Činitelji prihvaćanja javnih usluga e-participacije u Republici Hrvatskoj

Klačmer, Mario

Doctoral thesis / Disertacija

2020

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:847258

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository



Sveučilište u Zagrebu

Fakultet organizacije i informatike Varaždin

Mario Klačmer

ČINITELJI PRIHVAĆANJA JAVNIH USLUGA E-PARTICIPACIJE U REPUBLICI HRVATSKOJ

DOKTORSKI RAD

Varaždin, 2020.



Sveučilište u Zagrebu

Fakultet organizacije i informatike Varaždin

Mario Klačmer

ČINITELJI PRIHVAĆANJA JAVNIH USLUGA E-PARTICIPACIJE U REPUBLICI HRVATSKOJ

DOKTORSKI RAD

Mentori:
Prof.dr.sc. Neven Vrček
Izv.prof.dr.sc. Renata Mekovec

Varaždin, 2020.



Sveučilište u Zagrebu

Faculty of Organization and Informatics Varaždin

Mario Klačmer

DRIVERS OF ACCEPTANCE OF PUBLIC E-PARTICIPATION SERVICES IN REPUBLIC OF CROATIA

DOCTORAL DISSERTATION

Supervisors:
Prof.dr.sc. Neven Vrček
Izv.prof.dr.sc. Renata Mekovec

Varaždin, 2020.

PODACI O DOKTORSKOM RADU

I. AUTOR

Ime i prezime	Mario Klačmer
Datum i mjesto rođenja	13.3.1978., Varaždin
Naziv fakulteta i datum diplomiranja	Fakultet organizacije i informatike Varaždin, 2.2.2011., mr.sc.
	Fakultet organizacije i informatike Varaždin, 28.1.2004., dipl.inf.
Sadašnje zaposlenje	Općinski sud u Varaždinu

II. DOKTORSKI RAD

Naslov	Činitelji prihvaćanja javnih usluga e-participacije u Republici Hrvatskoj
Broj stranica, slika, tabela, priloga, bibliografskih podataka	160 stranica, 32 slike, 11 grafikona, 34 tablice, 1 prilog, 303 bibliografskih podataka
Znanstveno područje i polje iz kojeg je postignut akademski stupanj	Područje društvenih znanosti, polje informacijske i komunikacijske znanosti.
Mentor i voditelj rada	Neven Vrček, Renata Mekovec
Fakultet na kojem je rad obranjen	Fakultet organizacije i informatike Varaždin
Oznaka i redni broj rada	157

III. OCJENA I OBRANA

Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena tema	21.3.2017.
Datum predaje rada	25.3.2020.
Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena pozitivna ocjena rada	2.4.2020.
Sastav Povjerenstva koje je rad ocijenilo	Prof.dr.sc. Diana Šimić Izv.prof.dr.sc. Anamarija Musa Doc.dr.sc. Nikolina Žajdela Hrustek
Datum obrane	22.4.2020.
Sastav Povjerenstva pred kojim je rad obranjen	Prof.dr.sc. Diana Šimić Izv.prof.dr.sc. Anamarija Musa Doc.dr.sc. Nikolina Žajdela Hrustek
Datum promocije	

INFORMACIJE O MENTORIMA

Neven Vrček redoviti je profesor u trajnom zvanju na Fakultetu organizacije i informatike Varaždin Sveučilišta u Zagrebu. Diplomirao je na Elektrotehničkom fakultetu Sveučilišta u Zagrebu 1991. godine. Na istom je fakultetu magistrirao u listopadu 1995. godine te obranio doktorski rad u prosincu 1998. godine. Profesionalno obrazovanje nadopunjavao je nizom seminara i studijskih boravaka na stranim fakultetima i poduzećima. Na Fakultetu organizacije i informatike izvodi nastavu na više kolegija na svim razinama studija prvenstveno u domeni primjene informacijske tehnologije u organizacijama javnog i privatnog sektora. Autor je većeg broja znanstvenih i stručnih radova. Dio znanstvene djelatnosti ostvaruje preko znanstvenih projekata te je sudjelovao i vodio više projekata financiranih iz domaćih i EU izvora. Glavni je urednik znanstvenog časopisa Journal of Information and Organizational Sciences (JIOS) te predsjednik programskog odbora konferencije Central European Conference of Information and Intelligent Systems (CECIIS). Na Fakultetu organizacije i informatike deset je godina bio član uprave (prodekan i dekan). Član je Sektorskog odbora Hrvatske akreditacijske agencije za akreditaciju davatelja usluga certificiranja u području elektroničkog potpisa. Član je europske mreže eksperata za otvorene podatke javnog sektora i semantičku interoperabilnost. Predsjednik je Revizorskog odbora Hrvatske narodne banke. Za uspješan rad dobio je više društvenih priznanja, kao npr. srebrnu značku (2008.) Hrvatskog informatičkog zbora, medalju grada Varaždina (2007.), Memorial Eurocoin of Aurel Stodola.

