W_i	Mindomo		Wise Mapping	
		E_i	E	E_i	E
Razigranost (RZG)			0,6023		0,5160
RZG1	0,3630	0,6217		0,5279	
RZG5	0,3364	0,6022		0,5149	
RZG6	0,3006	0,5790		0,5028	
Estetika (EST)			0,7888		0,5038
EST2	0,3592	0,7900		0,5818	
EST4	0,3454	0,7770		0,4554	
EST5	0,2954	0,8011		0,4656	
Jedinstvenost (JDN)			0,6239		0,4874
JDN1	0,3632	0,6152		0,4610	
JDN2	0,2863	0,6022		0,5158	
JDN3	0,3505	0,6506		0,4916	
Užitak (UTK)			0,5874		0,4698
UTK2	0,3139	0,6013		0,4898	
UTK4	0,3596	0,5678		0,4442	
UTK5	0,3265	0,5957		0,4786	
Zadovoljstvo (ZDV)			0,6974		0,5292
ZDV1	0,3832	0,7091		0,5242	
ZDV2	0,3609	0,7054		0,5362	
ZDV4	0,2559	0,6701		0,5270	
Izmjereno radno opterećenje (IRO)			0,5016		0,2537
IRO1	0,2234	0,5393		0,2412	
IRO2	0,2697	0,4738		0,2745	
IRO3	0,2592	0,4551		0,2932	
IRO4	0,2477	0,5467		0,2009	
Zamijećeno radno opterećenje (ZRO)			0,5545		0,5251
ZRO1	0,3712	0,5177		0,4749	
ZRO2	0,3204	0,5344		0,5028	
ZRO3	0,3084	0,6199		0,6087	

Tablica 6.122 Elementarne i globalne preferencije Web 2.0 aplikacija za izradu mentalnih mapa (nastavak)

X_i	W_i	Mindomo		Wise Mapping	
		E_i	E	E_i	E
Zamijećen užitak (ZUT*)			0,6340		0,4873
RZG	0,1773	0,6023		0,5160	
EST	0,1881	0,7888		0,5038	
JDN	0,1668	0,6239		0,4874	
UTK	0,4678	0,5874		0,4698	
Radno opterećenje (ROP*)			0,5277		0,3873
IRO	0,5078	0,5016		0,2537	
ZRO	0,4922	0,5545		0,5251	
Napor (NPR)			0,6767		0,5839
OPR	0,5597	0,7276		0,6524	
ROP*	0,4403	0,5277		0,3873	
Zamijećeno zadovoljstvo (ZAZ*)			0,6823		0,5347
NPR	0,2205	0,6767		0,5839	
ZUT*	0,2026	0,6340		0,4873	
ZDV	0,5769	0,6974		0,5292	

* kompozitne varijable

Tablica 6.122 Elementarne i globalne preferencije Web 2.0 aplikacija za izradu mentalnih mapa (nastavak)

X_i	W_i	Mindomo		Wise Mapping	
		E_i	E	E_i	E
Zamijećeno vrijeme odaziva (ZVO)			0,8091		0,7881
ZVO2	0,3357	0,8002		0,7890	
ZVO3	0,3227	0,8123		0,7862	
ZVO4	0,3416	0,8151		0,7890	
Zamijećena skalabilnost (ZAS)			0,5938		0,5921
ZAS1	0,3425	0,5242		0,6190	
ZAS3	0,3312	0,6236		0,5874	
ZAS4	0,3263	0,6366		0,5688	
Zamijećena učinkovitost (ZAU)			0,6662		0,6057
ZAU1	0,3329	0,7026		0,6227	
ZAU3	0,3448	0,6552		0,6115	
ZAU4	0,3223	0,6422		0,5827	
Sveobuhvatnost konteksta (SVK)			0,6621		0,6198
SVK1	0,3327	0,6283		0,5678	
SVK2	0,3235	0,7407		0,7156	
SVK3	0,3438	0,6208		0,5799	
Zamijećena djelotvornost (ZAD)			0,6841		0,6091
ZAD2	0,3220	0,6701		0,6171	
ZAD3	0,3374	0,6914		0,6208	
ZAD4	0,3406	0,6905		0,5911	
Sprječavanje pogrješaka (SPO)			0,6663		0,6393
SPO1	0,3420	0,8141		0,7723	
SPO3	0,3337	0,8532		0,8104	
SPO4	0,3243	0,5297		0,5112	
Mogućnost oporavka (MOP)			0,7328		0,6858
MOP1	0,3238	0,7435		0,6822	
MOP2	0,3510	0,7714		0,7193	
MOP4	0,3252	0,6905		0,6589	
Pouzdanost (PZD)			0,7908		0,7581
PZD3	0,3128	0,7770		0,7407	
PZD4	0,3613	0,7835		0,7519	
PZD5	0,3259	0,8141		0,7844	
Korisnost (KRS)			0,6868		0,5966
KRS2	0,3508	0,6589		0,6097	
KRS3	0,3079	0,7063		0,5883	
KRS4	0,3413	0,6989		0,5911	

Tablica 6.122 Elementarne i globalne preferencije Web 2.0 aplikacija za izradu mentalnih mapa (nastavak)

X_i	W_i	Mindomo		Wise Mapping	
		E_i	E	E_i	E
Radni učinak (RAU)			0,7528		0,7371
ZVO	0,5395	0,8091		0,7881	
ZAS	0,4605	0,5938		0,5921	
Učinkovitost (UNK*)			0,6728		0,5501
RAU	0,2042	0,7528		0,7371	
IZU	0,2045	0,6229		0,3511	
ZAU	0,5913	0,6662		0,6057	
Djelotvornost (DTV*)			0,6602		0,5273
SVK	0,1706	0,6621		0,6198	
IZD	0,2091	0,6000		0,3667	
ZAD	0,6203	0,6841		0,6091	
Zamijećena pouzdanost (ZPD*)			0,7451		0,7106
SPO	0,2094	0,6663		0,6393	
MOP	0,2090	0,7328		0,6858	
PZD	0,5816	0,7908		0,7581	
Produktivnost (PDK)			0,6661		0,5379
UNK*	0,4706	0,6728		0,5501	
DTV*	0,5294	0,6602		0,5273	
Zamijećena korisnost (ZKS*)			0,6938		0,6033
ZPD*	0,2180	0,7451		0,7106	
PDK	0,2295	0,6661		0,5379	
KRS	0,5525	0,6868		0,5966	

* kompozitne varijable

Tablica 6.122 Elementarne i globalne preferencije Web 2.0 aplikacija za izradu mentalnih mapa (nastavak)

X_i	W_i	Mindomo		Wise Mapping	
		E_i	E	E_i	E
Mogućnost interakcije (MIN)			0,7115		0,5461
MIN1	0,1793	0,7286		0,5957	
MIN2	0,1978	0,8160		0,7593	
MIN5	0,2232	0,6171		0,5335	
MIN7	0,1928	0,6831		0,3132	
MIN8	0,2069	0,7249		0,5297	
Upravljanje artefaktima (UPA)			0,7519		0,6828
UPA2	0,2254	0,8216		0,7435	
UPA3	0,2094	0,7937		0,7091	
UPA4	0,1779	0,6087		0,7100	
UPA5	0,2102	0,8318		0,7193	
UPA7	0,1771	0,6626		0,5037	
Povratne informacije (PIN)			0,6108		0,5693
PIN1	0,1998	0,5716		0,5149	
PIN2	0,2050	0,5846		0,5493	
PIN3	0,1795	0,7203		0,6738	
PIN4	0,1847	0,6571		0,6190	
PIN6	0,2310	0,5846		0,5548	
Raspoloživost i pružanje pomoći (RIP)			0,6554		0,5134
RIP1	0,1990	0,6664		0,5437	
RIP3	0,1882	0,5901		0,4768	
RIP5	0,1987	0,6738		0,5260	
RIP6	0,2115	0,6394		0,5037	
RIP7	0,2026	0,6803		0,5139	
Funkcionalna prikladnost (FUP)			0,7319		0,6143
MIN	0,4903	0,7115		0,5461	
UPA	0,5097	0,7519		0,6828	
Podrška korisnicima (POK)			0,6311		0,5418
PIN	0,5308	0,6108		0,5693	
RIP	0,4692	0,6554		0,5134	
Kvaliteta usluge (KVU)			0,6557		0,5596
FUP	0,4817	0,7319		0,6143	
POK	0,5183	0,6311		0,5418	

Tablica 6.122 Elementarne i globalne preferencije Web 2.0 aplikacija za izradu mentalnih mapa (nastavak)

X_i	W_i	Mindomo		Wise Mapping	
		E_i	E	E_i	E
Pristupačnost (PST)			0,7961		0,6517
PST1	0,3411	0,7258		0,5511	
PST4	0,3395	0,8253		0,7026	
PST6	0,3194	0,8067		0,6571	
Dostupnost (DST)			0,8256		0,7279
DST1	0,3999	0,7983		0,7788	
DST4	0,3201	0,8866		0,8680	
DST5	0,2800	0,7862		0,3885	
Prenosivost (PNS)			0,6231		0,6104
PNS1	0,3243	0,6738		0,6664	
PNS2	0,3483	0,6162		0,6050	
PNS3	0,3274	0,5567		0,5335	
Interoperabilnost (INT)			0,7018		0,6602
INT1	0,3336	0,6859		0,6524	
INT2	0,3280	0,6134		0,5084	
INT3	0,3384	0,7175		0,6849	
Sigurnost (SGR)			0,6090		0,6082
SGR3	0,1657	0,4480		0,6162	
SGR4	0,1652	0,2807		0,2621	
SGR5	0,2093	0,7388		0,7546	
SGR6	0,2038	0,5948		0,5502	
SGR10	0,2560	0,7277		0,7156	
Dohvatljivost (DHV)			0,8116		0,6909
PST	0,4691	0,7961		0,6517	
DST	0,5309	0,8256		0,7279	
Otvorenost (OTV)			0,6422		0,6226
PNS	0,4951	0,6231		0,6104	
INT	0,5049	0,7018		0,6602	
Kvaliteta sustava (KVS)			0,6768		0,6376
DHV	0,3190	0,8116		0,6909	
OTV	0,2924	0,6422		0,6226	
SGR	0,3886	0,6090		0,6082	

Tablica 6.122 Elementarne i globalne preferencije Web 2.0 aplikacija za izradu mentalnih mapa (nastavak)

X_i	W_i	Mindomo		Wise Mapping	
		E_i	E	E_i	E
Stav prema korištenju (SPK)			0,7405		0,6058
SPK1	0,3231	0,7704		0,6180	
SPK2	0,3314	0,7277		0,6106	
SPK3	0,3455	0,7258		0,5901	
Lojalnost (LOJ)			0,4958		0,3439
LOJ1	0,3552	0,5130		0,3401	
LOJ2	0,3305	0,5428		0,3810	
LOJ3	0,3143	0,4349		0,3132	
Stav korisnika (STK*)			0,7033		0,6007
KVU	0,2452	0,6557		0,5596	
KVS	0,2301	0,6768		0,6376	
SPK	0,5247	0,7405		0,6058	
Kvaliteta u korištenju (KUK)			0,6298		0,4902
STK*	0,2336	0,7033		0,6007	
ZKS*	0,2591	0,6938		0,6033	
ZAZ*	0,2710	0,6823		0,5347	
LOJ	0,2363	0,4958		0,3439	

* kompozitne varijable

6.4.4.1 Prednosti Web 2.0 aplikacije Mindomo

Prema podacima prikupljenima od korisnika, aplikacija Mindomo je u najvećoj mjeri (82,56%) udovoljila podsustavu varijabli performansi pomoću kojih se mjeri dostupnost (DST) Web 2.0 aplikacije. Konkretnije, zahtjev koji se odnosi na jednostavnost pronalaska Web 2.0 aplikacije preko web tražilice (DST4) je zadovoljen 88,66%, zahtjev vezan uz mogućnost upotrebe Web 2.0 aplikacije svaki put kada je korisniku to potrebno (DST1) je zadovoljen 79,83%, dok je zahtjev koji se odnosi na mogućnost prijave postojećim (npr. Google, OpenID i sl.) korisničkim računom (DST5) zadovoljen 78,62%. Zamijećeno vrijeme odaziva (ZVO) je atribut kvalitete u korištenju čijim je zahtjevima aplikacija Mindomo također udovoljila u velikoj mjeri (80,91%). Naime, ista je zadovoljila 81,51% zahtjeva koji se odnosi na prihvatljivo vrijeme odaziva (ZVO4), 81,23% zahtjeva vezanog uz zamijećenu brzinu pokretanja odabranih funkcionalnosti sučelja (ZVO3) te 80,02% zahtjeva koji se odnosi na zamijećenu brzinu učitavanja radnog prostora i elemenata sučelja u web pregledniku (ZVO2). Uzimajući u obzir maločas navedene razine zadovoljenja zahtjeva kojima se mjere različiti aspekti zamijećenog vremena odaziva (ZVO) kao i osrednju razinu (59,38%) zadovoljenja zahtjeva namijenjenih vrjednovanju zamijećene skalabilnosti

(ZAS), aplikacija Mindomo je zadovoljila 75,28% zahtjeva podsustava varijabli performansi kojima se mjeri radni učinak (RAU).

Nadalje, aplikacija Mindomo je zadovoljila 79,61% varijabli performansi namijenjenih vrjednovanju pristupačnosti (PST) Web 2.0 aplikacije pri čemu je zahtjev vezan uz dostatnu veličinu teksta koji opisuje funkcionalnost pojedinih elemenata sučelja (PST4) zadovoljen 82,53%, zahtjev koji se odnosi na dostatnu veličinu elemenata sučelja (PST6) je zadovoljen 80,67% dok je zahtjev kojim se utvrđuje da li Web 2.0 aplikacija sadrži popis tipkovničkih kratica za pokretanje često korištenih funkcionalnosti sučelja (PST1) zadovoljen 72,58%. Obzirom da je aplikacija Mindomo u velikoj mjeri udovoljila zahtjevima dostupnosti (DST) i pristupačnosti (PST), ista je zadovoljila 81,16% zahtjeva definiranih varijablama performansi pomoću kojih se mjeri dohvatljivost (DHV) Web 2.0 aplikacije. Sljedeći atribut kvalitete u korištenju čijim je zahtjevima aplikacija Mindomo uvelike (79,08%) udovoljila je pouzdanost (PZD). Konkretnije, aplikacija Mindomo je zadovoljila 81,41% zahtjeva kojim se provjerava da li Web 2.0 aplikacija ima softverskih pogrješaka (PZD5), 78,35% zahtjeva pomoću kojeg se vrjednuje razina zamijećene stabilnosti Web 2.0 aplikacije (PZD4) i 77,70% zahtjeva primjenom kojeg se mjeri razina do koje korisnici smatraju da je Web 2.0 aplikacija pouzdana (PZD3). Uzimajući u obzir vrijednosti elementarnih preferencija zahtjeva kojima se vrjednuju različiti aspekti pouzdanosti (PZD; 79,08%), mogućnosti oporavka (MOP; 73,28%) i sprječavanja pogrješaka (SPO; 66,63%), aplikacija Mindomo je zadovoljila 74,51% svih zahtjeva definiranih kompozitnim podsustavom varijabli performansi pomoću kojih se mjeri zamijećena pouzdanost (ZPD*).

Aplikacija Mindomo je u dostatnoj mjeri (78,88%) udovoljila i varijablama performansi namijenjenim vrjednovanju estetike (EST) pri čemu je zahtjev kojim se utvrđuje da li Web 2.0 aplikacija lijepo izgleda (EST5) zadovoljen 80,11%, zahtjev pomoću kojeg se provjerava da li su boje koje prevladavaju na sučelju Web 2.0 aplikacije prikladno usklađene (EST2) je zadovoljen 79,00% dok je zahtjev primjenom kojeg se mjeri razina atraktivnosti sučelja Web 2.0 aplikacije (EST4) zadovoljen 77,70%. Sudeći prema rezultatima vrjednovanja, Web 2.0 aplikaciju Mindomo je lako naučiti upotrebljavati (LUK) jer je ista zadovoljila 75,71% zahtjeva namijenjenih vrjednovanju istoimenog atributa kvalitete u korištenju. Detaljnije, aplikacija Mindomo je zadovoljila 76,58% zahtjeva kojim se mjeri razina zamijećene jednostavnosti učenja korištenja funkcionalnostima sučelja Web 2.0 aplikacije (LUK3), 75,93% zahtjeva pomoću kojeg se utvrđuje razina do koje je jednostavno razviti vještinu korištenja Web 2.0 aplikacijom (LUK1) i 74,72% zahtjeva primjenom kojeg se mjeri razina zamijećene lakoće učenja izvršavanja zadataka pomoću Web 2.0 aplikacije (LUK2). Prihvatljive razine zadovoljenja zahtjeva namijenjenih vrjednovanju različitih dimenzija razumljivosti (RZM; 75,68%) i lakoće učenja korištenja (LUK;

75,71%) uspjele su kompenzirati osrednju razinu zadovoljenja zahtjeva namijenjenih vrjednovanju familijarnosti (FML; 66,48%) Web 2.0 aplikacije čime je aplikacija Mindomo zadovoljila 74,40% zahtjeva kompozitnog podsustava varijabli performansi primjenom kojih se vrjednuje zamijećena lakoća učenja korištenja (ZLU*) Web 2.0 aplikacijom.

Elementarna preferencija atributa kojim se vrjednuje razumljivost (RZM) je u kontekstu Web 2.0 aplikacije Mindomo poprimila vrijednost 75,68% iz razloga što je ista zadovoljila 77,14% zahtjeva pomoću kojeg se utvrđuje razina usklađenosti izgleda i namjene ikona (RZM3), 76,02% zahtjeva kojim se mjeri stupanj usklađenosti naziva funkcionalnih elemenata sučelja Web 2.0 aplikacije i konteksta njihove upotrebe (RZM4) te 73,98% zahtjeva kojim se vrjednuje razina zamijećene razumljivosti funkcionalnosti elemenata sučelja Web 2.0 aplikacije (RZM2). Od ostalih atributa kvalitete u korištenju čijim je zahtjevima aplikacija Mindomo udovoljila u prihvatljivoj mjeri (75,19%) potrebno je još spomenuti podsustav varijabli performansi koje su namijenjene vrjednovanju različitih aspekata upravljanja artefaktima (UPA). Konkretnije, zahtjev kojim se utvrđuje da li Web 2.0 aplikacija ima implementiranu funkcionalnost automatske pohrane artefakta (UPA5) je zadovoljen 83,18%, zahtjev pomoću kojeg se provjerava da li Web 2.0 aplikacija omogućava dodjelu razina vidljivosti kreiranom artefaktu (UPA2) je zadovoljen 82,16%, zahtjev kojim se utvrđuje da li Web 2.0 aplikacija podržava dodjeljivanje dozvola nad kreiranim artefaktom (UPA3) je zadovoljen 79,37%, zahtjev primjenom kojeg se provjerava da li Web 2.0 aplikacija sadrži funkcionalnost slanja obavijesti o promjenama nad artefaktom (UPA7) je zadovoljen 66,26% dok je zahtjev kojim se utvrđuje da li Web 2.0 aplikacija dozvoljava označavanje kreiranih artefakta pomoću tagova (UPA4) zadovoljen 60,87%.

6.4.4.2 Nedostatci Web 2.0 aplikacije Mindomo

Uzimajući u obzir sve atribute kvalitete u korištenju, aplikacija Mindomo je u najmanjoj mjeri (49,58%) udovoljila podsustavu varijabli performansi pomoću kojih se vrjednuje lojalnost korisnika (LOJ). Naime, zahtjev vezan uz namjeru učestalog korištenja Web 2.0 aplikacijom (LOJ3) je zadovoljen 43,49%, zahtjev koji se odnosi na namjeru daljnjeg korištenja Web 2.0 aplikacijom (LOJ1) je zadovoljen 51,30%, a zahtjev vezan uz namjeru da se Web 2.0 aplikacija preporuči potencijalnim korisnicima (LOJ2) je zadovoljen 54,28%. Sljedeći atribut kvalitete u korištenju čijim je zahtjevima aplikacija Mindomo udovoljila u manjoj mjeri (50,16%) je izmjereno radno opterećenje (IRO). Konkretnije, zahtjev vezan uz broj klikova mišem (IRO3) je zadovoljen 45,51%, zahtjev koji se odnosi na udaljenost prijeđenu pomicanjem mišem (IRO2) je zadovoljen 47,38%, zahtjev vezan uz broj pritisnutih tipaka na tipkovnici (IRO1) je zadovoljen

53,93%, dok je zahtjev koji se odnosi na broj pomicanja klizača na mišu (IRO4) zadovoljen 54,67%. Elementarna preferencija zamijećenog radnog opterećenja (ZRO) je u slučaju vrjednovanja kvalitete u korištenju Web 2.0 aplikacijom Mindomo poprimila vrijednost 55,45% iz razloga što je ista zadovoljila 51,77% zahtjeva kojim se utvrđuje razina zamijećene iscrpljenosti nakon interakcije sa Web 2.0 aplikacijom (ZRO1), 53,44% zahtjeva pomoću kojeg se mjeri stupanj zamijećenog umora u očima po završetku upotrebe Web 2.0 aplikacije (ZRO2) i 61,99% zahtjeva primjenom kojeg se utvrđuje razina zamijećenog umora u prstima, zglobovima i mišićima ruku nakon korištenja Web 2.0 aplikacijom (ZRO3). Uzimajući u obzir razine zadovoljenja zahtjeva kojima su vrjednovani različiti aspekti izmjerenog radnog opterećenja (IRO) i zamijećenog radnog opterećenja (ZRO), aplikacija Mindomo je zadovoljila 52,77% svih zahtjeva kompozitnog podsustava varijabli performansi kojima se mjeri radno opterećenje korisnika (ROP*).

Iz rezultata vrjednovanja je također evidentno da je aplikacija Mindomo zadovoljila 58,74% zahtjeva varijabli performansi kojima se mjeri užitak (UTK) korištenja Web 2.0 aplikacijom. Konkretnije, zahtjev kojim se mjeri razina zamijećenog osjećaja ugode koji upotreba Web 2.0 aplikacije stvara korisnicima (UTK4) je zadovoljen 56,78%, zahtjev pomoću kojeg se mjeri stupanj do kojeg se izvršavanje zadataka pomoću funkcionalnosti korisničkog sučelja Web 2.0 aplikacije sviđa korisnicima (UTK5) je zadovoljen 59,57% dok je zahtjev primjenom kojeg se mjeri razina do koje je interakcija sa Web 2.0 aplikacijom korisnicima zanimljiva (UTK2) zadovoljen 60,13%. Zamijećena skalabilnost (ZAS) je atribut kvalitete u korištenju čijim je zahtjevima aplikacija Mindomo udovoljila u osrednjoj (59,38%) mjeri. Naime, zahtjev kojim se utvrđuje da li Web 2.0 aplikacija omogućava izvršavanje kompleksnih zadataka (ZAS4) je zadovoljen 63,66%, zahtjev pomoću kojeg se provjerava da li Web 2.0 aplikacija podržava istovremeni rad na većem broju zadataka (ZAS3) je zadovoljen 62,36%, dok je zahtjev kojim se utvrđuje da li Web 2.0 aplikacija omogućava pohranu velike količine artefakata (ZAS1) zadovoljen 52,42%. Nadalje, aplikacija Mindomo je zadovoljila 60,00% zahtjeva pomoću kojeg se mjeri izmjerena djelotvornost (IZD) jer su korisnici njenom primjenom uspjeli dovršiti prosječno 31 od ukupno 43 reprezentativna koraka scenarija.

Razigranost (RZG) je atribut kvalitete u korištenju čija je elementarna preferencija u kontekstu vrjednovanja Web 2.0 aplikacije Mindomo poprimila vrijednost 60,23% zbog toga što je ista zadovoljila 57,90% zahtjeva kojim se provjerava da li upotreba Web 2.0 aplikacije potiče stvaralačku maštu korisnika (RZG6), 60,22% zahtjeva pomoću kojeg se utvrđuje da li upotreba Web 2.0 aplikacije potiče kreativnost korisnika (RZG5) i 62,17% zahtjeva primjenom kojeg se mjeri razina do koje upotreba Web 2.0 aplikacije uspješno zadržava pažnju korisnika dulje vrijeme (RZG1). Nadalje, aplikacija Mindomo je zadovoljila 60,90% zahtjeva definiranih

varijablama performansi pomoću kojih se mjeri sigurnost (SGR) Web 2.0 aplikacije. Naime, zahtjev prema kojem je kod izrade korisničkog računa potrebno definirati sigurnosno pitanje i odgovor (SGR4) je zadovoljen 28,07%, zahtjev prema kojem je tijekom kreiranja korisničkog računa potrebno unijeti CAPTCHA znakove (SGR3) je zadovoljen 44,80%, zahtjev prema kojem je za vrijeme otvaranja korisničkog računa potrebno unijeti lozinku koja sadrži minimalan broj znakova (SGR6) je zadovoljen 59,48%, zahtjev pomoću kojeg se provjerava da li su artefakti koji nastanu korištenjem Web 2.0 aplikacijom zaštićeni od neautoriziranih korisnika (SGR10) je zadovoljen 72,77% dok je zahtjev prema kojem je kod izrade korisničkog računa potrebno potvrditi prethodno unesenu lozinku (SGR5) zadovoljen 73,88%.

Sudeći prema rezultatima vrjednovanja, povratne informacije (PIN) koje aplikacija Mindomo pruža korisnicima su osrednje (61,08%) kvalitete. Naime, ista je zadovoljila 57,16% zahtjeva kojim se utvrđuje da li Web 2.0 aplikacija obavještava korisnika kada će pojedina aktivnost biti izvršena (PIN1), 58,46% zahtjeva kojim se utvrđuje da li Web 2.0 aplikacija nakon provedbe određenih aktivnosti nad artefaktom (npr. pohrana) prikazuje prikladnu povratnu poruku (PIN2), 58,46% zahtjeva kojim se provjerava da li Web 2.0 aplikacija pravovremeno obavještava korisnike o pogrješkama ili prekidima u radu (PIN6), 65,71% zahtjeva pomoću kojeg se mjeri zamijećena preciznost poruka koje prikazuje Web 2.0 aplikacija (PIN6) i 72,03% zahtjeva primjenom kojeg se mjeri zamijećena jasnoća poruka koje prikazuje Web 2.0 aplikacija. Konačno, korisnicima je u prosjeku bilo potrebno 98 sekundi da dovrše jedan reprezentativan korak scenarija kada su upotrebljavali Web 2.0 aplikaciju Mindomo čime je ista zadovoljila 62,29% zahtjeva izmjerene učinkovitosti (IZU).

6.4.4.3 Prednosti Web 2.0 aplikacije Wise Mapping

Promatrajući zasebno Web 2.0 aplikaciju Wise Mapping utvrđeno je da ista u najvećoj mjeri (78,81%) udovoljava zahtjevima zamijećenog vremena odaziva (ZVO) gdje je zahtjev kojim se mjeri razina zamijećene brzine učitavanja radnog prostora i elemenata sučelja Web 2.0 aplikacije u web pregledniku (ZVO2) zadovoljen 78,90%, zahtjev pomoću kojeg se provjerava da li je zamijećeno vrijeme odaziva Web 2.0 aplikacije prihvatljivo je zadovoljen 78,90%, a zahtjev primjenom kojeg se mjeri zamijećeno vrijeme čekanja do pokretanja i izvršavanja odabranih funkcionalnosti sučelja Web 2.0 aplikacije je zadovoljen 78,62%. Visoka razina zadovoljenja zahtjeva kojima se vrjednuje zamijećeno vrijeme odaziva (ZVO) je kompenzirala osrednju razinu (59,21%) zadovoljenja zahtjeva zamijećene skalabilnosti (ZAS) zbog čega je aplikacija Wise Mapping zadovoljila 73,71% svih zahtjeva podsustava varijabli performansi pomoću kojih se mjeri radni učinak (RAU). Pouzdanost se također ubraja među prednosti Web 2.0 aplikacije Wise

Mapping jer je ista zadovoljila 75,81% zahtjeva definiranih ovim atributom kvalitete u korištenju. Konkretnije, aplikacija Wise Mapping je zadovoljila 78,44% zahtjeva pomoću kojeg se provjerava da li Web 2.0 aplikacija ima softverskih pogrješaka (PZD5), 75,19% zahtjeva kojim se mjeri razina zamijećene stabilnosti Web 2.0 aplikacije (PZD4) i 74,07% zahtjeva primjenom kojeg se utvrđuje razina do koje korisnici smatraju da je Web 2.0 aplikacija pouzdana.

Sljedeći atribut kvalitete u korištenju čijim je zahtjevima aplikacija Wise Mapping udovoljila u dostatnoj mjeri (72,79%) je dostupnost (DST). Naime, zahtjev kojim se provjerava da li je Web 2.0 aplikaciju jednostavno pronaći preko web tražilice (DST4) je zadovoljen 86,80%, zahtjev pomoću kojeg se utvrđuje do koje je razine Web 2.0 aplikacija dostupna svaki put kada je korisnicima to potrebno (DST1) je zadovoljen 77,88%, a zahtjev primjenom kojeg se provjerava da li Web 2.0 aplikacija omogućuje prijavu sa postojećim (npr. OpenID) korisničkim računom (DST5) je zadovoljen 38,85%. Uzimajući u obzir maločas spomenute visoke razine zadovoljenja zahtjeva kojima se mjeri dostupnost (DST) kao i osrednju razinu (65,17%) zadovoljenja zahtjeva kojima se vrjednuje pristupačnost (PST), Web 2.0 aplikacija Wise Mapping je zadovoljila 69,09% zahtjeva podsustava varijabli performansi primjenom kojih se vrjednuje dohvatljivost (DHV).

Elementarna preferencija atributa kojim se vrjednuje razumljivost (RZM) je u kontekstu Web 2.0 aplikacije Wise Mapping poprimila vrijednost 71,53% iz razloga što je ista zadovoljila 73,14% zahtjeva kojim se provjerava da li naziv funkcionalnih elemenata sučelja Web 2.0 aplikacije odgovara kontekstu njihove upotrebe (RZM4), 72,30% zahtjeva pomoću kojeg se utvrđuje do koje je razine izgled ikona usklađen sa njihovom namjenom (RZM3) i 69,33% zahtjeva primjenom kojeg se vrjednuje zamijećena razumljivost funkcionalnosti sučelja Web 2.0 aplikacije (RZM2). Nadalje, aplikacija Wise Mapping je zadovoljila 69,74% zahtjeva varijabli performansi kojima se vrjednuje lakoća učenja korištenja (LUK) gdje je zahtjev pomoću kojeg se mjeri zamijećena brzina učenja korištenja funkcionalnostima sučelja Web 2.0 aplikacije (LUK3) zadovoljen 70,82%, zahtjev primjenom kojeg se utvrđuje razina do koje je jednostavno postati vješt u korištenju Web 2.0 aplikacijom (LUK1) je zadovoljen 70,17%, a zahtjev kojim se vrjednuje zamijećena lakoća učenja izvršavanja zadataka pomoću Web 2.0 aplikacije (LUK2) je zadovoljen 68,40%. Uzimajući u obzir navedene razine zadovoljenja zahtjeva kojima su se vrjednovali aspekti razumljivosti (RZM) i lakoće učenja korištenja (LUK) kao i osrednju razinu (62,47%) zadovoljenja zahtjeva pomoću kojih se vrjednovala familijarnost (FML), aplikacija Wise Mapping je zadovoljila 69,13% zahtjeva definiranih kompozitnim podsustavom varijabli performansi pomoću kojih se mjeri zamijećena lakoća učenja korištenja (ZLU*) Web 2.0 aplikacijom.

Mogućnost oporavka (MOP) se također ubraja među prednosti Web 2.0 aplikacije Wise Mapping jer je ista zadovoljila 68,58% zahtjeva definiranih ovim podsustavom varijabli performansi. Konkretnije, aplikacija Wise Mapping je zadovoljila 71,93% zahtjeva kojim se provjerava da li u slučaju nastanka pogrješke ili prekida u radu Web 2.0 aplikacije korisnik gubi sav posao koji je do tada napravio (MOP2), 68,22% zahtjeva pomoću kojeg se utvrđuje da li u slučaju nastanka pogrješke ili prekida u radu Web 2.0 aplikacija nakon ponovnog učitavanja prikazuje oporavljenju verziju artefakta (MOP1) i 65,89% zahtjeva primjenom kojeg se mjeri stupanj zamijećene brzine oporavka od pogrješke ili prekida u radu. Visoka razina zadovoljenja zahtjeva kojima se mjere aspekti pouzdanosti (PZD; 75,81%) je zajedno sa osrednjim stupnjevima zadovoljenja zahtjeva pomoću kojih se vrjednuju mogućnost oporavka (MOP; 68,58%) i sprječavanje pogrješaka (SPO; 63,93) u kontekstu vrjednovanja kvalitete u korištenju Web 2.0 aplikacije Wise Mapping rezultirala visokom razinom (71,06%) zadovoljenja zahtjeva kompozitnog podsustava varijabli performansi primjenom kojih se vrjednuje zamijećena pouzdanost (ZPD*).

Web 2.0 aplikacija Wise Mapping je na prihvatljivoj razini (68,28%) udovoljila i zahtjevima podsustava varijabli performansi kojima se vrjednuje upravljanje artefaktima (UPA). Naime, zahtjev pomoću kojeg se provjerava da li Web 2.0 aplikacija omogućava dodjelu razina vidljivosti kreiranom artefaktu (UPA2) je zadovoljen 74,35%, zahtjev primjenom kojeg se utvrđuje da li Web 2.0 aplikacija sadrži funkcionalnost automatske pohrane artefakta (UPA5) je zadovoljen 71,93%, zahtjev kojim se provjerava da li Web 2.0 aplikacija podržava označavanje kreiranih artefakata pomoću tagova (UPA4) je zadovoljen 71,00%, zahtjev pomoću kojeg se utvrđuje da li Web 2.0 aplikacija ima implementiranu funkcionalnost za dodjeljivanje dozvola nad kreiranim artefaktom (UPA3) je zadovoljen 70,91%, a zahtjev primjenom kojeg se utvrđuje da li Web 2.0 aplikacija sadrži funkcionalnost slanja obavijesti o promjenama nad artefaktom je zadovoljen 50,37%. Nadalje, aplikacija Wise Mapping je u znatnoj mjeri (67,56%) udovoljila i zahtjevima pamtljivosti (PMT) pri čemu je zahtjev kojim se mjeri razina do koje je lako zapamtiti gdje se nalaze pojedine funkcionalnosti sučelja Web 2.0 aplikacije (PMT2) zadovoljen 70,35%, zahtjev pomoću kojeg se provjerava u kojoj je mjeri jednostavno zapamtiti kako se upotrebljava Web 2.0 aplikacija (PMT1) je zadovoljen 68,03%, a zahtjev primjenom kojeg se utvrđuje razina do koje korisnici smatraju da će biti jednostavno prisjetiti se gdje se nalaze i kako se koriste funkcionalnosti sučelja Web 2.0 aplikacije čak i ako se ista neće dulje vrijeme upotrebljavati (PMT3) je zadovoljen 64,22%.

Od preostalih atributa kvalitete u korištenju koji odražavaju prednosti Web 2.0 aplikacije Wise Mapping potrebno je još izdvojiti interoperabilnost (INT). Naime, aplikacija Wise Mapping je zadovoljila 66,02% zahtjeva varijabli performansi spomenutog atributa kvalitete u korištenju pri

čemu je zahtjev kojim se provjerava da li je artefakte kreirane primjenom Web 2.0 aplikacije moguće pohraniti u formatima datoteka koji su korisnicima potrebni (INT3) zadovoljen 68,49%, zahtjev pomoću kojeg se utvrđuje da li kod preuzimanja i umetanja artefakta između Web 2.0 aplikacije i aplikacija koje korisnici redovito upotrebljavaju dolazi do promjene u strukturi artefakta (INT1) je zadovoljen 65,24%, a zahtjev primjenom kojeg se provjerava da li kod kopiranja artefakta između Web 2.0 aplikacije i aplikacija koje korisnici svakodnevno upotrebljavaju dolazi do promjene u strukturi artefakta (INT2) je zadovoljen 50,84%.

6.4.4.4 Nedostatci Web 2.0 aplikacije Wise Mapping

Analizom rezultata vrjednovanja utvrđeno je da Wise Mapping od svih podsustava varijabli performansi koje se nalaze u stablu zahtjeva kvalitete u korištenju Web 2.0 aplikacija u najmanjoj mjeri (25,37%) udovoljava zahtjevima atributa pomoću kojeg se vrjednuje izmjereno radno opterećenje (IRO). Naime, zahtjev vezan uz broj pomicanja klizača na mišu (IRO4) je zadovoljen 20,09%, zahtjev koji se odnosi na broj pritisnutih tipaka na tipkovnici (IRO1) je zadovoljen 24,12%, zahtjev vezan uz udaljenost prijeđenu pomicanjem miša (IRO2) je zadovoljen 27,45% dok je zahtjev koji se odnosi na broj klikova mišem (IRO3) zadovoljen 29,32%. Sljedeći kritični podsustav varijabli performansi u kontekstu vrjednovanja Web 2.0 aplikacije Wise Mapping je lojalnost (LOJ) iz razloga što je ista zadovoljila 34,39% zahtjeva definiranih varijablama performansi ovog atributa kvalitete u korištenju. Konkretnije, aplikacija Wise Mapping je zadovoljila 31,32% zahtjeva vezanog uz namjeru učestalog korištenja Web 2.0 aplikacijom u budućnosti (LOJ3), 34,01% zahtjeva koji se odnosi na namjeru daljnje upotrebe Web 2.0 aplikacije (LOJ1) te 38,10% zahtjeva vezanog uz namjeru da se Web 2.0 aplikacija preporuči svakome kome je potreban programski proizvod namijenjen izradi mentalnih mapa (LOJ2). Nadalje, aplikacija Wise Mapping je u nedovoljnoj mjeri (35,11%) udovoljila zahtjevu izmjerene učinkovitosti (IZU) iz razloga što je korisnicima za dovršavanje jednog reprezentativnog koraka scenarija primjenom ove Web 2.0 aplikacije u prosjeku bila potrebna 81 sekunda. U gotovo jednakoj mjeri (36,67%), aplikacija Wise Mapping je zadovoljila zahtjev izmjerene djelotvornosti (IZD) jer su korisnici kroz interakciju sa njom uspjeli dovršiti prosječno 24 od ukupno 43 reprezentativna koraka scenarija.

Sljedeći atribut kvalitete u korištenju čijim je zahtjevima aplikacija Wise Mapping udovoljila u maloj mjeri (46,98%) je užitak (UTK). Naime, zahtjev pomoću koje se vrjednuje razina zamijećene ugode koju upotreba Web 2.0 aplikacije pruža korisnicima (UTK4) je zadovoljen 44,42%, zahtjev kojim se mjeri stupanj sviđanja izvršavanja zadataka pomoću funkcionalnosti sučelja Web 2.0 aplikacije (UTK5) je zadovoljen 47,86%, a zahtjev primjenom kojeg se

provjerava do koje je mjere korisnicima zanimljivo upotrebljavati Web 2.0 aplikaciju (UTK2) je zadovoljen 48,98%. Jedinstvenost (JDN) je podsustav varijabli performansi čija je elementarna preferencija u kontekstu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijom Wise Mapping poprimila vrijednost 48,74% iz razloga što je ista zadovoljila 46,10% zahtjeva kojim se utvrđuje da li Web 2.0 aplikacija ima ono nešto po čemu se razlikuje od ostalih aplikacija (JDN1), 49,16% zahtjeva pomoću kojeg se provjerava da li se Web 2.0 aplikacija ističe u skupini aplikacija sa istom namjenom (JDN3) i 51,58% zahtjeva primjenom kojeg se vrjednuje razina generalne jedinstvenosti Web 2.0 aplikacije (JDN2).

Nadalje, aplikacija Wise Mapping je zadovoljila 50,38% zahtjeva varijabli performansi pomoću kojih se vrjednuje estetika (EST) Web 2.0 aplikacije pri čemu je zahtjev kojim se mjeri razina zamijećene atraktivnosti sučelja Web 2.0 aplikacije (EST4) zadovoljen 45,54%, zahtjev pomoću kojeg se utvrđuje razina do koje korisnici smatraju da Web 2.0 aplikacija lijepo izgleda (EST5) je zadovoljen 46,56%, a zahtjev primjenom kojeg se provjerava da li su boje koje prevladavaju na sučelju Web 2.0 aplikacije prikladno usklađene (EST2) je zadovoljen 58,18%.