Renata Mekovec izvanredna je profesorica na Fakultetu organizacije i informatike Varaždin Sveučilišta u Zagrebu. Diplomirala je na Fakultetu organizacije i informatike 2001. godine. Na istom je fakultetu magistrirala 2006. godine i doktorirala 2011. godine. Voditeljica je Katedre za razvoj informacijskih sustava i članica Katedre za informatičke tehnologije i računarstvo. Stručnjakinja je za područje zaštite osobnih podataka i kvalitete e-usluga, kao i za ocjenu kvalitete e-usluga. Pored brojnih domaćih i međunarodnih projekata, stekla je svoje voditeljske i upravljačke vještine kao prodekan za nastavu na Fakultetu za organizaciju i informatiku (2015-2019) te kao članica i koordinatorica brojnih radnih skupina u području interesa. Njezine nedavne projektne aktivnosti povezane su s domenom razvoja kvalifikacijskih standarda i standarda zanimanja u skladu s CROQF-om, razvojem digitalnih kompetencija i privatnosti u IoT-u. Na Fakultetu organizacije i informatike izvodi nastavu na predmetima Uredski informacijski sustavi, Upravljanje informacijskim servisima, Zaštita privatnosti u poslovnim sustavima. Njezin istraživački interes je u području zaštite privatnosti i osobnih podataka, kvalitete e-usluga i procjene kvalitete e-usluga, percepcije korisnika e-usluga o privatnosti i kvaliteti e-usluga.

ZAHVALE

Prije svega zahvaljujem se mentoru prof.dr.sc. Nevenu Vrčeku kao i sumentorici izv.prof.dr.sc. Renati Mekovec za savjete i usmjeravanje tijekom izrade doktorskog rada. Posebna zahvala pripada i prof.dr.sc Diani Šimić i doc.dr.sc. Nikolini Žajdela Hrustek na pomoći i uvijek konstruktivnim primjedbama i prijedlozima. Također, komentari izv.prof.dr.sc. Anamarije Musa dodatno su doprinjeli kvaliteti rada.

Sestra izv.prof.dr.sc. Marina Klačmer Čalopa i otac Vlado Klačmer davali su poticaj i potporu u trenutcima kada je pisanje ovog rada bilo najteže.

Na kraju hvala i svim drugim prijateljima i poznanicima koji su mi tijekom pisanja ovoga rada pomogli svojim zanimljivim savjetima, prijedlozima i konkretnim vlastitim iskustvima.

Rad je u potpunosti posvećen mojoj, tijekom pisanja ovoga rada, puno prerano preminuloj majci Ani Klačmer.

SAŽETAK

„Kad mnogo novih ideja odjednom dođe u opticaj,
društvo se mijenja“.
Clay Shirky, How the Internet will (one day) transform government

Informacijsko-komunikacijska tehnologija (IKT) s naglaskom na Internet i sve brojniji informacijski sustavi (IS) omogućuju brže, bolje i kvalitetnije društveno djelovanje. Prepoznala je to i država pa se elektroničkom upravom (e-upravom) naziva pružanje usluga građanima od strane državnih tijela koristeći informacijsko-komunikacijske tehnologije. Elektronička demokracija (e-demokracija), usmjerena na transformaciju političkog sustava, predstavlja jedan od glavnih strategijskih ciljeva te elektroničke uprave [54]. Elektronička participacija (e-participacija), kao dio elektroničke demokracije, posebna je vrsta usluge elektroničke uprave usmjerena na povećanje sudjelovanja građana u procesu donošenja političkih odluka i samim time unapređenja demokratskih procesa [1]. Naime, unutar klasičnog oblika demokracije, jedini participativni element jest sam čin glasanja koji predstavlja „delegiranje odluka ljudima ili strankama i samim time suzdržavanje od daljnjeg utjecaja na političke odluke“ [98]. Povijest poznaje i direktne oblike demokracije koji razvojem modernih informacijsko-komunikacijskih tehnologija ponovno dobivaju na važnosti. No usprkos ubrzanom razvoju tehnološke osnovice (Web 2.0 aplikacije), građani se i u 21. stoljeću osjećaju isključeno iz političkog života i utjecaja na političke odluke, odnosno umrežene tehnologije još uvijek nisu efikasan predvodnik demokratskih procesa [65].

Iako pregled literature pokazuje veći broj radova vezano uz e-participaciju (što govori i o aktualnosti teme), mali je broj istraživanja čimbenika utjecaja (eng. *factors*) na namjeru korištenja javnih usluga e-participacije u Republici Hrvatskoj. S toga, osnovni je cilj ovoga rada identificirati čimbenike utjecaja na namjeru korištenja i razviti okvir za mjerenje namjere korištenja javnih usluga e-participacije iz perspektive građana Republike Hrvatske kao korisnika, kao i ispitati strukturu potreba za raznim stupnjevima javnih usluga e-participacije. U tu svrhu predstavljeni model istraživanja ispituje povezanost sedam nezavisnih varijabli s namjerom korištenja javnih usluga e-participacije.