Elementarna preferencija podsustava varijabli performansi primjenom kojih se mjeri raspoloživost i pružanje pomoći (RIP) je u kontekstu vrjednovanja Web 2.0 aplikacije Wise Mapping poprimila vrijednost 51,34% iz razloga što je ista zadovoljila 47,68% zahtjeva kojim se utvrđuje da li su različiti oblici pomoći korisnicima dostupni sa različitih dijelova Web 2.0 aplikacije (RIP3), 50,37% zahtjeva pomoću kojeg se provjerava da li je u sadržajima online pomoći moguće jednostavno i brzo pronaći kako se koriste pojedine funkcionalnosti Web 2.0 aplikacije (RIP6), 51,39% zahtjeva primjenom kojeg se vrjednuje preglednost sadržaja online pomoći (RIP7), 52,60% zahtjeva pomoću kojeg se mjeri jasnoća sadržaja online pomoći (RIP5) i 54,37% zahtjeva kojim se utvrđuje da li Web 2.0 aplikacija raspolaže sa različitim oblicima online pomoći korisnicima.

Osim navedenog, aplikacija Wise Mapping je zadovoljila 51,60% zahtjeva pomoću kojih se vrjednuje razigranost (RZG) korisnika tijekom interakcije sa Web 2.0 aplikacijom. Naime, aplikacija Wise Mapping je zadovoljila 50,28% zahtjeva pomoću kojeg se vrjednuje do koje mjere upotreba Web 2.0 aplikacije potiče stvaralačku maštu korisnika (RZG6), 51,49% zahtjeva kojim se mjeri do koje razine upotreba Web 2.0 aplikacije potiče kreativnost korisnika (RZG5) i 52,79% zahtjeva primjenom kojeg se provjerava do koje mjere upotreba Web 2.0 aplikacije uspješno zadržava pažnju korisnika dulje vrijeme (RZG1). Uzimajući u obzir razine zadovoljenja zahtjeva kojima se vrjednuju različiti aspekti užitka (UTK; 46,98%), jedinstvenosti (JDN; 48,74%), estetike (EST; 50,38%) i razigranosti (RZG; 51,60%), aplikacija Wise Mapping je

zadovoljila 46,98% zahtjeva kompozitnog podsustava varijabli performansi namijenjenih mjerenju zamijećenog užitka (ZUT*).

Od preostalih podsustava varijabli performansi koji odražavaju nedostatke Web 2.0 aplikacije Wise Mapping potrebno je još spomenuti zamijećeno radno opterećenje (ZRO) jer je ista zadovoljila 52,51% zahtjeva pomoću kojih se vrjednuju aspekti ovog atributa kvalitete u korištenju. Naime, aplikacija Wise Mapping je zadovoljila 47,49% zahtjeva kojim se mjeri razina zamijećene iscrpljenosti nakon korištenja Web 2.0 aplikacijom (ZRO1), 50,28% zahtjeva pomoću kojeg se utvrđuje razina zamijećenog umora u očima nakon upotrebe Web 2.0 aplikacije (ZRO2) i 60,87% zahtjeva primjenom kojeg se provjerava razina zamijećenog umora u prstima, zglobovima i mišićima ruku nakon interakcije sa Web 2.0 aplikacijom (ZRO3).

Uzimajući u obzir vrijednosti elementarnih preferencija izmjerenog radnog opterećenja (IZRO) i zamijećenog radnog opterećenja (ZRO), aplikacija Wise Mapping nije u dovoljno velikoj mjeri (38,73%) zadovoljila zahtjeve kompozitnog podsustava varijabli kojim se vrjednuje radno opterećenje korisnika (ROP*) kao posljedica upotrebe Web 2.0 aplikacije.

7. DISKUSIJA

Ovo je poglavlje posvećeno zbirnoj interpretaciji rezultata teorijskog i empirijskog dijela istraživanja. Najprije će kroz testiranje ciljeva i hipoteza istraživanja biti poopćeni pronalasci koji se odnose na identifikaciju i kategorizaciju atributa kvalitete u korištenju, razvijene metrike i mjerne instrumente, analizu metrijskih karakteristika konceptualnog modela te identifikaciju problema tijekom interakcije sa vrjednovanim Web 2.0 aplikacijama. Na osnovi analize rezultata istraživanja, u drugom je dijelu poglavlja predložen skup preporuka i smjernica koje se u obliku heuristika mogu primijeniti u različitim fazama životnog ciklusa Web 2.0 aplikacija.

7.1 Testiranje ciljeva i hipoteza istraživanja

Osnovna svrha doktorskog rada je bila razviti metodologiju koja će omogućiti da se primjenom subjektivnih i objektivnih mjernih instrumenata vrjednuju pragmatični i hedonistički aspekti kvalitete u korištenju Web 2.0 aplikacijama. Kao temeljne smjernice za razvoj metodologije poslužili su ciljevi i hipoteze koji su definirani na samom početku istraživanja. Prvi cilj istraživanja je bio sljedeći:

C_1: Identificirati i kategorizirati atribute kvalitete u korištenju Web 2.0 aplikacijama te razviti instrumente za njihovo mjerenje.

Put ka oblikovanju metodologije vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama započeo je pregledom literature koji je proveden u teorijskom dijelu ovog doktorskog rada. Isti se sastojao od detaljne analize recentnih i relevantnih istraživanja u području interakcije čovjeka i računala te web inženjerstva koja su se bavila razvojem metoda, tehnika, metodologija, standarda, instrumenata i smjernica namijenjenih vrjednovanju kvalitete, kvalitete u korištenju, upotrebljivosti, korisničkog iskustva, prihvaćanja i uspjeha različitih vrsta web mjesta uključujući web stranice, web informacijske sustave, web portale i Web 2.0 aplikacije. Temeljem rezultata analize literature i provedbe tri pilot istraživanja generirane su 263 manifestne varijable kojima je 29 stručnjaka domene (19 istraživača u području web inženjerstva i/ili interakcije čovjeka i računala te 10 web razvojnih inženjera) odredilo relativnu važnost u vrjednovanju kvalitete u korištenju Web 2.0 aplikacijama. Iz početnog skupa manifestnih varijabli izuzeto je 8 čestica za koje su stručnjaci domene utvrdili da su redundantne te 138 čestica koje nisu udovoljile kriteriju pokazatelja sadržajne valjanosti i/ili prosječne vrijednosti relativne važnosti. Osim toga, iz daljnje je procedure uklonjeno i 9 atributa kvalitete u korištenju (dodana vrijednost sadržaja, mogućnost pretraživanja, odupiranje promjenama, potpunost

sadržaja, pravovremenost sadržaja, reputacija, točnost sadržaja, utjecaj društva i vjerodostojnost sadržaja) jer nijedna manifestna varijabla namijenjena mjerenju njihovih aspekata nije udovoljila maločas spomenutim kriterijima sadržajne valjanosti.

U nastavku su stručnjaci domene preostale 123 manifestne varijable kategorizirali u 37 predefiniranih atributa kvalitete u korištenju (djelotvornost, dosljednost, dostupnost, estetika, familijarnost, interaktivnost, interoperabilnost, jedinstvenost, kompatibilnost, korisnost, lakoća korištenja, lakoća učenja korištenja, lojalnost, minimalna aktivnost, minimalno opterećenje memorije, mogućnost komunikacije, mogućnost kontrole, mogućnost oporavka, mogućnost prilagodbe, mogućnost suradnje, pamtljivost, pouzdanost, povratne informacije, pristupačnost, raspoloživost i pružanje pomoći, razigranost, razumljivost, sigurnost, skalabilnost, sprječavanje pogrješaka, stav prema ponašanju, sveobuhvatnost konteksta, učinkovitost, upravljivost, užitak, vrijeme odaziva i zadovoljstvo). Analiza rezultata kategorizacije pokazala je da su stručnjaci domene 89% manifestnih varijabli pridružili ispravnom atributu kvalitete u korištenju. Pored toga, utvrđeno je da vrijednost Congerovog Kappa koeficijenta iznosi $\hat{\kappa}_c = 0{,}8059$ što implicira izvrsno podudaranje među stručnjacima domene u kontekstu kategorizacije manifestnih varijabli.

Atributima čiji naziv nije bio usklađen sa aspektom kvalitete u korištenju kojeg vrjednuju, isti je promijenjen prema prijedlozima stručnjaka domene. Tako je atribut „kompatibilnost“ preimenovan u „prenosivost“, atribut „interaktivnost“ u „upravljanje artefaktima“, a atribut „stav prema ponašanju“ u „stav prema korištenju“. Jednako je tako atributima koje je moguće vrjednovati subjektivnim i objektivnim instrumentima u naziv dodana riječ „izmjereno/izmjerena“ ukoliko su dimenzije atributa mjerene indikatorima odnosno „zamijećeno/zamijećena“ ako su aspekti atributa vrjednovani česticama. Ovim je postupkom dobiveno šest novih atributa kvalitete u korištenju: zamijećena djelotvornost, izmjerena djelotvornost, zamijećena učinkovitost, izmjerena učinkovitost, zamijećena skalabilnost i zamijećeno vrijeme odaziva. Nadalje, teorijski srodni atributi kvalitete u korištenju kojima su kao posljedica vrjednovanja sadržajne valjanosti ostale pridružene dvije ili samo jedna čestica su spojeni u nove atribute kvalitete u korištenju. Tako su čestice namijenjene vrjednovanju atributa „minimalno opterećenje memorije“ i „minimalna aktivnost“ spojene u atribut „zamijećeno radno opterećenje“, indikatori namijenjeni mjerenju atributa „minimalna aktivnost“ su izdvojeni kao zaseban atribut pod nazivom „izmjereno radno opterećenje“ dok su čestice atributa „mogućnost komunikacije“ i „mogućnost suradnje“ spojene u atribut „mogućnost interakcije“. Naposljetku, indikatori koja su inicijalno bili namijenjeni vrjednovanju minimalne aktivnosti korisnika su izdvojeni kao zaseban atribut pod nazivom „izmjereno radno opterećenje“. Kao rezultat

provedbe metode zatvorenog sortiranja karata, 123 manifestne varijable su svrstane u 38 latentnih varijabli odnosno atributa kvalitete u korištenju.

Konačan skup od 123 sadržajno valjane manifestne varijable poslužio je oblikovanju mjernih instrumenata. Subjektivno vrjednovanje relevantnih aspekata kvalitete u korištenju Web 2.0 aplikacijama provedeno je primjenom online upitnika koji je bio sačinjen od 117 čestica dok su objektivne dimenzije djelotvornosti, radnog opterećenja i učinkovitosti korisnika tijekom interakcije sa Web 2.0 aplikacijom mjerene pomoću 6 indikatora. Podaci vezani uz učinkovitost i radno opterećenje korisnika prikupljeni su primjenom alata Mousotron koji je bilježio koliko je korisnicima bilo potrebno vremena, koliko su tipaka na tipkovnici trebali pritisnuti, koliko su klikova mišem trebali napraviti, koliku su udaljenost trebali prijeći pomicanjem mišem te koliko puta su trebali pomaknuti klizač na mišu kako bi upotrebom pojedine Web 2.0 aplikacije dovršili reprezentativne korake scenarija. Pored toga, podaci koji se odnose na djelotvornost korisnika prikupljeni su pomoću obrazaca sa popisom reprezentativnih koraka scenarija na kojima su korisnici pored svakog koraka naznačili u kojoj su ga mjeri uspjeli dovršiti pomoću određene Web 2.0 aplikacije.

U sljedećem je koraku istraživanja 14 stručnjaka domene (istraživača u području web inženjerstva i/ili interakcije čovjeka i računala) primjenom metode otvorenog sortiranja karata kategoriziralo 38 atributa kvalitete u korištenju. Podaci prikupljeni metodom otvorenog sortiranja karata analizirani su hijerarhijskom klaster analizom pomoću koje je identificirana struktura od 35 različitih klastera. Naposljetku je utvrđeno da svih 38 atributa kvalitete u korištenju udovoljava kriterijima sadržajne valjanosti. Pomoću svega navedenog **ostvaren je prvi cilj istraživanja**.

Drugi cilj istraživanja je bio logička posljedica prvog cilja istraživanja, a glasio je kako slijedi:

C_2: Izraditi konceptualni model i ispitati njegovu valjanost i pouzdanost.

Sa drugim ciljem istraživanja je usko povezana prva hipoteza koja je isti konkretizirala na sljedeći način:

H_1: Konceptualni model vrjednovanja Web 2.0 aplikacija, temeljen na subjektivnim i objektivnim atributima kvalitete u korištenju, je valjan i pouzdan.

Ishodi pregleda literature i hijerarhijske klaster analize poslužili su kao teorijsko uporište za oblikovanje konceptualnog modela vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama. Na prvoj razini konceptualnog modela se nalazi 38 atributa kvalitete u korištenju od čega ih je 19 (dosljednost, estetika, familijarnost, jedinstvenost, korisnost, lakoća korištenja, lakoća učenja

korištenja, lojalnost, mogućnost kontrole, pamtljivost, pouzdanost, razigranost, razumljivost, stav prema korištenju, užitak, zadovoljstvo, zamijećena djelotvornost, zamijećena učinkovitost i zamijećeno radno opterećenje) operacionalizirano reflektivno dok je preostalih 19 (dostupnost, interoperabilnost, izmjerena djelotvornost, izmjereno radno opterećenje, izmjerena učinkovitost, mogućnost interakcije, mogućnost oporavka, mogućnost prilagodbe, povratne informacije, prenosivost, pristupačnost, raspoloživost i pružanje pomoći, sigurnost, sprječavanje pogrješaka, sveobuhvatnost konteksta, upravljanje artefaktima, upravljivost, zamijećena skalabilnost i zamijećeno vrijeme odaziva) operacionalizirano formativno. Druga razina je sačinjena od 7 atributa kvalitete u korištenju pri čemu su 2 (operabilnost i produktivnost) operacionalizirana reflektivno dok ih je 5 (dohvatljivost, funkcionalna prikladnost, otvorenost, podrška korisnicima i radni učinak) operacionalizirano formativno.

Operabilnost Web 2.0 aplikacije je mjerena aspektima lakoće učenja korištenja, pamtljivosti i lakoće korištenja Web 2.0 aplikacijom dok je produktivnost korisnika vrjednovana dimenzijama zamijećene učinkovitosti i zamijećene djelotvornosti korisnika. Dohvatljivost Web 2.0 aplikacije je mjerena aspektima pristupačnosti i dostupnosti Web 2.0 aplikacije dok se vrjednovanje funkcionalne prikladnosti Web 2.0 aplikacije temeljilo na dimenzijama atributa pomoću kojih se utvrđuje do koje mjere Web 2.0 aplikacija podržava upravljanje artefaktima i interakciju među korisnicima. Otvorenost Web 2.0 aplikacije je mjerena aspektima prenosivosti i interoperabilnosti Web 2.0 aplikacije. Podrška korisnicima je vrjednovana aspektima atributa primjenom kojih se mjeri kvaliteta povratnih informacija i sadržaja pomoći koje Web 2.0 aplikacija pruža korisnicima. Radni učinak Web 2.0 aplikacije je mjeren dimenzijama zamijećenog vremena odaziva i zamijećene skalabilnosti Web 2.0 aplikacije.

Od 3 atributa kvalitete u korištenju koji se u konceptualnom modelu nalaze na trećoj razini, 1 (napor) je operacionaliziran reflektivno, a 2 (kvaliteta sustava i kvaliteta usluge) su operacionalizirana formativno. Napor kojeg korisnici trebaju uložiti u interakciju sa Web 2.0 aplikacijom je vrjednovan aspektima operabilnosti Web 2.0 aplikacije i zamijećenog radnog opterećenja korisnika, kvaliteta sustava Web 2.0 aplikacije je mjerena dimenzijama dohvatljivosti, otvorenosti i sigurnosti Web 2.0 aplikacije dok je kvaliteta usluge Web 2.0 aplikacije vrjednovana aspektima podrške koju Web 2.0 aplikacija pruža svojim korisnicima kao i aspektima funkcionalne prikladnosti Web 2.0 aplikacije.

Kako bi se testirale teorijske veze između nezavisnih i zavisnih latentnih konstrukata u unutarnjem modelu, hipoteza H_1 je dekomponirana na 25 pothipoteza ($H_{1.1}$-$H_{1.25}$). Metrijske karakteristike konceptualnog modela vrjednovane su metodom modeliranja strukturalnim jednadžbama baziranoj na varijanci odnosno katalogom kriterija (Chin, 1998) koji se

upotrebljava u analizi puta tehnikom parcijalnih najmanjih kvadrata. Analiza višedimenzionalnih latentnih konstrukata temeljila se na pristupu koji je kombinacija hibridnih oblika tehnike hijerarhijskih komponenti (Chin et al. 2003; Lohmöller, 1989; Wold, 1982; Ringle et al. 2012) i dvostupanjske tehnike (Ciavolino i Nitti, 2013; Henseler i Chin, 2010; Henseler i Fassott, 2010; Wilson i Henseler, 2007;). Vrjednovanje vanjskog reflektivnog, vanjskog formativnog i unutarnjeg modela provedeno je u alatu SmartPLS 2.0 M3 (Ringle et al., 2005).

Analizom pouzdanosti manifestnih varijabli započelo je vrjednovanje metrijskih karakteristika konceptualnog modela. Pouzdanost reflektivnih manifestnih varijabli vrjednovana je analizom vrijednosti njihovih standardiziranih faktorskih opterećenja. Iz tablica 6.41, 6.59, 6.86 i 6.104 je vidljivo da se vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli prve razine kreću u rasponu od 0,707 do 0,962 što znači da iste objašnjavaju između 50% i 92,54% varijance u reflektivnim latentnim konstruktima koji se u konceptualnom modelu nalaze na prvoj razini. Tablice 6.42, 6.60, 6.87 i 6.105 jasno prikazuju da se vrijednosti standardiziranih faktorskih opterećenja manifestnih varijabli druge razine nalaze u intervalu od 0,844 do 0,933 što ukazuje da iste objašnjavaju između 71,23% i 87,05% varijance u reflektivnim latentnim konstruktima druge razine konceptualnog modela. Konačno, u tablicama 6.43, 6.61, 6.88 i 6.106 se može vidjeti da se vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli treće razine nalaze u rasponu od 0,765 do 0,899 što implicira da iste objašnjavaju između 58,52% i 80,82% varijance u reflektivnim latentnim konstruktima treće razine. Prema tome, sve reflektivne manifestne varijable koje se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama su pouzdane.

Pouzdanost formativnih manifestnih varijabli vrjednovana je analizom značajnosti vrijednosti njihovih standardiziranih faktorskih opterećenja te analizom značajnosti njihovih težinskih vrijednosti. Iz tablica 6.44, 6.62, 6.89 i 6.107 je evidentno da je u prosjeku 89,84% vrijednosti standardiziranih faktorskih opterećenja formativnih manifestnih varijabli prve razine značajno na razini $\alpha = 0{,}001$, prosječno 5,86% ih je značajno na razini $\alpha = 0{,}01$, dok ih je u prosjeku 4,30% značajno na razini $\alpha = 0{,}05$. S druge strane, tablice 6.45, 6.63, 6.90 i 6.108 te tablice 6.46, 6.64, 6.91 i 6.109 jasno pokazuju da su vrijednosti svih standardiziranih faktorskih opterećenja na drugoj i trećoj razini u konceptualnom modelu, respektivno, značajne na razini $\alpha = 0{,}001$. Na osnovi podataka prikazanih u tablicama 6.47, 6.65, 6.92 i 6.110 utvrđeno je da je prosječno 92,97% težinskih vrijednosti formativnih manifestnih varijabli prve razine značajno na razini $\alpha = 0{,}001$, u prosjeku 4,30% ih je značajno na razini $\alpha = 0{,}01$ dok ih je prosječno 2,73% značajno na razini $\alpha = 0{,}05$. Iz podataka koji se nalaze u tablicama 6.48, 6.66, 6.93 i 6.111 proizlazi da je u prosjeku 86,36% težinskih vrijednosti formativnih manifestnih varijabli druge razine značajno na razini $\alpha = 0{,}001$, prosječno 4,55% ih je značajno na razini $\alpha = 0{,}01$ dok ih je

u prosjeku 9,09% značajno na razini $\alpha = 0{,}05$. Naposljetku, prema podacima prikazanim u tablicama 6.49, 6.67, 6.94 i 6.112, prosječno 50% težinskih vrijednosti formativnih manifestnih varijabli treće razine je značajno na razini $\alpha = 0{,}001$ dok ih je u prosjeku po 25% značajno na razinama $\alpha = 0{,}01$ i $\alpha = 0{,}05$. Uzimajući u obzir navedeno, sve formativne manifestne varijable koje se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama su pouzdane.

Sljedeći korak u analizi metrijskih karakteristika konceptualnog modela sastojao se od vrjednovanja pouzdanosti latentnih konstrukata. Kao kriterij vrjednovanja pouzdanosti reflektivnih latentnih konstrukata korišten je koeficijent unutarnje dosljednosti. Iz rezultata vrjednovanja pouzdanosti prikazanim u tablicama 6.50, 6.68, 6.95 i 6.113 je vidljivo da se vrijednosti koeficijenta kompozitne pouzdanosti nalaze u intervalu od $\rho_c = 0{,}829$ do $\rho_c = 0{,}966$ za reflektivne latentne konstrukte prve razine, u rasponu od $\rho_c = 0{,}904$ do $\rho_c = 0{,}959$ za reflektivne latentne konstrukte druge razine te u intervalu od $\rho_c = 0{,}812$ do $\rho_c = 0{,}859$ za reflektivni latentni konstrukt treće razine. Obzirom da su utvrđene vrijednosti koeficijenta unutarnje dosljednosti veće od referentne vrijednosti $\rho_c = 0{,}707$, može se zaključiti da su svi reflektivni latentni konstrukti koji se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama pouzdani. Vrjednovanje pouzdanosti formativnih latentnih konstrukata provedeno je analizom multikolinearnosti. Obzirom da je u operacionalizaciji i analizi višedimenzionalnih konstrukata korištena kombinacija hibridnih tehnika, vrjednovanje multikolinearnosti je provedeno samo za formativne manifestne varijable prve razine. Na temelju podataka prikazanih u tablicama 6.51, 6.69, 6.96 i 6.114 utvrđeno je da se vrijednosti koeficijenta inflacije varijance kreću u intervalu od 1,002 do 4,703, a vrijednosti koeficijenta tolerancije u rasponu od 0,213 do 0,998. Kako utvrđeni intervali vrijednosti za oba koeficijenta udovoljavaju rasponima referentnih vrijednosti (koeficijent inflacije varijance < 5, koeficijent tolerancije > 0,2) može se zaključiti da je razina multikolinearnosti koja egzistira između formativnih manifestnih varijabli namijenjenih mjerenju istovjetnog temeljnog formativnog konstrukta prihvatljiva. Prema tome, svi formativni latentni konstrukti koji se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama su pouzdani.

Nakon što je utvrđena dostatna razina pouzdanosti latentnih konstrukata, započelo je vrjednovanje njihove valjanosti. Vrjednovanje konvergentne valjanosti reflektivnih latentnih konstrukata sastojalo se od analize vrijednosti prosječnih ekstrahiranih varijanci. Iz podataka prikazanih u tablicama 6.50, 6.68, 6.95 i 6.113 se može vidjeti da su reflektivni latentni konstrukti objasnili između 78,68% i 95,08% varijance manifestnih varijabli namijenjenih mjerenju njihovih aspekata. Navedeno implicira da svi reflektivni latentni konstrukti koji se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama

udovoljavaju kriteriju konvergentne valjanosti. Nomološka valjanost formativnih latentnih konstrukata vrjednovana je analizom značajnosti puteva koji su od istih odaslani prema reflektivnim latentnim konstruktima. Temeljem rezultata vrjednovanja koji se nalaze u tablicama 6.57, 6.75, 6.102 i 6.120 utvrđeno je da je u prosjeku 86,36% puteva odaslanih od formativnih latentnih konstrukata prema reflektivnim latentnim konstruktima značajno na razini $\alpha = 0{,}001$, prosječno 9,09% puteva je značajno na razini $\alpha = 0{,}01$ dok ih je u prosjeku 4,55% značajno na razini $\alpha = 0{,}05$. Iz navedenog proizlazi da svi formativni latentni konstrukti koji se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama udovoljavaju kriteriju nomološke valjanosti.

Diskriminacijska valjanost reflektivnih latentnih konstrukata vrjednovana je usporedbom vrijednosti standardiziranih faktorskih i unakrsnih opterećenja kao i usporedbom vrijednosti prosječne ekstrahirane varijance pojedinog reflektivnog latentnog konstrukta i kvadriranih vrijednosti njegovih dvosmjernih korelacija sa ostalim reflektivnim konstruktima koji se u konceptualnom modelu nalaze na istoj razini. Obzirom da se na trećoj razini konceptualnog modela nalazi samo jedan reflektivni latentni konstrukt (napor) nije mu bilo moguće utvrditi razinu diskriminacijske valjanosti već je vrjednovanje iste provedeno samo za reflektivne latentne konstrukte prve i druge razine. Iz podataka prikazanih u tablicama 6.41, 6.59, 6.86 i 6.104 i tablicama 6.42, 6.60, 6.87 i 6.105 je vidljivo da su vrijednosti standardiziranih faktorskih opterećenja reflektivnih manifestnih varijabli prve i druge razine, respektivno, sa temeljnim latentnim konstruktima veće od njihovih unakrsnih opterećenja sa ostalim reflektivnim latentnim konstruktima u konceptualnom modelu. Pored toga, tablice 6.52, 6.70, 6.97 i 6.115 te tablice 6.53, 6.71, 6.98 i 6.116 jasno prikazuju da su vrijednosti prosječnih ekstrahiranih varijanci reflektivnih latentnih konstrukata prve i druge razine, respektivno, veće od kvadriranih vrijednosti njihovih dvosmjernih korelacija sa preostalim reflektivnim latentnim konstruktima iste razine. Navedeno implicira da reflektivni latentni konstrukti dijele više varijance sa manifestnim varijablama koje mjere njihova obilježja nego sa ostalim reflektivnim latentnim konstruktima iste razine. Prema tome, svi reflektivni latentni konstrukti koji su sastavni dio konceptualnog modela vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama udovoljavaju kriterijima diskriminacijske valjanosti.

Analizom vrijednosti međukorelacija formativnih latentnih konstrukata vrjednovana je njihova diskriminacijska valjanost. Na osnovi podataka prikazanih u tablicama 6.54, 6.72, 6.99 i 6.117 utvrđeno je da formativni latentni konstrukti koji se u konceptualnom modelu nalaze na prvoj razini dijele između 0% i 31,70% varijance. Nadalje, temeljem rezultata analize koji se nalaze u tablicama 6.55, 6.73, 6.100 i 6.118 ustanovljeno je da formativni latentni konstrukti druge razine dijele između 3,31% i 29,92% zajedničke varijance. Naposljetku, iz podataka koji su sadržani u

tablicama 6.56, 6.74, 6.101 i 6.119 je vidljivo da formativni latentni konstrukti treće razine u konceptualnom modelu dijele između 21,07% i 39,82% varijance. Prema tome, svi formativni latentni konstrukti u konceptualnom modelu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama udovoljavaju kriteriju diskriminacijske valjanosti. Temeljem dosad predstavljenih rezultata vrjednovanja metrijskih karakteristika konceptualnog modela može se zaključiti da su formativno i reflektivno operacionalizirani vanjski modeli pouzdani i valjani.

Po završetku testiranja pouzdanosti i valjanosti vanjskih modela pristupilo se vrjednovanju metrijskih karakteristika unutarnjeg modela koje je započelo analizom vrijednosti koeficijenata determinacije. Potrebno je napomenuti da u višedimenzionalnom modelu latentni konstrukti nižih razina objašnjavaju 100% varijance latentnih konstrukata viših razina čije dimenzije predstavljaju. Zbog navedenog koeficijenti determinacije latentnih konstrukata druge i treće razine nisu zasebno interpretirani. Iz slika 6.23, 6.24, 6.27 i 6.28 je vidljivo da u konceptualnom modelu nezavisne latentne varijable objašnjavaju između 15,7% i 61,8% varijance u zavisnim latentnim varijablama. Formativni latentni konstrukti treće razine pomoću kojih se mjere dimenzije kvalitete sustava i kvalitete usluge Web 2.0 aplikacije objašnjavaju između 15,7% i 27,9% varijance u reflektivnom latentnom konstruktu prve razine kojim se vrjednuje stav prema korištenju Web 2.0 aplikacijom. Atributi kvalitete u korištenju namijenjeni vrjednovanju aspekata dosljednosti i mogućnosti prilagodbe Web 2.0 aplikacije objašnjavaju između 15,9% i 29,6% varijance u atributu kojim se vrjednuje pamtljivost Web 2.0 aplikacije. Formativni latentni konstrukti prve razine primjenom kojih se mjeri razina do koje Web 2.0 aplikacija sprječava nastanak pogrješaka te se od istih može oporaviti objašnjavaju između 21,1% i 37,8% varijance u reflektivnom latentnom konstruktu kojim se vrjednuje pouzdanost Web 2.0 aplikacije.

Indikatori pomoću kojih se mjeri broj pritisnutih tipaka na tipkovnici, udaljenost prijeđena pomicanjem miša, broj klikova mišem i broj pomicanja klizača na mišu koje su korisnici napravili tijekom upotrebe Web 2.0 aplikacije objašnjavaju između 25,8% i 43,0% varijance u reflektivnom latentnom konstruktu prve razine kojim se vrjednuje zamijećeno radno opterećenje korisnika za vrijeme interakcije sa Web 2.0 aplikacijom. Atributi kvalitete u korištenju primjenom kojih se utvrđuje stupanj familijarnosti i razumljivosti Web 2.0 aplikacije objašnjavaju između 33,9% i 47,2% varijance u atributu kojim se vrjednuje lakoća učenja korištenja Web 2.0 aplikacijom. Formativni latentni konstrukt druge razine primjenom kojeg se mjere aspekti produktivnosti korisnika i reflektivni latentni konstrukt prve razine pomoću kojeg se vrjednuje pouzdanost Web 2.0 aplikacije objašnjavaju između 38,6% i 46,9% varijance u reflektivnom latentnom konstruktu prve razine namijenjenom vrjednovanju korisnosti Web 2.0 aplikacije. Atributi kvalitete u korištenju pomoću kojih se vrjednuju korisnost Web 2.0 aplikacije,

stav prema korištenju Web 2.0 aplikacijom i zadovoljstvo korisnika objašnjavaju između 39,9% i 49,2% varijance u atributu namijenjenom vrjednovanju lojalnosti korisnika. Indikator primjenom kojeg se mjeri koliko reprezentativnih koraka scenarija korisnici mogu upotrebom Web 2.0 aplikacije dovršiti i reflektivni latentni konstrukt pomoću kojeg se utvrđuje do koje se razine Web 2.0 aplikacija može upotrebljavati izvan inicijalno naznačenog konteksta korištenja objašnjavaju između 42,3% i 46,0% varijance u reflektivnom latentnom konstruktu kojim se vrjednuje zamijećena djelotvornost korisnika.

Hedonistički atributi korisničkog iskustva pomoću kojih se vrjednuju dimenzije razigranosti korisnika te jedinstvenosti i estetike Web 2.0 aplikacije objašnjavaju između 44,4% i 59,7% varijance u atributu kojim se mjeri razina užitka kojeg interakcija sa Web 2.0 aplikacijom pruža korisnicima. Indikator primjenom kojeg se mjeri koliko je vremena potrebno korisnicima da dovrše reprezentativne korake interakcije sa Web 2.0 aplikacijom i formativni latentni konstrukt druge razine pomoću kojeg se vrjednuje radni učinak Web 2.0 aplikacije objašnjavanju između 46,4% i 50,6% varijance u reflektivnom latentnom konstruktu namijenjenom vrjednovanju zamijećene učinkovitosti korisnika. Atribut pomoću kojeg se utvrđuje do koje mjere korisnici mogu kontrolirati interakciju sa Web 2.0 aplikacijom i atribut primjenom kojeg se vrjednuje kvaliteta navigacijskih mehanizama sa kojima raspolaže Web 2.0 aplikacija objašnjavaju između 47,6% i 56,4% varijance u atributu kojim se vrjednuje lakoća korištenja Web 2.0 aplikacijom. Naposljetku, reflektivni latentni konstrukt treće razine pomoću kojeg se mjeri koliko napora korisnici trebaju uložiti u korištenje Web 2.0 aplikacijom i reflektivni latentni konstrukt prve razine primjenom kojeg se utvrđuje koliko je korisnicima ugodno upotrebljavati Web 2.0 aplikaciju objašnjavaju između 51,25% i 61,8% varijance u atributu kojim se vrjednuje zadovoljstvo korisnika.

Na osnovi razmotrenih rezultata definirane su referentne vrijednosti koeficijenta determinacije koje mogu poslužiti identifikaciji prediktorske snage egzogenih latentnih varijabli u konceptualnom modelu. Prema tome, vrijednosti koeficijenta determinacije od 0,15, 0,34 i 0,46 impliciraju malu, srednju i veliku prediktorsku snagu nezavisnih latentnih varijabli, respektivno. Navedene referentne vrijednosti su ujedno i svojevrstan kompromis referentnih vrijednosti koje su za istu namjenu predložili Cohen (1988), Chin (1998) i Hair et al. (2011). U tablicama 6.57, 6.75, 6.102 i 6.120 te na slikama 6.23, 6.24, 6.27 i 6.28 se nalaze vrijednosti koeficijenata puta sa naznakom razine značajnosti. Analizom spomenutih vrijednosti utvrđeno je da je u prosjeku 80,85% koeficijenata puta značajno na razini $\alpha = 0{,}001$, prosječno 10,64% ih je značajno na razini $\alpha = 0{,}01$ dok ih je u prosjeku 8,51% značajno na razini $\alpha = 0{,}05$. Prema tome, **sve pretpostavljene ($H_{1.1}$-$H_{1.25}$) teorijske veze između egzogenih i endogenih latentnih konstrukata u konceptualnom modelu su potvrđene**.

Obzirom da se dimenzije atributa „izmjereno radno opterećenje“ vrjednuju objektivno pomoću četiri različita indikatora, analiza veličine utjecaja i prediktivne valjanosti provedena je za svakog od njih zasebno. Rezultati vrjednovanja veličine utjecaja i prediktivne valjanosti nezavisnih varijabli nalaze se u tablicama 6.58, 6.76, 6.103 i 6.121. Analizom spomenutih rezultata utvrđeno je da u prosjeku 60,71% nezavisnih varijabli ima mali utjecaj, prosječno 21,43% nezavisnih varijabli ima srednji utjecaj, a u prosjeku 17,86% nezavisnih varijabli ima veliki utjecaj na zavisne varijable u konceptualnom modelu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama. Iz rezultata vrjednovanja prediktivne valjanosti koji su prikazani u tablicama 6.58, 6.76, 6.103 i 6.121 je vidljivo da prosječno 71,43% nezavisnih varijabli ima malu prediktivnu valjanost, u prosjeku 25% nezavisnih varijabli ima srednju prediktivnu valjanost dok prosječno 3,57% nezavisnih varijabli koje se nalaze u konceptualnom modelu vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama ima veliku prediktivnu valjanost.

Uzimajući u obzir rezultate analize metrijskih karakteristika koji se nalaze u tablicama 6.41-6.76 i 6.86-6.121 te slikama 6.23, 6.24, 6.27 i 6.28 moguće je zaključiti da konceptualni model vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama udovoljava svim kriterijima pouzdanosti i valjanosti. Ovime je **drugi cilj istraživanja ostvaren, a prva hipoteza potvrđena**.

Treći i posljednji cilj istraživanja definiran je na sljedeći način:

C_3: Razviti metodologiju vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama koja će:

a) **ubrzati proces identifikacije problema tijekom upotrebe Web 2.0 aplikacija,**
b) **olakšati analizu i komparaciju vrjednovanih Web 2.0 aplikacija.**

Kako bi se spomenuti cilj bolje pojasnio i precizirao, isti je dekomponiran na sljedeće dvije hipoteze:

H_2. Na temelju konceptualnog modela te analize prednosti i nedostataka postojećih metoda, razvit će se metodologija vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama.

H_3. Metodologija vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama omogućava učinkovitu analizu i komparaciju vrjednovanih Web 2.0 aplikacija.

Kompozitni indeksi kvalitete u korištenju vrjednovanih Web 2.0 aplikacija izračunati su primjenom metode logičkog bodovanja preferencija (Dujmović, 1975). Najprije je na temelju

pouzdanog i valjanog konceptualnog modela oblikovano stablo zahtjeva. Manifestne varijable (čestice i indikatori) su operacionalizirane kao listovi stabla, reflektivni i formativni latentni konstrukti su modelirani kao čvorovi stabla dok je kompozitni indeks kvalitete u korištenju Web 2.0 aplikacijama specificiran kao korijen stabla. Na osnovi podataka prikupljenih tijekom provedbe pilot istraživanja (Orehovački, 2010; Orehovački, 2011a; Orehovački et al., 2012a; Orehovački et al., 2013) definirani su elementarni kriteriji primjenom kojih je utvrđeno u kojoj mjeri svaka od vrjednovanih Web 2.0 aplikacija udovoljava zahtjevima u stablu odnosno relevantnim aspektima kvalitete u korištenju. Maločas spomenutim postupkom izračunate su vrijednosti elementarnih preferencija za varijable performansi. Zatim je uzorak stručnjaka domene koji su sudjelovali u primjeni metode zatvorenog sortiranja karata bio uključen u grupno procjenjivanje težina za sve varijable i podsustave performansi koji se nalaze u stablu zahtjeva. Razina podudaranja među stručnjacima u kontekstu ponderiranja varijabli performansi testirana je Kendallovim *W* koeficijentom (Kendall i Babington-Smith, 1939; Wallis, 1939). Analizom rezultata utvrđeno je da su vrijednosti Kendallovog koeficijenta podudaranja *W* značajno različite od nule što implicira da su ocjene koje su stručnjaci domene dodijelili podsustavima performansi međusobno zavisne. Temeljem vrijednosti normaliziranih težina i elementarnih preferencija varijabli performansi izračunate su elementarne preferencije podsustava čija obilježja varijable performansi mjere. Postupak se ponavljao po razinama stabla od dna prema vrhu sve dok na osnovi normaliziranih težina i elementarnih preferencija podsustava varijabli performansi nije izračunat kompozitni indeks kvalitete u korištenju za svaku vrjednovanu Web 2.0 aplikaciju.

Izračunom elementarnih i globalnih preferencija dovršen je razvoj metodologije vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama. Ista je proširila koncept kvalitete u korištenju koji je definiran međunarodnim standardom ISO/IEC 25010 (2011) te ga prilagodila kontekstu Web 2.0 aplikacija. Uključivanjem stručnjaka domene i korisnika kao najvažnijih dionika životnog ciklusa Web 2.0 aplikacija, metodologija je omogućila identifikaciju pragmatičnih i hedonističkih atributa kvalitete u korištenju te njihovo vrjednovanje primjenom subjektivnih i objektivnih mjernih instrumenata. Kako bi se umanjili nedostatci i naglasile prednosti postojećih metoda u identifikaciji problema koji se manifestiraju tijekom korištenja Web 2.0 aplikacijama, iste su vrjednovane kombinacijom različitih metoda (upitnik, automatsko zapisivanje postupaka, mjerenje radnog učinka korisnika i povratne informacije od korisnika). Iz svega dosad navedenog proizlazi da je **druga hipoteza potvrđena**.

Razvijena metodologija omogućila je analizu i usporedbu vrjednovanih Web 2.0 aplikacija po svim varijablama performansi i podsustavima preferencija koji se nalaze u stablu zahtjeva. Tako je utvrđeno da se Web 2.0 aplikacije za kolaborativno uređivanje teksta razlikuju 4,93% u razini

zadovoljenja svih zahtjeva kvalitete u korištenju. Usporedbom Web 2.0 aplikacije za kolaborativno uređivanje teksta sa aspekta zadovoljenja zahtjeva koji se u stablu nalaze na razini listova utvrđeno je da između aplikacija Zoho Writer i Microsoft Word Web App najmanja razlika egzistira na razini varijabli performansi pomoću kojih se provjerava: da li su elementi sučelja intuitivni za korisnika (UPR6; 0,00%), da li Web 2.0 aplikacija obavještava korisnika kada će pojedina aktivnost biti izvršena (PIN1; 0,09%), da li Web 2.0 aplikacija ima široku mogućnost primjene (SVK3; 0,19%), da li je Web 2.0 aplikaciju moguće upotrebljavati i izvan konteksta za koji je originalno namijenjena (SVK2; 0,28%) te da li je tekst koji opisuje funkcionalnosti pojedinih elemenata sučelja dovoljno velik za čitanje (PST4; 0,38%). Pored toga, pronađeno je da se Web 2.0 aplikacije za kolaborativno uređivanje teksta u velikoj mjeri razlikuju u slučaju zadovoljenja zahtjeva sljedećih podsustava varijabli performansi: izmjerena učinkovitost (IZU; 40,36%), izmjereno radno opterećenje (IRO; 28,34%), izmjerena djelotvornost (IZD; 21,43%), interoperabilnost (INT; 17,83%) i mogućnost interakcije (MIN; 10,23%).

Analizom Web 2.0 aplikacije Zoho Writer utvrđeno je da je ista u najvećoj mjeri udovoljila zahtjevima primjenom kojih se provjerava: da li je Web 2.0 aplikaciju jednostavno pronaći preko web tražilice (DST4; 89,30%), da li Web 2.0 aplikacija omogućuje da se ponište i ponove promjene na artefaktu (SPO3; 82,39%), da li je Web 2.0 aplikacija dostupna svaki put kada je korisniku to potrebno (DST1; 80,68%), da li je artefakte koji nastanu korištenjem Web 2.0 aplikacijom moguće pohraniti u formatima datoteka koji su korisnicima potrebni (INT3; 77,65%) te da li je tekst koji opisuje funkcionalnosti sučelja Web 2.0 aplikacije dovoljno velik za čitanje (PST4; 77,46%). Jednako tako, utvrđeno je da aplikacija Zoho Writer u najmanjoj mjeri udovoljava zahtjevima sljedećih podsustava varijabli performansi: izmjerena učinkovitost (IZU; 27,70%), izmjereno radno opterećenje (IRO; 30,78%), lojalnost (LOJ; 40,52%), užitak (UTK; 46,41%) i razigranost (RZG; 49,72%). Rezultati vrjednovanja Web 2.0 aplikacije Microsoft Word Web App pokazali su da je ista u najmanjoj mjeri udovoljila zahtjevima kojima se utvrđuje: da li korisnici planiraju Web 2.0 aplikaciju ubuduće često upotrebljavati (LOJ3; 33,81%), koliko reprezentativnih koraka scenarija korisnici primjenom Web 2.0 aplikacije mogu dovršiti (IZD1; 35,71%), da li korisnici namjeravaju nastaviti upotrebljavati Web 2.0 aplikaciju (LOJ1; 36,17%), da li bi korisnici svakome preporučili Web 2.0 aplikaciju (LOJ2; 37,31%) te da li je korisnicima ugodno koristiti se Web 2.0 aplikacijom (UTK4; 38,54%). Nasuprot tome, pronađeno je da je aplikacija Microsoft Word Web App u velikoj mjeri udovoljila zahtjevima podsustava varijabli performansi pomoću kojih se vrjednuju dostupnost (DST; 77,27%), familijarnost (FML; 76,78%), razumljivost (RZM; 74,54%), pristupačnost (PST; 74,20%) i lakoća učenja korištenja (LUK; 72,91%) Web 2.0 aplikacijom.

Komparacijom Web 2.0 aplikacija za izradu mentalnih mapa pronađeno je da se Mindomo i Wise Mapping razlikuju 13,96% u zadovoljenju zahtjeva definiranih varijablama performansi u stablu kvalitete u korištenju. Najveći doprinos spomenutoj razlici su na razini listova u stablu dale varijable performansi čijim se zahtjevima provjerava: da li Web 2.0 aplikacija omogućava prijavu sa postojećim korisničkim računom (DST5; 39,78%), da li Web 2.0 aplikacija omogućava sinkronu komunikaciju među korisnicima (MIN7; 36,99%), koliko je puta potrebno pomaknuti klizač na mišu da bi se primjenom Web 2.0 aplikacije dovršili reprezentativni koraci scenarija (IRO4; 34,58%), da li Web 2.0 aplikacija lijepo izgleda (EST5; 33,55%) te da li Web 2.0 aplikacija ima atraktivno sučelje (EST4; 32,16%). S druge strane, najmanji udio u razlici među vrjednovanim Web 2.0 aplikacijama za izradu mentalnih mapa su imali sljedeći podsustavi varijabli performansi: sigurnost (SGR; 0,08%), zamijećena skalabilnost (ZAS; 0,17%), prenosivost (PNS; 1,27%), zamijećeno vrijeme odaziva (ZVO; 2,09%) i sprječavanje pogrješaka (SPO; 2,70%).

Rezultati vrjednovanja Web 2.0 aplikacije Mindomo pokazali su da je ista u najmanjoj mjeri zadovoljila zahtjeve varijabli performansi pomoću kojih se utvrđuje: da li je tijekom izrade korisničkog računa potrebno definirati sigurnosno pitanje i odgovor (SGR4; 28,07%), da li korisnici planiraju Web 2.0 aplikaciju često upotrebljavati (LOJ3; 43,49%), da li je tijekom registracije novog korisnika potrebno unijeti CAPTCHA znakove (SGR3; 44,80%), koliko je puta potrebno kliknuti mišem da bi se dovršili reprezentativni koraci scenarija interakcije sa Web 2.0 aplikacijom (IRO3; 45,51%) te koliku je udaljenost potrebno prijeći pomicanjem miša da bi se dovršili reprezentativni koraci scenarija upotrebe Web 2.0 aplikacije (IRO2; 47,38). Nasuprot tome, Mindomo je u velikoj mjeri udovoljio zahtjevima sljedećih podsustava varijabli performansi: dostupnost (82,56%), zamijećeno vrijeme odaziva (80,91%), pristupačnost (79,61%), pouzdanost (79,08%) i estetika (78,88%). Kroz analizu Web 2.0 aplikacije Wise Mapping pronađeno je da ista uvelike udovoljava zahtjevima varijabli performansi kojima se provjerava: da li je Web 2.0 aplikaciju lako pronaći preko web tražilice (DST4; 86,80%), da li Web 2.0 aplikacija omogućuje korisniku da poništi i ponovi promjene na artefaktu (SPO3; 81,04%), da li se radni prostor i elementi sučelja Web 2.0 aplikacije brzo učitavaju u web pregledniku (ZVO2; 78,90%), da li je vrijeme odaziva Web 2.0 aplikacije prihvatljivo (ZVO4; 78,90%) te da li je potrebno dugo čekati da se pokrenu i izvrše odabrane funkcionalnosti sučelja Web 2.0 aplikacije (ZVO3; 78,62%). U suprotnosti sa navedenim, aplikacija Wise Mapping je u najmanjoj mjeri udovoljila zahtjevima sljedećih podsustava varijabli performansi: izmjereno radno opterećenje (IRO; 25,37%), lojalnost (34,39%), izmjerena učinkovitost (IZU; 35,11%), izmjerena djelotvornost (IZD; 36,67%) i užitak (UTK; 46,98%).

Iz svega navedenog je evidentno da metodologija vrjednovanja kvalitete u korištenju omogućuje učinkovitu analizu i komparaciju Web 2.0 aplikacija te ubrzava identifikaciju problema sa kojima se korisnici suočavaju tijekom interakcije sa Web 2.0 aplikacijama. Zbog toga je moguće zaključiti da je **treći cilj istraživanja ostvaren, a treća hipoteza potvrđena**.

7.2 Smjernice i preporuke za unaprjeđenje metodike razvoja i vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama

Na temelju rezultata istraživanja provedenog u sklopu doktorskog rada oblikovan je skup smjernica i preporuka koje se mogu upotrebljavati u različitim fazama životnog ciklusa Web 2.0 aplikacije: od izrade specifikacije zahtjeva preko dizajna i razvoja Web 2.0 aplikacije pa sve do vrjednovanja svih relevantnih aspekata kvalitete u korištenju. Smjernice i preporuke su nastale formalizacijom manifestnih varijabli iz konceptualnog modela odnosno zahtjeva varijabli performansi koje se nalaze u stablu kvalitete u korištenju Web 2.0 aplikacijama. Primjenom smjernica i preporuka moguće je utvrditi u kojoj mjeri Web 2.0 aplikacija odstupa od definiranih zahtjeva.

Smjernice predstavljaju skup zahtjeva kvalitete u korištenju kojima svaka Web 2.0 aplikacija treba obavezno udovoljavati. Ukoliko Web 2.0 aplikacija ne udovolji pojedinom zahtjevu smjernice to će dovesti do značajnog smanjenja vrijednosti elementarne preferencije podsustava varijabli performansi kao i do osjetnog smanjenja vrijednosti kompozitnog indeksa kvalitete u korištenju Web 2.0 aplikacijom. Preporuke su skup zahtjeva kvalitete u korištenju za koje je poželjno, ali ne i obavezno, da im Web 2.0 aplikacija udovoljava. Ako Web 2.0 aplikacija ne udovolji određenom zahtjevu preporuke doći će do neznatnog smanjenja vrijednosti elementarne preferencije podsustava varijabli performansi kao i do minornog smanjenja vrijednosti kompozitnog indeksa kvalitete u korištenju Web 2.0 aplikacijom.

Ukoliko se smjernice i preporuke sagledaju iz perspektive web razvojnih inženjera, iste je moguće svrstati u dvije podskupine. Endogene smjernice i preporuke su aspekti upotrebljivosti na koje web razvojni inženjeri mogu direktno utjecati tijekom razvojnog procesa pojedine Web 2.0 aplikacije. Skupina egzogenih smjernica i preporuka se sastoji od aspekata korisničkog iskustva na koje web razvojni inženjeri nemaju direktan utjecaj, ali ih trebaju vrjednovati kako bi temeljem podataka prikupljenih od korisnika mogli unaprijediti kvalitetu u korištenju Web 2.0 aplikacijom.

7.2.1 Endogene smjernice

Aspekti interakcije sa Web 2.0 aplikacijom trebaju biti dosljedni. U svim dijelovima Web 2.0 aplikacije dizajn sučelja te način i mjesto prikazivanja poruka trebaju biti jednaki. Poželjno je i da funkcionalnosti sučelja budu jednako razmještene u svim dijelovima Web 2.0 aplikacije.

Elementi sučelja Web 2.0 aplikacije trebaju biti neprestano dostupni. Svaki put kada korisnici pristupaju Web 2.0 aplikaciji, ona treba biti dostupna za upotrebu. Ukoliko korisnici ne posjeduju poveznicu do Web 2.0 aplikacije, istu treba biti moguće jednostavno pronaći preko web tražilice. Ako korisnici imaju otvoren korisnički račun kod popularnih web mjesta kao što su Facebook ili Google, Web 2.0 aplikacija im treba omogućiti prijavu posredstvom tog korisničkog računa.

Korištenje Web 2.0 aplikacijom treba rezultirati povećanjem djelotvornosti korisnika. Web 2.0 aplikacija treba raspolagati sa svim funkcionalnostima koje su korisnicima potrebne da točno i u potpunosti dovrše zadatke.

Korištenje Web 2.0 aplikacijom treba rezultirati povećanjem učinkovitosti korisnika. Web 2.0 aplikacija treba omogućiti korisnicima da dovrše zadatke u najkraćem mogućem roku.

Web 2.0 aplikacija treba biti lagana za upotrebu. Korisnicima treba biti lako upotrebljavati funkcionalne elemente sučelja Web 2.0 aplikacije i njihovom primjenom izvršavati zadatke.

Web 2.0 aplikaciju treba biti lako naučiti upotrebljavati. Korisnicima treba biti lako razviti vještinu korištenja Web 2.0 aplikacijom počam od načina upotrebe funkcionalnih elemenata sučelja pa sve do njihove primjene u izvršavanju zadataka.

Korisnici trebaju imati kontrolu nad interakcijom sa Web 2.0 aplikacijom. Korisnicima treba biti jednostavno postići da Web 2.0 aplikacija radi što oni žele. Pored toga, korisnici trebaju imati potpunu slobodu u načinu korištenja Web 2.0 aplikacijom. Poželjno je i da redoslijed korištenja funkcionalnostima sučelja Web 2.0 tijekom izvršavanja zadataka bude prepušten korisniku.

Web 2.0 aplikacija se treba moći oporaviti od pogrješaka ili prekida u radu. Ako tijekom interakcije sa Web 2.0 aplikacijom dođe do pogrješke ili prekida u radu, Web 2.0 aplikacija treba sačuvati sav posao koji je do tog trenutka napravljen. Pored toga, Web 2.0 aplikacija se treba moći brzo oporaviti od pogrješaka ili prekida u radu te nakon ponovnog učitavanja prikazati oporavljenu verziju artefakta.

Interakcija sa Web 2.0 aplikacijom treba biti lako pamtljiva. Korisnicima treba biti lagano zapamtiti i prisjetiti se kako se upotrebljava Web 2.0 aplikacija te gdje se nalaze pojedine funkcionalnosti njena sučelja.

Web 2.0 aplikacija treba biti pouzdana u radu. Web 2.0 aplikacija ne bi smjela sadržavati softverske pogrješke. Pored toga, Web 2.0 aplikacija bi trebala biti stabilna u radu.

Web 2.0 aplikacija treba obavještavati korisnike o promjenama u svom statusu ili radu. Ukoliko tijekom interakcije sa Web 2.0 aplikacijom dođe do pogrješke ili prekida u radu, Web 2.0 aplikacija treba o tome pravovremeno obavijestiti korisnika. Nakon provedbe određene aktivnosti nad artefaktom (primjerice pohrane), Web 2.0 aplikacija treba prikazati prikladnu povratnu poruku. Jednako tako, Web 2.0 aplikacija treba obavijestiti korisnika kada će pojedina aktivnost biti dovršena (primjerice učitavanje u web pregledniku). Premda je nužno da poruke koje Web 2.0 aplikacija prikazuje budu jasne, poželjno je da iste budu i precizne.

Web 2.0 aplikacija treba biti upotrebljiva u različitim radnim okruženjima. Dostupnost elemenata sučelja i način korištenja Web 2.0 aplikacijom se ne bi smjeli razlikovati među web preglednicima. Poželjno je da u navedenom ne postoji razlika među uređajima koje je moguće spojiti na Internet.

Web 2.0 aplikacija treba biti upotrebljiva svim skupinama korisnika bez obzira na njihove karakteristike i sposobnosti. Tekst koji opisuje funkcionalnosti elemenata sučelja i objekti koji se nalaze na sučelju trebaju biti dostatne veličine. Poželjno je i da Web 2.0 aplikacija sadrži popis tipkovničkih kratica za pokretanje funkcionalnih elemenata sučelja.

Web 2.0 aplikacija treba raspolagati sa sadržajima pomoći korisnicima. Sadržaji pomoći trebaju omogućiti korisnicima da na jednostavan i učinkovit način pronađu kako se upotrebljava pojedina funkcionalnost sučelja. Pored toga, sadržaji pomoći trebaju biti pregledni i jasni. Poželjno je da Web 2.0 aplikacija sadrži različite oblike pomoći korisnicima te da isti budu dostupni sa bilo kojeg dijela Web 2.0 aplikacije.

Elementi sučelja Web 2.0 aplikacije trebaju biti razumljivi. Izgled ikona treba odgovarati njihovoj namjeni, nazivlje elemenata sučelja treba biti usklađeno sa kontekstom njihove upotrebe, a njihova funkcionalnost očigledna.

Web 2.0 aplikacija treba omogućiti zaštitu podataka i artefakata korisnika od neautorizirane upotrebe. Tijekom izrade korisničkog računa, Web 2.0 aplikacija treba od korisnika tražiti da ponovi unos lozinke koja je sačinjena od unaprijed definiranog minimalnog

broja znakova. Poželjno je da Web 2.0 aplikacija od korisnika traži da prilikom izrade korisničkog računa unese CAPTCHA znakove te definira sigurnosno pitanje i odgovor.

Web 2.0 aplikacija treba raspolagati sa funkcionalnostima koje sprječavaju nastanak pogrješaka i omogućuju njihovo ispravljanje. Ako tijekom upotrebe Web 2.0 aplikacije korisnik napravi pogrješku, Web 2.0 mu treba omogućiti da istu brzo i jednostavno ispravi. Jednako tako, Web 2.0 aplikacija treba sadržavati funkcionalnosti koje omogućuju korisniku da poništi i ponovi promjene nad artefaktom. Prije nego što provede bilo koju vrstu destruktivne operacije (primjerice brisanje artefakta) Web 2.0 aplikacija treba zatražiti potvrdu od korisnika.

Web 2.0 aplikacija treba biti lagana za upravljanje. Elementi sučelja Web 2.0 aplikacije trebaju biti intuitivni za upotrebu te strukturirani na način da korisnici mogu brzo i jednostavno pronaći funkcionalnosti koje su im potrebne. Web 2.0 aplikacija treba raspolagati sa različitim navigacijskim mehanizmima (primjerice tražilica, izbornici i sl.). Elementi sučelja trebaju biti raspoređeni na način da su srodne funkcionalnosti zajedno grupirane. Potrebno je i optimizirati broj elemenata u izborniku i podizbornicima.

Web 2.0 aplikacija treba brzo reagirati na aktivnosti korisnika. Vrijeme odaziva Web 2.0 aplikacije treba biti korisnicima prihvatljivo. Radni prostor i elementi sučelja Web 2.0 aplikacije se trebaju brzo učitavati u web preglednicima. Korisnici ne bi smjeli dugo čekati da se pokrenu odabrane funkcionalnosti sučelja Web 2.0 aplikacije.

7.2.2 Egzogene smjernice

Web 2.0 aplikacija treba biti korisna za izvršavanje zadataka. Korištenje Web 2.0 aplikacijom treba rezultirati povećanjem performansi korisnika u izvršavanju zadataka. Pored toga, Web 2.0 aplikacija treba biti prikladna za izvršavanje zadataka unutar specificiranog konteksta upotrebe.

Interakcija sa Web 2.0 aplikacijom treba rezultirati lojalnim korisnicima. Nakon prve interakcije sa Web 2.0 aplikacijom, pojedinci trebaju biti voljni istu nastaviti upotrebljavati, preporučiti je svakome kome je potrebna aplikacija te namjene te postati njeni aktivni korisnici.

Web 2.0 aplikacija treba stvoriti pozitivan stav korisnika prema njenoj upotrebi. Korisnicima se treba sviđati ideja o korištenju Web 2.0 aplikacijom. Pored toga, korisnici trebaju smatrati kako interakcija sa Web 2.0 aplikacijom predstavlja dobru odluku.

Web 2.0 aplikacija treba svojim karakteristikama i specifičnostima zadovoljiti korisnike. Web 2.0 aplikacija treba ispuniti očekivanja korisnika, udovoljiti njihovim željama i potrebama te ih se dojmiti.

7.2.3 Endogene preporuke

Poželjno je da dizajn sučelja Web 2.0 aplikacije bude vizualno privlačan. Kako bi se povećao opći dojam lijepog izgleda i atraktivnosti Web 2.0 aplikacije posebnu je pozornost potrebno posvetiti odabiru boja koje će prevladavati na sučelju i njihovoj usklađenosti.

Poželjno je da aspekti interakcije sa Web 2.0 aplikacijom budu poznati. Preporučljivo je da izgled ikona te naziv i raspored elemenata korisničkog sučelja budu slični istima u aplikacijama koje korisnici redovito upotrebljavaju.

Poželjno je da Web 2.0 aplikacija omogućava prijenos kreiranih artefakata. Web 2.0 treba podržavati pohranu kreiranih artefakata u formatima datoteka koji su korisnicima potrebni. Kod prijenosa artefakta (preuzimanjem i umetanjem i/ili kopiranjem i lijepljenjem) između Web 2.0 aplikacije i aplikacija koje korisnici svakodnevno upotrebljavaju ne bi smjelo doći do promjene u strukturi artefakta.

Poželjno je da korištenje Web 2.0 aplikacijom rezultira smanjenjem radnog opterećenja korisnika. Bilo bi dobro kada bi korisnici primjenom Web 2.0 aplikacije mogli dovršiti zadatke sa što manjom količinom pritisnutih tipaka na tipkovnici, prijeđene udaljenosti pomicanjem miša, klikova mišem i pomicanja klizača na mišu. Nakon upotrebe Web 2.0 aplikacije, korisnici se ne bi trebali osjećati iscrpljeno. Pored toga, korisnici po završetku interakcije sa Web 2.0 aplikacijom ne bi trebali osjećati umor u očima, prstima, zglobovima i mišićima ruku.

Poželjno je da Web 2.0 aplikacija bude jedinstvena. Preporučljivo je da Web 2.0 aplikacija ima nešto po čemu se razlikuje od ostalih aplikacija te što je ističe u skupini aplikacija sa istom namjenom.

Poželjno je da Web 2.0 aplikacija podržava različite oblike interakcije među korisnicima. Preporučljivo je da Web 2.0 aplikacija omogućava rad većeg broja korisnika na izradi artefakata, podržava sinkronu i asinkronu komunikaciju među korisnicima te sadrži funkcionalnosti dodjele pristupa kreiranom artefaktu preko direktne poveznice i liste kontakata.

Poželjno je da Web 2.0 aplikacija raspolaže funkcionalnostima prilagodbe elemenata sučelja. Preporučljivo je da Web 2.0 aplikacija sadrži funkcionalnosti prilagodbe radnog prostora, jezika prikaza te načina prikaza formata datuma i vremena.

Poželjno je da Web 2.0 aplikacija bude upotrebljiva i izvan originalno naznačenog konteksta korištenja. Preporučljivo je da Web 2.0 aplikacija ima širi spektar primjene te podržava izradu raznovrsnih artefakata.

Poželjno je da Web 2.0 aplikacija raspolaže funkcionalnostima koje omogućuju upravljenje artefaktima. Preporučljivo je da Web 2.0 aplikacija sadrži funkcionalnosti za: dodjelu razine vidljivosti kreiranim artefaktima, automatsku pohranu artefakta, dodjelu dozvola nad artefaktima, označavanje artefakata pomoću tagova i slanje obavijesti o promjenama nad artefaktima.

Poželjno je da Web 2.0 aplikacija u slučaju povećanog radnog opterećenja zadrži prihvatljivu razinu upotrebljivosti. Preporučljivo je da Web 2.0 aplikacija korisnicima omogućava pohranu velike količine artefakata, istovremeni rad na većem broju zadataka, te izvršavanje kompleksnih zadataka.

7.2.4 Egzogene preporuke

Poželjno je da Web 2.0 aplikacija usmjerava koncentraciju korisnika na aktivnost koju isti obavlja te potiče upotrebu njegovih kognitivnih vještina. Bilo bi dobro kada bi upotreba Web 2.0 aplikacije mogla zaokupiti pažnju korisnika dulje vrijeme. Jednako je tako poželjno da funkcionalni elementi sučelja Web 2.0 aplikacije potiču kreativnost i stvaralačku maštu korisnika.

Poželjno je da interakcija sa Web 2.0 aplikacijom korisnicima stvara osjećaj ugode. Bilo bi dobro kada bi se korisnicima interakcija sa Web 2.0 aplikacijom sviđala te im bila zanimljiva.

8. ZAKLJUČAK

Web revolucija koja je započela prije gotovo jedno desetljeće u velikoj je mjeri promijenila način razvoja i korištenja web mjestom. Statične web stranice orijentirane prezentiranju informacija i sustave za upravljanje sadržajem naslijedile su dinamične i interaktivne web aplikacije usmjerene na korisnike. Tijekom razvojnih epoha koje su prethodile Webu 2.0 jedino su pojedinci sa dostatnom razinom informacijske pismenosti bili u mogućnosti kreirati i uređivati web mjesta dok su svi ostali bili pasivni konzumenti objavljenih sadržaja. Danas svaki korisnik ima mogućnost da upotrebom Web 2.0 aplikacije samostalno ili u suradnji sa ostalim korisnicima kreira artefakte i njima upravlja. Jednako tako, korisnici mogu primjenom društvenih mreža ili aplikacija specijaliziranih za generiranje web stranica oblikovati vlastito web mjesto te na njemu integrirati, organizirati i dijeliti kreirane artefakte. Pored toga, Web 2.0 je omogućio svakom korisniku da postane aktivnim dionikom životnog ciklusa web mjesta. Naime, nove značajke više ne dolaze upakirane u novu verziju web mjesta već se dodaju svakodnevno kao posljedica korisničkog iskustva.

Zbog velikog broja prednosti, koristi i načina primjene, Web 2.0 aplikacije su postale neizostavan dio svih važnijih pora ljudskog djelovanja. Integracija Web 2.0 aplikacija u obrazovanje potakla je razvoj kolaborativnog učenja te olakšala kontinuirano praćenje studenata. S druge strane, implementacija Web 2.0 aplikacija u poslovne sfere rezultirala je unaprjeđenjem procesa donošenja odluka te povećanjem produktivnosti zaposlenika i zadovoljstva klijenata. Kao logička posljedica maločas navedenog, svakim je danom sve više novih Web 2.0 aplikacija koje svojim specifičnostima pokušavaju zadobiti naklonost korisnika. Međutim, mali je broj Web 2.0 aplikacija koje su tijekom svojeg životnog vijeka uspjele zadržati ili povećati broj aktivnih korisnika. Naime, u posljednjih su nekoliko godina mnoge Web 2.0 aplikacije ugašene ili prenamijenjene jer su ih korisnici iz nekog razloga prestali upotrebljavati. Kako bi se utvrdilo koji pragmatični i hedonistički aspekti interakcije sa Web 2.0 aplikacijom u značajnoj mjeri doprinose zadovoljstvu i lojalnosti korisnika, u sklopu ovog doktorskog rada oblikovana je metodologija koja omogućava vrjednovanje svih relevantnih atributa kvalitete u korištenju Web 2.0 aplikacijama. Razvijena metodologija je najznačajniji znanstveni doprinos ovog doktorskog rada. Međutim, kako njeni sastavni dijelovi predstavljaju zasebne doprinose, isti će biti detaljnije razmotreni u nastavku.

8.1 Znanstveni doprinosi

Doktorski rad je rezultirao sa nekoliko značajnih znanstvenih doprinosa u području interakcije čovjeka i računala te web inženjerstva. Prvi od njih jest konačan skup relevantnih atributa kvalitete u korištenju Web 2.0 aplikacijama. Primjenom metode zatvorenog sortiranja karata, 19 istraživača i 10 web razvojnih inženjera je modificiralo početni skup od 46 atributa kvalitete u korištenju. Zatim je 14 istraživača upotrebom metode otvorenog sortiranja karata oblikovalo konačnu strukturu od 38 sadržajno valjanih atributa kvalitete u korištenju Web 2.0 aplikacijama. Na temelju navedenog je koncept kvalitete u korištenju definiran međunarodnim standardom ISO/IEC 25010 (2011) proširen atributima upotrebljivosti, kvalitete i korisničkog iskustva te konstruktima koji prema teoriji razložne akcije, teoriji planiranog ponašanja, modelu prihvaćanja tehnologije, općoj teoriji prihvaćanja i korištenja tehnologijom, modelu uspjeha informacijskog sustava i teoriji potvrđivanja očekivanja imaju značajan utjecaj na zadovoljstvo i lojalnost korisnika. Pored toga, oblikovana je definicija prema kojoj kvaliteta u korištenju predstavlja mjeru do koje pragmatični aspekti Web 2.0 aplikacije i hedonističke dimenzije interakcije sa elementima njena sučelja u određenom kontekstu upotrebe udovoljavaju određenim zahtjevima korisnika.

Sljedeći znanstveni doprinos doktorskog rada su valjani mjerni instrumenti vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama koji su ovisno o trenutku primjene svrstani u dvije skupine. U prvoj skupini se nalaze mjerni instrumenti pomoću kojih se podaci od korisnika prikupljaju tijekom upotrebe Web 2.0 aplikacije. Predstavnici prve skupine mjernih instrumenata su obrazac sa reprezentativnim koracima scenarija interakcije sa Web 2.0 aplikacijom i program specijaliziran za automatsko zapisivanje aktivnosti korisnika. Objektivni podaci se upotrebom obrasca prikupljaju na način da korisnici pored svakog reprezentativnog koraka scenarija navode u kolikoj ga mjeri mogu dovršiti pomoću specifične Web 2.0 aplikacije. Proporcija broja reprezentativnih koraka scenarija koje je korisnik uspio dovršiti primjenom određene Web 2.0 aplikacije i ukupnog broja reprezentativnih koraka u scenariju je indikator izmjerene djelotvornosti korisnika (Orehovački et al., 2012a; Orehovački et al., 2013). Navedeni je indikator ekvivalentan metrici kojom se vrjednuje dovršenost zadatka (ISO/IEC, 2004).

Količina vremena potrebna za dovršetak reprezentativnih koraka scenarija interakcije sa Web 2.0 aplikacijom indikator je učinkovitosti korisnika (Orehovački et al., 2012a; Orehovački et al., 2013) koji je istovjetan metrici vremena odaziva definiranoj standardom ISO/IEC 9126-3 (2003). S druge strane, broj tipaka na tipkovnici, udaljenost prijeđena pomicanjem miša, broj klikova mišem i broj pomicanja klizača na mišu su indikatori radnog opterećenja korisnika izmjerenog za vrijeme provedbe reprezentativnih koraka scenarija pomoću Web 2.0 aplikacije

(Orehovački et al., 2012a; Orehovački et al., 2013). Spomenuti se indikatori objektivno mjere specijaliziranim alatima kao što je Mousotron (Blacksun Software, 2012).

Jedini predstavnik druge skupine mjernih instrumenata je upitnik koji se primjenjuje nakon što korisnici dovrše sve reprezentativne korake scenarija. Upitnik je sačinjen od 117 čestica namijenjenih subjektivnom vrjednovanju aspekata kvalitete u korištenju Web 2.0 aplikacijama. Podaci se prikupljaju na način da korisnici izražavaju razinu svog slaganja sa tvrdnjom pojedine čestice preko Likertove skale od pet stupnjeva (1 – u potpunosti se slažem, 5 – uopće se ne slažem).

Pouzdan i valjan višedimenzionalan konceptualni model sačinjen od reflektivno i formativno operacionaliziranih latentnih konstrukata gdje svaki predstavlja relevantnu dimenziju kvalitete u korištenju Web 2.0 aplikacijama je još jedan od značajnih znanstvenih doprinosa doktorskog rada. Pored toga, vrlo važan doprinos jest i hibridna tehnika namijenjena vrjednovanju metrijskih karakteristika konceptualnih modela sačinjenih od višedimenzionalnih združenih latentnih konstrukata. Analizom metrijskih karakteristika vanjskih modela utvrđeno je da su vrijednosti standardiziranih faktorskih opterećenja svih reflektivnih manifestnih varijabli jednake ili veće od 0,707 što znači da svaka od njih objašnjava barem 50% varijance u temeljnom latentnom konstruktu. Pored toga, većina vrijednosti standardiziranih faktorskih opterećenja i težinskih vrijednosti formativnih manifestnih varijabli je značajna na razini $\alpha = 0{,}001$ dok su preostale vrijednosti spomenutih kriterija apsolutnog i relativnog doprinosa formativnih varijabli značajne na razinama $\alpha = 0{,}01$ i $\alpha = 0{,}05$. Prema tome, manifestne varijable koje mjere obilježja temeljnih latentnih konstrukata u konceptualnom modelu su pouzdane. Nadalje, vrijednosti koeficijenta unutarnje dosljednosti svih reflektivnih latentnih konstrukata u konceptualnom modelu su veće od 0,707 što je indikator njihove pouzdanosti. S druge strane, vrijednosti koeficijenta inflacije varijance su manje od 5, a vrijednosti koeficijenta tolerancije veće od 0,2 u slučaju svih formativnih latentnih konstrukata koji se nalaze u konceptualnom modelu što implicira njihovu pouzdanost.

Svaki reflektivni latentni konstrukt u konceptualnom modelu u prosjeku objašnjava 50% ili više (AVE > 0,50) varijance manifestnih varijabli koje su mu pridružene što ukazuje da isti udovoljavaju metrijskom kriteriju konvergentne valjanosti. Nasuprot tome, sve vrijednosti koeficijenata parcijalne regresije odnosno puteva odaslanih od formativnih latentnih konstrukata prema reflektivnim latentnim konstruktima u konceptualnom modelu su statistički značajne što potvrđuje njihovu nomološku valjanost. Jednako tako svi reflektivni latentni konstrukti koji se nalaze u konceptualnom modelu udovoljavaju kriterijima diskriminacijske valjanosti. Naime, vrijednosti standardiziranih faktorskih opterećenja svih manifestnih varijabli

sa njihovim temeljnim latentnim konstruktima su veće od vrijednosti njihovih unakrsnih opterećenja sa ostalim latentnim konstruktima u konceptualnom modelu. Osim toga, vrijednosti prosječnih ekstrahiranih varijanci svih reflektivnih latentnih konstrukata su veće od kvadriranih vrijednosti njihovih dvosmjernih korelacija sa preostalim reflektivnim latentnim konstruktima u konceptualnom modelu što znači da svaki od njih dijeli više varijance sa manifestnim varijablama koje mjere njihova obilježja nego sa ostalim reflektivnim latentnim konstruktima. Naposljetku, utvrđeno je da svi formativni latentni konstrukti udovoljavaju kriteriju diskriminacijske valjanosti jer su vrijednosti njihovih međukorelacija manje od 0,707 što implicira da isti dijele manje od 50% zajedničke varijance.

Značajan doprinos doktorskog rada su i definirane referentne vrijednosti koeficijenta determinacije. Testiranjem metrijskih karakteristika unutarnjeg modela u kontekstu četiri vrjednovane Web 2.0 aplikacije, utvrđeno je da egzogeni latentni konstrukti objašnjavaju između 15,7% i 61,8% varijance u endogenim latentnim konstruktima. Uzimajući u obzir predložene referentne vrijednosti koeficijenta determinacije kao i rezultate analize metrijskih karakteristika unutarnjeg modela svih vrjednovanih Web 2.0 aplikacija, identificirana je prediktorska snaga egzogenih latentnih konstrukata koji se nalaze u konceptualnom modelu. Dosljednost i mogućnost prilagodbe Web 2.0 aplikacije imaju malu snagu (u prosjeku $R^2 = 0{,}220$) u predikciji pamtljivosti Web 2.0 aplikacije. Razigranost korisnika, estetika Web 2.0 aplikacije i jedinstvenost Web 2.0 aplikacije imaju veliku snagu (u prosjeku $R^2 = 0{,}497$) u predikciji užitka interakcije sa Web 2.0 aplikacijom. Familijarnost i razumljivost Web 2.0 aplikacije imaju srednju snagu (u prosjeku $R^2 = 0{,}401$) u predikciji lakoće učenja korištenja Web 2.0 aplikacijom. Indikatori pomoću kojih se mjeri broj pritisnutih tipaka na tipkovnici, udaljenost prijeđena pomicanjem miša, broj klikova mišem i broj pomicanja klizača na mišu imaju srednju snagu (u prosjeku $R^2 = 0{,}348$) u predikciji zamijećenog radnog opterećenja korisnika.

Formativni konstrukt kojim se utvrđuje do koje se mjere Web 2.0 aplikacija može upotrebljavati izvan naznačenog konteksta korištenja i indikator primjenom kojeg se mjeri koliko reprezentativnih koraka scenarija korisnici mogu dovršiti upotrebom Web 2.0 aplikacije imaju srednju snagu (u prosjeku $R^2 = 0{,}438$) u predikciji zamijećene djelotvornosti korisnika. Indikator pomoću kojeg se mjeri količina vremena potrebna za dovršetak reprezentativnih koraka scenarija i formativni konstrukt kojim se mjeri radni učinak Web 2.0 aplikacije imaju veliku snagu (u prosjeku $R^2 = 0{,}488$) u predikciji zamijećene učinkovitosti korisnika. Korisnost Web 2.0 aplikacije, zadovoljstvo korisnika i stav prema korištenju imaju srednju snagu (u prosjeku $R^2 = 0{,}437$) u predikciji lojalnosti korisnika. Konstrukti kojima se vrjednuje mogućnost kontrole i upravljivost Web 2.0 aplikacijom imaju veliku snagu (u prosjeku $R^2 = 0{,}513$) u predikciji lakoće korištenja Web 2.0 aplikacijom.

Kvaliteta sustava i kvalitete usluge Web 2.0 aplikacije imaju malu snagu (u prosjeku $R^2 = 0{,}234$) u predikciji stava prema korištenju. Konstrukti pomoću kojih se utvrđuje do koje razine Web 2.0 aplikacija sprječava nastanak pogrješaka i omogućava oporavak od istih imaju malu snagu (u prosjeku $R^2 = 0{,}303$) u predikciji pouzdanosti Web 2.0 aplikacije. Produktivnost korisnika i pouzdanost Web 2.0 aplikacije imaju srednju snagu (u prosjeku $R^2 = 0{,}433$) u predikciji korisnosti Web 2.0 aplikacije. Količina napora kojeg korisnici trebaju uložiti u korištenje Web 2.0 aplikacijom i razina užitka kojeg korisnici osjećaju tijekom interakcije sa Web 2.0 aplikacijom imaju veliku snagu (u prosjeku $R^2 = 0{,}568$) u predikciji zadovoljstva korisnika. Pored navedenog, utvrđeno je da su svi koeficijenti parcijalne regresije u unutarnjem modelu statistički značajni.

Nadalje, identificirana je struktura odnosa između nezavisnih i zavisnih varijabli u konceptualnom modelu. Razigranost korisnika ima srednju prediktivnu valjanost (u prosjeku $q^2 = 0{,}28$) i veliki utjecaj (prosječno $f^2 = 0{,}41$) dok estetika i jedinstvenost Web 2.0 aplikacije imaju malu prediktivnu valjanost (u prosjeku $q^2 = 0{,}03$; $q^2 = 0{,}04$, respektivno) i mali utjecaj (prosječno $f^2 = 0{,}06$; $f^2 = 0{,}07$, respektivno) na užitak interakcije sa Web 2.0 aplikacijom. Familijarnost Web 2.0 aplikacije ima mali utjecaj (u prosjeku $f^2 = 0{,}11$) i malu valjanost u predikciji (prosječno $q^2 = 0{,}10$), a razumljivost Web 2.0 aplikacije srednji utjecaj (u prosjeku $f^2 = 0{,}21$) i srednju valjanost u predikciji (prosječno $q^2 = 0{,}17$) lakoće učenja korištenja Web 2.0 aplikacijom. Dosljednost i mogućnost prilagodbe Web 2.0 aplikacije imaju malu prediktivnu valjanost (u prosjeku $q^2 = 0{,}12$; $q^2 = 0{,}08$, respektivno) i mali utjecaj (prosječno $f^2 = 0{,}13$; $f^2 = 0{,}09$, respektivno) na pamtljivost Web 2.0 aplikacije. Mogućnost kontrole i upravljivost Web 2.0 aplikacijom imaju srednji utjecaj (u prosjeku $f^2 = 0{,}32$; $f^2 = 0{,}33$, respektivno) i srednju valjanost (prosječno $q^2 = 0{,}24$; $q^2 = 0{,}25$, respektivno) u predikciji lakoće korištenja Web 2.0 aplikacijom. Od indikatora izmjerenog radnog opterećenja korisnika, udaljenost prijeđena pomicanjem miša ima malu prediktivnu valjanost (u prosjeku $q^2 = 0{,}12$) i srednji utjecaj (prosječno $f^2 = 0{,}17$) dok broj pritisnutih tipaka na tipkovnici, broj klikova mišem i broj pomicanja klizača na mišu imaju malu prediktivnu valjanost (u prosjeku $q^2 = 0{,}07$; $q^2 = 0{,}09$; $q^2 = 0{,}09$, respektivno) i mali utjecaj (prosječno $f^2 = 0{,}10$; $f^2 = 0{,}13$; $f^2 = 0{,}14$, respektivno) na zamijećeno radno opterećenje korisnika tijekom interakcije sa Web 2.0 aplikacijom.