Rad daje empirijsku evaluaciju proširenog Davis-ovog Modela prihvaćanja tehnologije s konstruktima Teorije planiranog ponašanja i Modela povjerenja. Posebna pažnja posvećena je razvoju mjernog instrumenta istraživanja, odnosno za potrebe empirijskog istraživanja i testiranja hipoteza razvijen je upitnik s 36 čestica Likertovog tipa mjerenih na ordinalnoj

ljestvici s pet stupnjeva. U glavnom istraživanju podaci su prikupljeni metodom anketiranja i to na uzorku od 400 ispitanika na području Republike Hrvatske. Valjanost predloženog strukturalnog modela za mjerenje povezanosti predloženih čimbenika s namjerom korištenja javnim uslugama e-participacije ispitana je primjenom metode parcijalnih najmanjih kvadrata modeliranja strukturalnim jednadžbama (engl. *Partial Least Squares Structural Equation Modeling, PLS-SEM*) te su testirane hipoteze. Rezultati istraživanja potvrdili su pozitivno i značajno tri od sedam hipoteza, odnosno rezultati pokazuju da postoji pozitivna i statistički značajna povezanost između „Očekivane korisnosti", „Očekivane kontrole ponašanja" i „Povjerenja u Internet" s namjerom korištenja javnim uslugama e-participacije.

Ključne riječi: E-uprava, Uprava 2.0, Web 2.0, E-demokracija, E-participacija, TAM

ABSTRACT

„When a lot of new ideas suddenly come into circulation,
it changes society.“
Clay Shirky, How the Internet will (one day) transform government

Information and communication technology (ICT) with an emphasis on the Internet and the growing number of information systems (IS) enable faster, better and better quality social activities. The state has also recognized this, so electronic government (e-government) is called the provision of services to citizens by government bodies using information and communication technologies. Electronic democracy (e-democracy), aimed at transforming the political system, is one of the main strategic goals of this electronic government [54]. Electronic participation (e-participation), as part of e-democracy, is an e-government service aimed at increasing citizen participation in political decision-making and thus improving democratic processes [1]. Namely, within the classical form of democracy, the only participatory element is the very act of voting, which is “delegating decisions to people or parties and thus refraining from further influencing political decisions” [98]. History also knows the direct forms of democracy that are gaining on importance with the development of modern information and communication technologies. However, despite the accelerated development of the technological base (Web 2.0 applications), citizens in the 21st century also feel disconnected from political life and influences on political decisions, that is networked technologies are still not an effective leader of democratic processes [65].

Although the literature review shows a large number of papers related to e-participation (which also speaks to the relevance of the topic), there is a small number of studies of drivers of acceptance (factors) on the intention to use public e-participation services in the Republic of Croatia. Therefore, the main aim of this paper is to identify the factors of influence on the intention to use and to develop a framework for measuring the intention to use public e-participation services from the perspective of the citizens of the Republic of Croatia as users, as well as to examine the structure of needs for different levels of public e-participation services. To this end, the presented research model examines the correlation of seven independent variables with the intention of using public e-participation services.

The paper provides an empirical evaluation of the extended Davis Model of Technology Acceptance with Constructs of Planned Behavior Theory and the Model of Trust. Particular attention was given to the development of a measuring instrument of research, that is, for the

purposes of empirical research and hypothesis testing, a questionnaire was developed with 36 items measured on a five-point ordinal Likert-type scale. In the main survey, data were collected by a survey method, based on a sample of 400 respondents in the Republic of Croatia. The validity of the proposed structural model for measuring the relationship between the proposed factors and the intention to use public e-participation services was tested using the Partial Least Squares Structural Equation Modeling (PLS-SEM) method and hypotheses were tested. The results of the research confirmed positively and significantly three out of seven hypotheses, that is, there is a positive and statistically significant correlation between "Expected usefulness", "Expected behavioral control" and "Trust in the Internet" with the intention of using public e-participation services..

Keywords: E-government, Government 2.0, Web 2.0, E-democracy, E-participation, TAM

SADRŽAJ

1. UVOD 1

1.1. Područje istraživanja 3

1.2. Motivacija istraživanja 4

1.3. Ciljevi istraživanja i istraživačko pitanje 8

2. POVIJEST DIGITALNE TRANSFORMACIJE JAVNE UPRAVE 11

2.1. Statički Web i Uprava 1.0 12

2.2. Društveni mediji i Uprava 2.0 14

2.3. Uprava 3.0 – blockchain i transformacija uprave u digitalnom dobu 17

3. ELEKTRONIČKA PARTICIPACIJA 21

3.1. Definiranje i povijest elektroničke participacije 25

3.2. Primjeri elektroničke participacije 33

3.3. Grad Varaždin i elektronička participacija 37

3.4. Europska unija i elektronička participacija 39

4. TEORIJSKI MODELI PRIHVAĆANJA TEHNOLOGIJA - POČECI, RAZVOJ I MOGUĆA BUDUĆA KRETANJA 46

5. KONCEPTUALNI OKVIR ISTRAŽIVANJA 54

5.1. Istraživačka filozofija i korištene vrste istraživanja 54

5.2. Pitanje digitalnog jaza 55

5.3. Izgradnja konceptualnog modela - racionalnost teorijske integracije 58

5.4. Hipoteze u istraživanju 64

6. METODOLOGIJA EMPIRIJSKOG ISTRAŽIVANJA 66

6.1. Razvoj mjernih skala anketnog upitnika 66

6.2. Predistraživanje – validacija anketnog upitnika kao glavnog mjernog instrumenta empirijskog istraživanja 73

6.2.1. Populacija i uzorak predistraživanja 73

6.2.2. Pouzdanost instrumenata u predistraživanju – Cronbachov alfa 74

6.2.3. Valjanost instrumenta u predistraživanju 75

6.3. Glavno istraživanje – validacija konceptualnog modela 75

6.3.1. Populacija i uzorak glavnog empirijskog istraživanja 76

6.3.2. Metoda analize dobivenih podataka – modeliranje strukturalnim jednadžbama i testiranje hipoteza 80

6.3.3. Klasifikacija indikatora – reflektivni i formativni konstrukti 84
6.3.4. Procjena mjernog (vanjskog) modela – mode A 85
6.3.5. Procjena strukturalnog (unutarnjeg) modela i testiranje hipoteza 87

7. REZULTATI EMPIRIJSKOG ISTRAŽIVANJA 90

7.1. Predistraživanje - sociodemografske karakteristike ispitanika 90
7.1.1. Pouzdanost instrumenta u predistraživanju – Cronbachov alfa 92

7.2. Glavno istraživanje - sociodemografske karakteristike i deskriptivna statistika ispitanika 92
7.2.1. Procjena mjernog (vanjskog) modela - mode A 106
7.2.2. Procjena strukturalnog (unutarnjeg) modela i testiranje hipoteza 109
7.2.3. Struktura potražne strane za javnim uslugama elektroničke participacije 114

8. RASPRAVA 116

8.1. Analiza ciljeva, hipoteza i istraživačkog pitanja istraživanja 116

8.2. Pregled i usporedba rezultata dosadašnjih empirijskih istraživanja 120

8.3. Ograničenja glavnog istraživanja 123

8.4. Mogući daljnji smjerovi istraživanja 123

9. ZAKLJUČAK 128

LITERATURA 132

PRILOZI 150

ŽIVOTOPIS 156

Popis slika

Slika 1: Tehnološke sposobnosti i tržišne potrebe kao čimbenici inovacije
Slika 2: Tabulirajući stroj Hermana Hollerith-a
Slika 3: Razlika između Web 1.0 i Web 2.0
Slika 4: *Blockchain* i sudska praksa sudova u Estoniji
Slika 5: *Whistle stop* turneja Trumana 1948.godine
Slika 6: Web stranice slovenskog Instituta za e-participaciju
Slika 7: Grafički prikaz odnosa ključnih pojmova
Slika 8: Anketno ispitivanje građana EU o potrebi ukidanja ljetno/zimskog računanja vremena
Slika 9: Online peticija za ostanak Velike Britanije u EU
Slika 10: Mapa povezanosti i međusobne ovisnosti pod programa u Linux-u
Slika 11: Mapa utjecaja američkog poreznog zakona na druge američke zakone
Slika 12: Zakon o copyrightu na GitHub-u
Slika 13: Platforma Rahvakogu
Slika 14: Web stranice usluge POPVOX
Slika 15: E-participacijski portal Neighborland
Slika 16: DemocracyOS
Slika 17: E-budžetiranje grada Pazina
Slika 18: E-participativni proračun grada Siska
Slika 19: E-participacija na stranicama grada Bjelovara
Slika 20: Usluge e-participacije grada Zagreba
Slika 21: Usluge e-participacije grada Varaždina
Slika 22: Naslovnica jedne od konferencija o Web 2.0 tehnologijama u javnom sektoru
Slika 23: Konstrukti Teorije planiranog ponašanja
Slika 24: Konstrukti Modela prihvaćanja tehnologije
Slika 25: Knjižnice kao dionici e-demokracije
Slika 26: Vennov dijagram čimbenika utjecaja na namjeru korištenja javnim uslugama e-participacije
Slika 27: Konceptualni model za potrebe istraživanja u doktorskom radu
Slika 28: SEM dijagram puta
Slika 29: Strukturalni model s koeficijentima puta i determinacije
Slika 30: Web portal otvorenih podataka američke Nacionalne uprave za aeronautiku i svemir

Slika 31: Faze donošenja Zakona o visokom školstvu njemačke pokrajine Sjeverne Rajne - Vestfalije
Slika 32: Particiopedia

Popis grafikona

Grafikon 1: Postotak pojedinaca koji koriste Internet za participaciju na društvenim mrežama u zemljama EU 28 i zemljama kandidatima u 2019. godini
Grafikon 2: Postotak pojedinaca koji koriste Internet za interakciju s tijelima javne vlasti putem Web stranica u zemljama EU 28 i zemljama kandidatima u 2019. godini
Grafikon 3: Postotak pojedinaca koji koriste Internet za online konzultaciju u zemljama EU28 i zemljama kandidatima u 2019. godini
Grafikon 4: Nesrazmjer ponude i stvarnog korištenja e-usluga u EU27+
Grafikon 5: Gartnerov Hype Cycle za digitalnu državnu tehnologiju u 2018. godini
Grafikon 6: Povjerenje Europljana u institucije
Grafikon 7: Izlaznost birača u Republici Hrvatskoj na parlamentarne izbore
Grafikon 8: Društveni mediji i glasovanje u SAD-u 2012. godine
Grafikon 9: E-participacijski indeks Hrvatske u odnosu na regionalnog i svjetskog lidera Dansku
Grafikon 10: Postotak domaćinstva s pristupom na Internet u zemljama EU28 i zemljama kandidatima u 2019. godini
Grafikon 11: Grafički prikaz odnosa koeficijenata puta i p-vrijednosti u odnosu na referentnu p-vrijednost