Razina užitka interakcije sa Web 2.0 aplikacijom ima veliki utjecaj (prosječno $f^2 = 0{,}66$) i veliku valjanost u predikciji (u prosjeku $q^2 = 0{,}44$), a količina napora uloženog u korištenje Web 2.0 aplikacijom mali utjecaj (prosječno $f^2 = 0{,}16$) i malu valjanost (u prosjeku $q^2 = 0{,}11$) u predikciji zadovoljstva korisnika. Kvaliteta sustava i kvaliteta usluge Web 2.0 aplikacije imaju mali utjecaj (prosječno $f^2 = 0{,}10$; $f^2 = 0{,}05$, respektivno) i malu valjanost (u prosjeku

$q^2 = 0{,}08$; $q^2 = 0{,}04$, respektivno) u predikciji stava prema korištenju Web 2.0 aplikacijom. Formativni latentni konstrukt kojim se provjerava do koje mjere Web 2.0 aplikacija sprječava nastanak pogrješaka ima malu prediktivnu valjanost (u prosjeku $q^2 = 0{,}11$) i srednji utjecaj (prosječno $f^2 = 0{,}15$), a formativni latentni konstrukt kojim se utvrđuje do koje se mjere Web 2.0 aplikacija može oporaviti od pogrješaka u radu ima malu prediktivnu valjanost (u prosjeku $q^2 = 0{,}10$) i mali utjecaj (prosječno $f^2 = 0{,}14$) na reflektivni latentni konstrukt namijenjen vrjednovanju pouzdanosti Web 2.0 aplikacije. Indikator kojim se mjeri koliko reprezentativnih koraka scenarija korisnici mogu dovršiti upotrebom Web 2.0 aplikacije ima veliki utjecaj (prosječno $f^2 = 0{,}43$) i srednju valjanost (u prosjeku $q^2 = 0{,}26$) u predikciji, a formativni latentni konstrukt pomoću kojeg se provjerava da li je Web 2.0 aplikaciju moguće upotrebljavati i izvan naznačenog konteksta korištenja ima mali utjecaj (prosječno $f^2 = 0{,}09$) i malu valjanost (u prosjeku $q^2 = 0{,}05$) u predikciji zamijećene djelotvornosti korisnika.

Formativni latentni konstrukt druge razine kojim se mjeri radni učinak Web 2.0 aplikacije ima malu prediktivnu valjanost (u prosjeku $q^2 = 0{,}06$) i mali utjecaj (prosječno $f^2 = 0{,}10$), a indikator primjenom kojeg se mjeri količina vremena koja je korisnicima potrebna za dovršetak reprezentativnih koraka scenarija srednju prediktivnu valjanost (u prosjeku $q^2 = 0{,}33$) i veliki utjecaj (prosječno $f^2 = 0{,}59$) na reflektivni konstrukt prve razine namijenjen vrjednovanju zamijećene učinkovitosti korisnika. Reflektivni latentni konstrukt druge razine kojim se vrjednuje produktivnost korisnika ima srednju prediktivnu valjanost (u prosjeku $q^2 = 0{,}34$) i veliki utjecaj (prosječno $f^2 = 0{,}47$), a reflektivni latentni konstrukt namijenjen mjerenju pouzdanosti Web 2.0 aplikacije malu prediktivnu valjanost (u prosjeku $q^2 = 0{,}03$) i mali utjecaj (prosječno $f^2 = 0{,}04$) na reflektivni latentni konstrukt prve razine kojim se vrjednuje korisnost Web 2.0 aplikacije. Naposljetku, korisnost Web 2.0 aplikacije, stav prema korištenju Web 2.0 aplikacijom i zadovoljstvo korisnika imaju mali utjecaj ($f^2 = 0{,}03$; $f^2 = 0{,}10$; $f^2 = 0{,}11$, respektivno) i malu valjanost ($q^2 = 0{,}02$; $q^2 = 0{,}06$; $q^2 = 0{,}07$, respektivno) u predikciji lojalnosti korisnika.

Relevantan doprinos doktorskog rada predstavljaju i elementarni kriteriji pomoću kojih se utvrđuje u kolikoj mjeri Web 2.0 aplikacije udovoljavaju zahtjevima objektivnih (indikatora) i subjektivnih (čestica u upitniku) metrika. Dok vrijednost elementarnog kriterija indikatora izmjerene djelotvornosti treba na skali elementarnih preferenci biti što veća, nužno je da vrijednosti elementarnih kriterija čestica, indikatora izmjerene učinkovitosti korisnika i indikatora izmjerenog radnog opterećenja korisnika na skali elementarnih preferencija budu što manje.

Stablo zahtjeva koje temeljem vrijednosti elementarnih kriterija te relevantnosti i težinskih vrijednosti varijabli performansi omogućava izračun vrijednosti elementarnih preferencija i kompozitnog indeksa kvalitete u korištenju Web 2.0 aplikacijama također predstavlja značajan doprinos doktorskog rada. Dok vrijednosti elementarnih preferencija odražavaju razinu do koje je Web 2.0 aplikacija udovoljila zahtjevima varijabli performansi ili specifičnom podsustavu kvalitete u korištenju, globalna preferencija odnosno kompozitni indeks predstavlja mjeru do koje je Web 2.0 aplikacija udovoljila svim zahtjevima kvalitete u korištenju. Prema tome, stablo zahtjeva omogućuje učinkovitu komparaciju vrjednovanih Web 2.0 aplikacija na svim razinama granularnosti. Jednako tako, stablo zahtjeva olakšava identifikaciju problema kvalitete u korištenju Web 2.0 aplikacijama. Pod problemom kvalitete u korištenju se podrazumijeva svaka varijabla performansi čijem zahtjevu Web 2.0 aplikacija nije udovoljila u dostatnoj mjeri. Navedeno se odnosi na pragmatične i na hedonističke zahtjeve o kojima ovisi uspjeh Web 2.0 aplikacije. Naime, analizom rezultata vrjednovanja obje skupine Web 2.0 aplikacija utvrđeno je da su glavni uzrok niskog stupnja lojalnosti korisnika i osrednje razine zadovoljstva korisnika činjenica što iste nisu u dostatnoj mjeri udovoljile zahtjevima podsustava varijabli performansi pomoću kojih se vrjednuje razigranost korisnika, jedinstvenost Web 2.0 aplikacije, užitak interakcije sa Web 2.0 aplikacijom, učinkovitost korisnika, djelotvornost korisnika i radno opterećenje korisnika.

Posljednji značajan znanstveni doprinos ovog doktorskog rada su smjernice i preporuke koje se mogu primijeniti u različitim fazama životnog ciklusa Web 2.0 aplikacije. Dok smjernice predstavljaju zahtjeve kvalitete u korištenju kojima Web 2.0 aplikacija treba obavezno udovoljiti, preporuke su zahtjevi kvalitete u korištenju za koje je poželjno da im Web 2.0 aplikacija udovoljava. Web razvojni inženjeri mogu zahtjeve endogenih smjernica i preporuka implementirati tijekom dizajna i razvoja Web 2.0 aplikacije. Međutim, kako egzogene smjernice i preporuke predstavljaju posljedicu korisničkog iskustva, web razvojni inženjeri na njihove zahtjeve nemaju direktan utjecaj već trebaju utvrditi u kolikoj im mjeri Web 2.0 aplikacija udovoljava kako bi temeljem podataka prikupljenih od korisnika mogli donositi odluke o daljnjem razvoju iste.

Spomenuti ishodi doktorskog rada predstavljaju vrijedan instrumentarij koji je u jednakoj mjeri koristan web razvojnim inženjerima i istraživačima. Web razvojni inženjeri mogu upotrijebiti konceptualni model kao predložak za izradu specifikacije zahtjeva korisnika, primijeniti mjerne instrumente u vrjednovanju svih ili odabranih aspekata kvalitete u korištenju Web 2.0 aplikacijama te slijediti smjernice i preporuke tijekom razvoja Web 2.0 aplikacija. Identificirani atributi kvalitete u korištenju mogu poslužiti kao teorijsko uporište za provedbu novih istraživanja u domeni vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama. Pored toga,

istraživači mogu primijeniti metodologiju vrjednovanja na uzorku Web 2.0 aplikacija iste ili druge namjene. Nadalje, istraživači u različitim područjima informacijskih i komunikacijskih znanosti mogu upotrijebiti identificirane referentne vrijednosti koeficijenta determinacije za utvrđivanje intenziteta prediktorske snage egzogenih varijabli u konceptualnom modelu. Konačno, istraživači iz bilo kojeg znanstvenog područja mogu primijeniti hibridnu tehniku modeliranja višedimenzionalnih združenih latentnih konstrukata u svrhu testiranja metrijskih karakteristika konceptualnih modela koji su od istih sačinjeni.

8.2 Ograničenja istraživanja

Tijekom interpretacije znanstvenih doprinosa potrebno je u obzir uzeti nekoliko ograničenja istraživanja. Prvo ograničenje je vezano uz uzorak sudionika u istraživanju. U oba se eksperimenta uzorak sudionika sastojao od studenata koji su primjenom Web 2.0 aplikacija izvršavali reprezentativne korake scenarija. Sudionici su se unutar uzorka međusobno razlikovali prema studiju kojeg pohađaju, iskustvu u radu sa računalom i korištenju Internetom, učestalosti i intenzitetu korištenja Internetom te učestalosti korištenja Web 2.0 aplikacijama. Međutim, uzorci su bili homogeni prema zanimanju i dobnoj strukturi sudionika. Pored toga, uzorci sudionika su bili prigodni jer su u istraživanje bili uključeni samo oni studenti kojima su autor doktorskog rada i moderatori provedbe istraživanja držali nastavu. Zbog toga je uputno provesti dodatno istraživanje kako bi se utvrdilo da li se rezultati vrjednovanja značajno razlikuju ako je uzorak sudionika randomiziran i sačinjen od predstavnika heterogenih skupina korisnika.

Sljedeće ograničenje se odnosi na uzorak vrjednovanih Web 2.0 aplikacija. Provedbom tri pilot istraživanja i dva eksperimenta utvrđeno je da postoji opći skup atributa kvalitete u korištenju namijenjen vrjednovanju različitih vrsta Web 2.0 aplikacija. Međutim, svaka skupina Web 2.0 aplikacija ima svoje specifičnosti koje u određenoj mjeri utječu na globalnu preferenciju kvalitete u korištenju te ih je shodno tome potrebno vrjednovati. Iz navedenog proizlazi da ishode doktorskog rada nije moguće generalizirati na sve vrste Web 2.0 aplikacija već samo one koje su namijenjene izradi i upravljanju artefaktima poput online uredskih paketa, aplikacija za organizaciju i upravljanje znanjem, aplikacija namijenjenih podcastingu te društvenih mreža. Prema tome, potrebno je istražiti da li postoje atributi kvalitete u korištenju koji značajno doprinose kvaliteti u korištenju preostalim vrstama Web 2.0 aplikacija, a da nisu obuhvaćeni metodologijom koja je razvijena u sklopu doktorskog rada.

8.3 Smjernice za buduća istraživanja

Ishodi doktorskog rada otvorili su mogućnosti za nova istraživanja. Na osnovi podataka prikupljenih tijekom provedbe metode sortiranja karata utvrđeno je da stručnjaci domene smatraju kako je kvalitetu artefakata kreiranih primjenom Web 2.0 aplikacija potrebno mjeriti, ali ne kao sastavni dio metodologije vrjednovanja kvalitete u korištenju Web 2.0 aplikacijama već zasebno. Glavni razlog tome je što korisnici ne mogu objektivno procijeniti kvalitetu artefakata koje su kreirali. Stoga će daljnje istraživanje jednim svojim dijelom biti usmjereno na razvoj metodologije koja će omogućavati identifikaciju i vrjednovanje svih relevantnih aspekata kvalitete artefakata kreiranih pomoću Web 2.0 aplikacija. U tom će se slučaju uzorak sudionika sastojati od dvije skupine korisnika – prva će kreirati artefakte, a druga vrjednovati njihovu kvalitetu u određenom kontekstu upotrebe.

Veze u konceptualnom modelu su pretpostavljene temeljem pregleda literature i rezultata hijerarhijske klaster analize. Obzirom da je riječ o kompleksnom modelu, brojni su odnosi između atributa kvalitete u korištenju Web 2.0 aplikacijama ostali neistraženi. Zbog toga će u daljnjem istraživanju biti analizirane metrijske karakteristike konceptualnog modela koji će biti sačinjen od novog skupa pretpostavljenih veza. Primjerice, biti će testirano u kolikoj mjeri familijarnost i razumljivost Web 2.0 aplikacije doprinose pamtljivosti i lakoći korištenja Web 2.0 aplikacijom, da li užitak interakcije sa Web 2.0 aplikacijom ima značajan direktan utjecaj na lojalnost korisnika i slično.

Iz rezultata provedenih eksperimenata je vidljivo da su objektivne metrike osjetljivije na razinu zadovoljenja elementarnih kriterija od subjektivnih metrika. Ukoliko se u obzir uzmu rezultati vrjednovanja sve četiri Web 2.0 aplikacije, evidentno je da su iste u manjoj mjeri udovoljile zahtjevima koji su definirani indikatorima od zahtjeva koji su specificirani česticama upitnika. Zbog navedenog će daljnje istraživanje biti usmjereno na razvoj dodatnog skupa objektivnih metrika koji će proširiti repozitorij mjernih instrumenata namijenjenih vrjednovanju kvalitete u korištenju Web 2.0 aplikacijama.

LITERATURA

Abdinnour-Helm, S.F., Chaparro, B.S., Farmer, S.M.: Using the End-User Computing Satisfaction (EUCS) Instrument to Measure Satisfaction with a Web Site. Decision Sciences, vol. 36, no. 2, pp. 341-364 (2005)

Abels, E.G., White, M.D., Hahn, K.: A user-based design process for Web sites. OCLC Systems & Services, vol. 15, no. 1, pp. 35 – 44 (1999)

Abran, A., Khelifi, A., Suryn, W., Seffah, A.: Usability meanings and interpretations in ISO standards. Software Quality Journal, vol. 11, no. 4, pp. 325–338 (2003)

Agarwal, R., Prasad, J.: The Role of Innovation Characteristics and Perceived Voluntariness in the Acceptance of Information Technologies. Decision Sciences, vol. 28, no. 3, pp. 557-582 (1997)

Agarwal, R.,Venkatesh, V.: Assessing a firm's Web presence: A heuristic evaluation procedure for the measurement of usability. Information Systems Research, vol. 13, no. 2, pp. 168–186 (2002)

Ahn, T., Ryu, S., Han, I.: The impact of Web quality and playfulness on user acceptance of online retailing. Information & Management, vol. 44, no. 3, pp. 263–275 (2007)

Ahuja, J.S., Webster, J.: Perceived disorientation: An examination of a new measure to assess web design effectiveness. Interacting with Computers, vol. 14, no. 1, pp. 15–29 (2001)

Aivalis, C.J., Boucouvalas, A.C.: Log File Analysis of E-commerce Systems in Rich Internet Web 2.0 Applications. In: 15th Panhellenic Conference on Informatics, pp. 222-226. IEEE Press, Kastoria (2011)

Ajzen, I., Fishbein, M.: Understanding Attitudes and Predicting Social Behavior. Prentice-Hall, Englewood Cliffs (1980)

Ajzen, I.: From intentions to actions: A theory of planned behavior. In: Kuhi, J., Beckmann, J. (eds.) Action-control: From cognition to behavior, pp. 11-39. Springer, Heidelberg (1985)

Ajzen, I.: The Theory of Planned Behavior. Organizational Behavior and Human Decision Processes, vol. 50, no. 2, pp. 179-211 (1991)

Aladwani, A.M., Palvia, P.C.: Developing and validating an instrument for measuring user-perceived web quality. Information & Management, vol. 39, no. 6, pp. 467–476 (2002)

Alben, L.: Quality of experience: defining the criteria for effective interaction design. Interactions, vol. 3, no. 3, pp. 11-15 (1996)

Albers, S.: PLS and Success Factor Studies in Marketing. In: Esposito Vinzi, V., Chin, W. W., Henseler, J., Wang, H. (eds.), Handbook of Partial Least Squares, pp. 411–427. Springer, Heidelberg (2010)

Alkhattabi, M., Neagu, D., Cullen, A.: Assessing information quality of e-learning systems: a web mining approach. Computers in Human Behavior, vol. 27, no. 2, pp. 862–873 (2011),

Almeida, J.M., Gonçalves, M.A., Figueiredo, F., Pinto, H., Belém, F.: On the Quality of Information for Web 2.0 Services. IEEE Internet Computing, vol. 14, no. 6, pp. 47–55 (2010)

Alonso-Ríos, D., Vázquez-García, A., Mosqueira-Rey, E., Moret-Bonillo, V.: Usability: A Critical Analysis and a Taxonomy. International Journal of Human-Computer Interaction, vol. 26, no. 1, pp. 53-74 (2010)

Alsaghier, H., Ford, M., Nguyen, A., Hexel, R.: Conceptualising Citizen's Trust in e-Government: Application of Q Methodology. Electronic Journal of e-Government, vol. 7, no. 4, pp. 295–310 (2009)

Altman, D.G.: Practical Statistics for Medical Research. Chapman & Hall, London (1991)

Alva, M.E., , Martínez, A.B., del Carmen Suárez, M., Labra, J.E., Cueva, J.M., Sagástegui, H.: Towards the evaluation of usability in educative websites. International Journal of Technology Enhanced Learning, vol. 2, no. 1/2, pp. 145-161 (2010)

Al-Badi, A.H., Mayhew, P.J.: A Framework for Designing Usable Localised Business Websites. Communications of the IBIMA, p. 24 (2010), preuzeto 22. lipnja 2013. sa <http://www.ibimapublishing.com/journals/CIBIMA/2010/184405/184405.pdf>

Anastasi, A., Urbina, S.: Psychological testing. Pearson, Upper Saddle River (1997)

Anderson, P.: What is Web 2.0? Ideas, technologies and implications for education. JISC Technology and Standards Watch, p. 64 (2007) preuzeto 27. lipnja 2013. sa <http://www.jisc.ac.uk/media/documents/techwatch/tsw0701b.pdf>

Atkinson, M., Kydd, C.: Individual characteristics associated with World-Wide-Web use: an empirical study of playfulness and motivation. ACM SIGMIS Database, vol. 28, no. 2, pp. 53-62 (1997)

Augen, J.: Trading Realities: the truth, the lies, and the hype in-between. Pearson Education, New Jersey (2011)

Babić, Z.: Modeli i metode poslovnog odlučivanja. Ekonomski fakultet, Split (2011)

Bagozzi, R.P.: Structural equation models in marketing research: Basic principles. In: Bagozzi, R.P. (ed.) Principles of marketing research, pp. 317–385. Blackwell, Oxford (1994)

Bagozzi, R.P., Yi, Y.: On the evaluation of structural equation models. Journal of the Academy of Marketing Science, vol. 16, no. 1, pp. 74–94 (1988)

Bangor, A., Kortum, P.T., Miller, J.T.: An Empirical Evaluation of the System Usability Scale. International Journal of Human-Computer Interaction, vol. 24, no. 6, pp. 574-594 (2008)

Barclay, D.W., Higgins, C.A., Thompson, R.: The partial least squares approach to causal modeling: personal computer adoption and use as illustration. Technology Studies, vol. 2, no. 2, pp. 285–309 (1995)

Bargas-Avila, J.A., Hornbæk, K.: Old Wine in New Bottles or Novel Challenges? A Critical Analysis of Empirical Studies of User Experience. In: 29th ACM SIGCHI Conference on Human Factors in Computing Systems, pp. 2689-2698. ACM, Vancouver (2011)

Barnes, S.J.: Understanding use continuance in virtual worlds: Empirical test of a research model. Information & Management, vol. 48, no. 8, pp. 313–319 (2011)

Barnes, S.J., Vidgen, R.: Measuring web site quality improvements: a case study of the forum on strategic management knowledge exchange. Industrial Management & Data Systems, vol. 103, no. 5, pp. 297-309 (2003)

Basili, V.R., Weiss, D.M.: A Methodology for Collecting Valid Software Engineering Dana. IEEE Transactions on Software Engineering, vol. SE-10, no. 6, pp. 728-738 (1984)

Bastien, J.M.C, Scapin, D.L.: Ergonomic Criteria for the Evaluation of Human-Computer Interfaces. Technical Report No. 156 (1993), preuzeto 22. lipnja 2013. sa <http://www.webmaestro.gouv.qc.ca/publications/archives/webeducation1998-2004/2000-11/criteres.pdf>

Basu, A.: Context-Driven Assessment of Commercial Web Sites. In: 36th Hawaii International Conference on SystemSciences, p. 1-8. IEEE, Waikoloa Village (2003)

Batini, C., Cappiello, C., Francalanci, C., Maurino, A.: Methodologies for Data Quality Assessment and Improvement. ACM Computing Surveys, vol. 41, no. 3, DOI: 10.1145/1541880.1541883 (2009)

Beach, L.R., Mitchell, T.R.: The Basics of Image Theory. In: Beach, L.R. (ed.) Image Theory: Theoretical and Empirical Foundations, pp. 3-18. Lawrence Erlbaum, Mahwah (1998)

Becker, J-M., Klein, K., Wetzels, M.: Hierarchical Latent Variable Models in PLS-SEM: Guidelines for Using Reflective-Formative Type Models. Long Range Planning, vol. 45, no. 5-6, pp. 359-394 (2012)

Becker, S.A., Berkemeyer, A.: Rapid Application Design and Testing of Web Usability. IEEE MultiMedia, vol. 9, no. 4, pp. 38-46 (2002)

Becker, S.A., Mottay, F.E.: A Global Perspective on Web Site Usability. IEEE Software, vol. 18, no. 1, pp. 54-61 (2001)

Beebe, K.R., Pell, R.J., Seasholtz, M.B.: Chemometrics: A practical guide. Wiley, New York (1998)

Bennett, J.L.: The commercial impact of usability in interactive systems. In: Shackel, B. (ed.), Man–Computer Communication, Infotech State of the Art Report, vol. 2. Infotech International, Maidenhead (1979)

Berners-Lee, T.: Information Management: A Proposal (1989), preuzeto 30. travnja 2012. sa <http://www.w3.org/History/1989/proposal.html>

Berners-Lee, T.: Weaving the Web: The Original Design and Ultimate Destiny of the World Wide Web by Its Inventor, HarperCollins Publishers, New York (1999)

Berners-Lee, T., Cailliau, R.: WorldWideWeb: Proposal for a HyperText Project (1990), preuzeto 30. travnja 2012. sa <http://www.w3.org/History/19921103-hypertext/hypertext/WWW/Proposal.html>

Berners-Lee, T., Cailliau, R., Groff, J-F., Pollermann, B.: World-Wide Web: The Information Universe. Electronic Networking, vol. 2, no. 1, pp. 52-58 (1992)

Berners-Lee, T., Cailliau, R., Luotonen, A., Nielsen, H.F., Secret, A.: The World-Wide Web. Communications of the ACM, vol. 37, no. 8, pp. 76-82 (1994)

Berners-Lee, T., Connolly, D.: Hypertext Markup Language - 2.0 (1995), preuzeto 12. srpnja 2012. sa <http://ftp.ics.uci.edu/pub/ietf/html/rfc1866.txt>

Bertoa, M.F., Troya, J.M., Vallecillo, A.: Measuring the usability of software components. The Journal of Systems and Software, vol. 79, no. 3, 427–439 (2006)

Bevan, N.: Extending Quality in Use to Provide a Framework for Usability Measurement. In: Kurosu, M. (ed.) HCD 2009. Lecture Notes in Computer Science, vol. 5619, pp. 13–22. Springer, Heidelberg (2009a)

Bevan, N.: What is the difference between the purpose of usability and user experience evaluation methods? In: UXEM Workshop, Uppsala, Sweden (2009b), preuzeto 25. lipnja 2013. sa <http://www.nigelbevan.com/papers/What_is_the_difference_between_usability_and_user_experience_evaluation_methods.pdf>

Bevan, N., Kirakowski, J., Maissel, J.: What is usability? In: 4th International Conference on HCI (1991), preuzeto 1. lipnja 2012. sa <http://www.nigelbevan.com/papers/whatis92.pdf>

Bhattacherjee, A.: An empirical analysis of the antecedents of electronic commerce service continuance. Decision Support Systems, vol. 32, no. 2, pp. 201–214 (2001a)

Bhattacherjee, A.: Understanding Information Systems Continuance: An Expectation-Confirmation Model. MIS Quarterly, vol. 25, no. 3, pp. 351-370 (2001b)

Bias, R.: Interface-Walkthroughs: Efficient Collaborative Testing. IEEE Software, vol. 8, no. 5, pp. 94-95 (1991)

BitPipe: User experience (2013), preuzeto 25. lipnja 2013. sa <http://www.bitpipe.com/tlist/User-Experience.html>

Black, N.J., Lockett, A., Ennew, C., Winklhofer, H., McKechnie, S.: Modelling consumer choice of distribution channels: an illustration from financial services. International Journal of Bank Marketing, vol. 20, no. 4, pp. 161–173 (2002)

Blacksun Software: Mousotron - Mouse and Keyboard Usage Measurement (2012), preuzeto 26. lipnja 2012. sa <http://www.blacksunsoftware.com/mousotron.html>

Blythe, M., Hassenzahl, M.: The semantics of fun: Differentiating enjoyable experiences. In:. Blythe, M.A., Overbeeke, K., Monk, A.F., Wright, P.C. (eds.), Funology: From Usability to Enjoyment, pp. 91-100. Kluwer Academic Publishers, Dordrecht (2003)

Bollen, K.A.: Structural equations with latent variables. Wiley, New York (1989)

Bollen, K.A., Davis, W.R.: Causal Indicator Models: Identification, Estimation, and Testing. Structural Equation Modeling: A Multidisciplinary Journal, vol. 16, no. 3, pp. 498-522 (2009)

Bollen, K.A., Lennox, R.: Conventional Wisdom on Measurement: A Structural Equation Perspective. Psychological Bulletin, vol. 110, no. 2, pp. 305–314 (1991)

Boudreau, M., Gefen, D., Straub, D.: Validation in IS Research: A State-of-the-Art Assessment. MIS Quarterly, vol. 25, no. 1, pp. 1-23 (2001)

Bovee, M., Srivastava, R.P., Mak, B.: A conceptual framework and belief-function approach to assessing overall information quality. International Journal of Intelligent Systems, vol. 18, no. 1, pp. 51-74 (2003)

Brady, L., Phillips, C.: Aesthetics and usability: A look at color and balance. Usability News (2003) preuzeto 21. lipnja 2013. sa < http://usabilitynews.org/aesthetics-and-usability-a-look-at-color-and-balance/>

Brin, S., Page, L.: The anatomy of a large-scale hypertextual Web search engine. Computer Networks and ISDN Systems, vol. 30, no. 1-7, pp. 107-117 (1998)

Brinck, T. Gergle, D., Wood, S.D.: Designing Web sites that work: Usability for the Web. Morgan Kaufmann, San Francisco (2002)

Brooke, J.: SUS: a „quick and dirty" usability scale. In: Jordan, P.W., Thomas, B., Weerdmeester, B.A., McClelland, I.L. (eds.) Usability Evaluation in Industry, pp. 189-194. Taylor and Francis, London (1996)

Brown, A., Jay, C., Chen, A. Q., Harper, S.: The uptake of Web 2.0 technologies, and its impact on visually disabled users. Universal Access in the Information Society, vol. 11, no. 2, pp. 185-199 (2012)

Brown, I.T.J.: Individual and Technological Factors Affecting Perceived Ease of Use of Web-based Learning Technologies in a Developing Country. The Electronic Journal on Information Systems in Developing Countries, vol. 9, no. 5, pp. 1-15 (2002)

Brynjolfsson, E.: The contribution of information technology to consumer welfare. Information Systems Research, vol. 7, no. 3, pp. 281– 300 (1996)

Buckley, G., Dujmović, J.J.: Interfacing the System Evaluation Method LSP with E-commerce Web Sites. ComSIS, vol. 5, no. 1, pp. 25-40 (2008)

Calero, C., Ruiz, J., Piattini, M.: Classifying web metrics using the web quality model. Online Information Review, vol. 29, no. 3, pp. 227-248 (2005)

Caplan, S.: Using focus groups methodology for ergonomic design. Ergonomics, vol. 33, no. 5, pp. 527-533 (1990)

Cappel, J.J., Huang, Z.: A usability analysis of company websites. Journal of Computer Information Systems, vol. 48, no. 1, pp. 117-123 (2007)

Cappiello, C., Daniel, F., Matera, M., Pautasso, C.: Information Quality in Mashups. IEEE Internet Computing, vol. 14, no. 4, pp. 14-22 (2010)

Cappiello, C., Daniel, F., Koschmider, A., Matera, M., Picozzi, M.: A Quality Model for Mashups. In: Auer, S., Diaz, O., Papadopoulos, G.A. (eds.), ICWE 2011. Lecture Notes in Computer Science, vol. 6757, pp. 137–151. Springer, Heidelberg (2011)

Caruana, A., Ewing, M.T.: How corporate reputation, quality, and value influence online loyalty. Journal of Business Research, vol. 63, no. 9-10, pp. 1103–1110 (2010)

Casaló, L., Flavián, C., Guinalíu, M.: The role of perceived usability, reputation, satisfaction and consumer familiarity on the website loyalty formation process. Computers in Human Behavior, vol. 24, no. 2, pp. 325–345 (2008)

Cassel, C.M, Hackl, P., Westlund, A.H.: Robustness of partial least-squares method for estimating latent variable quality structures. Journal of Applied Statistics, vol. 26, no. 4, pp. 435–446 (1999)

Cassel, C.M., Hackl, P., Westlund, A.H.: On measurement of intangible assets: A study of robustness of partial least squares. Total Quality Management, vol. 11, no. 7, pp. 897–907 (2000)

Castañeda, J.A., Muñoz-Leiva, F., Luque, T.: Web Acceptance Model (WAM): Moderating effects of user experience. Information & Management, vol. 44, no. 4, pp. 384–396 (2007)

Cenfetelli, R.T., Bassellier, G.: Interpretation of Formative Measurement in Information Systems Research. MIS Quarterly, vol. 33, no. 4, pp. 689-707 (2009)

Chang, S.E., Chen, S-Y., Liu, Y-H.: A user study of accessing web applications via voice cellular phone: a model comparison approach. Behaviour & Information Technology, vol. 28, no. 5, pp. 471-484 (2009)

Chen, C.-W.D., Cheng, C.-Y.J.: Understanding consumer intention in online shopping: a respecification and validation of the DeLone and McLean model. Behaviour & Information Technology, vol. 28, no. 4, pp. 335-345 (2009)

Cheung, C.M.K., Lee, M.K.O.: The Asymmetric Effect of Website Attribute Performance on Satisfaction: An Empirical Study. In: 38th Hawaii International Conference on System Sciences, p. 1-10. IEEE, Waikoloa Village (2005)

Chin, J.P., Diehl, V.A., Norman, K.L.: Development of an Instrument Measuring User Satisfaction of the Human-Computer Interface. In: Conference on Human Factors in Computing Systems, pp. 213-218. ACM, Washington (1988)

Chin, W.W.: The partial least squares approach to structural equation modeling. In: Marcoulides, G.A. (ed.), Modern Methods for Business Research, pp. 295–358. Lawrence Erlbaum Associates, Mahwah (1998)

Chin, W.W.: How to Write Up and Report PLS Analyses. In: Esposito Vinzi, V., Chin, W.W., Henseler, J., Wang, H. (eds.), Handbook of Partial Least Squares, pp. 655-690. Springer, Heidelberg (2010)

Chin, W.W., Gopal, A.: Adoption intention in GSS: Relative importance of beliefs. ACM SIGMIS Database, vol. 26, no. 2-3, pp. 42–64 (1995)

Chin, W.W., Marcolin, B.L., Newsted, P.R.: A partial least squares latent variable modeling approach for measuring interaction effects: Results from a monte carlo simulation study and an electronic-mail emotion/adoption study. Information Systems Research, vol. 14, no. 2, pp, 189–217 (2003)

Chin, W.W., Newsted, P.R.: Structural equation modeling analysis with small samples using partial least squares. In: Hoyle, R.H. (ed.), Statistical strategies for small sample research, pp. 307–341. Sage Publications, Thousand Oaks (1999)

Chiu, C-M., Lin, H-Y., Sun, S-Y., Hsu, M-H.: Understanding customers' loyalty intentions towards online shopping: an integration of technology acceptance model and fairness theory. Behaviour & Information Technology, vol. 28, no. 4, pp. 347-360 (2009)

Churchill, G.A., Jr.: A Paradigm for Developing Better Measures of Marketing Constructs. Journal of Marketing Research, vol. 16, no. 1, pp. 64–73 (1979)

Ciavolino, E., Nitti, M.: Using the Hybrid Two-Step estimation approach for the identification of second-order latent variable models. Journal of Applied Statistics, vol. 40, no. 3, pp. 508-526 (2013)

Clemons, E.K., Reddi, S.P., Row, M.C.: The impact of information technology on the organization of economic activity: The „move to the middle" hypothesis. Journal of Management Information Systems, vol. 10, no. 2, pp. 9–35 (1993)

Cohen, J.: A coefficient of agreement for nominal scales. Educational and Psychological Measurement, vol. 20, no. 1, pp. 37-46 (1960)

Cohen, J.: Statistical power analysis for the behavioral sciences. Lawrence Erlbaum Associates, Hillsdale (1988)

Cohen, J., Cohen, P., West, S.G., Aiken, L.S.: Applied Multiple Regression/Correlation Analysis for the Behavioral Sciences. Lawrence Erlbaum Associates, Mahwah (2002)

Cohen, P., Cohen, J., Teresi, J., Marchi, M., Velez, C. N.: Problems in the measurement of latent variables in structural equations causal models. Applied Psychological Measurement, vol. 14, no. 2, pp. 183–196 (1990)

Colbert, M.: User experience of communication before and during rendezvous: interim results. Personal and Ubiquitous Computing, vol. 9, no. 3, pp. 134-141 (2005)

Conger, A.J.: Integration and Generalization of Kappas for Multiple Raters. Psychological Bulletin, vol. 88, no. 2, pp. 322-328 (1980)

Connolly, D.: A Little History of the World Wide Web (2000), preuzeto 1. svibnja 2012. sa <http://www.w3.org/History.html>

Constantine, L.L., Lockwood, L.A.D.: Software for Use: A Practical Guide to the Models and Methods of Usage-Centered Design. ACM, Boston (1999)

Covella, G., Olsina, L.: Assessing Quality in Use in a Consistent Way. In: 6th International Conference on Web Engineering, pp. 1-8. ACM, Palo Alto (2006)

Cox, J., Dale, B.G.: Key quality factors in Web site design and use: an examination. International Journal of Quality & Reliability Management, vol. 19, no. 7, pp. 862-888 (2002)

Craney, T.A., Surles, J.G.: Model-Dependent Variance Inflation Factor Cutoff Values. Quality Engineering, vol. 14, no. 3, pp. 391–403 (2002)

Cronbach, L.J.: Coefficient alpha and the internal structure of tests. Psychometrika, vol. 16, no. 3, pp. 297–334 (1951)

Csikszentmihalyi, M.: Beyond Boredom and Anxiety. Jossey-Bass, San Francisco (1975)

Cyr, D., Hassanein, K., Head, M., Ivanov, A.: The role of social presence in establishing loyalty in e-service environments. Interacting with Computers, vol. 19, no. 1, pp. 43–56 (2007)

Cyr, D., Head, M., Ivanov, A.: Perceived interactivity leading to e-loyalty: Development of a model for cognitive–affective user responses. International Journal of Human-Computer Studies, vol. 67, no. 10, pp. 850–869 (2009)

Davis, F.D.: Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. MIS Quarterly, vol. 13, no. 3, pp. 319-340 (1989)

Davis, F.D., Bagozzi, R.P., Warshaw, P.R.: User Acceptance of Computer Technology: A Comparison of Two Theoretical Models. Management Science, vol. 35, no. 8, pp. 982-1003 (1989)

Debnath, N., Dasso, A., Funes, A., Uzal, R., Paganini, J.: E-government Services Offerings Evaluation Using Continuous Logic. In: IEEE/ACS International Conference on Computer Systems and Applications (AICCSA), pp. 886-892. IEEE, Amman (2007)

DeLone, W.H., McLean, E.R.: Information systems success: The quest for the dependent variable. Information Systems Research, vol. 3, no. 1, pp. 60–95 (1992)

DeLone, W.H., McLean, E.R.: The DeLone and McLean Model of Information Systems Success: A Ten-Year Update. Journal of Management Information Systems, vol. 19, no. 4, pp. 9–30 (2003)

DeLone, W.H., McLean, E.R.: Measuring e-Commerce Success: Applying the DeLone & McLean Information Systems Success Model. International Journal of Electronic Commerce, vol. 9, no. 1, pp. 31–47 (2004)

De Sarkar, T. Impact of online interactivity dimensions on library website quality. Annals of Library and Information Studies, vol. 59, no.4, pp. 231-239 (2012)

Desmet. P. M. A., Hekkert. P.: Framework of product experience. International Journal of Design, vol. 1, no. 1, pp. 57-66 (2007)

De Wulf, K., Schillewaert, N., Muylle, S., Rangarajan, D.: The role of pleasure in web site success, Information & Management, vol. 43, no. 4, pp. 434-446 (2006)

Dholakia, R.R., Miao, Z., Dholakia, N., Fortin, D.R.: Interactivity and revisits to websites: a theoretical framework. RITIM Working Paper (2000), preuzeto 21. lipnja 2013. sa <http://ritim.cba.uri.edu/wp2001/wpdone3/interactivity.pdf>

Diamantopoulos, A.: The error term in formative measurement models: Interpretation and modeling implications. Journal of Modelling in Management, vol. 1, no. 1, pp. 7–17 (2006)

Diamantopoulos, A., Riefler, P., Roth, K.P.: Advancing formative measurement models. Journal of Business Research, vol. 61, no. 12, pp. 1203–1218 (2008)

Diamantopoulos, A., Siguaw, J.A.: Formative Versus Reflective Indicators in Organizational Measure Development: A Comparison and Empirical Illustration. British Journal of Management, vol. 17, no. 4, pp. 263–282 (2006)

Diamantopoulos, A., Winklhofer, H.M.: Index Construction with Formative Indicators: An Alternative to Scale Development. Journal of Marketing Research, vol. 38, no. 2, pp. 269-277 (2001)

Diaper, D.: Task observation for human-eomputer interaction. In: Diaper, D. (ed.), Task Analysis for Human-Computer Interaction, pp. 210-237. Ellis Horwood, Chichester (1989)

Digital Analytics Association: The Official DAA Definition of Web Analytics (2006), preuzeto 26. lipnja 2012. sa <http://www.digitalanalyticsassociation.org/?page=aboutus>

Dijkstra, T.K.: Latent Variables and Indices: Herman Wold's Basic Design and Partial Least Squares. In: Esposito Vinzi, V., Chin, W.W., Henseler, J., Wang, H. (eds.), Handbook of Partial Least Squares, pp. 23-46. Springer, Heidelberg (2010)

Dix, A., Finlay, J., Abowd, G.D., Beale, R.: Human-Computer Interaction, Third Edition. Prentice-Hall, Haddington (2004)

Doerr, J., Hartkopf, S., Kerkow, D., Landmann, D., Amthor, P.: Built-in User Satisfaction – Feature Appraisal and Prioritization with AMUSE. Proceedings of the 15th IEEE International Requirements Engineering Conference, pp. 101-110. IEEE, Delhi (2007)

Doll, W.J., Torkzadeh, G.: The measurement of end-user computing satisfaction. MIS Quarterly, vol. 12, no. 2, pp. 259–274 (1988)

Downes, S.: E-learning 2.0. eLearn Magazine – Education and Technology in Perspective (2005), preuzeto 13. veljače 2011. sa <http://www.elearnmag.org/subpage.cfm?section=articles&article=29-1>