Popis tablica

Tablica 1: Kronološki poredak nastanka modela prihvaćanja tehnologije
Tablica 2: Definicije konstrukta istraživačkog konceptualnog modela
Tablica 3: Istraživačke hipoteze
Tablica 4: Operacionalizacija reflektivne egzogene latentne varijable „Očekivana korisnost“
Tablica 5: Operacionalizacija reflektivne egzogene latentne varijable „Očekivana jednostavnost upotrebe“
Tablica 6: Operacionalizacija reflektivne egzogene latentne varijable „Povjerenje u Internet“
Tablica 7: Operacionalizacija reflektivne egzogene latentne varijable „Povjerenje u državu“
Tablica 8: Operacionalizacija reflektivne egzogene latentne varijable „Stav prema ponašanju“
Tablica 9: Operacionalizacija reflektivne egzogene latentne varijable „Subjektivna norma“
Tablica 10: Operacionalizacija reflektivne egzogene latentne varijable „Očekivana kontrola ponašanja“
Tablica 11: Operacionalizacija reflektivne endogene latentne varijable „Namjera korištenja“
Tablica 12: Karakteristike uzorka - distribucija frekvencija u predistraživanju (N=40)
Tablica 13: Cronbachov alfa koeficijent pouzdanosti skala korištenih u predistraživanju
Tablica 14: Karakteristike uzorka - distribucija frekvencija u glavnom istraživanju (N=400)
Tablica 15: Deskriptivna statistika skale „Očekivana korisnost“
Tablica 16: Deskriptivna statistika skale „Očekivana jednostavnost upotrebe“
Tablica 17: Deskriptivna statistika skale „Povjerenje u Internet“
Tablica 18: Deskriptivna statistika skale „Povjerenje u državu“
Tablica 19: Deskriptivna statistika skale „Stav prema ponašanju“
Tablica 20: Deskriptivna statistika skale „Subjektivna norma“
Tablica 21: Deskriptivna statistika skale „Očekivana kontrola ponašanja“
Tablica 22: Deskriptivna statistika skale „Namjera korištenja“
Tablica 23: Sumarni rezultati procjene mjernog modela
Tablica 24: Diskriminantna valjanost – Fornell i Larcker-ov kriterij
Tablica 25: Diskriminantna valjanost – kriterij unakrsnih opterećenja (eng. cross-loadings)

Tablica 26: Heterotrait-monotrait omjer korelacije
Tablica 27: VIF vrijednosti
Tablica 28: R^2 vrijednost
Tablica 29: f^2 vrijednosti
Tablica 30: Q^2 vrijednost
Tablica 31: Dobivene vrijednosti nakon bootstrapp procedure
Tablica 32: Frekvencija odgovora vezano uz strukturu potražne strane za javnim uslugama e-participacije (N=400)
Tablica 33: Potvrđene i nepotvrđene hipoteze istraživanja
Tablica 34: Objasnidbena snaga korištenog modela

1. UVOD

„Kao član Europske komisije imao sam mogućnost vidjeti utjecaj koji informacijsko-komunikacijske tehnologije imaju na demokratske postupke, te kako su građani neposredno utjecali na donošenje zaključka. Kod prošlogodišnje pripreme novog Zakona o kemikalijama proveli smo savjetovanje s građanima. Do donošenja zaključka primili smo 6500 mišljenja preko elektronske pošte, telefaksa i mrežne aplikacije Interaktivno oblikovanje politike. Svaki odaziv smo analizirali tijekom ljeta. Zahvaljujući savjetovanju, otkrili smo da je predloženi zakon imao manjkavosti koje bi povećale troškove za nekoliko milijardi eura, posebno za manja poduzeća. Bila je to najviša točka u našoj Internet posredovanoj upravi u okviru Europske komisije do danas.“

Erkki Likkanen, povjerenik za poduzetništvo i informacijsko društvo Europske komisije

Vremena kada su političari u svojim političkim aktivnostima obilazili razne skupove, mitinge ili čak posjećivali građane od vrata do vrata su prošla. Nove tehnologije dosežu u kratkom roku (i na cjenovno prihvatljiv način) do velikog broja građana [1].[1] Fizički prostor seli se u virtualni, gdje ljudi izmjenjuju mišljenja o aktualnim problemima stvarajući tako javno mnijenje koje utječe kako na nacionalnu tako i na lokalnu politiku [2].

Pad građanskih inicijativa u javnoj sferi djelovanja (kao što je sam čin izlaska na izbore) već je dulje vrijeme u fokusu moderne uprave. Statistički pokazatelji jasno pokazuju da se broj birača u Hrvatskoj u ovom mileniju smanjio za 900 000 [3]. Informacijsko-komunikacijske tehnologije alat su za koji se smatra da može preokrenuti ovaj trend [4]. Europska komisija, uvidjevši spomenuti pad u građanskim inicijativama, već 2006. godine kao dio i2010 strategijskog okvira za informacijsko društvo iz 2005.godine, predstavlja „i2010 Akcijski Plan eUprave“ koji eksplicite kao ciljeve spominje e-demokraciju i e-participaciju s ciljem promicanja građana u aktivne sudionike u procesu donošenja političkih odluka [5].

Web 2.0 tehnologije, predstavljene 2007. godine u Gartnerovom *E-government Hype Cycle*-u[2] kao zadnje sredstvo kojim bi građani mogli postići društvene ciljeve [6], nužan su, ali ne i

[1] Tijekom pisanja ovog rada (9/2018) Facebook je objavio da je prvi put zabilježio 1 milijardu korisnika logiranu u isti trenutak na ovu popularnu društvenu mrežu.

[2] Radi se o grafičkom prikazu, odnosno krivulji kretanja pojedinih tehnologija koja je originalni „izum“ konzultacijske kuće Gartner i za koju ne postoji adekvatan hrvatski prijevod. Krivulja predstavlja kretanje

dovoljan uvjet za rješavanje ovoga problema. Metode i instrumenti javne participacije zadnjih desetak godina zasigurno su se promijenili. Stoga je opravdano pitanje kreće li se demokracija u smjeru potpune digitalizacije, u smislu da donositelji političkih odluka u 21. stoljeću postaju obični *crowdsourcing*[3] moderatori.

No Reddick tvrdi kako je malo vjerojatno da će građani koristiti Internet, pogotovo preko Web stranica elektroničke uprave, za participativne i konzultacijske aktivnosti [7]. Sve prednosti e-participacije neće biti iskorištene tako dugo dok građani ne počnu aktivno koristiti alate za e-participaciju. A što odbija građane od korištenja usluga e-participacije, a što ih privlači, još nije dovoljno istraženo. Unatoč porastu važnosti e-participacijskih tehnologija, potencijalni čimbenici utjecaja na građane da počnu koristiti e-participacijske tehnologije još uvijek nisu dosta istraženi [8]. Kako utjecati na veći stupanj e-participacije od strane građana, kao i utvrđivanje strukture potreba za različitim razinama javnih usluga e-participacije samo su neka pitanja kojima se ovaj radi bavi.

U skladu s gore navedenim, ideja istraživanja čimbenika utjecaja na namjeru korištenja *online* Web 2.0 javnim uslugama e-participacije čini se znanstveno relevantna i opravdana. Stoga je svrha ovoga rada steći nove spoznaje o ponašanju građana Republike Hrvatske vezano uz namjeru korištenja javnim uslugama e-participacije.

Na podlozi recentne i relevantne istražene literature o čimbenicima koji su povezani s prihvaćanjem javnih usluga e-participacije, koristeći postojeće teorije i modele, kao i empirijski prikupljene podatke, izrađen je teorijski konceptualni model[4] koji je operacionaliziran u anketni upitnik. U radu se polazi od Davis-ovog modela prihvaćanja tehnologije (eng. *Technology acceptance model*, TAM) prema kojem najbolji prediktor stvarnog korištenja nekog informacijskog sustava jest namjera korištenja istog tog sustava. Model prihvaćanja tehnologije proširen je čimbenicima Teorije planiranog ponašanja (eng. *Theory of Planned Behavior*, TPB) i Modela povjerenja (eng. *Trust model*, TM). Predloženi

---

nadolazeće tehnologije kroz tipične faze u kojima se odvija njen životni ciklus, od pretjeranog entuzijazma do faze zrelosti.

[3] Pojam *crowdsourcing* prvi put spominje novinar Jeff Howe 2006.godine u tekstu za časopis Wired kad kaže da „*Crowdsourcing* je proces koji se koristi snagom i znanjem mnoštva za postizanje konkretnog cilja koji je donedavno bio u domeni specijalizirane manjine“.

[4] Konceptualni model pojednostavljeni je prikaz strukture i međuodnosa aspekata istraživačkog fenomena. Temeljni elementi svakog konceptualnog modela su mjere i konstrukti. Mjere (ili manifestne varijable) opažljivi su kvantitativni podaci prikupljeni promatranjem, intervjuom, upitnikom ili nekim drugim mjernim instrumentom ili empirijskom metodom. U literaturi se kao sinonim za manifestne varijable upotrebljavaju pojmovi čestice i indikatori [9] [10]. Konstrukti (ili latentne varijable) teorijski su koncepti koje nije moguće direktno mjeriti već se o njima zaključci donose temeljem manifestnih varijabli [11].

„Model korištenja javnih usluga e-participacije“ (eng. *Public E-Participation Services Intention to use Model*, PEPSIM) od strane građana Republike Hrvatske kao korisnika empirijski je provjeren na skupu podataka prikupljenih anketom. Ispitivanjem su dobiveni podaci kojim čimbenicima država (Vlada) treba upravljati kako bi postigla veću prihvaćenost javnih usluga e-participacije.