Drennan, J., Kennedy, J., Pisarski, A.: Factors affecting student attitudes toward flexible online learning in management education. Journal of educational research, vol. 98, no. 6 pp. 331-338 (2005)

Duchowski, A.T.: Eye Tracking Methodology: Theory and Practice, Second edition. Springer-Verlag, London (2007)

Dujmović, J.J.: Weighted conjunctive and disjunctive means and their application in system evaluation. Publikacije Elektrotehničkog fakulteta Univerziteta u Beogradu, Serija: Matematika i Fizika, no. 461-497, pp. 147-158 (1974)

Dujmović, J.J.: Extended continuous logic and the theory of complex criteria. Publikacije Elektrotehničkog fakulteta Univerziteta u Beogradu, Serija: Matematika i Fizika, no. 498-541, pp. 197-216 (1975)

Dujmović, J.J.: Partial Absorption Function. Publikacije Elektrotehničkog fakulteta Univerziteta u Beogradu, Serija: Matematika i Fizika, no. 634-677, pp. 156-163 (1979)

Dujmović, J.J.: Preferential Neural Networks. In: Antognetti, P., Milutinović, V. (eds.) Neural Networks - Concepts, Applications, and Implementations, Volume II, pp. 155 - 206. Prentice Hall, Englewood Cliffs (1991)

Dujmović, J.J.: Continuous Preference Logic for System Evaluation. IEEE Transactions on Fuzzy Systems, vol. 15, no. 6, pp. 1082-1099 (2007)

Dujmović, J.J.: Characteristic Forms of Generalized Conjunction/Disjunction. In: IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), pp. 1075-1080. IEEE, Hong Kong (2008)

Dujmović, J.J., Bayucan, A.R.: A Quantitative Method for Software Evaluation and its Application in Evaluating Windowed Environments (1997), preuzeto 2. srpnja 2012 sa <http://www.seas.com/downloadUNReg/sample_eval/SEAS_WE.pdf>

Dujmović, J.J., Larsen, H.L.: Properties and Modeling of Partial Conjunction/Disjunction. In: De Baets, B., De Caluwe, R., De Tré, G., Fodor, J., Kacprzyk, J., Zadrozny, S. (eds.) Current Issues in Data and Knowledge Engineering, pp. 215-224. EXIT, Warsaw (2004)

Dujmović, J.J., Nagashima, H.: LSP method and its use for evaluation of Java IDEs. International Journal of Approximate Reasoning, vol. 41, no. 1, pp. 3-22 (2006)

Dumas, J.S., Redish, J.C.: A Practical Guide to Usability Testing. Intellect Ltd, Exeter (1999)

Educause Learning Initiative: 7 things you should know about...Second Life (2008), preuzeto 27. lipnja 2013. sa <http://net.educause.edu/ir/library/pdf/eli7038.pdf>

Edwards, J.R.: Multidimensional constructs in organizational behavior research: an integrative analytical framework. Organizational Research Methods, vol. 4, no. 2, pp. 144–192 (2001)

Edwards, J.R.: The Fallacy of Formative Measurement. Organizational Research Methods, vol. 14, no. 2, pp. 370-388 (2011)

Edwards, J.R., Bagozzi, R.P.: On the Nature and Direction of Relationships between Constructs. Psychological Methods, vol. 5, no. 2, pp. 155-174 (2000)

Edwards, D.M., Hardman, L.: Lost in hyperspace: Cognitive mapping and navigation in a hypertext environment. In: McAleese, R. (ed.), Hypertext: Theory into Practice, pp 90-105. Intellect Books, Exeter (1999)

Eighmey, J.: Profiling user responses to commercial web sites. Journal of Advertising Research, vol. 37, no. 3, pp. 59-66 (1997)

Esposito Vinzi, V., Trinchera, L., Amato, S.: PLS Path Modeling: From Foundations to Recent Developments and Open Issues for Model Assessment and Improvement. In: Esposito Vinzi, V., Chin, W.W., Henseler, J., Wang, H. (eds.), Handbook of Partial Least Squares, pp. 47-82. Springer, Heidelberg (2010)

Facebook: Key Facts (2013a), preuzeto 21. svibnja 2013. sa <http://newsroom.fb.com/Key-Facts>

Facebook: Timeline (2013b), preuzeto 21. svibnja 2013. sa <https://newsroom.fb.com/Timeline>

Farkas, D.K., Farkas, J.B.: Guidelines for Designing Web Navigation. Technical Communication, vol. 47, no. 3, pp. 341-358 (2000)

Fernandez, A., Insfran, E., Abrahão, S.: Integrating a Usability Model into Model-Driven Web Development Processes. In: Vossen, G., Long, D.D.E., Yu, J.X. (eds.), WISE 2009, Lecture Notes in Computer Science, vol. 5802, pp. 497–510. Springer, Heidelberg (2009)

Fernandez, A., Insfran, E., Abrahão, S.: Usability evaluation methods for the web: A systematic mapping study. Information and Software Technology, vol. 53, no. 8, pp. 789–817 (2011)

Finstad, K.: The Usability Metric for User Experience. Interacting with Computers, vol. 22, no. 5, pp. 323–327 (2010)

Fishbein, M., Ajzen, I.: Belief, Attitude, Intention and Behavior: An Introduction to Theory and Research. Addison-Wesley, Reading (1975)

Flanders, V. Peters, D.: Son of Web Pages that Suck: Learn Good Design by Looking at Bad Design. Sybex, San Francisco (2002)

Flavián, C., Guinalíu, M., Gurrea, R.: The role played by perceived usability, satisfaction and consumer trust on website loyalty. Information & Management, vol. 43, no. 1, pp. 1–14 (2006)

Fleiss, J.L.: Measuring nominal scale agreement among many raters. Psychological Bulletin, vol. 76, no. 5, pp. 378-382 (1971)

Fornell, C.G.: A second generation of multivariate analysis: An overview. In: Fornell, C. (ed.), A second generation of multivariate analysis, pp. 1–21. Praeger, New York (1982)

Fornell, C.G., Bookstein, F.L.: Two structural equation models: LISREL and PLS applied to consumer exit-voice theory. Journal of Marketing Research, vol. 19, no. 4, pp. 440–452 (1982)

Fornell, C.G., Cha, J.: Partial least squares. In: Bagozzi, R.P. (ed.), Advanced methods of marketing research, pp. 52–78. Blackwell, Cambridge (1994)

Fornell, C.G., Larcker, D.F.: Structural equation models with unobservable variables and measurement error: Algebra and statistics. Journal of Marketing Research, vol. 18, no. 3, pp. 328–388 (1981)

Freeze, R.D., Raschke, R.L.: An Assessment of Formative and Reflective Constructs in IS Research. Proceedings of the 15th European Conference on Information Systems, pp. 1481-1492. AIS, St. Gallen (2007)

Fuchs, C., Diamantopoulos, A.: Using Single-Item Measures for Construct Measurement in Management Research: Conceptual Issues and Application Guidelines. Die Betriebswirtschaft, vol. 69, no. 2, pp. 197-212 (2009)

Galletta, D.F., Henry, R.M., McCoy, S., Polak, P.: Web Site Delays: How Tolerant are Users? Journal of the Association for Information Systems, vol. 5, no. 1, pp. 1-28 (2004)

Galletta, D.F., Henry, R.M., McCoy, S., Polak, P.: When the Wait Isn't So Bad: The Interacting Effects of Website Delay, Familiarity, and Breadth. Information Systems Research, vol. 17, no. 1, pp. 20–37 (2006)

Garrido, A., Rossi, G., Distante, D.: Refactoring for Usability in Web Applications. IEEE Software, vol. 28, no. 3, pp. 60-67 (2011)

Garvin, D.A.: What Does "Product Quality" Really Mean? Sloan Management Review, pp. 25-43 (1984)

Gediga, G., Hamborg, K-C., Düntsch, I.: The IsoMetrics usability inventory: An operationalization of ISO 9241-10 supporting summative and formative evaluation of software systems. Behaviour & Information Technology, vol. 18, no. 3, pp. 151 – 164 (1999)

Gefen, D.: E-commerce: the role of familiarity and trust. Omega, vol. 28, no. 6, pp. 725-737 (2000)

Gefen, D., Karahanna, E., Straub, D.W.: Inexperience and experience with online stores: the importance of TAM and trust. IEEE Transactions on Engineering Management, vol. 50, no. 3, pp. 307–321 (2003)

Gefen, D., Rigdon, E.E., Straub, D.: An Update and Extension to SEM Guidelines for Administrative and Social Science Research. MIS Quarterly, vol. 35, no. 2, pp. iii-xiv (2011)

Gefen, D., Straub, D.W.: Consumer trust in B2C e-Commerce and the importance of social presence: Experiments in e-Products and e-Services. Omega, vol. 32, no. 6, pp. 407–424 (2004)

Gefen, D., Straub, D.W., Boudreau, M.-C.: Structural equation modelling and regression: Guidelines for research practice. Communications of the Association for Information Systems, vol. 4, no. 1, pp. 1–78 (2000)

Geisser, S.: A predictive approach to the random effect model. Biometrika, vol. 61, no. 1, pp. 101–107 (1975)

Gena, C., Weibelzahl, S.: Usability Engineering for the Adaptive Web. In: Brusilovsky, P., Kobsa, A., Nejdl, W. (eds.) The Adaptive Web. Lecture Notes in Computer Science, vol. 4321, pp. 720-762 (2007)

Gledec, G.: Quality model for the World Wide Web. In: 8th International Conference on Telecommunications (ConTEL), pp. 281-287. IEEE, Zagreb (2005)

Goldberg, S.: Internet access? It's in the box. Network World, vol. 11, no. 43, pp. 43-44 (1994)

González, M., Masip, L., Granollers, A., Oliva, M.: Quantitative analysis in a heuristic evaluation experiment. Advances in Engineering Software, vol. 40, no. 12, pp. 1271–1278 (2009)

Google: Our history in depth (2012), preuzeto 12. srpnja 2012. sa <http://www.google.com/about/company/history/>

Gould, J.D., Lewis, C.: Designing for usability: Key principles and what designers think. Communications of the ACM, vol. 28, no. 3, pp. 300-311 (1985)

Goto, K.: Brand Value and the User Experience (2004), preuzeto 25. lipnja 2013. sa <http://www.digital-web.com/articles/brand_value_and_the_user_experience/>

Götz, O., Liehr-Gobbers, K., Krafft, M.: Evaluation of Structural Equation Models Using the Partial Least Squares (PLS) Approach. In: Esposito Vinzi, V., Chin, W. W., Henseler, J., Wang, H. (eds.), Handbook of Partial Least Squares, pp. 691-711. Springer, Heidelberg (2010)

Grewal, R., Cote, J.A., Baumgartner, H.: Multicollinearity and Measurement Error in Structural Equation Models: Implications for Theory Testing. Marketing Science, vol. 23, no. 4, pp. 519–529 (2004)

Grossman, T., Fitzmaurice, G., Attar, R.: A survey of software learnability: metrics, methodologies and guidelines. In: 27th SIGCHI Conference on Human Factors in Computing Systems, pp. 649–658. ACM, Boston (2009)

Grudin, J.: Utility and usability: research issues and development contexts. Interacting with Computers, vol. 4, no. 2, pp. 209-217 (1992)

Guan, Z., Lee, S., Cuddihy, E., Ramey, J.: The validity of the stimulated retrospective think-aloud method as measured by eye tracking. In: Conference on Human Factors in Computing Systems, pp. 1253–1262. ACM, Quebec (2006)

Gundavaram, S.: CGI Programming on the World Wide Web. O'Reilly Media, Sebastopol (1996)

Gwet, K.L.: Handbook of Inter-Rater Reliability: The Definitive Guide to Measuring the Extent of Agreement Among Multiple Raters, 3rd edition. Advanced Analytics, Gaithersburg (2012)

Ha, S., Stoel, L.: Consumer e-shopping acceptance: Antecedents in a technology acceptance model. Journal of Business Research, vol. 62, no. 5, pp. 565–571 (2009)

Haenlein, M., Kaplan, A.M.: A Beginner's Guide to Partial Least Squares Analysis. Understanding Statistics, vol. 3, no. 4, pp. 283-297 (2004)

Hair, J.F., Black, W.C., Babin, B.J., Anderson, R.E., Tatham, R.L.: Multivariate Data Analysis. Pearson, Upper Saddle River (2006)

Hair, J.F., Ringle, C.M., Sarstedt, M.: PLS-SEM: Indeed a Silver Bullet. Journal of Marketing Theory and Practice, vol. 19, no. 2, pp. 139–151 (2011)

Hair, J.F., Sarstedt, M., Ringle, C.M., Mena, J.A.: An assessment of the use of partial least squares structural equation modeling in marketing research. Journal of the Academy of Marketing Science, vol. 40, no. 3, pp. 414-433 (2012)

Hall, R.H., Hanna, P.: The impact of web page text-background colour combinations on readability, retention, aesthetics and behavioural intention. Behaviour & Information Technology, vol. 23, no. 3, pp. 183–195 (2004)

Harper, B., Slaughter, L., Norman, K.: Questionnaire administration via the WWW: A validation and reliability study for a user satisfaction questionnaire. In: World Conference on the WWW and Internet. Association for the Advancement of Computing in Education, Toronto (1997), preuzeto 23. lipnja 2012. sa <http://lap.umd.edu/quis/publications/harper1997.pdf>

Hart, J., Ridley, C., Taher, F., Sas, C., Dix, A.: Exploring the Facebook Experience: A New Approach to Usability. In: 5th Nordic Conference on Human-Computer Interaction: Building Bridges, pp. 471–474. ACM, Lund (2008)

Hart, S. G., Staveland, L.E.: Development of NASA-TLX (Task Load Index): Results of empirical and theoretical research. In: Hancock, P.A., Meshkati, N. (eds.), Human mental workload, pp. 139-183. Elsevier, Amsterdam (1988)

Hartson, H.R., Castillo, J.C., Kelso, J., Neale, W.C.: Remote evaluation: the network as an extension of the usability laboratory. In: SIGCHI conference on Human factors in computing systems: common ground, pp. 228-235. ACM, Vancouver (1996)

Hasan, L., Abuelrub, E.: Assessing the quality of web sites. Applied Computing and Informatics, vol. 9, no. 1, pp. 11–29 (2011)

Hashim, N., Sultan, A.B.M.: Knowledge Management and Usability Model for Knowledge Management System. Computer and Information Science, vol. 2. no. 3, pp. 166-175 (2009)

Hassanein, K., Head, M.: Manipulating perceived social presence through the web interface and its impact on attitude towards online shopping. International Journal of Human-Computer Studies , vol. 65, no. 8, pp. 689–708 (2007)

Hassenzahl, M.: The thing and I:understanding the relationship between user and product. In: Blythe, M., Overbeeke, C., Monk, A.F., Wright, P.C. (eds.), Funology: From Usability to Enjoyment pp. 31 – 42. Kluwer, Dordrecht (2003)

Hassenzahl, M.: User Experience (UX): Towards an experiential perspective on product quality. In: 20th International Conference of the Association Francophone d'Interaction Homme-Machine, pp. 11-15. ACM, Metz (2008)

Hassenzahl, M., Burmester, M., Koller, F.: AttrakDiff: Ein Fragebogen zur Messung wahrgenommener hedonischer und pragmatischer Qualität. In: Ziegler, J., Szwillus, G. (eds.) Mensch & Computer 2003: Interaktion in Bewegung, pp. 187–196. B. G. Teubner, Stuttgart (2003)

Hassenzahl, M., Tractinsky, N.: User experience - a research agenda. Behaviour & Information Technology, vol. 25, no. 2, pp. 91–97 (2006)

Helfert, M., Foley, O.: A Context Aware Information Quality Framework. In: 4th International Conference on Cooperation and Promotion of Information Resources in Science and Technology, pp. 187-193. IEEE, Beijing (2009)

Henseler, J.: On the convergence of the partial least squares path modeling algorithm. Computational Statistics, vol. 25, no. 1, pp. 107–120 (2010)

Henseler, J., Chin, W.W.: A Comparison of Approaches for the Analysis of Interaction Effects Between Latent Variables Using Partial Least Squares Path Modeling. Structural Equation Modeling, vol. 17, no. 1, pp. 82-109 (2010)

Henseler, J., Fassott, G.: Testing Moderating Effects in PLS Path Models: An Illustration of Available Procedures. In: Esposito Vinzi, V., Chin, W.W., Henseler, J., Wang, H. (eds.), Handbook of Partial Least Squares, pp. 713–735. Springer, Heidelberg (2010)

Henseler, J., Ringle, C.M., Sinkovics, R.R.: The use of partial least squares path modeling in international marketing. Advances in International Marketing, vol. 20, pp. 277-319 (2009)

Hertzum, M.: Images of Usability. International Journal of Human-Computer Interaction, vol. 26, no. 6, pp. 567-600 (2010)

Hix, D., Hartson, H.R.: Developing User Interfaces: Ensuring Usability Through Product and Process. John Wiley and Sons, Hoboken (1993)

Holtzblatt, K., Jones, S.: Contextual Inquiry: A Participatory Technique for System Design. In: Schuler, D., Namioka, A. (eds.) Participatory Design: Principles and Practice, pp. 177-210. Lawrence Earlbaum, Hillsdale (1993)

Hong, S., Kim, J.: Architectural criteria for website evaluation – conceptual framework and empirical validation. Behaviour & Information Technology, vol. 23, no. 5, pp. 337-357 (2004)

Hornbæk, K.: Current practise in measuring usability: Challenges to usability studies and research. International Journal of Human-Computer Studies, vol. 64, no. 2, pp. 79-102 (2006)

Hui, B.S., Wold, H.O.A.: Consistency and consistency at large of partial least squares estimates. In: Jöreskog, K.G., Wold, H.O.A. (eds.), Systems under Indirect Observation, Part II, pp. 119–130, North-Holland, Amsterdam (1982)

Hulland, J.: Use of partial least squares (PLS) in strategic management research: a review of four recent studies. Strategic Management Journal, vol. 20, no. 2, pp. 195–204 (1999)

Hsu, M.-H., Chiu, C.-M.: Predicting electronic service continuance with a decomposed theory of planned behavior. Behaviour & Information Technology, vol. 23, no. 5, pp. 359–373 (2004)

Hwang, H., Malhotra, N.K., Kim, Y., Tomiuk, M.A., Hong, S.: A comparative study on parameter recovery of three approaches to structural equation modeling. Journal of Marketing Research, vol. 47, no. 4, pp. 699–712 (2010)

Institute of Electrical and Electronics Engineers (IEEE) std. 610.12-1990. IEEE standard glossary of software engineering terminology (1990)

ISO 8402: Quality management and quality assurance – Vocabulary (1994)

ISO 9241-11: Ergonomic requirements for office work with visual display terminals (VDTs) - Part 11: Guidance on usability (1998)

ISO 9241-110: Ergonomics of human-system interaction - Part 110: Dialogue principles (2006)

ISO 9241-210: Ergonomics of human-system interaction - Part 210: Human-centred design for interactive systems (2010)

ISO/IEC 9126: Information technology - Software product evaluation - Quality characteristics and guidelines for their use (1991)

ISO/IEC 9126-1: Information technology – Software product quality - Part 1: Quality model (2001)

ISO/IEC 9126-2: Software engineering - Product quality - Part 2: External metrics (2003a)

ISO/IEC 9126-3: Software engineering - Product quality - Part 3: Internal metrics (2003b)

ISO/IEC 9126-4: Software engineering - Product quality - Part 4: Quality in use metrics (2004)

ISO/IEC 25010: Systems and software engineering - Systems and software Quality Requirements and Evaluation (SQuaRE) - System and software quality models (2011a)

ISO/IEC 25012: Systems and software engineering - Systems and software Quality Requirements and Evaluation (SQuaRE) – Data quality model (2008)

ISO/IEC 25040: Systems and software engineering - Systems and software Quality Requirements and Evaluation (SQuaRE) - Evaluation process (2011b)

Ivory, M.Y., Hearst, M.A.: The State of the Art in Automating Usability Evaluation of User Interfaces. ACM Computing Surveys, vol. 33, no. 4, pp. 470–516 (2001)

Jarvis, C.B., MacKenzie, S.B., Podsakoff, P.M.: A Critical Review of Construct Indicators and Measurement Model Misspecification in Marketing and Consumer Research. Journal of Consumer Research, vol. 30, no. 2, pp. 199-218 (2003)

Jiang, J.J., Muhanna, W.A., Klein, G.: User resistance and strategies for promoting acceptance across system types. Information & Management, vol. 37, no. 1, pp. 25-36 (2000)

Johnson, J.: Web Bloopers: 60 Common Web Mistakes and How to Avoid Them. Morgan Kaufmann Publishers, San Francisco (2003)

Jöreskog, K.G., Wold, H.O.A.: The ML and PLS technique for modelling with latent variables: Historical and comparative aspects. In: Jöreskog, K.G., Wold, H.O.A. (eds.), Systems under indirect oberservation, Part I, pp. 263–270. North-Holland, Amsterdam (1982)

Kahn, M.J., Prail, A.: Formal Usability Inspections. In: Nielsen, J., Mack, R.L. (eds.) Usability Inspection Methods, pp. 141-170. Wiley & Sons, New York (1994)

Kalbach, J., Gustafson, A.: Designing Web Navigation: Optimizing the User Experience. O'Reilly Media, Sebastopol (2007)

Kamel Boulos, M.N., Wheeler, S.: The emerging Web 2.0 social software: an enabling suite of sociable technologies in health and health care education. Health Information & Libraries Journal, vol. 24, no. 1, pp. 2–23 (2007)

Karahanna, E., Straub, D.W., Chervany, N.L.: Information technology adoption across time: A cross-sectional comparison of pre-adoption and post-adoption beliefs. MIS Quarterly, vol. 23, no. 2, pp. 183–213 (1999)

Kaushik, A.: Web Analytics: An Hour A Day. Wiley Publishing, Indianapolis (2007)

Kelman, H.C.: Compliance, Identification, and Internalization: Three Processes of Attitude Change. Journal of Conflict Resolution, vol. 2, no. 1, pp. 51-60 (1958)

Kendall, M.G., Babington-Smith, B.: The Problem of m Rankings. Annals of Mathematical Statistics, vol. 10, pp. 275-287 (1939)

Kennedy, S.: Using video in the BNR usability lab. ACM SIGCHI Bulletin, vol. 21, no. 2, pp. 92-95 (1989)

Kim, H.-W., Chan, H. C., Chan, Y. P.: A Balanced Thinking–Feelings Model of Information Systems Continuance. International Journal of Human-Computer Studies, vol. 65, no. 6, pp. 511-525 (2007)

Kirakowski, J., Claridge, N., Whitehand, R.: Human Centered Measures of Success in Web Site Design. In: 4th Conference on Human Factors & the Web (1998), preuzeto 24. lipnja 2012. sa <http://zing.ncsl.nist.gov/hfweb/att4/proceedings/kirakowski/index.html>

Kirakowski, J., Corbett, M.: SUMI: the software measurement inventory. British Journal of Educational Technology, vol. 24, no. 3, pp. 210-212 (1993)

Krug, S.: Don't Make Me Think: A Common Sense Approach to Web Usability, Second Edition. New Riders Press, Berkeley (2005),

Kuniavsky, M.: Smart Things: Ubiquitous Computing User Experience Design. Morgan Kaufmann, Burlington (2010)

Landis, J., Koch, G.: Measurement of Observer Agreement for Categorical Data. Biometrics, vol. 33, no. 1, pp. 159-174 (1977)

Lavie, T., Tractinsky, N.: Assessing dimensions of perceived visual aesthetics of web sites. International Journal of Human-Computer Studies, vol. 60, no. 3, pp. 269–298 (2004)

Law, E.L-C., Roto, V., Hassenzahl, M., Vermeeren, A.P.O.S., Kort, J.: Understanding, Scoping and Defining User eXperience: A Survey Approach. In: 27th ACM SIGCHI Conference on Human Factors in Computing Systems, pp. 719-728. ACM, Boston (2009)

Law, E.L-C., Van Schaik, P.: Modelling user experience – An agenda for research and practice. Interacting with Computers, vol. 22, no. 5, pp. 313–322 (2010)

Law, K., Wong. C-S.: Multidimensional Constructs in Structural Equation Analysis: An Illustration Using the Job Perception and Job Satisfaction Constructs. Journal of Management, vol. 25, no. 2, pp. 143–160 (1999)

Lawshe, C.H.: A Quantitative Approach to Content Validity. Personnel Psychology, vol. 28, no. 4, pp. 563-575 (1975)

Lederer, A.L., Maupin, D.J., Sena, M.P., Zhuang, Y.: The technology acceptance model and the World Wide Web. Decision Support Systems, vol. 29, no. 3, pp. 269–282 (2000)

Lee, T.: The impact of perceptions of interactivity on customer trust and transaction intentions in mobile commerce. Journal of Electronic Commerce Research, vol. 6, no. 3, pp. 165–180 (2005)

Lee, Y., Kozar, K.A.: Investigating the effect of website quality on e-business success: An analytic hierarchy process (AHP) approach. Decision Support Systems, vol. 42, no. 3, pp. 1383–1401 (2006)

Lee, Y., Kozar, K.A.: Designing usable online stores: A landscape preference perspective. Information & Management, vol. 46, no. 1, pp. 31–41 (2009)

Lee, Y., Kozar, K.A.: Designing Websites and Composing Music: Identifying Usability Constructs and Their Nomological Networks. Journal of Electronic Commerce Research, vol. 13, no. 4, pp. 320-344 (2012)

Lee, Y., Kwon, O.: Intimacy, familiarity and continuance intention: An extended expectation–confirmation model in web-based services. Electronic Commerce Research and Applications, vol. 10, no. 3, pp. 342–357 (2011)

Lee Y.W., Strong, D.M., Kahn, B.K., Wang, R.Y.: AIMQ: a methodology for information quality assessment. Information & Management, vol. 40, no. 2, pp. 133–146 (2002)

Levy, M.: WEB 2.0 implications on knowledge management. Journal of Knowledge Management, vol. 13, no. 1, pp. 120-134 (2009)

Lew, P., Olsina, L., Zhang, L.: Quality, Quality in Use, Actual Usability and User Experience as Key Drivers for Web Application Evaluation. In: Benatallah, B., Casati, F., Kappel, G., Rossi, G. (eds.) ICWE 2010. Lecture Notes in Computer Science, vol. 6189, pp. 218–232. Springer, Heidelberg (2010)

Lew, P., Zhang, L., Wang, S.: Model and Measurement for Web Application Usability from an End User Perspective. In: 1st Quality Assessment in Web Workshop (2009), preuzeto 22. lipnja 2013. sa < http://ceur-ws.org/Vol-561/paper2.pdf>

Lewis, B.R., Snyder, C.A., Rainer, R.K., Jr.: An empirical assessment of the information resource management construct. Journal of Management Information Systems, vol. 12, no. 1, pp. 199-223 (1995)

Lewis, C.: Using the 'thinking-aloud' method in cognitive interface design. Research Report RC9265. IBM T. J. Watson Research Center, Yorktown Heights (1982)

Lewis, J.R.: IBM Computer Usability Satisfaction Questionnaires: Psychometric Evaluation and Instructions for Use. International Journal of Human-Computer Interaction, vol. 7, no. 1, pp. 57-78 (1995)

Lewis, J.R.: Psychometric Evaluation of the PSSUQ Using Data from Five Years of Usability Studies. International Journal of Human-Computer Interaction, vol. 14, no. 3 & 4, pp. 463-488 (2002)

Liao, C., Palvia, P., Chen, J-L.: Information technology adoption behavior life cycle: Toward a Technology Continuance Theory (TCT). International Journal of Information Management, vol. 29, no. 4, pp. 309–320 (2009)

Liaw, S.-S. Understanding user perceptions of World-wide web environments. Journal of Computer Assisted Learning, vol. 18, no. 2, pp. 137-148 (2002)

Likert, R.: A technique for the measurement of attitudes. Archives of Psychology, vol. 140, pp. 1-55 (1932)

Lin, C.S., Wu, S., Tsai, R.J.: Integrating perceived playfulness into expectation-confirmation model for web portal context. Information & Management, vol. 42, no. 5, pp. 683-693 (2005)

Lin, H-F.: An application of fuzzy AHP for evaluating course website quality. Computers & Education, vol. 54, no. 4, pp. 877–888 (2010)

Lin, H-F., Lee, G-G.: Determinants of success for online communities: an empirical study. Behaviour & Information Technology, vol. 25, no. 6, pp. 479 – 488 (2006)

Lin, H.X., Choong, Y-Y., Salvendy, G.: A proposed index of usability: a method for comparing the relative usability of different software systems. Behaviour & Information Technology, vol. 16, no. 4/5, pp. 267-278 (1997)

Liu, C., Arnett, K.P.: Exploring the factors associated with Web site success in the context of electronic commerce. Information & Management, vol. 38, no. 1, pp. 23-33 (2000)

Lohmöller, J.-B. Latent variable path modeling with partial least squares. Physica, Heidelberg (1989)

Loiacono, E.T., Watson, R.T., Goodhue, D.L.: WebQual™: A Measure of Web Site Quality. International Journal of Electronic Commerce, vol. 11, no. 3, pp. 51-87 (2007)

Lund, A.M.: Measuring Usability with the USE Questionnaire. STC Usability SIG Newsletter, vol. 8, no. 2 (2001), preuzeto 24. lipnja 2012. sa <http://www.stcsig.org/usability/newsletter/0110_measuring_with_use.html>

Lynch, P.J., Horton, S.: Web Style Guide: Basic Design Principles for Creating Web Sites, 3rd Edition. Yale University, Kendallville (2008)

MacCallum, R.C., Browne, M.W.: The use of causal indicators in covariance structure models: Some practical issues.Psychological Bulletin, vol. 114, no. 3, pp. 533–541 (1993)

Mack, R.L., Burdett, J.M.: When novices elicit knowledge: Question-asking in designing, evaluating and learning to use software. In: Hoffman, R. (ed.), The Psychology of Expertise: Cognitive Research and Empirical AI, pp. 245-268. Springer-Verlag, New York (1992)

MacKenzie, S.B.: Opportunities for Improving Consumer Research through Latent Variable Structural Equation Modeling. Journal of Consumer Research, vol. 28, no. 1, pp. 159-166 (2001)

MacKenzie, S.B., Podsakoff, P.M., Jarvis, C.B.: The Problem of Measurement Model Misspecification in Behavioral and Organizational Research and Some Recommended Solutions. Journal of Applied Psychology, vol. 90, no. 4, pp. 710-730 (2005)

Madsen, M., Gregor, S.: Measuring Human-Computer Trust. In: 11th Australasian Conference on Information Systems (2000), preuzeto 22. lipnja 2013. sa <citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.93.3874&rep=rep1&type=pdf>

Madu, C.N., Madu, A.A.: Dimensions of e-quality. International Journal of Quality & Reliability Management, vol. 19, no. 3, pp. 246 – 258 (2002)

Mäkelä, A., Fulton Suri, J.: Supporting Users' Creativity: Design to Induce Pleasurable Experiences. In: Proceedings of the International Conference on Affective Human Factors Design, pp. 387-394. ASEAN Academic, London (2001)

Malone, T.W.: Toward a theory of intrinsically motivating instruction. Cognitive Science, vol. 5, no. 4, pp. 333-369 (1981)

Markus, M.L.: Electronic mail as the medium of managerial choice. Organization Science, vol. 5, no. 4, pp. 502 – 527 (1994)

Martocchio, J.J., Webster, J.: Effects of feedback and cognitive playfulness on performance in microcomputer software training, Personnel Psychology, vol. 45, no. 3, pp. 553-578 (1992)

Mason, R.O.: Measuring information output: A communication systems approach. Information & Management, vol. 1, no. 5, pp. 219–234 (1978)

Miller, R.B.: Human ease of use criteria and their tradeoffs. IBM Report TR 00.2185. IBM Poughkeepsie Lab, New York (1971)

McAfee, A.P.: Enterprise 2.0: The Dawn of Emergent Collaboration. MIT Sloan Management Review, vol. 47, no. 3, pp. 21-28 (2006)

McDougall, J.S.: Expand your business on eBay. Entrepreneur Media, Madison (2007)

McKinney, V., Yoon, K., Zahedi, F.: The measurement of web-customer satisfaction: An expectation and disconfirmation approach. Information Systems Research, vol. 13, no. 3, pp. 296-316 (2002)

Molich, R., Nielsen, J.: Improving a Human-Computer Dialogue. Communications of the ACM, vol. 33, no. 3, pp. 338-348 (1990)

Mooi, E., Sarstedt, M.: A Concise Guide to Market Research. Springer-Verlag, Berlin (2011)

Moon, J-W., Kim, Y-G.: Extending the TAM for a World-Wide-Web context. Information & Management, vol. 38, no. 4, pp. 217–230 (2001)

Moore, G.C., Benbasat, I.: Development of an Instrument to Measure the Perceptions of Adopting an Information Technology Innovation. Information Systems Research, vol. 2, no. 3, pp. 192-222 (1991)

Moraga, M.Á., Calero, C., Piattini, M.: A First Proposal of a Portal Quality Model. In: IADIS International Conference e-Society 2004, pp. 630-638. IADIS, Avila (2004)

Moustakis, V.S., Litos, C., Dalivigas, A., Tsironis, L.: Website Quality Assessment Criteria. In: 9th International Conference on Information Quality, pp. 59-73. MIT Sloan School of Management, Cambridge (2004)

Mueller, C.J., Komogortsev, O.V.. Tamir, D., Feldman, L.: An Effort-Based Approach to Measuring Software Usability. Technical Reports-Computer Science (2008), preuzeto 22. lipnja 2013. sa <https://digital.library.txstate.edu/handle/10877/2594>

Murugesan, S.: Web X.0: A Road Map. In: Murugesan, S. (ed.) Handbook of Research on Web 2.0, 3.0, and X.0: Technologies, Business, and Social Applications, pp. 1-11. IGI Global, Hershey (2010)

Musser, J., O'Reilly, T. Web 2.0 Principles and Best Practices. O'Reilly Media, Sebastopol (2007)

Muylle, S., Moenaert, R., Despontin, M.: The conceptualization and empirical validation of web site user satisfaction. Information & Management, vol. 41, no. 5, pp. 543–560 (2004)

Nah, F.F.-H.: A study on tolerable waiting time: how long are Web users willing to wait? Behaviour & Information Technology, vol. 23, no. 3, pp. 153–163 (2004)

Nahm, A.Y., Solís-Galván, L.E., Subba Rao, S., Ragun-Nathan, T.S.: The Q-sort Method: Assessing Reliability and Construct Validity of Questionnaire Items at a Pre-Testing Stage. Working Paper, p. 27 (2002), preuzeto 25. travnja 2013. sa <http://latienda.ie.edu/working_papers_economia/WP02-08.pdf>

Natt, A.K.: Usability and design issues for a good website. In: 4th Annual Multimedia Systems, Electronics and Computer Science (2004), preuzeto 22. lipnja 2013. sa <mms.ecs.soton.ac.uk/mms2004/papers/akn201.rtf>

Neil, T.: 6 Tips for a Great Flex UX: Review Usability Best Practices (2009), preuzeto 22. lipnja 2012. sa <http://designingwebinterfaces.com/6-tips-for-a-great-flex-ux-part-5>

Nemzow, M.: Ecommerce "Stickiness" for Customer Retention. Journal of Internet Banking and Commerc, vol. 4, no. 1 (1999), preuzeto 21. lipnja 2013. sa <http://www.arraydev.com/commerce/jibc/9908-03.htm>

Newswise: Professor Who Used Second Life for Course (2009), preuzeto 27. lipnja 2013. sa <http://www.newswise.com/articles/professor-who-used-second-life-for-course>

Nielsen, J.: Usability engineering at a discount. In: Salvendy, G., Smith, M.J. (eds.) Designing and Using Human-Computer Interfaces and Knowledge Based Systems, pp. 394-401. Elsevier, Amsterdam (1989)

Nielsen, J.: Finding usability problems through heuristic evaluation. In: Conference on Human Factors in Computing, pp. 373-380. ACM, Monterey (1992)

Nielsen, J.: Usability Engineering. Morgan Kaufmann, San Francisco (1993)

Nielsen, J.: Heuristic evaluation. In: Nielsen, J., Mack, R.L. (eds.) Usability Inspection Methods, pp. 25-62. Wiley & Sons, New York (1994)

Nielsen, J.: Designing Web Usability. New Riders Publishing, Berkeley (2000)

Nielsen, J.: Ten Usability Heuristics (2005), preuzeto 22. lipnja 2012. sa <http://www.useit.com/papers/heuristic/heuristic_list.html>

Nielsen, J., Mack, R.L.: Usability Inspection Methods. Wiley & Sons, New York (1994)

Norman, D.: The design of everyday things. Doubleday, New York (1988)

Norman, D.: Emotional design: Why we love (or hate) everyday things. Basic Books, New York (2004)

Norušis, M.J.: IBM SPSS Statistics 19 Statistical Procedures Companion. Addison Wesley, Boston (2012)

Nov, O., Ye, C.: Users' Personality and Perceived Ease of Use of Digital Libraries: The Case for Resistance to Change. Journal of the American Society for Information Science and Technology, vol. 59, no. 5, pp. 845–851 (2008)

Nunnally, J.C., Bernstein, I.H.: Psychometric theory. McGraw-Hill, New York (1994)

Nyman, N.: The User Experience equation (2005), preuzeto 25. lipnja 2013. sa <http://www.nnyman.com/personal/2005/11/18/the-user-experience-equation/>

O'Donnell, P.J., Scobie, G., Baxter, I.: The use of focus groups as an evaluation technique in HCI. In: Diaper, D., Hammond, N. (eds.), People and Computers VI, pp. 211-224. Cambridge University Press, Cambridge (1991)

O'Malley, C. E., Draper, S. W., Riley, M. S.: Constructive interaction: A method for studying human-computer-human interaction. In: First IFIP International Conference on Human-Computer Interaction, pp. 269-274. IFIP, London (1984)

O'Reilly, T.: What Is Web 2.0: Design Patterns and Business Models for the Next Generation of Software (2005), preuzeto 6. svibnja 2012. sa <http://oreilly.com/web2/archive/what-is-web-20.html>

O'Reilly, T., Battelle, J.: Web Squared: Web 2.0 Five Years On (2009), preuzeto 29. svibnja 2012. sa <http://gossgrove.com/sites/default/files/web2009_websquared-whitepaper.pdf>

Offutt, J.: Quality Attributes of Web Software Applications. IEEE Software, vol. 19, no. 2, pp. 25-32 (2002)

Oliver, R.L.: A cognitive model for the antecedents and consequences of satisfaction. Journal of Marketing Research, vol. 17, no. 4, pp. 460–469 (1980)

Olsina, L., Rossi, G.: Measuring Web Application Quality with WebQEM. IEEE Multimedia, vol. 9, no. 4, pp. 20-29 (2002)

Olsina, L., Sassano, R., Mich, L.: Towards the Quality for Web 2.0 Applications. In: 8th International Workshop on Web Oriented Software Technology (2009), preuzeto 21. lipnja 2013. sa <http://ceur-ws.org/Vol-493/iwwost2009-olsina.pdf>

Oreg, S.: Resistance to Change: Developing an Individual Differences Measure. Journal of Applied Psychology, vol. 88, no. 4, pp. 680 – 693 (2003)

Orehovački, T.: Proposal for a Set of Quality Attributes Relevant for Web 2.0 Application Success. In: 32nd International Conference on Information Technology Interfaces, pp. 319–326. IEEE Press, Cavtat (2010)

Orehovački, T.: Perceived Quality of Cloud Based Applications for Collaborative Writing. In: Pokorny, J., Repa, V., Richta, K., Wojtkowski, W., Linger, H., Barry, C., Lang, M. (eds.) Information Systems Development – Business Systems and Services: Modeling and Development, pp. 575–586. Springer, Heidelberg (2011a)

Orehovački, T.: Development of a Methodology for Evaluating the Quality in Use of Web 2.0 Applications. In: Campos, P., Graham, N., Jorge, J., Nunes, N., Palanque, P., Winckler, M. (eds.) INTERACT 2011, Part IV. Lecture Notes in Computer Science, vol. 6949, pp. 382–385. Springer, Heidelberg (2011b)