Uključivanjem dodatnih čimbenika u polazni Model prihvaćanja tehnologije (TAM), ovaj rad između ostalog daje i nove spoznaje o čimbenicima utjecaja na namjeru korištenja javnih usluga e-participacije i time sveobuhvatnije doprinosi objašnjenju stvarnog korištenja javnih usluga e-participacije. Prema spoznajama autora ovo istraživanje predstavlja prvo ispitivanje ovakvog konceptualnog modela metodom modeliranja strukturalnim jednadžbama, a sve u svrhu istraživanja namjere korištenja javnih usluga e-participacije u Republici Hrvatskoj.[5]

1.1. Područje istraživanja

Informacijske usluge postaju temelj suvremenih gospodarstava. Državna uprava također se uključila u digitalizaciju (internetizaciju) svojih usluga. No koncept e-uprave polako zastarijeva. Novi koncept, Uprava 2.0, bazirana na konceptu korisnika kao proizvođača sadržaja, predstavlja unaprijeđen način komunikacije građana s državnom upravom. Rast korištenja Web 2.0 tehnologijama koje su temelj Uprave 2.0 utjecao je na rad država, odnosno na način na koji država građanima osigurava usluge [8]. Fokus ovog rada jest upravo na stavovima građana prema upotrebi Web 2.0 tehnologija u komunikaciji s državnom upravom.

Postavlja se više pitanja kao npr. je li možda prihvaćanje *online* Web 2.0 javnih usluga e-participacije višedimenzionalno pitanje, a ne samo tehničko? Koji čimbenici utječu (odnosno točnije bi bilo reći su povezani, s obzirom da je ovo korelacijsko istraživanje kojim ne možemo pokazati uzročnost) na prihvaćanje tih usluga? I kakvu razinu e-participacije građani uopće žele? Naime, problem je u tome što država često razvija elektroničke usluge bez stvarnog mjerenja potreba građana.

Važno je naglasiti da ovaj rad e-participaciju gleda isključivo kao vrstu usluge elektroničke uprave, različitu od usluga kakve nude razne ne-državne institucije (naime i komentiranje raznih karakteristika automobila na nekom auto forumu je e-participacija). Već i sam naslov

[5] Hrvatski autori Bošnjak, Galešić i Kliček u svojem su članku iz 2007. godine obradili utjecaj komponenata Teorije planiranog ponašanja + moralne obveze na online političku participaciju u Hrvatskoj koristeći linearnu regresijsku analizu [12].

rada ukazuje na to, naglašavajući da se radi o javnim uslugama, koje najopćenitije možemo definirati uslugama koje se smatraju odgovornošću države.

Dakle, područje istraživanja ovog rada jesu specifične javne usluge e-participacije. No, za razliku od radova koji ove usluge istražuju s ponudbene strane, ovaj se rad fokusira na istraživanje potražne strane za uslugama e-participacije elektroničke uprave.

Naime, implementacija usluga elektroničke uprave nije samo jednostavno stavljanje informacija *online*. Ona je kompleksno, višedimenzionalno pitanje i zahtijeva duboko razumijevanje potreba i zahtijeva građana, a sve s ciljem što većeg prihvaćanja e-usluga od strane građana. Država u pravilu opskrbljuje građane onim uslugama koje ona smatra potrebnim, dok zanemaruje stvarne potrebe građana, stvarajući tako nesrazmjer između ponude i potražnje [13]. No, iako je razumijevanje razvoja elektroničke uprave i proučavanje čimbenika koje utječu na njen razvoj postalo važno istraživačko područje, malo je istraživanja koja istražuju čimbenike utjecaja na prihvaćanje novih, javnih usluga e-participacije. A u današnjem visokotehnološkom društvu, razumijevanje zašto ljudi prihvaćaju ili odbijaju nove tehnologije jedan je od zanimljivijih i važnijih problema.

Tehnologije na kojima se temelji elektronička uprava u zadnje vrijeme drastično se mijenjaju. Tijekom istraživanja literature o Web 2.0 aplikacijama, zapažen je jedan paradoks koji je kasnije i poslužio kao motivacija za istraživanje. Naime, u raznim statističkim podacima vidljiv je snažan rast korištenja „klasičnih“ Web 2.0 aplikacija (Facebook, Twitter) nasuprot sporom prihvaćanju *online* Web 2.0 javnih usluga. Slično je i u Hrvatskoj, pa je tako trenutačno 2 000 000 građana Republike Hrvatske aktivno u *online* svijetu Web 2.0 društvene e-participacijske mreže Facebook [14].

A država se mora susretati s građanima tamo gdje su oni *online*!

1.2. Motivacija istraživanja

Iako u zadnje vrijeme e-participacija zaokuplja pažnju znanstvenika, malo se zna o „silama“ koje pokreću građane na e-participaciju. Definiramo li e-participaciju kao „korištenje informacijske i komunikacijske tehnologije s ciljem proširivanja i produbljivanja političke participacije omogućujući tako građanima da međusobno komuniciraju kako jedni s drugima tako i sa svojim izabranim zastupnicima s ciljem donošenja odluka od javnog značaja“ postavlja se pitanje zašto neki građani aktivnije koriste e-participaciju od drugih[15].