Orehovački, T., Granić, A., Kermek, D.: Exploring the Quality in Use of Web 2.0 Applications: The Case of Mind Mapping Services. In: Harth, A., Koch, N. (eds.) ICWE 2011 Workshops. Lecture Notes in Computer Science, vol. 7059, pp. 266–277. Springer, Heidelberg (2012a)

Orehovački, T., Konecki, M., Stapić, Z.: Primjena Web 2.0 tehnologija u poslovanju. In: CASE 20 - metode i alati za razvoj poslovnih i informatičkih sustava, pp. 197-202. CASE, Rijeka (2008)

Orehovački, T., Kovačić, A., Bubaš, G.: Taxonomy of Web 2.0 Applications with Educational Potential. In: Cheal, C., Coughlin, J., Moore, S. (eds.) Transformation in Teaching: Social Media Strategies in Higher Education, pp. 43–72. Informing Science Press, Santa Rosa (2012b)

Orehovački, T., Granić, A.; Kermek, D.: Evaluating the Perceived and Estimated Quality in Use of Web 2.0 Applications. The Journal of Systems and Software, vol. 86, no. 12, pp. 3039-3059 (2013)

Osgood, C. E., Suci, G., Tannenbaum, P.: The measurement of meaning. University of Illinois Press, Urbana (1957)

Ozok, A.A., Salvendy, G.: Measuring consistency of web page design and its effects on performance and satisfaction. Ergonomics, vol. 43, no. 4, pp. 443 - 460 (2000)

Ozok, A.A., Salvendy, G.: How consistent is your web design? Behaviour & Information Technology, vol. 20, no. 6, pp. 433-447 (2001)

Oztekin, A., Kong, Z.J., Uysal, O.: UseLearn: A novel checklist and usability evaluation method for eLearning systems by criticality metric analysis. International Journal of Industrial Ergonomics, vol. 40, no. 4, pp. 455-469 (2010)

Oztekin, A., Nikov, A., Zaim, S.: UWIS: An assessment methodology for usability of web-based information systems. The Journal of Systems and Software, vol. 82, no. 12, pp. 2038-2050 (2009)

Palmer, J.W.: Designing for Web Site Usability. Computer, vol. 35, no. 7, pp. 102-103 (2002a)

Palmer, J.W.: Web Site Usability, Design, and Performance Metrics. Information Systems Research, vol. 13, no. 2, pp. 151-167 (2002b)

Pang, M., Suh, W., Hong, J., Kim, J., Lee, H.: A New Web Site Quality Assessment Model for the Web 2.0 Era. In: Murugesan, S. (ed.), Handbook of Research on Web 2.0, 3.0, and X.0: Technologies, Business, and Social Applications, pp. 387-410. IGI Global, Hershey (2010)

Page, L., Brin, S., Motwani, R., Winograd, T.: The PageRank Citation Ranking: Bringing Order to the Web (1999), preuzeto 12. srpnja 2012. godine sa <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.31.1768>

Parasuraman, A., Zeithaml, V.A., Berry, L.L.: SERVQUAL: A Multiple-Item Scale For Measuring Consumer Perception. Journal of Retailing, vol. 64, no. 1, pp. 12-40 (1988)

Parasuraman, A., Berry, L.L., Zeithaml, V.A.: Refinement and reassessment of the SERVQUAL scale. Journal of Retailing, vol. 67, no. 4, pp. 420-450 (1991)

Parasuraman, A., Zeithaml, V.A., Malhotra, A.: E-S-QUAL A Multiple-Item Scale for Assessing Electronic Service Quality. Journal of Service Research, vol. 7, no. 3, pp. 213-233 (2005)

Pardell, D.: Eina multiplataforma per analitzar els resultats en exercicis de Card Sorting. Universidad de Lleida, Lleida (2006)

Parker, S.P.: McGraw-Hill Dictionary of Scientific and Technical Terms, Sixth Edition. McGraw-Hill Professional Publishing, New York (2002)

Paulussen, R., Trienekens, J., van Zeist, B., Hendriks, P.: Kwaliteit van Softwareprodukten - Ervaringen met een kwaliteitsmodel. Kluwer Bedrijfsinformatie, Deventer (1996)

Pempek, T.A., Yermolayeva, Y.A., Calvert, S.L.: College students' social networking experiences on Facebook. Journal of Applied Developmental Psychology, vol. 30, no. 3, pp. 227–238 (2009)

Peragine, J., Russell, C.: eBay income: how anyone of any age, location, and/or background can build a highly profitable online business with eBay. Atlantic Publishing Group, Ocala (2011)

Petter, S., Straub, D., Rai, A.: Specifying Formative Constructs in Information Systems Research. MIS Quarterly, vol. 31, no. 4, pp. 623-656 (2007)

Pitt, L.F ., Watson, R.T ., Kavan, C.B.: Service quality: A measure of information systems effectiveness. MIS Quarterly, vol. 19, no. 2, 173– 188 (1995)

Plantak Vukovac, D., Orehovački, T.: Metode vrednovanja web upotrebljivosti. In: CASE 22 - Metode i alati za razvoj poslovnih i informatičkih sustava, pp. 171-182. CASE, Zagreb (2010)

Poelmans, S., Wessa, P., Milis, K., Bloemen, E., Doom, C: Usability and acceptance of e-learning in statistics education, based on the compendium platform, pp. 1-10. IATED, Madrid (2008)

Polites, G.L., Roberts, N., Thatcher, J.: Conceptualizing models using multidimensional constructs: a review and guidelines for their use. European Journal of Information Systems, vol. 21, pp. 22–48 (2012)

Polson, P.G., Lewis, C., Rieman, J., Wharton, C.: Cognitive walkthroughs: A method for theory-based evaluation of user interfaces. International Journal of Man-Machine Studies, vol. 36, no. 5, pp. 741-773 (1992)

Pomerol, J-C., Barba-Romero, S.: Multicriterion decision in management: principles and practise. Kluwer Academic Publishers, Boston (2000)

Porta, E.: Implementació d'un Editor de Card Sorting multiplataforma. Universidad de Lleida, Lleida (2005)

Postrel. V.: The Substance of Style: How the Rise of Aesthetic Value Is Remaking Commerce, Culture, and Consciousness. HarperCollins Publishers, New York (2003)

Preece, J.: Sociability and usability in online communities: Determining and measuring success. Behaviour & Information Technology, vol. 20, no. 5, pp. 347-356 (2001)

Quesenbery, W.: What Does Usability Mean: Looking Beyond 'Ease of Use'. In: 48th International Conference Society for Technical Communication. STC, Chicago (2001) preuzeto 2. lipnja 2012. sa <http://www.wqusability.com/articles/more-than-ease-of-use.html>

Rababah, O.M.A., Masoud, F.A.: Key Factors for Developing a Successful E-commerce Website. Communications of the IBIMA, p. 9 (2010), preuzeto 22. lipnja 2013. sa <http://www.ibimapublishing.com/journals/CIBIMA/2010/763461/763461.pdf>

Raggett, D., Lam, J., Alexander, I.F., Kmiec, M.: Raggett on HTML 4. Addison Wesley Longman, Harlow (1998)

Ramo, J.C.: Jeffrey Preston Bezos: 1999 Person of the Year. Time, vol. 154, no. 26 (1999)

Redman, T.C: Data Quality for the Information Age. Artech House, Norwood (1996)

Reichheld, F.F., Schefter, P.: E-loyalty: Your secret weapon on the web. Harvard Business Review, vol. 78, no. 4, pp. 105-113 (2000)

Reid, G.B., Nygren, T.E.: The subjective workload assessment technique: A scaling procedure for measuring mental workload. In: Hancock, P.A.. Meshkati, N. (eds.), Human mental workload, pp. 185–218. Elsevier, Amsterdam (1988)

Reinartz, W., Haenlein, M., Henseler, J.: An empirical comparison of the efficacy of covariance-based and variance-based SEM. International Journal of Research in Marketing, vol. 26, no. 4, pp. 332–344 (2009)

Ringle, C.M., Sarstedt, M., Straub, D.W.: A Critical Look at the Use of PLS-SEM in MIS Quarterly. MIS Quarterly, vol. 36, no. 1, pp. iii-xiv (2012)

Ringle, C.M., Wende, S., Will, A.: SmartPLS 2.0 M3 (2005)

Ringle, C.M., Götz, O., Wetzels, M., Wilson, B.: On the use of formative measurement specifications in structural equation modeling: A Monte Carlo simulation study to compare covariance-based and partial least squares model estimation methodologies, Research Memoranda RM/09/014. METEOR, Maastricht (2009)

Rivlin, G.: Wallflower at the Web Party. The New York Times (2006), preuzeto 27. lipnja 2013. sa < http://www.nytimes.com/2006/10/15/business/yourmoney/15friend.html?_r=2&>

Roschelle, J., Teasley, S.: The construction of shared knowledge in collabrative problem solving. In: C.E. O'Malley, C.E. (ed.), Computer supported collaborative learning, vol. 128, pp. 69-97. Springer-Verlag, Heidelberg (1995)

Rossiter, J.R: The C-OAR-SE procedure for scale development in marketing. International Journal of Research in Marketing, vol. 19, no. 4, pp. 305–335 (2002)

Rosson, M.B., Carroll, J.M.: Usability Engineering: Scenario-Based Development of Human-Computer Interaction. Morgan Kaufmann, San Francisco (2002)

Roto, V., Law, E.L-C. Vermeeren, A.P.O.S., Hoonhout, J.: User experience white paper - Bringing clarity to the concept of user experience (2011), preuzeto 25. lipnja 2013. sa <http://www.allaboutux.org/files/UX-WhitePaper.pdf>

Safavi, R.: Interface Design Issues to Enhance Usability of E-commerce Websites and Systems. In: International Conference on Computer Technology and Development, pp. 277 – 281. IEEE, Kota Kinabalu (2009)

Sánchez-Franco, M.J.: Exploring the influence of gender on the web usage via partial least squares. Behaviour & Information Technology, vol. 25, no. 1, pp. 19-36. (2006)

Sánchez-Franco, M.J., Roldán, J.L.: Web acceptance and usage model: A comparison between goal-directed and experiential web users. Internet Research, vol. 15, no. 1, pp. 21–48 (2005)

Sassano, R., Olsina, L., Mich, L.: Modeling Content Quality for the Web 2.0 and Follow-on Applications. In: Murugesan, S. (ed.), Handbook of Research on Web 2.0, 3.0, and X.0: Technologies, Business, and Social Applications, pp. 371-386. IGI Global, Hershey (2010)

Sauro, J., Kindlund, E.: A Method to Standardize Usability Metrics Into a Single Score. In: 23th International Conference on Human Factors in Computing Systems (CHI), pp. 401-409. ACM, Portland (2005)

Scapin, D.L., Senach, B., Trousse, B., Pallot, M.: User Experience: Buzzword or New Paradigm? In: 5th International Conference on Advances in Computer-Human Interactions, pp. 336-341. IARIA, Valencia (2012)

Schenkman, B.N., Jönsson, F.U.: Aesthetics and preferences of web pages. Behaviour & Information Technology, vol. 19, no. 5, pp. 367–377 (2000)

Schlosser, A.: The User Experience and Web Site Success. E-business review, pp. 57-61 (2003), preuzeto 22. lipnja 2013. sa <http://faculty.bschool.washington.edu/aschloss/articles/schlosser%20ebiz%20review%202003.pdf>

Seddon, P.B.: A respecification and extension of the DeLone and McLean model of IS success. Information Systems Research, vol. 8, no. 3, pp. 240–253 (1997)

Seffah, A., Donyaee, M., Kline, R.B., Padda, H.K.: Usability measurement and metrics: A consolidated model. Software Quality Journal, vol. 14, no. 2, pp. 159-178 (2006)

Seffah, A., Metzker, E.: Adoption-centric Usability Engineering: Systematic Deployment, Assessment and Improvement of Usability Methods in Software Engineering. Springer-Verlag, London (2009)

Selim, H.M.: An empirical investigation of student acceptance of course websites. Computers & Education, vol. 40, no. 4, pp. 343-360 (2003)

Shackel, B.: The concept of usability. In: Bennet, J., Case, D., Sandelin, J., Smith, M. (eds.) Visual Display Terminals, pp. 45-87. Prentice-Hall, Englewood Cliffs (1984)

Shackel, B.: Usability - Context, framework, definition, design and evaluation. In: Shackel, B., Richardson, S.J. (eds.) Human Factors for Informatics Usability, pp. 21-31. Cambridge University Press, Cambridge (1991)

Shamdasani, P.N., Stanaland, A.J.S., Tan, J.: Location, location, location: insights for advertising placement on the Web. Journal of Advertising Research, vol. 41, no. 4, pp. 7–21 (2001)

Shannon, C.E., Weaver, W.: The Mathematical Theory of Communication. University of Illinois Press, Urbana (1949)

Shea, B.: Avoiding Scalability Shock. Software Testing & Quality Engineering Magazine, vol. 2, no. 3, pp. 42-46 (2000)

Sheskin, D.J.: Handbook of Parametric and Nonparametric Statistical Procedures. Chapman and Hall/CRC, Boca Raton (2004)

Shin, D-H.: User acceptance of mobile Internet: Implication for Convergence technologies, Interacting with Computers, vol. 19, no. 4, pp. 472-483 (2007)

Shin, D-H.: Understanding purchasing behaviors in a virtual economy: Consumer behavior involving virtual currency in Web 2.0 communities. Interacting with Computers, vol. 20, no. 4–5, pp. 433–446 (2008)

Shneiderman, B.: Designing the user interface: Strategies for effective human-computer interaction, 3rd edition. Addison-Wesley Publishing, Reading (1998)

Siegel, S., Castellan Jr., N.J.: Nonparametric Statistics for The Behavioral Sciences. McGraw-Hill, New York (1988)

Silva, P.A., Dix, A.: Usability – Not as we know it! In: 21st British HCI Group Annual Conference on HCI 2007: People and Computers XXI: HCI...But not as We Know It, vol. 2, pp. 103–106. ACM, University of Lancaster (2007)

Simonson, M.R., Maurer, M., Montag-Torardi, M., Whitaker, M.: Development of a standardized test of computer literacy and a computer anxiety index. Journal of Educational Computing Research, vol. 3, no. 2, pp. 231–247 (1987)

Sonderegger, A., Sauer, J.: The influence of design aesthetics in usability testing: Effects on user performance and perceived usability. Applied Ergonomics, vol. 41, no. 3, pp. 403–410 (2010)

Song, J.H., Zinkhan, G.M.: Exploring the Determinants of Perceived Web Site Interactivity, Journal of Marketing, vol. 72, no. 2, pp. 99-113 (2008)

Spool, J., Schroeder, W.: Testing Web Sites: Five Users Is Nowhere Near Enough. In: ACM Conference on Human Factors in Computing (CHI), pp. 285- 286. ACM, Seattle (2001)

Srinivasan, S.S., Anderson, R., Ponnavolu, K.: Customer loyalty in e-commerce: an exploration of its antecedents and consequences. Journal of Retailing, vol. 78, no. 1, pp. 41–50 (2002)

Steuer, J.: Defining Virtual Reality: Dimensions determining Telepresence. Journal of Communication, vol. 42, no. 4, pp. 73-93 (1992)

Stone, M.: Cross-validatory choice and assessment of statistical predictions. Journal of the Royal Statistical Society, vol. 36, no. 2, pp. 111–133 (1975)

Straub, D., Boudreau, M-C., Gefen, D.: Validation Guidelines for IS Positivist Research. Communications of the Association for Information Systems, vol. 13, no. 1, pp. 380-427 (2004)

Su, S.Y.W., Dujmović, J.J., Batory, D.S., Navathe, S.B., Elnicki, R.: A Cost-Benefit Decision Model: Analysis, Comparison, and Selection of Data Management Systems. ACM Transactions on Database Systems, vol. 12, no. 3, pp. 472-520 (1987)

Sutcliffe, A.: Designing for User Engagement: Aesthetic and Attractive User Interfaces. Synthesis Lectures on Human-Centered Informatics, vol. 2, no. 1, pp. 1-55 (2009)

Sward, D., MacArthur, G.: Making user experience a business strategy. In Law, E.L-C., Vermeeren, A.P.O.S., Hassenzahl, M., Blythe, M. (eds.), In: Workshop on Towards a UX Manifesto, pp. 35-40. COST, Lancaster (2007)

Tamir, D., Mueller, C.J., Komogortsev, O.V.: An Effort-based Framework for Evaluating Software Usability Design, Report Number TXSTATE-CS-TR-2010-22 (2010), preuzeto 23. lipnja 2012. sa <https://digital.library.txstate.edu/bitstream/handle/10877/2576/fulltext.pdf>

Tarafdar, M., Zhang, J.: Analyzing the influence of web site design parameters on web site usability. Information Resources Management Journal, vol. 18, no. 4, pp. 62–80 (2005)

Tate, M., Evermann, J., Hope, B., Barnes, S.: Perceived Service Quality in a University Web Portal: Revising the E-Qual Instrument. In: 40th Annual Hawaii International Conference on System

Sciences, p. 10. IEEE, Waikoloa (2007), preuzeto 22. lipnja 2013. sa <http://www.computer.org/csdl/proceedings/hicss/2007/2755/00/27550147b.pdf>

Taylor, S., Todd, P.A.: Assessing IT Usage: The Role of Prior Experience. MIS Quarterly, vol. 19, no. 2, pp. 561-570 (1995a)

Taylor, S., Todd, P.A.: Understanding Information Technology Usage: A Test of Competing Models. Information Systems Research, vol. 6, no. 4, pp.144-176 (1995b)

Temme, D.: Die Spezifikation und Identifikation formativer Messmodelle der Marketingforschung in Kovarianzstrukturanalysen. Marketing: Zeitschrift für Forschung und Praxis, vol. 28, no. 3, pp. 183–196 (2006)

Temme, D., Kreis, H., Hildebrandt, L.: A Comparison of Current PLS Path Modeling Software: Features, Ease-of-Use, and Performance. In: Esposito Vinzi, V., Chin, W. W., Henseler, J., Wang, H. (eds.) Handbook of Partial Least Squares, pp. 737-756. Springer, Heidelberg (2010)

Tenenhaus, M., Esposito Vinzi, V., Chatelin, Y-M., Lauro, C.: PLS path modeling. Computational Statistics & Data Analysis, vol. 48, no. 1, pp. 159–205 (2005)

Teoh, K.K., Ong, T.S., Lim, P.W., Liong, R.P.Y., Yap, C.Y.: Explorations on Web Usability. American Journal of Applied Sciences, vol. 6, no. 3, pp. 424-429 (2009)

The Minnesota Gopher Team: University of Minnesota Gopher software licensing policy (1993), preuzeto 11. srpnja 2012. sa <http://www.nic.funet.fi/pub/vms/networking/gopher/gopher-software-licensing-policy.ancient>

Thompson, A.-J., Kemp, E.A.: Web 2.0: extending the framework for heuristic evaluation. In: 10th International Conference NZ Chapter of the ACM's Special Interest Group on Human-Computer Interaction, pp. 29–36. ACM, New Zealand (2009)

Tobias, P., Spiegel, D.S.: Is Design the Preeminent Protagonist in User Experience? ACM Ubiquity, vol. 10, no. 6, DOI: <10.1145/1569801.1569802> (2009)

Tobii: The Basics of Eye Tracking (2011), preuzeto 21. lipnja 2012. sa <http://www.tobii.com/en/gaze-interaction/global/eye-tracking/

Tractinsky, N., Hassenzahl, M.: Arguing for Aesthetics in Human-Computer Interaction. I-com, vol. 4, no. 3, pp. 66-68 (2005)

Tractinsky, N., Katz, A.S., Ikar, D.: What is beautiful is usable. Interacting with Computers, vol. 13, no. 2, pp. 127–145 (2000)

Travis, D.: 247 web usability guidelines (2009), preuzeto 21. lipnja 2012. Sa <http://www.userfocus.co.uk/resources/guidelines.html>

Tripathi, P., Kumar, M., Shrivastava, N.: Ranking of Indian E-commerce Web-applications by Measuring Quality Factors. In: 9th ACIS International Conference on Software Engineering, Artificial Intelligence, Networking, and Parallel/Distributed Computing (SNPD), pp. 949-954. IEEE, Phuket (2008)

Tullis, T.S., Albert, W.B.: Measuring the User Experience: Collecting, Analyzing, and Presenting Usability Metrics. Morgan Kaufmann, Burlington (2008)

Tyldesley, D.A.: Employing usability engineering in the development of pffice products. The Computer Journal, vol. 31, no. 5, pp. 431-436 (1988)

Usability First: Customer experience (2013), preuezto 25. Lipnja 2013. Sa <http://www.usabilityfirst.com/glossary/customer-experience/>

Usability Professionals' Association (UPA): What is usability? (2013a) preuzeto 27. lipnja 2012. sa <http://www.upassoc.org/usability_resources/about_usability/definitions_of_usability.html>

Usability Professionals' Association (UPA): Usability Body of Knowledge - User Experience (UE) (2013b)< http://www.usabilitybok.org/glossary/19#letteru >

Uxmatters: What is User Experience? (2013), preuzeto 25. lipnja 2013. sa <http://www.uxmatters.com/glossary/>

Väänänen-Vainio-Mattila, K., Wäljas, M., Ojala, J., Segerståhl, K. Identifying Drivers and Hindrances of Social User Experience in Web Services. In: 28th SIGCHI Conference on Human Factors in Computing Systems, pp. 2499-2502. ACM, Atlanta (2010)

Vallerand, R.J.: Toward a hierarchical model of intrinsic and extrinsic motivation. Advances in Experimental Social Psychology, vol. 29, pp. 271–360 (1997)

Van den Haak, M.J., De Jong, M.D.T., Schellens, P.J.: Retrospective vs. concurrent think-aloud protocols: Testing the usability of an online library catalogue. Behaviour & Information Technology, vol. 22, no. 5, pp. 339-351 (2003)

Van der Heijden, H., 2003. Factors influencing the usage of websites: the case of a generic portal in The Netherlands. Information & Management, vol. 40, no. 6, pp. 541–549 (2003)

Van Schaik, P., Ling, J.: Five Psychometric Scales for Online Measurement of the Quality of Human-Computer Interaction in Web Sites. International Journal of Human-Computer Interaction, vol. 18, no. 3, pp. 309-322 (2005)

Van Schaik, P., Ling, J.: An integrated model of interaction experience for information retrieval in a Web-based encyclopaedia. Interacting with Computers, vol. 23, no. 1, pp. 18-32 (2011)

Van Welie, M., Van der Veer, G.C., Eliëns, A.: Breaking down usability. In: Seventh IFIP TC13 International Conference on Human-Computer Interaction, pp. 613–620. IOS Press, Edinburgh (1999)

Vanderdonckt, J., Beierekdar, A.: Automated Web Evaluation by Guideline Review. Journal of Web Engineering, vol. 4, no. 2, pp. 102-117 (2005)

Venkatesh, V.: Determinants of Perceived Ease of Use: Integrating Control, Intrinsic Motivation, and Emotion into the Technology Acceptance Model. Information Systems Research, vol. 11, no. 4, pp. 342–365 (2000)

Venkatesh, V., Bala, H.: Technology Acceptance Model 3 and a Research Agenda on Interventions. Decision Sciences, vol. 39, no. 2, pp. 273-315 (2008)

Venkatesh, V., Davis, F.D.: A Theoretical Extension of the Technology Acceptance Model: Four Longitudinal Field Studies. Management Science, vol. 46, no. 2, pp. 186-204 (2000)

Venkatesh, V., Morris, M.G., Ackerman, P.L.: A longitudinal field investigation of gender differences in individual technology adoption decision-making processes. Organizational Behavior and Human Decision Processes, vol. 83, no. 1, pp. 33–60 (2000)

Venkatesh, V., Morris, M.G., Davis, G.B., Davis, F.D.: User Acceptance of Information Technology: Toward a Unified View. MIS Quarterly, vol. 27, no. 3, pp. 425-478 (2003)

Venkatesh, V., Thong, J.Y.L., Xu, X.: Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology. MIS Quarterly, vol. 36, no. 1, pp. 157-178 (2012)

Vermeeren, A.P.O.S., Law, E.L-C., Roto, V., Obrist, M., Hoonhout, J., Väänänen-Vainio-Mattila, K.: User Experience Evaluation Methods: Current State and Development Needs. In: 6th Nordic Conference on Human-Computer Interaction, pp. 521-530. ACM, Reykjavik (2010)

Vetter, R.J., Spell, C., Ward, C.: Mosaic and the World Wide Web. Computer, vol. 27, no. 10, pp. 49-57 (1994)

Vilares, M.J., Almeida, M.H., Coelho, P.S.: Comparison of likelihood and PLS estimators for structural equation modeling: A simulation with customer satisfaction data. In: Esposito Vinzi, V., Chin, W. W., Henseler, J., Wang, H. (eds.) Handbook of Partial Least Squares, pp. 289-305. Springer, Heidelberg (2010)

Vora, P., Helander, M:: A Teaching method as an alternative to the concurrent think-aloud method for usablity testing. In: Anzai, Y, Ogawa, K., Mori, H. (eds.) Symbiosis of Human and Artifact: Human and Social Aspects of Human-Computer Interaction, pp.375-380. Elsevier, Amsterdam (1995)

Voss, K.E., Spangenberg, E.R., Grohmann, B.: Measuring the hedonic and utilitarian dimensions of consumer attitude. Journal of Marketing Research, vol. 40, no. 3, pp. 310 – 320 (2003)

Voyager, D.: Second Life statistics 2013 spring update (2013), preuzeto 27. lipnja 2013. sa <http://danielvoyager.wordpress.com/2013/04/02/second-life-statistics-2013-spring-update/>

Wang, R.Y, Strong, D.M.: Beyond accuracy: What data quality means to data consumers. Journal of Management Information Systems, vol. 12, no. 4, pp. 5-34 (1996)

Wallis, W.A.: The Correlation Ratio for Ranked Data. Journal of the American Statistical Association, vol. 34, pp. 533-538 (1939)

Webb, H.W., Webb, L.A.: SiteQual: an integrated measure of Web site quality. Journal of Enterprise Information Management, vol. 17, no. 6, pp. 430–440 (2004)

Weber, S., Rech, J.: An Overview and Differentiation of the Evolutionary Steps of the Web X.Y Movement: The Web Before and Beyond 2.0. In: Murugesan, S. (ed.) Handbook of Research on Web 2.0, 3.0, and X.0: Technologies, Business, and Social Applications, pp. 12-39. IGI Global, Hershey (2010)

Webster, J., J.J. Martocchio, J.J.: Microcomputer playfulness: development of a measure with workplace implications. MIS Quarterly, vol. 16, no. 2, pp. 201-226 (1992)

Weinberg, B.D.: Don’t keep your Internet customers waiting too long at the (virtual) front door. Journal of Interactive Marketing, vol. 14, no. 1, pp. 30-38 (2000)

Werts, C.E., Linn, R.L., Jöreskog, K.G.: Intraclass reliability estimates: Testing structural assumptions. Educational and Psychological Measurement, vol. 34, no. 1, pp. 25–33 (1974)

Wetzels, M., Odekerken-Schröder, G., van Oppen, C.: Using PLS Path Modeling for Assessing Hierarchical Construct Models: Guidelines and Empirical Illustration. MIS Quarterly, vol. 33, no. 1, pp. 177-195 (2009)

Wharton, C., Rieman, J., Lewis, C., Polson, P.G.: The Cognitive Walkthrough Method: A Practitioner's Gude. In: Nielsen, J., Mack, R.L. (eds.) Usability Inspection Methods, pp. 105-140. Wiley & Sons, New York (1994)

Willis, N.R.: Death of the American Investor: The Emergence of a New Global eShareholder. NetWorth Publications, Phoenix (2011)

Wilson, B., Henseler, J.: Modeling Reflective Higher-Order Constructs using Three Approaches with PLS Path Modeling: A Monte Carlo Comparison. In: Thyne, M., Deans, K. R., Gnoth, J. (eds.) Australian and New Zealand Marketing Academy Conference, pp. 791-800. University of Otago, Otago (2007)

Wixom, B.H., Todd, P.A.: A theoretical integration of user satisfaction and technology acceptance. Information Systems Research, vol. 16, no. 1, pp. 85–102 (2005)

Wixon, D., Jones, S., Tse, L., Casaday, G.: Inspections and Design Reviews: Framework, History, and Reflection. In: Nielsen, J., Mack, R.L. (eds.) Usability Inspection Methods, pp. 77-104. Wiley & Sons, New York (1994)

Wixon, D., Wilson, C.: The Usability Engineering Framework for Product Design and Evaluation. In: Helander, M.G., Landauer, T.K., Prabhu, P.V. (eds.), Handbook of Human-Computer Interaction, pp. 653-688. Elsevier, Amsterdam (1997)

Wold, H.O.A.: Path models with latent variables: The NIPALS approach. In: Blalock, H.M., Aganbegian, A., Borodkin, F.M., Boudon, R., Capecchi, V. (eds.) Quantitative sociology: International perspectives on mathematical and statistical modeling, pp. 307–357. Academic, New York (1975)

Wold, H.O.A.: Soft modeling: the basic design and some extensions. In: Jöreskog, K.G., Wold, H.O.A. (eds.), Systems under Indirect Observation, Part II, pp. 1–54, North-Holland, Amsterdam (1982)

Wold, H.O.A.: Introduction to the second generation of multivariate analysis. In: Wold, H. O. A. (ed.), Theoretical empiricism: A general rationale for scientific model-building, pp. VIII–XL. Paragon House, New York (1989)

World Wide Web Consortium (1991), preuzeto 30. travnja 2012. sa <http://www.w3.org/History/19921103-hypertext/hypertext/WWW/LineMode/

Browser.html>

World Wide Web Consortium: Tenth Anniversary Timeline (2004), preuzeto 11. srpnja 2012. sa <http://www.w3.org/2004/Talks/Styles/w3c10/images/timeline.pdf>

World Wide Web Consortium: Current Members (2012), preuzeto 12. srpnja 2012. sa <http://www.w3.org/Consortium/Member/List>

World Wide Web Consortium: Web Content Accessibility Guidelines (WCAG) 2.0 (2008), preuzeto 22. lipnja 2013. sa <http://www.w3.org/TR/WCAG20/>

Xiao, L., Dasgupta, S.: User Satisfaction with Web Portals: An Empirical Study. In: Gao, Y. (ed.) Web Systems Design And Online Consumer Behavior, pp. 193-205. Idea Group, Hershey (2005)

Xu, L., Lin, J., Chan, H. C.: The Moderating Effects of Utilitarian and Hedonic Values on Information Technology Continuance. ACM Transactions on Computer-Human Interaction, vol. 19, no. 2, DOI: 10.1145/2240156.2240160 (2012)

Yi, M.Y., Hwang, Y.: Predicting the use of web-based information systems: self-efficacy, enjoyment, learning goal orientation, and the technology acceptance model. International Journal of Human-Computer Studies, vol. 59, no. 4, pp. 431–449 (2003)

Yip, M.C.L., Mendes, E.: Web Usability Measurement: Comparing Logic Scoring Preference to Subjective Assessment. In: Lowe, D., Gaedke, M. (eds.) ICWE 2005. Lecture Notes in Computer Science, vol. 3579, pp. 53-62. Springer, Heidelberg (2005)

Yoo, B., Donthu, N.: Developing a Scale to Measure the Perceived Quality of Internet Shopping Sites (SITEQUAL), Quarterly Journal of Electronic Commerce, vol. 2, no. 1, pp. 31-47 (2001)

Zhang, P., Von Dran, G.M.: Satisfiers and dissatisfiers: A two-factor model for website design and evaluation. Journal of the American Society for Information Science, vol. 51, no. 14, pp. 1253–1268 (2000)

Zhang, Z.: Usability Evaluation. In: Zaphiris, P., Kurniawan, S. (eds.) Human Computer Interacion Research in Web Design and Evaluation, pp. 209-228. Idea Group, Hershey (2007)

Zhang, Z., Basili, V., Shneiderman, B.: An Empirical Study of Perspective-Based Usability Inspection. Proceedings of the Human Factors and Ergonomics Society Annual Meeting, vol. 42, no. 19, pp. 1346-1350 (1998)

Zhang, Z., Basili, V., Shneiderman, B.: Perspective-based Usability Inspection: An Empirical Validation of Efficacy. Empirical Software Engineering, vol. 4, no. 1, pp. 43-69 (1999)

PRILOZI

Zamolba za sudjelovanje u istraživanju poslana stručnjacima domene i
Upute stručnjacima domene za provedbu metode zatvorenog sortiranja karata iii
Upute stručnjacima domene za primjenu metode otvorenog sortiranja karata xiii
Upute stručnjacima domene za sudjelovanje u grupnom procjenjivanju težina xv
Upute sudionicima u istraživanju (verzija na hrvatskom i španjolskom jeziku) xix
Reprezentativni scenarij interakcije sa Web 2.0 aplikacijama za kolaborativno uređivanje teksta (verzija na hrvatskom i španjolskom jeziku) xxv
Reprezentativni scenarij interakcije sa Web 2.0 aplikacijama za izradu mentalnih mapa (verzija na hrvatskom i španjolskom jeziku) xxx

PRILOG A

ZAMOLBA ZA SUDJELOVANJE U ISTRAŽIVANJU POSLANA STRUČNJACIMA DOMENE

Dear Madam/Sir,

My name is Tihomir Orehovački and I am working as a teaching assistant and novice researcher at the Department of Theoretical and Applied Foundations of Information Sciences of the Faculty of Organization and Informatics in Varaždin, University of Zagreb, Croatia. My PhD supervisors are Prof. Dr. Dragutin Kermek from the University of Zagreb, and Prof. Dr. Andrina Granić from the University of Split.

The main aim of my research is development of a methodology for evaluating the quality in use of Web 2.0 applications. You have been chosen as an expert very familiar with Human Computer Interaction / Web Engineering discipline and therefore have a knowledge and experience to make valuable contribution to my study. Your participation will consist of three steps.

In a first step, I would kindly ask you to fill the online survey available at

http://www.kwiksurveys.com?s=OHHDKN_8c95a505

The survey comprises three parts: general information, professional experience, and areas of expertise. The estimated time for completion is approximately 10-15 minutes. The collected data will be used only for the purpose of my doctoral dissertation. In a second step, you will be asked to categorize a predefined list of questions into attributes and then attributes into main categories of the quality in use. The proposed names of the attributes and categories of quality in use will be given in advance. In the last step, you will be asked to determine the relative importance relevance of each question, attribute, and category. In a few weeks, I will send you a list of questions together with detailed guidelines.

I sincerely hope you will find some time to help me with my research. Thank you very much in advance.

Yours sincerely,

Tihomir Orehovački
Faculty of Organization and Informatics
University of Zagreb
Croatia
tihomir.orehovacki@foi.hr

PRILOG B

UPUTE STRUČNJACIMA DOMENE ZA PROVEDBU METODE ZATVORENOG SORTIRANJA KARATA

Dear Madam/Sir,

Thank you for accepting the request for assistance in my PhD research and completing the online survey. The main aim of my study is to develop a methodology for evaluating the quality in use of Web 2.0 applications. The essential part of the methodology are a questionnaire and a tool for logging actual use (Mousotron) and it is of high importance that they evaluate only necessary and relevant items and indicators related to the quality in use of Web 2.0 applications. Therefore, you are kindly asked to provide valuable contribution in the following steps:

1. **Carefully read the entire document.** In case of any vagueness or difficulties, please do not hesitate to contact me any time at **tihomir.orehovacki@foi.hr**
2. Evaluate the clearness, understandability, and completeness of items, indicators, attributes, and categories. If necessary, reword certain items and indicators or rephrase the name of specific attributes and categories. Moreover, if you find particular items, indicators, attributes, or category missing, please add them in the space provided.
3. Categorize items and indicators into attributes and then attributes into main categories of the quality in use of Web 2.0 applications.
4. Determine the relevance level of each item, indicator and attribute of the quality in use of Web 2.0 applications.

The purpose of the aforementioned steps is to ensure that:

- all items are clear and understandable to the potential respondents,
- a questionnaire contains all the necessary and relevant items related to the evaluation of the quality in use of Web 2.0 applications,
- objective attributes are measured with all the necessary and relevant indicators,
- collected data is valid.

The estimated time needed for the evaluation is approximately 5 hours.

GUIDELINES FOR THE EVALUATION

1. ITEMS

Start the evaluation on the first worksheet (ITEMS) in the Microsoft Excel file (QS_QIU.xls). Please evaluate the items according to the following instructions:

a. Column A contains the list of items (257). This column is locked and cannot be modified.
b. Use column B to determine the relevance of each item (you can find the definition of each relevance level on page 8):
    i. Insert 0 (zero) if for some reason you cannot determine the relevance of a particular item.
    ii. Insert 1 if you believe that a particular item is mandatory.
    iii. Insert 2 if you believe that a particular item is desired.
    iv. Insert 3 if you believe that a particular item is not important and therefore should be omitted.
c. If you think the specific item should be reworded, please do it in column C. Otherwise, you can leave the column C blank.
d. Use column D to briefly explain why the item should be reworded or why you cannot determine the relevance level of a particular item. Otherwise, you can leave the column D blank.
e. Mark with **X** the attribute (columns E – AX) for which you believe that the particular item belongs to. Please assign each item to **only one** of the proposed attributes.
f. If you find certain items missing, but necessary for evaluating the quality in use of Web 2.0 applications, you are kindly asked to:
    i. Add them below the row 259
    ii. Determine their relevance level
    iii. Assign them to the corresponding attribute
g. In order to ensure that each attribute is measured with only necessary items, please assign between 3 and 5 items to each attribute!

2. INDICATORS

Continue the evaluation on the second worksheet (INDICATORS) in the Microsoft Excel file (QS_QIU.xls). Please evaluate the indicators according to the following instructions:

a. Column A contains the list of indicators (6). This column is locked and cannot be modified.
b. Use column B to determine the relevance of each indicator (you can find the definition of each relevance level on page 8):
    i. Insert 0 (zero) if for some reason you cannot determine the relevance of a particular indicator.
    ii. Insert 1 if you believe that a particular indicator is mandatory.
    iii. Insert 2 if you believe that a particular indicator is desired.
    iv. Insert 3 if you believe that a particular indicator is not important and therefore should be omitted.
c. If you think the specific indicator should be reworded, please do it in column C. Otherwise, you can leave the column C blank.
d. Use column D to briefly explain why the indicator should be reworded or why you cannot determine the relevance level of a particular indicator. Otherwise, you can leave the column D blank.
e. Mark with **X** the attribute (columns E – AX) for which you believe that the particular indicator belongs to. Please assign each indicator to **only one** of the proposed attributes.
f. If you find certain indicators missing, but necessary for evaluating the quality in use of Web 2.0 applications, you are kindly asked to:
    i. Add them below the row 8
    ii. Determine their relevance level
    iii. Assign them to the corresponding attribute
g. Please not that it is not necessary to assign indicators to each of the proposed attributes!

3. ATTRIBUTES

Complete the evaluation on the third worksheet (ATTRIBUTES) in the Microsoft Excel file (QS_QIU.xls). Please evaluate the attributes according to the following instructions:

a. Column A contains the list of attributes (46). This column is locked and cannot be modified.
b. Use column B to determine the relevance of each attribute (you can find the definition of each relevance level on page 8):
    i. Insert 0 (zero) if for some reason you cannot determine the relevance of a particular attribute.

ii. Insert 1 if you believe that a particular attribute is mandatory.
iii. Insert 2 if you believe that a particular attribute is desired.
iv. Insert 3 if you believe that a particular attribute is not important and therefore should be omitted.

c. If you think the name of specific attribute should be rephrased, please do it in column C. Otherwise, you can leave the column C blank.
d. Use column D to briefly explain why the name of attribute should be rephrased or why you cannot determine the relevance level of a particular attribute. Otherwise, you can leave the column D blank.
e. Mark with **X** the category (columns E – J) for which you believe that the particular attribute belongs to. Please assign each attribute to **only one** of the proposed categories.
f. If you find certain attributes missing, but necessary for evaluating the quality in use of Web 2.0 applications, you are kindly asked to:
   i. Add them below the row 48
   ii. Determine their relevance level
   iii. Assign them to the corresponding category
   iv. Assign corresponding items to them in the first worksheet (ITEMS)
   v. Assign corresponding indicators to them in the second worksheet (INDICATORS)
g. If you believe that some attributes are too similar, you can merge them into one attribute.
h. If you think that some attributes are too general, but necessary, you can convert them into categories.
i. **In order to ensure that each category is measured with only necessary attributes, please allocate between 2 and 5 attributes to each category!**

DEFINITION OF TERMS

- ATTRIBUTE is a specific property or feature that can be measured by means of items and/or indicators.
- CATEGORY is a quality in use characteristic composed of attributes.
- ITEM is a questionnaire statement which the respondents will be asked to evaluate according to subjective or objective criteria.
- INDICATOR is a measure that provides an estimate of particular attributes.
- MOUSOTRON is a logging actual use tool meant for gathering objective data about mouse movements, mouse clicks, keystrokes, and time on task.

- QUALITY IN USE is considered to be one of the most important factors that affect a wide acceptance of software applications. It is comprised of two seemingly different but rather complementary concepts: usability and user experience.
- USABILITY refers to the evaluation of pragmatic attributes (e.g. efficiency, effectiveness, learnability, understandability, aesthetic, etc.) through the use of both subjective (e.g. a questionnaire) and objective measuring instruments (e.g. a tool for logging actual use).
- USER EXPERIENCE consists of applying subjective measuring instruments (e.g. a questionnaire) on the assessment of hedonic attributes (e.g. satisfaction, loyalty, pleasure, etc.).

DEFINITION OF ATTRIBUTES, CATEGORIES, AND RELEVANCE LEVELS

In order to facilitate the evaluation and categorization, please find enclosed the definition of corresponding attributes, categories, and relevance levels. Definitions are also attached as comments to corresponding attributes, categories, and relevance levels on each of the worksheets.

1. ATTRIBUTES

    - ACCESSIBILITY – extent to which the web application can be used by people with the widest range of characteristics and capabilities (e.g. users with specified disabilities).
    - AESTHETIC – degree of visual attractiveness of a web interface design.
    - ATTITUDE TOWARD BEHAVIOR – degree of users' favorableness toward web application use.
    - AVAILABILITY – degree to which web application and interface features are continuously available.
    - COLLABORATIVITY – extent to which web application supports teamwork and data sharing.
    - COMMUNICATIVITY – extent to which web application supports different types of communication among users.
    - COMPATIBILITY – degree to which web application operates properly with different types of devices (e.g. smart phones, tablets, PCs, laptops, etc.) and among different environments (e.g. web browsers, operating systems, etc.).
    - CONSISTENCY - degree to which the same structure, design, and terminology are used throughout the web application.

- CONTENT CORRECTNESS - degree to which content created by means of the web application is correct, accurate, and valid.
- CONTENT COVERAGE - degree to which content created by means of the web application is complete, displayed clearly, and appropriately represented.
- CONTENT CREDIBILITY - degree to which content created by means of the web application is unbiased, trustworthy, and verifiable.
- CONTENT TIMELINESS - degree to which content created by means of the web application can be supplemented, modified, and updated.
- CONTENT VALUE-ADDED - degree to which information content is advantageous and contributes to make new decisions.
- CONTEXT COVERAGE (FLEXIBILITY) - extent to which web application is usable within and beyond initially intended contexts of use.
- CONTROLLABILITY – extent of ease to make the web application do what the user wants (e.g. freedom in executing tasks, the order in which web interface functionalities are used, etc.)
- CUSTOMIZABILITY – degree to which the web application can be customized to meet users' needs and suit the characteristics of the task.
- EASE OF USE - extent to which interaction with the web application is free of effort.
- EFFECTIVENESS – extent to which tasks can be executed accurately and completely by using the web application.
- EFFICIENCY - extent to which the execution of a task using the web application saves resources (e.g. time to complete the task, etc.).
- ERROR PREVENTION – degree to which the web application prevents the occurrence of errors and provides the features for their correction (e.g. revision history, undo and redo functionalities, etc.).
- FAMILIARITY - extent to which interaction with the web application is similar to previously used applications.
- FEEDBACK – extent to which web application appropriately displays messages and notifies the user about its status or progress of task at hand.
- HELPFULNESS – extent to which various forms of help are available and useful.
- INTERACTIVITY – extent to which web application creates a feeling of use of desktop application (e.g. auto save) and contains functionalities that facilitate artifacts management.
- INTEROPERABILITY – degree to which web application can exchange files with other applications and use files that were exchanged.

- LEARNABILITY – degree to which is easy to learn to use the web application.
- LOYALTY – extent to which the user is willing to continue to use the web application or recommend it to others.
- MEMORABILITY - degree to which is easy to remember how the web application is used and where particular interface features are located.
- MENTAL EFFORT - the amount of mental and perceptive activity required to complete a task.
- NAVIGABILITY - extent to which web interface features are well organized and various navigation mechanisms are provided.
- PHYSICAL EFFORT – the amount of keyboard- and mouse-assisted motor activity required to complete a task.
- PLAYFULNESS - extent to which the use of web application holds the users' attention and stimulates their imagination.
- PLEASURE - extent to which the use of web application satisfies users' hedonic goals and arouses their emotional responses.
- RECOVERABILITY – extent to which the web application can recover from errors and operational interruptions.
- RELIABILITY – extent to which web application is dependable, stable, and bug-free.
- REPUTATION - extent to which popularity of web application affect user's decision to use it.
- RESISTANCE TO CHANGES – degree to which the user is interested in new web technologies and likes to try them out.
- RESPONSIVENESS - extent of the speed of the web application's response to users' requests and actions
- SATISFACTION - extent to which the web application use meets user's expectations
- SCALABILITY - extent to which the web application is capable to operate under an increased or expanding workload (e.g. simultaneous work of a large number of users or simultaneous execution of a large number of complex tasks, etc.)
- SEARCHABILITY – extent of efficiency and accuracy of the web application's internal search engine.
- SECURITY - degree to which web application contains functionalities and mechanisms that protect data from unauthorized use.
- SOCIAL INFLUENCE – extent to which people whose opinion is relevant to user or information in various media influence user's decision to use the web application.

- UNDERSTANDABILITY - extent to which interface functionalities (e.g. menu elements, icons) are clear and unambiguous to the user.
- UNIQUENESS – extent to which the web application is distinctive among applications with the same purpose.
- USEFULNESS – extent to which using the web application improves the user performance in executing tasks.

2. CATEGORIES

- SYSTEM QUALITY – refers to the attributes that measure the quality of the web application as a system.
- SERVICE QUALITY – refers to the attributes that measure the quality of interaction between the web application and users.
- CONTENT QUALITY – refers to the attributes that measure the quality of the content created by means of the web application.
- PERFORMANCE - refers to the attributes that measure the quality of tasks execution using the web application.
- EFFORT - refers to the attributes that measure the effortlessness of the web application use.
- ACCEPTABILITY – refers to the attributes that measure the likeability and behavioral intentions related to the web application use.

3. RELEVANCE LEVELS

- MANDATORY – an essential item, indicator, attribute, or category for evaluating the quality in use of Web 2.0 applications.
- DESIRED – an important (but not mandatory) item, indicator, attribute, or category for evaluating the quality in use of Web 2.0 applications.
- NOT RELEVANT – item, indicator, attribute, or category that is not important for evaluating the quality in use of We 2.0 applications and therefore should be omitted.

IMPORTANT NOTES

1. In order to make the evaluation process easier, the first column and top row are fixed. When using the horizontal slider, you will notice that list of list of metrics (on first worksheet), and attributes (on second worksheet) remain fixed while other columns are moving left or right. On the other hand, when using vertical slider or mouse scroll, you will notice that headers on first and second worksheets remain fixed while other rows are moving up or down.
2. All the fields that should not be filled are locked.
3. After completing all three worksheets (ITEMS, INDICATORS, and ATTRIBUTES), please add your valuable comments in the fourth worksheet (COMMENTS).
4. In the last worksheet (STATISTICS) you can track the number of items and indicators you have assigned to particular attribute as well as the number of attributes you have allocated to specific category.
5. When assessing items, indicators, and attributes please consider that they will be used for evaluation of Web 2.0 applications such as Google Docs or Mindomo.
6. **It is not necessary to fill the whole Microsoft Excel file (QS_QIU.xls) at once!** You can save your work somewhere on your computer and continue at any time.

Thank you very much for all your efforts and time!

Yours sincerely,

Tihomir Orehovački
Faculty of Organization and Informatics
University of Zagreb
Croatia
tihomir.orehovacki@foi.hr

PRILOG C

UPUTE STRUČNJACIMA DOMENE ZA PRIMJENU METODE OTVORENOG SORTIRANJA KARATA

Dear Madam/Sir,

Thank you for accepting the request for assistance in my PhD research. You are kindly asked to provide valuable contribution in the following steps:

1. **Carefully read the entire document.** In case of any vagueness or difficulties, please do not hesitate to contact me any time at **tihomir.orehovacki@foi.hr**
2. Using card sorting program written in Java, categorize attributes of the **quality in use of Web 2.0 applications**.

GUIDELINES FOR THE EVALUATION

Start the evaluation by running the **CardSortingGRIHO.jar** program and opening **qs_tihomir.jdt** file. Run sorting exercise, enter your name and using the drag-and-drop functionality, categorize attributes according to their theoretical similarities. If you believe that particular attribute is not aimed for evaluating the **quality in use of Web 2.0 applications**, please leave it uncategorized. At the end of evaluation, give a name to each of the categories you created.

After you complete the evaluation, please send the results of the card sorting (file with **.ecs** extension) by e-mail to **tihomir.orehovacki@foi.hr**

Thank you very much for all your efforts and time!

Yours sincerely,

Tihomir Orehovački
Faculty of Organization and Informatics
University of Zagreb
Croatia

PRILOG D

UPUTE STRUČNJACIMA DOMENE ZA SUDJELOVANJE U GRUPNOM PROCJENJIVANJU TEŽINA

Dear Madam/Sir,

Thank you for accepting the request for assistance in my PhD research. This is the very last part of the evaluation involving experts in the field. You are kindly asked to provide valuable contribution in the following steps:

1. Carefully read the entire document**.** In case of any vagueness or difficulties, please do not hesitate to contact me any time at **tihomir.orehovacki@foi.hr**
2. Using MS Excel, please assign:
    a. the relevance rank and weight to each item and indicator in measuring the underlying construct (colored yellow) of the quality in use of Web 2.0 applications;
    b. the relevance rank and weight to lower-level constructs regarding their impact on higher-level construct (colored yellow).

GUIDELINES FOR THE EVALUATION

1. ASSIGNING RELEVANCE LEVELS TO ITEMS AND INDICATORS

Start with the evaluation on the worksheet ITEMS in the Microsoft Excel file (**rlw_qiu.xls**). Column A contains the list of items and underlying constructs (colored yellow). Please assign relevance levels according to the following instructions:

a. Use column B to assign the **rank** to each item thus evaluating its relevance in measuring the underlying constructs. Given that **n** represents number of items aimed for measuring underlying construct, please:
    i. Insert **n-1** if you believe that particular item is the most important for measuring the underlying construct.
    ii. Insert **n-2** if you believe that particular item is second most important for measuring the underlying construct.
    iii. …
    iv. Insert **0** if you believe that particular item is the least important for measuring the underlying construct.

For example, if particular construct is measured with 3 items (e.g. Accessibility) then please assign rank 2 to the most important item, rank 1 to the second important item, and rank 0 to the least important item. On the other hand, if particular construct is measured with 5 items (e.g. Feedback) then please assign rank 4 to the most important

item, rank 3 to the second important item, rank 2 to the third important item, rank 1 to the fourth important item, and rank 0 to the least important item.

b. Use column C to assign the **relevance weight** to each item (**1 – very weak importance; 2 - weak importance; 3 - moderate importance; 4 - strong importance; 5 - very strong importance**) meant for measuring the underlying construct. Please note that two or more items can have the same importance in measuring the underlying construct.
c. If you think the name of specific item should be rephrased, please do it in column D. Otherwise, you can leave the column D blank.

Continue with the evaluation on the worksheet ITEMS+INDICATORS where items and indicators jointly measure underlying higher-level construct. Please repeat steps a-c in order to assign both relevance rank and level to each item and indicator aimed for measuring underlying higher-level construct.

2. ASSIGNING RELEVANCE LEVELS TO CONSTRUCTS

Continue with the evaluation on the worksheet 1ST LEVEL where you are kindly asked to evaluate the impact of lower-level constructs on higher-level constructs. Column A contains the list of lower-level constructs affecting the higher-level construct (colored yellow). Please assign relevance levels in accordance with the following instructions:

a. Use column B to assign the **rank** to each lower-level construct thus evaluating its impact on the higher-level construct. Given that **n** represents number of lower-level constructs, please:
    i. Insert **n-1** if you believe that particular lower-level construct (e.g. 2nd level) has the highest impact on higher-level (e.g. 1st level) construct.
    ii. Insert **n-2** if you believe that particular lower-level construct (e.g. 2nd level) has the second highest impact on higher-level (e.g. 1st level) construct.
    iii. …
    iv. Insert **0** if you believe that particular lower-level construct (e.g. 2nd level) has the lowest impact on higher-level (e.g. 1st level) construct.

For example, if particular higher-level construct (e.g. Loyalty) is affected by 3 lower-level constructs then please assign rank 2 to the lower-level construct that has the highest impact on the higher-level construct, rank 1 to the lower-level construct that has the second highest impact on the higher-level construct, and rank 0 to the lower-level construct that has the lowest impact on the higher-level construct.

b. Use column C to assign the **relevance weight of impact** to each lower-level construct (**1 – very weak importance; 2 - weak importance; 3 - moderate importance; 4 - strong importance; 5 - very strong importance**) affecting the higher-level construct. Please note that two or more lower-level constructs can have the same impact on the higher-level construct.
c. If you think the name of specific construct should be rephrased, please do it in column D. Otherwise, you can leave the column D blank.

Please repeat steps a-c for all the remaining sheets in the Microsoft Excel file.

IMPORTANT NOTES

1. In order to make the evaluation process easier, the first column is fixed. When using the horizontal slider, you will notice that list of constructs remain fixed while other columns are moving left or right.
2. When assigning relevance levels to items, indicators, and constructs, please consider that they are used for evaluation of Web 2.0 applications such as **Google Docs** (collaborative writing) or **Mindomo** (mind mapping).
3. After you complete all the aforementioned steps of the evaluation, please send the results by e-mail to **tihomir.orehovacki@foi.hr**

Thank you very much for all your efforts and time!

Yours sincerely,

Tihomir Orehovački
Faculty of Organization and Informatics
University of Zagreb
Croatia

PRILOG E

UPUTE SUDIONICIMA U ISTRAŽIVANJU
(VERZIJA NA HRVATSKOM I ŠPANJOLSKOM JEZIKU)

UPUTE SUDIONICIMA ISTRAŽIVANJA

Poštovani studenti,

Hvala Vam što sudjelujete u istraživanju vezano uz izradu doktorske disertacije!

Prije nego što započnete sa provedbom istraživanja, molim Vas da obratite pozornost na sljedećih nekoliko koraka:

1. Instalirajte Mousotron na svom računalu. Najnoviju verziju Mousotrona (7.0) možete preuzeti sa sljedećeg web mjesta: **http://www.blacksunsoftware.com/mousotron.html**
2. Provjerite da li su na Vašem računalu instalirana sljedeća dva web preglednika: Google Chrome i Mozilla Firefox. Molim da prije provedbe istraživanja instalirate **oba** web preglednika na svoje računalo.
3. U zaglavlju oba obrasca, napišite svoje službeno korisničko ime (LDAP) kako bi se podaci koji će se prikupiti mogli razlikovati. Primjerice, LDAP studenta Ivan Horvat može biti u kraćem (**ihorvat**) ili dužem (**ivan.horvat**) obliku. Molim Vas da **isto** korisničko ime koristite na svim mjestima gdje je to u koracima scenarijama navedeno, kod kreiranja korisničkih računa za obje aplikacije te kod popunjavanja online upitnika.
4. Provjerite da li je alat Mousotron pravilno konfiguriran:
    a. Da li prikuplja sve podatke kao na slici 1
    b. Da li je podešen na metrički sustav (km, m, cm)
    c. Da li definirana veličina monitora odgovara veličini monitora sa kojim radite

Slika 1. Pravilno konfiguriran Mousotron

5. **Ako je Mousotron pravilno konfiguriran, preskočite ovaj korak.** U slučaju da Mousotron nije pravilno konfiguriran to možete učiniti na sljedeći način (prikazano na slici 2):
    a. Desnim klikom miša bilo gdje u programu odaberite **Setup Mousotron Pro** (isti efekt se postiže klikom na gumb **Setup**),
    b. Pod karticom **General** podesite veličinu zaslona (**Monitor**) tako da odgovara dimenzijama monitora kojeg koristite,
    c. Podesite **Units** na **Metric system**,
    d. Pod karticom Displayed Items označite sve kućice.

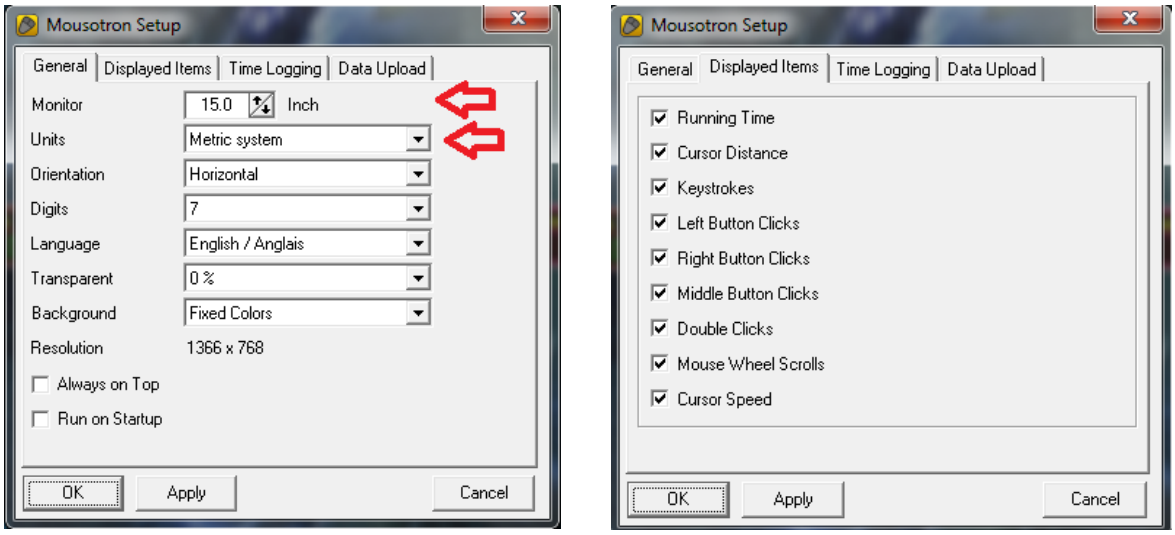

Slika 2. Konfiguracija Mousotrona

6. Prije provedbe istraživanja resetirajte brojač (**desni klik – Reset Counters)** i **ugasite Mousotron**
7. Optimalna količina vremena potrebna za dovršetak scenarija je 30-40 minuta po aplikaciji. Online upitnik (**276 pitanja**) je potrebno popuniti tek nakon što je scenarij dovršen sa obje aplikacije.
8. **VRLO VAŽNO!** Ukoliko korake scenarija koji započinju sa „provjerite“ ili „pronađite“ ne možete izvršiti u roku od najviše dvije minute, preskočite taj korak i uz njega stavite oznaku minus (-). Naime, bez obzira na to što su neki koraci scenarija navedeni, to ne znači da ih je sve moguće izvršiti sa obje aplikacije. Navedeno se ne odnosi na korake kreiranja korisničkog računa, crtanja, pisanja te korak koji zahtjeva ponavljanje nekoliko koraka scenarija sa alternativnim web preglednikom!
9. Na kraju provedbe scenarija sa svakom od aplikacija potrebno je zaustaviti Mousotron, izraditi njegov screenshot (tipka PrintScreen) i zalijepiti (CTRL+V) u Word. Uz svaki screenshot potrebno je navesti na koju se aplikaciju odnosi. Word dokument je potrebno poslati na sljedeću e-mail adresu: **tihomir.orehovacki@gmail.com**
10. Nakon provedbe scenarija sa obje aplikacije, potrebno je popuniti online upitnik. **Preporučljivo je da se online upitnik popunjava odjednom!** Ako će se popunjavati u više navrata, predlažem da se to učini u Firefox web pregledniku sa uključenim Javascript i kolačićima (cookies). Optimalno vrijeme za popunjavanje online upitnika je 50 minuta.
11. Ukoliko niste sigurni kako bi vrednovali web aplikaciju prema nekoj tvrdnji, predlažem da pokrenete web aplikaciju i prisjetite se rada sa njom ili provjerite da li sadrži funkcionalnost koja je sa tvrdnjom iz upitnika povezana.
12. Obrazac koji sadrži korake scenarija (**KP_FOI** ili **MM_FOI**) je potrebno predati najkasnije do **26. siječnja 2012. godine** u vrijeme nadoknada laboratorijskih vježbi ili u vrijeme konzultacija.

Od iznimno je velike važnosti da podaci prikupljeni Mousotronom i online upitnikom budu valjani. Stoga Vas molim da oba koraka istraživanja izvršite u potpunosti. Puno hvala!!!

Tihomir Orehovački

INSTRUCCIONES PARA LOS PARTICIPANTES EN EL ESTUDIO

Apreciados estudiantes,

Gracias por participar en una investigación relacionada con mi tesis doctoral!

Antes de empezar con el estudio, porfavor presten atención a los siguientes pasos:

1. Instalen Mousotron en su ordenador. La última versión de Moustron puede descargarse de: http://www.blacksunsoftware.com/mousotron.html
2. Verifiquen que en su ordenador tienen instalados los navegadores **Google Chrome** y **Mozilla Firefox, ambos** son necesarios para los pasos posteriores.
3. Para poder diferenciar los datos recogidos, se ruega que escriban su nombre de usuario en la cabecera del formulario con los pasos del escenario. Por ejemplo, el nombre del usuario **Juan García** puede indicarse en su forma abreviada (**jgarcia**) o completa (**juan.garcia**). Porfavor, usen **el mismo** nombre de usuario en los pasos del escenario cada vez que se lo pidan, cuando creen una cuenta en cada una de las aplicaciones y cuando completen el cuestionario online.
4. Asegúrense que Mousotron está configurado correctamente:
   a. Recoge todos los datos tal y como se muestra en la figura 1?
   b. Está configurado en el sistema métrico (km, m, cm)?
   c. La medida de pantalla definida en el programa corresponde con la suya?

Figura 1. Mousotron con una configuración correcta

5. **Si Mousotron está configurado correctamente, pueden saltar este paso.** En caso contrario, se ruega configuren Mousotron como se indica a continuación (ver figura 2):

   Pulse el botón derecho del ratón en cualquier parte del programa para seleccionar **Setup Mousotron Pro**. También se puede llegar a esta opción con el botón de **Setup**.

   a. Pulse el botón derecho del ratón en cualquier parte del programa para seleccionar **Setup Mousotron Pro**. También se puede llegar a esta opción con el botón de **Setup**.
   b. En la pestaña **General**, indicar la medida de la pantalla (**Monitor**) según el monitor usado.
   c. Establecer las Unidades al Sistema métrico (**Units**, **Metric system**)
   d. En la pestaña **Displayed Items** activar todas las opciones.

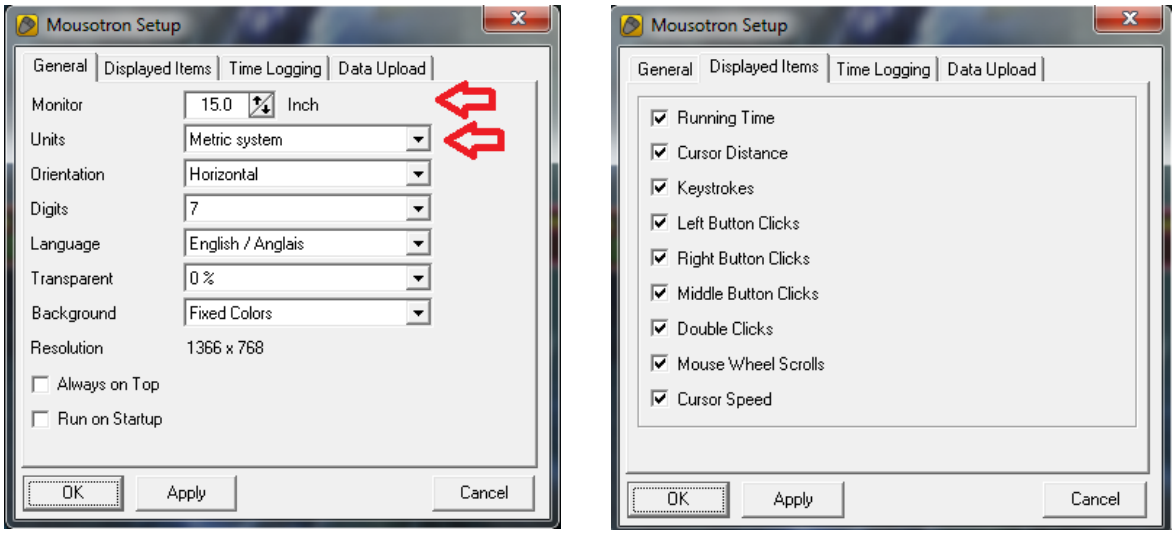

Figura 2. Configuración de Mousotron

6. Antes de empezar los pasos del escenario, resetear el contador (**botón derecho del ratón – Reset Counters**) y apage Mousotron.
7. El tiempo óptimo de realización de los escenarios es de 30 a 40 minutos por aplicación. Porfavor, completen primero todos los pasos del escenario con ambas aplicaciones antes de empezar a rellenar los cuestionarios en línea (276 ítems) .
8. **MUY IMPORTANTE!** Si el paso del escenario que empieza por "verifica" o "busca" no se puede finalizar en dos minutos, salténselo e introduzcan un signo de menos (-) junto a él. Aunque algunos de los pasos se han listado en el escenario, ello no significa que puedan realizarse con ambas aplicaciones. Lo anterior **no se aplica a**: los pasos de creación de cuentas de usuarios, de dibujar un mapa o escribir un texto, o de repetición de algunos pocos pasos del escenario con un navegador web alternativo!
9. Cuando hayan completado todos los pasos del escenario con la aplicación, porfavor paren Mousotron, hagan una captura de pantalla de los datos recogidos (con la tecla PrintScreen) y copienla (con las teclas Ctrl+V) en un documento Microsoft Word. Porfavor, para cada captura especifiquen a cuál de las aplicaciones usadas corresponde. Envien porfavor el documento MS Word con las capturas de pantalla a la siguiente dirección e-mail: **tihomir.orehovacki@gmail.com**
10. Cuando hayan completado todos los pasos del escenario con ambas aplicaciones, porfavor rellenen el formulario online. **Es recomendable rellenar todo el cuestionario de una sola vez!** De todos modos, si planean rellenarlo en diferentes momentos, les sugiero cargar el cuestionario usando Chrom o Firefox y activar Javascripts y cookies. El tiempo óptimo para rellenar el formulario es de 50 minutos.
11. Si dudan sobre la evaluación de una aplicación web al responder uno de los ítems del cuestionario, les sugiero que la carguen de nuevo en su navegador web e intenetn recordar como la usaron o verifiquen si contiene la característica a la que hace referencia la pregunta del cuestionario.
12. Porfavor, complete el cuestionario de manera que se comparen las aplicaciones que ha estado usando y se responda las preguntas especificadas.
13. Porfavor, imprima el escenario, rellene las respuetas (+ ó -) en la hoja impresa.

a. Las personas cuyos **apellidos** empiezan por una letra de la **A a la M** deben escoger el escenario Aplicaciones para Escritura Colaborativa (fichero: **CW_UDL.pdf**)
b. Las personas cuyos **apellidos** empiezan por una letra de la **N a la Z** deben escoger el escenario del Mapa Mental (fichero: **MM_UDL.pdf**)

14. Porfavor realice **TODO** antes del **26 de Mayo de 2012**. Completa el cuestionario online y envie la hoja del escenario con la tarea a esta dirección de correo: tihomir.orehovacki@gmail.com
    a. Si es un estudiante de Lleida, puede dársela directamente al profesor Toni Granollers
    b. En caso contrario, puede escanear las hojas resultatntes o bien escribir de nuevo las respuestas en el docuemnto word (por favor, **no responda directamente en la hoja word mientras ralice el ejercicio**).

Es muy importante que los datos recogidos con Mousotron y con los cuestionario sean válidos. Por ello, les ruego que realizen todos los pasos de la investigación al completo. Muchísimas gracias!!!

Tihomir Orehovački, Universidad de Zagreb, Croacia

PRILOG F

REPREZENTATIVNI SCENARIJ INTERAKCIJE SA WEB 2.0 APLIKACIJAMA ZA KOLABORATIVNO UREĐIVANJE TEKSTA (VERZIJA NA HRVATSKOM I ŠPANJOLSKOM JEZIKU)

Unesite Vaše korisničko ime (LDAP):	

VRJEDNOVANJE KVALITETE U KORIŠTENJU WEB 2.0 APLIKACIJAMA

Istraživanje je sastavni dio doktorske disertacije čiji je cilj razviti metodologiju koja će olakšati analizu i usporedbu vrjednovanih Web 2.0 aplikacija. Vaše sudjelovanje u istraživanju će se sastojati od dva koraka. U prvom ćete pomoću dvije Web 2.0 aplikacije odraditi nekoliko online aktivnosti prema unaprijed zadanom scenariju dok ćete u drugom popuniti online upitnik. Kako bi lakše pratili koji ste dio scenarija odradili, predlažem da znakom plus (+) označite svaki korak scenarija koji ste odradili. Ukoliko naiđete na korak scenarija koji zbog bilo kojeg razloga ne možete realizirati, preskočite ga i uz njega stavite minus (-). **Prije nego što pristupite popunjavanju upitnika, potrebno je scenarij dovršiti sa obje Web 2.0 aplikacije.** Scenarij je najprije potrebno izvršiti pomoću Web 2.0 aplikacije Zoho Writer (oznaka 1 u tablici), a nakon toga pomoću Web 2.0 aplikacije Microsoft Word Web App (oznaka 2 u tablici). **Hvala Vam što sudjelujete u ovom istraživanju!**

Tihomir Orehovački, FOI Varaždin

KORACI SCENARIJA	**1**	**2**
1. Pokrenite **Mousotron** (ikona se nalazi na desktopu računala).		
2. Pokrenite web preglednik **Google Chrome**. Koristeći web tražilicu (npr. Google) pronađite i učitajte web aplikaciju.		
3. Provjerite da li je web aplikaciju moguće koristiti bez izrade korisničkog računa.		
4. Provjerite da li web aplikacija omogućava prijavu sa postojećim korisničkim računom (Google, Facebook, Open ID, Yahoo i sl.)		
5. Izradite korisnički račun te se prijavite sa korisničkim imenom i lozinkom.		
6. Kreirajte novi tekstualni dokument naziva **prvi_LDAP** gdje je LDAP vaše korisničko ime. U slučaju studenta **Ivan Horvat** dokument bi nosio naziv **prvi_ihorvat**		
7. Provjerite koje sve vrste pomoći korisnicima pruža web aplikacija.		
8. U materijalima pomoći pronađite kako se učitava slika u dokument.		
9. Pronađite na kojim je sve uređajima podržan rad sa web aplikacijom (PC, tablet, pametni mobilni telefoni i sl.)		
10. Pronađite popis tipkovničkih kratica i u njemu kraticu za podcrtavanje (underline) teksta		
11. Na sučelju pronađite ikonu za umetanje poveznice (linka) te na njoj zaustavite kursor miša.		
12. Podesite veličinu radnog lista na 120%.		
13. Postavite prikaz radnog lista na cijeli ekran (full screen).		
14. Vratite veličinu i prikaz radnog lista na početne (default) vrijednosti. Promijenite jezik sučelja na hrvatski jezik. Ukoliko je sučelje već na hrvatskom jeziku, promijenite ga u engleski jezik.		
15. Na radnom listu napišite sljedeći tekst: **Razlike između Web 1.0 i Web 2.0 aplikacija**		
16. Tekst iz koraka 15 formatirajte na sljedeći način: font: Helvetica, veličina 16, boja: ljubičasta, stil: podebljano i podcrtano.		
17. Ugasite web preglednik. Ponovno pokrenite web preglednik i učitajte web aplikaciju.		
18. Provjerite da li su se promjene u **prvi_LDAP** automatski pohranile prije gašenja web preglednika. Nastavite raditi sa dokumentom **prvi_LDAP**		
19. Na radnom listu nacrtajte sljedeću tablicu: *Web 1.0* | *Web 2.0* korištenje | sudjelovanje		
20. Na radnom listu napišite sljedeću formulu: $A = \sqrt{b}\pi r^2$		

21. U dokument učitajte sliku pustinje (Desert) koja se nalazi na računalu pod My Documents/Sample Pictures. Podesite veličinu slike na 307 x 230 piksela.		
22. U podnožje dokumenta (footer) umetnite brojeve stranica.		
23. Označite sav sadržaj dokumenta te ga kopirajte u desktop aplikaciju Microsoft Word.		
24. Pohranite promjene nad dokumentom te ga označite sljedećim ključnim riječima (tagovima): research, Web 2.0		
25. Datoteku **prvi_LDAP** pohranite u **.doc** formatu bilo gdje na računalu te otvorite pomoću desktop aplikacije Microsoft Word.		
26. Datoteku **prvi_LDAP** pohranite u **.pdf** formatu bilo gdje na računalu.		
27. Izradite dokument **drugi_LDAP** i u njega kopirajte naslov, tablicu i sliku iz **prvi_LDAP.** Neka za vrijeme kopiranja oba dokumenta budu otvorena/aktivna.		
28. Pomoću web aplikacije otvorite bilo koju tekstualnu datoteku (.doc ili .docx) koja se nalazi na računalu te joj promijenite ime u **treci_LDAP**		
29. Tekstu u datoteci **treci_LDAP** promijenite font u Arial veličine 10 te ga obostrano poravnajte.		
30. Kreirajte mapu **dokumenti** i tamo prebacite datoteku **treci_LDAP**		
31. Preko liste kontakata, korisniku **torehova** ili **torehova@gmail.com** dodijelite mogućnost modifikacije dokumenta **prvi_LDAP.**		
32. Generirajte direktnu poveznicu za **javno** pristupanje dokumentu **drugi_LDAP**		
33. Dokument **treci_LDAP** učinite **privatnim**.		
34. Provjerite da li web aplikacija sadrži funkcionalnost čavrljanja (chat)		
35. U dokumentu **prvi_LDAP** obrišite sliku pustinje. Korištenjem opcije undo, poništite brisanje slike.		
36. U dokumentu **drugi_LDAP** obrišite sliku pustinje. Korištenjem opcije za upravljanje promjenama nad dokumentom (npr. **revision history**), poništite brisanje slike.		
37. U web pregledniku **Mozilla Firefox** učitajte web aplikaciju i ponovite korake 19-22. Dokument nazovite **cetvrti_LDAP.** Ugasite Mozillu Firefox i nastavite rad u **Google Chrome** web pregledniku.		
38. Dokumentu **prvi_LDAP** pridružite sljedeći komentar: **Kolaborativno pisanje**		
39. Provjerite da li postoji mogućnost objavljivanja sadržaja dokumenta na društvenoj mreži		
40. Uključite opciju o primanju promjena nad dokumentom **prvi_LDAP** putem e-maila		
41. Provjerite da li postoji funkcionalnost pamćenja korisničkog imena i lozinke (remember me) te da li postoji mogućnost oporavka korisničkog računa (zaboravljena lozinka i sl.)		
42. Korištenjem interne tražilice pretražite/filtrirajte dokumente. Kao ključnu riječ najprije koristite **treci**, potom **treći** i na kraju **Web 2.0**		
43. Sortirajte prikaz kreiranih dokumenata prema nazivu.		
44. Obrišite dokument **cetvrti_LDAP**		
45. Provjerite da li web aplikacija sadrži politiku privatnosti i uvjete korištenja		
46. Web aplikaciju prebacite u offline način rada. Odjavite se i ugasite web preglednik.		
47. **Zaustavite Mousotron**. Napravite screenshot prikupljenih podataka (tipka PrtScr) i kopirajte (Ctrl+V) u Word dokument. **Resetirajte brojač (desni klik – Reset Counters). Ugasite Mousotron**.		
48. Pobrišite sve datoteke koje ste pohranili na računalo.		
49. Ponovite korake 1-48 sa drugom aplikacijom.		
50. Dokument sa Mousotron screenshotovima pohranite prema sljedećem formatu: **FOI_KP_LDAP.doc** gdje je LDAP Vaše korisničko ime. Dokument pošaljite na **tihomir.orehovacki@gmail.com**		

Popunite online upitnik koji se nalazi na: **http://www.kwiksurveys.com?u=PISANJE**
ILI **http://www.kwiksurveys.com?s=OCJMMI_96a35535**

Entre tu nombre de usuario:	

EVALUANDO LA CALIDAD DE USO DE APLICACIONES WEB 2.0

El estudio es parte de una tesis doctoral que tiene por objetivo el desarrollar una metodología que facilite el análisis y la comparación de la evaluación de aplicaciones Web 2.0. Su participación en el estudio consistirá en la realización de dos pasos. En primer lugar, se le pide que complete unas actividades online de acuerdo a un escenario predefinido. Posteriormente, en segundo lugar, se le pide que conteste a un cuestionario (también online). Para facilitarle el seguimiento de las partes del escenario que vaya completando, le sugiero que vaya marcando con un signo más (+) cada vez que complete un paso del escenario. Si durante la realización se encuentra que por cualquier razón no puede completar un determinado paso, sálteselo y márquelo con un signo menos (-). **Por favor, no empiece con el cuestionario hasta que haya completado todos los pasos del escenario con las dos aplicaciones Web 2.0.** Primeramente, complete todos los pasos del escenario utilizando la aplicación Web 2.0 **Zoho Writer** (etiqueta 1 en la tabla), posteriormente realice lo mismo utilizando la aplicación Web 2.0 **Microsoft Word Web App** (etiqueta 2 en la tabla). **Muchas gracias por participar en este estudio!**

Tihomir Orehovački, Universidad de Zagreb, Croacia

PASOS DEL ESCENARIO	**1**	**2**
1. Ejecute la aplicación **Mousotron** (icono en el escritorio)		
2. Ejecute el navegador web **Google Chrome**. Mediante un buscador (por ejemplo Google), encuentre y acceda a la aplicación web.		
3. Compruebe si la aplicación Web puede utilizarse sin la creación de una cuenta de usuario.		
4. Compruebe si la aplicación Web permite identificarse mediante una cuenta existente (Google, Facebook, Open ID, Yahoo, etc.)		
5. Cree una cuenta de usuario e identifíquese con dicha cuenta (login y password).		
6. Cree un documento de texto nuevo con el nombre **primero_NDU** donde **NDU** representa su nombre de usuario. Por ejemplo, si el nombre del estudiante es **Juan García** el documento a crear deberá llamarse **primero_juan_garcia**		
7. Comprueba qué tipos de ayuda proporciona la aplicación web a los usuarios.		
8. En la ayuda, encuentra la información acerca de cómo insertar una imagen en el documento.		
9. Encuentra información sobre los diferentes dispositivos que soportan la aplicación (PC, Tablet, smartphone, etc.)		
10. Encuentra la lista de "atajos del teclado" y en esta el atajo para subrayar texto.		
11. En la interfaz web, encuentra el icono para insertar un enlace (link) y sitúa el cursor del ratón encima de éste.		
12. Ajusta el tamaño de la hoja de cálculo al 120%.		
13. Visualiza la hoja de cálculo en modo de pantalla completa.		
14. Establece el tamaño y la visualización de la hoja de cálculo a los valores por defecto. Cambia las preferencias del idioma a español. Si la interfaz ya está en español, cámbialo a inglés.		
15. Escribe el siguiente texto en la hoja de cálculo (documento): **Diferencias entre aplicaciones Web 1.0 y Web 2.0**		
16. Formatea el texto que has escrito en el paso 15 con estas características: fuente: Helvetica, tamaño 16, color: purpura, estilo: negrita y subrayado.		
17. Cierra el navegador web. Ejecuta de nuevo el navegador y carga la aplicación web.		
18. Comprueba que los cambios en **primero_NDU** se han guardado de forma automática antes de cerrar el navegador. Procede a trabajar con el documento **primero_NDU.**		
19. En la hoja de cálculo (documento) crea la siguiente tabla: *Web 1.0* | *Web 2.0* usando | participando		
20. En la hoja de cálculo (documento), crea la siguiente fórmula: $A = \sqrt{b}\pi r^2$		
21. Inserta una imagen de un desierto en el documento. La imagen se encuentra en este sitio:		

Bibliotecas/Imágenes/Imágenes de muestra. Ajusta el tamaño de la imagen a 307 x 230 píxeles.		
22. Añade los números de página en el pie del documento.		
23. Selecciona todo el contenido del documento y cópialo en la aplicación de escritorio Microsoft Word.		
24. Guarda los cambios en un documento y etiquétalo con las siguientes palabras: investigación, Web 2.0		
25. Guarda el documento como **primero_NDU.doc** en cualquier lugar de tu ordenador y después ábrelo con la aplicación de escritorio Microsoft Word.		
26. Guarda el documento como **primero_NDU.pdf** en cualquier lugar de tu ordenador.		
27. Crea un documento **segundo_NDU** y copia en él el título, la tabla y la imagen desde **primero_NDU**. Asegúrate que durante la copia ambos documentos están abiertos/activos.		
28. Utilizando aplicaciones web, abre cualquier fichero de texto (.doc O .docx) úbicado en tu ordenador y renómbralo cómo **tercero_NDU**		
29. Cambia el formato del estilo del texto en **tercero_NDU** con estas características: Arial, tamaño 10 y alineación justificada.		
30. Crea una carpeta **documentos** y sitúa en ella el fichero **tercero_NDU**		
31. Usando la lista de contactos, asigna permisos para poder modificar el documento **primero_NDU** al usuario **torehova** O **torehova@gmail.com**		
32. Genera un enlace (link) directo para acceso público al documento **segundo_NDU**		
33. Marca como privado el documento **tercero_NDU**.		
34. Comprueba si la aplicación Web dispone de características para realizar un chat.		
35. En el documento **primero_NDU** elimina la imagen del desierto. Utilizando la característica "deshacer" ("undo"), cancela la eliminación de la imagen.		
36. En el documento **segundo_NDU** elimina la imagen del desierto. Utilizando las características para gestionar cambios en el documento (por ejemplo "revisión histórica"), cancela la eliminación de la imagen.		
37. Utilizando el navegador web **Mozilla Firefox**, carga la aplicación web y repite los pasos 19-22. Titula el nuevo documento como **cuarto_NDU**. Cierra el navegador Mozilla Firefox y continúa trabajando con el navegador web Google Chrome.		
38. Añade el comentario **escritura colaborativa** al documento **primero_NDU**		
39. Comprueba si existe una opción para compartir/publicar el contenido del documento en las redes sociales.		
40. Activa la opción para recibir los cambios mediante correo-e para los cambios realizados en el documento **primero_NDU**		
41. Comprueba si existe una característica para recordar el nombre de usuario y el password y si existe alguna opción para recuperar la cuenta (por ejemplo, para el caso de no recordar el password, etc.).		
42. Utilizando el buscador de documentos interno, utiliza las siguientes palabras clave para búsqueda: primero **tercero**, y después **Web 2.0**		
43. Ordena los documentos creados por el nombre.		
44. Elimina el documento **cuarto_NDU**		
45. Comprueba si la aplicación web contiene políticas de privacidad y términos de uso.		
46. Cambia la aplicación Web al modo "offline". Desconéctate (log off) y cierra el navegador web.		
47. **Para Mousotron**. Toma una captura de pantalla de los datos recolectados (tecla ImpPan) y cópiala (ctrl + V) en un documento Word. **Resetea el contador (botón derecho del ratón – Reset Counters). Cierra Mousotron**.		
48. Elimina todos los ficheros que has salvado en tu ordenador.		
49. Repite los pasos 1-48 con otra aplicación.		
50. Guarda capturas de pantalla de Mousotron en el documento **UdL_CW_NDU.doc** dónde NDU es tu nombre de usuario. Envía el documento a **tihomir.orehovacki@gmail.com**		

Completa el cuestionario online que podrás encontrar en este enlace web: **http://kwiksurveys.com?u=ESCRITO** O **http://kwiksurveys.com?s=LBMOGJ_d0e25bcc**

PRILOG G

REPREZENTATIVNI SCENARIJ INTERAKCIJE SA WEB 2.0 APLIKACIJAMA ZA IZRADU MENTALNIH MAPA (VERZIJA NA HRVATSKOM I ŠPANJOLSKOM JEZIKU)

Unesite Vaše korisničko ime (LDAP):	

VRJEDNOVANJE KVALITETE U KORIŠTENJU WEB 2.0 APLIKACIJAMA

Istraživanje je sastavni dio doktorske disertacije čiji je cilj razviti metodologiju koja će olakšati analizu i usporedbu vrjednovanih Web 2.0 aplikacija. Vaše sudjelovanje u istraživanju će se sastojati od dva koraka. U prvom ćete pomoću dvije Web 2.0 aplikacije odraditi nekoliko online aktivnosti prema unaprijed zadanom scenariju dok ćete u drugom popuniti online upitnik. Kako bi lakše pratili koji ste dio scenarija odradili, predlažem da znakom plus (+) označite svaki korak scenarija koji ste odradili. Ukoliko naiđete na korak scenarija koji zbog bilo kojeg razloga ne možete realizirati, preskočite ga i uz njega stavite minus (-). **Prije nego što pristupite popunjavanju upitnika, potrebno je scenarij dovršiti sa obje Web 2.0 aplikacije.** Scenarij je najprije potrebno izvršiti pomoću Web 2.0 aplikacije Mindomo (oznaka 1 u tablici), a nakon toga pomoću Web 2.0 aplikacije Wise Mapping (oznaka 2 u tablici). **Hvala Vam što sudjelujete u ovom istraživanju!**

Tihomir Orehovački, FOI Varaždin

KORACI SCENARIJA	**1**	**2**
1. Pokrenite **Mousotron** (ikona se nalazi na desktopu računala).		
2. Pokrenite web preglednik **Google Chrome**. Koristeći web tražilicu (npr. Google) pronađite i učitajte web aplikaciju.		
3. Provjerite da li je web aplikaciju moguće koristiti bez izrade korisničkog računa.		
4. Provjerite da li web aplikacija omogućava prijavu sa postojećim korisničkim računom (Google, Facebook, Open ID, Yahoo i sl.)		
5. Izradite korisnički račun te se prijavite sa korisničkim imenom i lozinkom.		
6. Kreirajte novi dokument naziva **prva_LDAP** gdje je LDAP vaše korisničko ime. U slučaju studenta **Ivan Horvat** dokument bi nosio naziv **prva_ihorvat**		
7. Provjerite koje sve vrste pomoći korisnicima pruža web aplikacija.		
8. U materijalima pomoći pronađite kako se formatiraju elementi mentalne mape (boja, font i sl.)		
9. Pronađite na kojim je sve uređajima podržan rad sa web aplikacijom (PC, tablet, pametni mobilni telefoni i sl.)		
10. Pronađite popis tipkovničkih kratica i u njemu kraticu za podcrtavanje teksta (underline)		
11. Na sučelju pronađite ikonu za umetanje poveznice (linka) te na njoj zaustavite kursor miša.		
12. Podesite veličinu radnog lista na 120%.		
13. Postavite prikaz radnog lista na cijeli ekran (full screen).		
14. Vratite veličinu i prikaz radnog lista na početne (default) vrijednosti. Promijenite jezik sučelja na hrvatski jezik. Ukoliko je sučelje već na hrvatskom jeziku, promijenite ga u engleski jezik.		
15. Na radnom listu izradite mentalnu mapu sa centralnom temom (topic) **godišnja doba** i podtemama **proljeće, ljeto, jesen** i **zima**		
16. Tekst centralne teme formatirajte na sljedeći način: font: Arial, veličina 16, boja: ljubičasta, stil: podebljano. Tekst podtema formatirajte na sljedeći način: font: Helvetica, veličina 12, boja: crna, stil: ukošeno		
17. Ugasite web preglednik. Ponovno pokrenite web preglednik i učitajte web aplikaciju.		
18. Provjerite da li su se promjene u **prva_LDAP** automatski pohranile prije gašenja web preglednika. Nastavite raditi sa dokumentom **prva_LDAP**		
19. Svakoj temi i podtemi pridružite ikonu.		
20. Glavnoj temi pridružite link: **www.foi.unizg.hr**		
21. Pohranite promjene nad dokumentom te ga označite sljedećim ključnim riječima (tagovima): research, Web 2.0		

22. Datoteku **prva_LDAP** pohranite u **.png** formatu bilo gdje na računalu te učitajte pomoću desktop aplikacije Microsoft Word.		
23. Datoteku **prva_LDAP** pohranite u **.pdf** formatu bilo gdje na računalu.		
24. Izradite dokument **druga_LDAP**. Na radnom listu izradite mentalnu mapu sa centralnom temom (topic) **mjeseci** i podtemama **prosinac, siječanj** i **veljača**		
25. Iz dokumenta **druga_LDAP** kopirajte podteme **prosinac, siječanj** i **veljača** te ih pridružite podtemi **zima** u dokumentu **prva_LDAP** kao podteme treće razine**.** Neka za vrijeme kopiranja oba dokumenta budu otvorena/aktivna.		
26. Provjerite da li postoji mogućnost učitavanja (import) mentalne mape koja je nastala korištenjem druge web ili desktop aplikacije za izradu mentalnih mapa.		
27. Izradite dokument **treca_LDAP** te u njega kopirajte mapu iz **prva_LDAP.** Rasporedite podteme tako da proljeće i ljeto budu s desne, a jesen i zima s lijeve strane centralne teme.		
28. Preko liste kontakata, korisniku **torehova** ili **torehova@gmail.com** dodijelite mogućnost modifikacije dokumenta **prva_LDAP**		
29. Generirajte direktnu poveznicu za **javno** pristupanje dokumentu **druga_LDAP**		
30. Datoteku **treca_LDAP** učinite **privatnom**.		
31. Kreirajte mapu dokumenti i u nju prebacite datoteku **treca_LDAP**		
32. Provjerite da li web aplikacija sadrži funkcionalnost čavrljanja (chat)		
33. U dokumentu **prva_LDAP** obrišite podtemu jesen. Korištenjem opcije **undo**, poništite brisanje podteme.		
34. U dokumentu **prva_LDAP** obrišite podtemu zima. Korištenjem opcije za upravljanje promjenama nad dokumentom (npr. **revision history**), poništite brisanje podteme.		
35. U web pregledniku **Mozilla Firefox** učitajte web aplikaciju i ponovite korake 15, 16, 19 i 20. Dokument nazovite **cetvrta_LDAP.** Ugasite Mozillu Firefox i nastavite rad u **Google Chrome** web pregledniku.		
36. Dokumentu **prva_LDAP** pridružite sljedeći komentar: **Mentalna mapa**		
37. Provjerite da li postoji mogućnost objavljivanja sadržaja dokumenta na društvenoj mreži		
38. Uključite opciju o primanju promjena nad dokumentom **prva_LDAP** putem e-maila		
39. Provjerite da li postoji funkcionalnost pamćenja korisničkog imena i lozinke (remember me) te da li postoji mogućnost oporavka korisničkog računa (zaboravljanje lozinke i sl.)		
40. Korištenjem interne tražilice pretražite/filtrirajte dokumente. Kao ključnu riječ najprije koristite **treca**, potom **treća** i na kraju **Web 2.0**.		
41. Sortirajte prikaz kreiranih dokumenata prema nazivu.		
42. Obrišite dokument **cetvrta_LDAP**		
43. Provjerite da li web aplikacija sadrži politiku sigurnosti/privatnosti i uvjete korištenja.		
44. Web aplikaciju prebacite u offline način rada. Odjavite se i ugasite web preglednik.		
45. **Zaustavite Mousotron**. Napravite screenshot prikupljenih podataka (tipka PrtScr) i kopirajte (Ctrl+V) u Word dokument. **Resetirajte brojač (desni klik – Reset Counters). Ugasite Mousotron**.		
46. Pobrišite sve datoteke koje ste pohranili na računalo.		
47. Ponovite korake 1-46 sa drugom aplikacijom.		
48. Dokument sa Mousotron screenshotovima pohranite prema sljedećem formatu: **FOI_MM_LDAP.doc** gdje je LDAP Vaše korisničko ime. Dokument pošaljite na **tihomir.orehovacki@gmail.com**		

Popunite online upitnik koji se nalazi na: **http://www.kwiksurveys.com?u=MAPE**
ILI **http://www.kwiksurveys.com?s=OCHIOK_e79b36cc**

Entre tu nombre de usuario:	

EVALUANDO LA CALIDAD DE USO DE LAS APLICACIONES WEB 2.0

El estudio es parte del trabajo doctoral cuyo objetivo es desarrollar una metodología que permita facilitar el análisis y comparación de las aplicaciones Web 2.0 evaluadas. Su participación en el estudio consistirá en dos partes. En la primera parte, se le solicitará completar unas actividades en línea de acuerdo al escenario predefinido, mientras que en la segunda parte se le solicitará llenar una encuesta en línea. Con el fín de facilitar el seguimiento de las partes del escenario que han sido completadas, se sugiere colocar el signo más (+) junto a cada paso del escenario que se haya completado. De lo contrario, si hay alguna parte que no se hay acompletado, se puede obviar y colocar el signo menos(-) junto a cada paso. **Antes de comenzar a llenar la encuesta en línea, por favor complemete todos los pasos del escenario con ambas aplicaciones Web 2.0.** En primer lugar, complete todos los pasos del escenario usando la aplicación Web 2.0 **Mindomo** (etiqueta 1 in la tabla), y después la aplicacióm Web 2.0 **Wise Mapping** (etiqueta 2 in la tabla). **Muchas gracias por participar en este estudio!**

Tihomir Orehovački, Universidad de Zagreb, Croacia

PASOS DEL ESCENARIO	1	2
1. Ejecute el **Mousotron** (el ícono está en el escritorio).		
2. Ejecute el navegador **Google Chrome**. Usando un buscador (e.j. Google) encuentre y cargue la aplicación Web.		
3. Verifique si la aplicación Web puede ser usada sin crear una cuenta.		
4. Verifique si la aplicación Web permite logearse sin tener una cuenta existente (Google, Facebook, Open ID, Yahoo, etc.)		
5. Crear una cuenta y logearse con su nombre de usuario y clave.		
6. Crear un nuevo documento (mapa mental) llamado **primero_NDU** donde **NDU** representa su usuario. Por ejemplo, el estudiante **Juan García** debería crear un documento llamado **primero_juan_garcia**		
7. Verificar que tipo de ayuda la aplicación Web provee a los usuarios.		
8. En la ayuda de materiales encontrar la información sobre como darle forma al estilo de los mapas mentales (color, tipo de letra, etc.)		
9. Encontrar información sobre que dispositivos pueden ser utilizados con la aplicación Web (PC, tablet, smartphone, etc.)		
10. Encontrar una lista de shortcuts y con ellos subrayar el texto.		
11. En la interface Web, ubicar el ícono para incluir un link y colocar el cursor del mouse sobre él.		
12. Ajustar el tamaño de la hoja de trabajo al 120%.		
13. Configurar la hoja de trabajo a una vista completa de la pantalla.		
14. Configurar el tamaño y despliegue de la hoja de trabajo a los valores por defecto. Cambiar las preferencias del lenguaje a Español. Si la interface ya está en Español cambiarla a Inglés.		
15. En la hoja de trabajo crear un mapa mental con los temas **estaciones del año** y subtemas **verano, primavera, otoño e invierno**		
16. Cambiar las propiedades del texto del tema central a: tipo: Arial, tamaño: 16, color: morado, estilo: Negrilla. Cambiar las propiedades del texto a los subtemas a: tipo: Helvetica, tamaño: 12, color: negro, estilo: italico		
17. Cerrar el navegador web. Ejecutar nuevamente el navegador Web y cargar la aplicación Web.		
18. Verificar si los cambios en **primero_NDU** se han guardado automáticamente antes de cerrar la aplicación Web. Continue trabajando con el documento **primero_NDU**		
19. Agregue un ícono a cada tema y subtema.		
20. Agregue un link **www.foi.unizg.hr** al tema.		
21. Guarde los cambios del documento y etiquetelo con las siguientes palabras claves: investigación, Web 2.0		

22. Guarde el documento como **primero_NDU.png** en cualquier parte de su computador y luego abralo usando la aplicación de escritorio Microsoft Word.		
23. Guarde el documento como **primero_NDU.pdf** en cualquier parte de su computador.		
24. Crear un documento **segundo_NDU**. En la hoja de trabajo cree un mapa mental con el tema **meses** y subtemas **diciembre, enero y febrero**.		
25. Copar los subtemas **diciembre, enero y febrero** del documento **segundo_NDU** y pegarlos como subtemas del 3er nivel al subtema **invierno** en el documento **primero_NDU**. Estar seguro que durante el proceso de copiado los documentos estén abiertos/activos.		
26. Verificar si la aplicación web contiene una característica de importar mapas mentales creados usando otras aplicaciones Web o aplicaciones de escritorio para mapas mentales.		
27. Crear un mapa mental **tercero_NDU** y copiar un mapa mental desde **primero_NDU.** Organizar lso subtemas de tal forma que primavera y verano estén en el lado derecho, y otoño e invierno en el lado izquierdo del tema principal.		
28. Usando la lista de contactos, asigne permisos al usuario **torehova** O **torehova@gmail.com** de poder modificar el documento **primero_NDU**.		
29. Generar un link directo para acceso público al documento **segundo_NDU**		
30. Hacer que el documento **tercero_NDU** sea privado.		
31. Crear una carpeta **documentos** y luego ubicarla en el archivo **tercero_NDU**.		
32. Verificar si la aplicación Wen contiene un chat.		
33. En el documento **primero_NDU** borrar el subtema **otoño**. Usando la opción de deshacer, cancelar la eliminación del subtema.		
34. En el documento **primero_NDU** borrar el subtema **invierno**. Usando la funcionalidad para administrar cambios en el documento (e.j. revisión histórica), cancelar la eliminación del subtema.		
35. Usando el navegador **Mozilla Firefox**, cargar la aplicación Web y repetir los pasos 15, 16, 19, y 20. Denomine al nuevo documento creado como **cuarto_NDU**. Cierre el navegador Mozilla Firefox y continue con el navegador Google Chrome.		
36. Adicione el comentario **Mind map** al documento **primero_NDU**		
37. Verificar si hay una opción para compartir/publicar el contenido del documento en la Red Social.		
38. Facilitar la opción de recibir cambios por e-mail para los cambios del documento **primero_NDU**.		
39. Verificar si hay una funcionalidad de recordar el nombre de uusaurio y contraseña y si hay una opción de recuperar la cuenta (en caso de olvido de la contraseña por ejemplo)		
40. Usando el buscador interno localice los documentos. Usar las siguientes palabras claves para búsqueda: primero **tercero**, y luego **Web 2.0**		
41. Organizar los documentos creados por el item de nombre.		
42. Borrar el documento **cuarto_NDU**		
43. Verificar si la aplciación web contiene políticas de privacidad y términos de uso.		
44. Cambia la aplicción web a modo offline.		
45. **Detener Mousotron**. Hacer una captura de pantalla de los datos recolectados (tecla PRTSCR) y copiarlo (Ctrl + V) en un documento Word. **Configurar el contador (botón derecho - Reset Counters). Cerrar Mousotron**.		
46. Borrar todos los archivos que has guardado en el.		
47. Repetir los pasos 1-46 con otra aplicación.		
48. Guarda capturas de pantalla de Mousotron en el documento **UdL_CW_NDU.doc** dónde NDU es tu nombre de usuario. Envía el documento a **tihomir.orehovacki@gmail.com**		

Completar el cuestionario en línea que está ubicado en: **http://kwiksurveys.com?u=MAPAS**
O **http://kwiksurveys.com?s=LBENMF_e7cdbdb5**

ŽIVOTOPIS

Tihomir Orehovački rođen je 24. kolovoza 1982. godine u Koprivnici. Osnovnu školu završio je 1996. godine u Svetom Petru Orehovcu. Srednju školu „Ivan Seljanec“, smjer komercijalist završio je 2000. godine u Križevcima. Iste je godine upisao Fakultet organizacije i informatike u Varaždinu. Diplomirao je 17. veljače 2005. godine na smjeru Informacijski sustavi. Pedagoško-psihološku naobrazbu stekao je 2006. godine na Visokoj učiteljskoj školi u Čakovcu. Poslijediplomski sveučilišni doktorski studij upisao je na Fakultetu organizacije i informatike u studenome 2006. godine. Po završetku diplomskog studija bio je zaposlen na radnom mjestu financijskog savjetnika u poslovnici Wüstenrot stambene štedionice u Čakovcu, profesora stručnih predmeta u Graditeljskoj školi u Čakovcu te učitelja informatike u Osnovnoj školi Vladimira Nazora u Zagrebu. Od 16. listopada 2006. zaposlen je na Fakultetu organizacije i informatike u suradničkom zvanju asistent na Katedri za teorijske i primijenjene osnove informacijskih znanosti. Sudjelovao je ili još uvijek sudjeluje u izvođenju nastave na kolegijima Strukture podataka, Programiranje 1 i Programiranje 2 na sveučilišnom preddiplomskom studiju, Računalom posredovana komunikacija na sveučilišnom diplomskom studiju te Dizajn programskih proizvoda, Programiranje i Napredno programiranje na stručnom studiju.

Znanstveno se i stručno usavršavao na brojnim radionicama u zemlji i inozemstvu. Sudjelovao je u radu na jednom međunarodnom Tempus projektu i dva projekta koja su bila financirana iz domaćih sredstava. Od travnja do srpnja 2012. godine boravio je na Sveučilišta u Lleidi u Španjolskoj gdje je u sklopu GRIHO istraživačke grupe proveo projekt koji je bio financiran sredstvima Hrvatske zaklade za znanost. Bio je suorganizator i predavač na dvije radionice vezane uz upravljanje međunarodnim projektima, te pet radionica i jednog webinara na temu primjene Web 2.0 aplikacija u obrazovanju. Aktivni je recenzent za nekoliko međunarodnih znanstvenih konferencija (CHI, INTERACT, IUI, ITI, InSITE i IISIT) i znanstvenih časopisa (JSS i IJEE). Član je programskog odbora međunarodne znanstvene konferencije ACM International Conference on Intelligent User Interfaces. Dobitnik je sljedećih nagrada i priznanja: TUTOREM 2012 Mini-Project Winner, Priznanje Dekana Fakulteta organizacije i informatike za posebno zalaganje u istraživanjima i publiciranju radova u 2011. godini, Nagrada za uporabu društvenog softvera u e-kolegiju na Sveučilištu u Zagrebu za akademsku godinu 2010./2011., EUNIS Dørup E-learning Award 2011 i EUNIS 2010 Commended Paper. Član je Laboratorija za generativno programiranje i strojno učenje. Bio je član Odbora za promotivne aktivnosti FOI te član Povjerenstva natjecanja FOI CORE 2009. i 2010. godine. Član je međunarodnih strukovnih udruženja ACM, EUNIS ELTF, IEEE i ISWE. Objavio je 49 znanstvenih i 9 stručnih radova.

POPIS RADOVA

Znanstveni radovi

1. **Orehovački, Tihomir**; Granić, Andrina; Kermek, Dragutin. Evaluating the Perceived and Estimated Quality in Use of Web 2.0 Applications. The Journal of Systems and Software, vol. 86, no. 12, pp. 3039-3059 (2013)
2. **Orehovački, Tihomir**; Kermek, Dragutin; Granić, Andrina. Examining the Quality in Use of Web 2.0 Applications: A Three-Dimensional Framework. In: Stephanidis, C. (ed.) Posters, Part I, HCII 2013. Communications in Computer and Information Science, vol. 373, pp. 149-153. Springer, Heidelberg (2013)
3. **Orehovački, Tihomir**; Žajdela Hrustek, Nikolina. Development and Validation of an Instrument to Measure the Usability of Educational Artifacts Created with Web 2.0 Applications. In: Marcus, A. (ed.), DUXU, Part I, HCII 2013. Lecture Notes in Computer Science, vol. 8012, pp. 369-378. Springer, Heidelberg (2013)
4. Radošević, Danijel; Magdalenić, Ivan; **Orehovački, Tihomir**. Building Process of SCT Generators. Proceedings of the 36th International Convention on Information and Communication Technology, Electronics and Microelectronics, pp. 1037-1042. IEEE, Opatija (2013)
5. **Orehovački, Tihomir**; Žajdela Hrustek, Nikolina. Towards a Framework for Usability Evaluation of Educational Artifacts created with Web 2.0 Applications: A Pilot Study. Proceedings of the 36th International Convention on Information and Communication Technology, Electronics and Microelectronics, pp. 565-570. IEEE, Opatija (2013)
6. **Orehovački, Tihomir**; Al Sokkar, Abdullah A.M.; Derboven, Jan; Khan, Azam. Exploring the Hedonic Quality of Slow Technology. CHI 2013 Workshop on Changing Perspectives of Time in HCI, pp. 1-6. ACM, Paris (2013)
7. Magdalenić, Ivan; Radošević, Danijel; **Orehovački, Tihomir**. Autogenerator: Generation and Execution of Programming Code on Demand. Expert Systems with Applications, vol. 40, no. 8, pp. 2845-2857 (2013)
8. Bubaš, Goran; Ćorić, Ana; **Orehovački, Tihomir**. The integration and assessment of students' artefacts created with diverse Web 2.0 applications. International Journal of Knowledge Engineering and Soft Data Paradigms, vol. 3, no. 3/4, pp. 261-279 (2012)

9. Kovačić, Andreja; Bubaš, Goran; **Orehovački, Tihomir**. Thinking outside the task: Learner autonomy and creativity in Web 2.0-based dialogic spaces. eLearning Tag 2012 - E-Didaktik - Lernen in virtuellen sozialen Räumen, pp. 83-89. FH Joanneum - University of Applied Sciences, Graz (2012)
10. Kovačić, Andreja; Bubaš, Goran; **Orehovački, Tihomir**. Integrating culture into a Business English course: Students' perspective on a collaborative online writing project. Proceedings of the 23rd Central European Conference on Information and Intelligent Systems, pp. 195-202. Faculty of Organization and Informatics, Varaždin, Croatia (2012)
11. Bubaš, Goran; **Orehovački, Tihomir**; Kovačić, Andreja. E-learning with Web 2.0 Tools: What Can('t) Go Wrong. Book of Abstracts of the 18th European University Information Systems (EUNIS) Congress, pp. 43-44. Universidade de Trás-os-Montes e Alto Douro, Vila Real (2012)
12. **Orehovački, Tihomir**; Radošević, Danijel; Konecki, Mladen. Acceptance of Verificator by Information Science Students. Proceedings of the 34th International Conference on Information Technology Interfaces, pp. 223-230. IEEE, Cavtat (2012)
13. Reif, Ivan; **Orehovački, Tihomir**. ViSA: Visualization of Sorting Algorithms. Proceedings of the 35th MIPRO International Convention on Computers in Education, pp. 1146-1151. IEEE, Opatija (2012)
14. Radošević, Danijel; **Orehovački, Tihomir**; Magdalenić, Ivan. Towards Software Autogeneration. Proceedings of the 35th International Convention on Information and Communication Technology, Electronics and Microelectronics, pp. 1076-1081. IEEE, Opatija (2012)
15. **Orehovački, Tihomir**; Bubaš, Goran; Kovačić, Andreja. Taxonomy of Web 2.0 Applications with Educational Potential. In: Cheal, Catheryn; Coughlin, John; Moore, Shaun (eds.) Transformation in Teaching: Social Media Strategies in Higher Education, pp. 43–72. Informing Science Press, Santa Rosa (2012)
16. **Orehovački, Tihomir**; Granić, Andrina; Kermek, Dragutin. Exploring the Quality in Use of Web 2.0 Applications: The Case of Mind Mapping Services. In: Harth, Andreas; Koch, Nora (eds.) ICWE 2011 Workshops. Lecture Notes in Computer Science, vol. 7059, pp. 266–277. Springer, Heidelberg (2012)
17. Radošević, Danijel; Magdalenić, Ivan; **Orehovački, Tihomir**. Error Messaging in Generative Programming. Proceedings of the 22nd Central European Conference on Information and Intelligent Systems, pp. 181–186. Faculty of Organization and Informatics, Varaždin (2011)

18. Đanić, Mario; Radošević, Danijel; **Orehovački, Tihomir**. Evaluation of Student Programming Assignments in Online Environments. Proceedings of the 22nd Central European Conference on Information and Intelligent Systems, pp. 111–116. Faculty of Organization and Informatics, Varaždin (2011)
19. **Orehovački, Tihomir**. Development of a Methodology for Evaluating the Quality in Use of Web 2.0 Applications. In: Campos, Pedro; Graham, Nicholas; Jorge, Joaquim; Nunes, Nuno; Palanque, Philippe; Winckler, Marco (eds.) INTERACT 2011, Part IV. Lecture Notes in Computer Science, vol. 6949, pp. 382–385. Springer, Heidelberg (2011)
20. **Orehovački, Tihomir**. Perceived Quality of Cloud Based Applications for Collaborative Writing. In: Pokorny, Jaroslav; Repa, Vaclav; Richta, Karel; Wojtkowski, Wita; Linger, Henry; Barry, Chris; Lang, Michael (eds.) Information Systems Development – Business Systems and Services: Modeling and Development, pp. 575–586. Springer, Heidelberg (2011)
21. Radošević, Danijel; **Orehovački, Tihomir**. An Analysis of Novice Compilation Behavior using Verificator. Proceedings of the 33rd International Conference on Information Technology Interfaces, pp. 325–330. IEEE, Cavtat (2011)
22. **Orehovački, Tihomir**; Schatten, Markus; Lovrenčić, Alen. Implementing a Logic System for Testing Functional Independent Normal Form in Relational Databases. Proceedings of the 33rd International Conference on Information Technology Interfaces, pp. 167–172. IEEE, Cavtat (2011)
23. Bubaš, Goran; Ćorić, Ana; **Orehovački, Tihomir**. Strategies for implementation of Web 2.0 tools in academic education. In: 17th EUNIS International Congress, pp. 1–17. European University Information Systems, Dublin (2011)
24. Bubaš, Goran; Ćorić, Ana; **Orehovački, Tihomir**. The integration of students' artifacts created with Web 2.0 tools into Moodle, blog, wiki, e-portfolio and Ning. Proceedings of the 35th International Convention on Information and Communication Technology, Electronics and Microelectronics, pp. 1084–1089. IEEE, Opatija, (2011)
25. Bubaš, Goran; Ćorić, Ana; **Orehovački, Tihomir**. The Evaluation of the Use of Online Community Tool Ning for Support of Student Interaction and Learning. Proceedings of the 21st Central European Conference on Information and Intelligent Systems, pp. 171–178. Faculty of Organization and Informatics, Varaždin (2010)
26. Radošević, Danijel; **Orehovački, Tihomir**; Stapić, Zlatko. Automatic On-line Generation of Student's Exercises in Teaching Programming. Proceedings of the 21st Central European Conference on Information and Intelligent Systems, pp. 87–93. Faculty of Organization and Informatics, Varaždin (2010)

27. Bubaš, Goran; **Orehovački, Tihomir**; Ćorić, Ana; Balaban, Igor. Evaluation of Web 2.0 Tools in the e-Learning Context: Case Studies Related to Pedagogy and Usability. In: Rudak, Leszek; Diks, Krzysztof; Madey, Jan (eds.) University Information Systems - Selected Problems, pp. 259–277. Difin SA, Warsaw (2010)

28. **Orehovački, Tihomir**. Proposal for a Set of Quality Attributes Relevant for Web 2.0 Application Success. Proceedings of the 32nd International Conference on Information Technology Interfaces, pp. 319–326. IEEE, Cavtat (2010)

29. Radošević, Danijel; **Orehovački, Tihomir**; Lovrenčić, Alen. Verificator: Educational Tool for Learning Programming. Informatics in Education, vol. 8 no. 2, pp. 261–280 (2009)

30. Konecki, Mario; **Orehovački, Tihomir**; Kermek, Dragutin. Design Patterns - education and classification challenge. Proceedings of the 20th Central European Conference on Information and Intelligent Systems, pp. 375–381. Faculty of Organization and Informatics, Varaždin (2009)

31. Radošević, Danijel; **Orehovački, Tihomir**; Lovrenčić, Alen. New approaches and tools in teaching programming. Proceedings of the 20th Central European Conference on Information and Intelligent Systems, pp. 49–57. Faculty of Organization and Informatics, Varaždin (2009)

32. **Orehovački, Tihomir**; Stapić, Zlatko; Bubaš, Goran. Mobile location based service for location and presentation of cultural heritage objects and Web 2.0 technologies. Informatologia, vol. 42 no. 2, pp. 110–117 (2009)

33. Lovrenčić, Alen; Konecki, Mario; **Orehovački, Tihomir**. 1957 - 2007: 50 Years of Higher Order Programming Languages. Journal of Information and Organizational Sciences, vol. 33 no. 1, pp. 79–150 (2009)

34. Stapić, Zlatko; **Orehovački, Tihomir**; Lovrenčić, Alen. In Search of an Improved BoM and MRP Algorithm. Proceedings of the 31st International Conference on Information Technology Interfaces, pp. 665–670. IEEE, Cavtat (2009)

35. **Orehovački, Tihomir**; Bubaš, Goran; Konecki, Mario. Web 2.0 in Education and Potential Factors od Web 2.0 Use by Students of Information Systems. Proceedings of the 31st International Conference on Information Technology Interfaces, pp. 443–448. IEEE, Cavtat (2009)

36. Konecki, Mario; **Orehovački, Tihomir**; Lovrenčić, Alen. Detecting Computer Code Plagiarism in Higher Education. Proceedings of the 31st International Conference on Information Technology Interfaces, pp. 409–414. IEEE, Cavtat (2009)

37. Konecki, Mario; **Orehovački, Tihomir**; Stapić, Zlatko. IT Users' Awareness about the Need of Strong Passwords Creation. In: Katalinic, Branko (ed.) DAAAM International Scientific Book 2008, pp. 387–394. DAAAM International, Vienna (2008)
38. Bubaš, Goran; **Orehovački, Tihomir**, Konecki, Mario. Factors and Predictors of Online Security and Privacy Behavior. Journal of Information and Organizational Sciences, vol. 32 no. 2, pp. 79–98 (2008)
39. Radošević, Danijel; Konecki, Mario; **Orehovački, Tihomir**. Java Applications Development Based on Component and Metacomponent Approach. Journal of Information and Organizational Sciences, vol. 32 no. 2, pp. 137–147 (2008)
40. Konecki, Mario; **Orehovački, Tihomir**; Lovrenčić, Alen. Detecting code re-use potential. Proceedings of the 19th Central European Conference on Information and Intelligent Systems, pp. 627–631. Faculty of Organization and Informatics, September 24-26, Varaždin, Croatia (2008)
41. Đanić, Mario; **Orehovački, Tihomir**; Stapić, Zlatko. Introducing CaCM: towards new students collaboration model. Proceedings of the 19th Central European Conference on Information and Intelligent Systems, pp. 267–273. Faculty of Organization and Informatics, September 24-26, Varaždin, Croatia (2008)
42. Stapić, Zlatko; **Orehovački, Tihomir**; Đanić, Mario. Determination of optimal security settings for LMS Moodle. Proceedings of the 31st MIPRO International Convention on Information Systems Security, pp. 84–89. Croatian Society for Information and Communication Technology, Electronics and Microelectronics, Opatija (2008)
43. **Orehovački, Tihomir**; Konecki, Mario; Radošević, Danijel. Web 2.0 technologies in university education. Proceedings of the 31st MIPRO International Convention on Computers in Education, pp. 269–273. Croatian Society for Information and Communication Technology, Electronics and Microelectronics, Opatija (2008)
44. Stapić, Zlatko; **Orehovački, Tihomir**; Vrček, Neven. Modular Approach in Integration of ICT Technologies into Mobile Heart-Work Monitoring System. Proceedings of the 27th International Conference on Organizational Science Development, pp. 2793–2799. Faculty of Organizational Sciences, Portorož (2008)
45. **Orehovački, Tihomir**; Konecki, Mario; Bubaš, Goran. Security and Privacy Related Online Behavior of Experienced ICT Users. Proceedings of the 27th International Conference on Organizational Science Development, pp. 1932–1940. Faculty of Organizational Sciences, Portorož (2008)

46. Radošević, Danijel; **Orehovački, Tihomir**; Konecki, Mario. Web oriented applications generator development through reengineering process. In: Katalinic, Branko (ed.) DAAAM International Scientific Book 2007, pp. 443–458. DAAAM International, Vienna (2007)
47. **Orehovački, Tihomir**; Dušak, Vesna; Jadrić, Mario. Choosing the most appropriate simulation method for business process modelling using AHP method. Proceedings of the 18th International Conference on Information and Intelligent Systems, pp. 257–262. Faculty of Organization and Informatics, Varaždin (2007)
48. Konecki, Mario; Hutinski, Željko; **Orehovački, Tihomir**. Secure web applications? Proceedings of the 30th MIPRO International Convention on Information System Security, pp. 162–166. Croatian Society for Information and Communication Technology, Electronics and Microelectronics, Opatija (2007)
49. Radošević, Danijel; **Orehovački, Tihomir**; Konecki, Mario. PHP Scripts Generator for Remote Database Administration based on C++ Generative Objects. Proceedings of the 30th MIPRO International Convention on Intelligent Systems, pp. 167–171. Croatian Society for Information and Communication Technology, Electronics and Microelectronics, Opatija (2007)

Stručni radovi

1. Plantak Vukovac, Dijana; **Orehovački, Tihomir**. Metode vrednovanja web upotrebljivosti. CASE 22 - metode i alati za razvoj poslovnih i informatičkih sustava, pp. 171–182. June 7-9, Zagreb, Croatia (2010)
2. **Orehovački, Tihomir**. Vremenski plan rada na projektu. In: Divjak, Blaženka (ed.) Projekti u znanosti i razvoju: Europski programi, pp. 55–64. TIVA Tiskara, Varaždin (2009)
3. Konecki, Mario; Stapić, Zlatko; **Orehovački, Tihomir**. Razvoj aplikacija korištenjem uzoraka dizajna. CASE 20 - metode i alati za razvoj poslovnih i informatičkih sustava, pp. 203–209. June 3-5; Opatija, Croatia (2008)
4. **Orehovački, Tihomir**; Konecki, Mario; Stapić, Zlatko. Primjena Web 2.0 tehnologija u poslovanju. CASE 20 - metode i alati za razvoj poslovnih i informatičkih sustava, pp. 197–202. June 3-5, Opatija, Croatia (2008)
5. Stapić, Zlatko; **Orehovački, Tihomir**; Konecki, Mario. OCL kao preduvjet automatiziranom generiranju programskog koda. CASE 20 - metode i alati za razvoj poslovnih i informatičkih sustava, pp. 87–94. June 3-5, Opatija, Croatia (2008)

6. **Orehovački, Tihomir**, Konecki, Mario; Radošević, Danijel. Alati za e-obrazovanje 2.0. 9. CARNetova korisnička konferencija (CUC). November 19-21, Rijeka, Croatia (2007)
7. **Orehovački, Tihomir**; Bubaš, Goran; Kermek, Dragutin. Razvoj kvalitete u e-obrazovanju. 9. CARNetova korisnička konferencija (CUC), November 19-21, Rijeka, Croatia (2007)
8. Kermek, Dragutin; **Orehovački, Tihomir**; Bubaš, Goran. Procjena i unapređenje kvalitete u e-obrazovanju. Zbornik radova stručno - znanstvenog skupa "E - obrazovanje", pp. 169–177. September 12th, Varaždin, Croatia (2007)
9. **Orehovački, Tihomir**; Konecki, Mario; Radošević, Danijel. Web 2.0 i evolucija e-obrazovanja. Zbornik radova stručno - znanstvenog skupa "E - obrazovanje", pp. 145–155. September 12th, Varaždin, Croatia (2007)