Prema dostupnim podacima, Njemačka ima jednu od najrazvijenijih telekomunikacijskih infrastruktura na svijetu. No suprotno očekivanjima, Njemačka je po svim istraživanjima slabo rangirana na ljestvicama korištenja usluga e-uprave [16]. I u najnovijem UN istraživanju Njemačka je tek 12-ta zemlja po razvijenosti elektroničke uprave. Također, činjenica je i da se svakih 6. mjeseci broj Facebook korisnika u Njemačkoj udvostruči [16]. Stoga se prebacivanje usluga elektroničke uprave na društvene mreže (Web 2.0 platforma) čini logičnom i opravdanom idejom.

No mijenja li se tada bitnije stupanj korištenja?

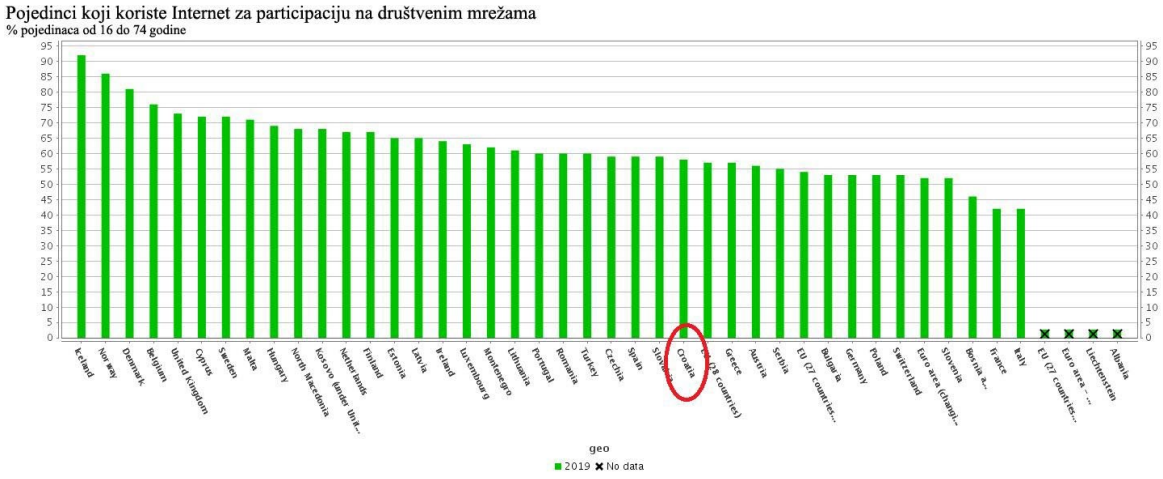
Aladalah, Cheung i Lee proučavajući građansku participaciju u Upravi 2.0 dolaze do zaključka kako „korištenje Web 2.0 tehnologija ne vodi uvijek do snažnijeg korištenja Uprave 2.0“. Građani su još uvijek više skloniji dijeljenju političkog mišljenja na svojoj Facebook stranici nego potpisivanju npr. e-peticije o istom pitanju [6].

I mnogi drugi autori slažu se da porast korištenja društvenih medija nije popraćen višim stupnjem korištenja javnih e-participacijskih tehnologija [17]. Alsashedi, Persaud i Kindra u članku iz 2015. godine navode kako je Vlada Saudijske Arabije u posljednjem desetljeću uložila znatna sredstva u sofisticirane Web tehnologije s ciljem promicanja e-participacije. No međutim, stupanj e-participacije je ostao mali [18].

Alharbi i dr. u članku iz 2015. godine zaključuju da „postoji mala vjerojatnost da će građani koristiti Internet, točnije Web stranice elektroničke uprave, za participacijske aktivnosti“ kao i da „do danas ima malo informacija o tome što odbija građane od korištenja e-participacijskih usluga ili što utječe na prihvaćanje“ i kako u ovom području postoje velike praznine [8].

I Le Blanc govori o početno visokim očekivanjima od Web 2.0 aplikacija vezano uz e-participaciju. Razlog tome leži u samoj interaktivnoj prirodi Web 2.0 aplikacija za koje se smatralo da će drastično smanjiti troškove participacije i proširiti mogućnosti interakcije između države i njenih građana. Rezultat toga biti će snažniji interes i veći stupanj participacije od strane građana. Ali prema Le Blanc-u „ovakva očekivanja, potaknuta tehno-optimizmom, koji i inače prati razvoj elektroničke uprave, nisu se odrazila u rezultatima na terenu“. Na primjer, u Europskoj uniji, između 2014. i 2019. godine stupanj građanske participacije (na nacionalnoj i lokalnoj razini) u konzultacijama ili glasovanju ostao je praktično isti [19].

Pogledamo li zadnje Eurostat-ove podatke iz 2019. godine za Hrvatsku, uočavamo neke zanimljivosti.

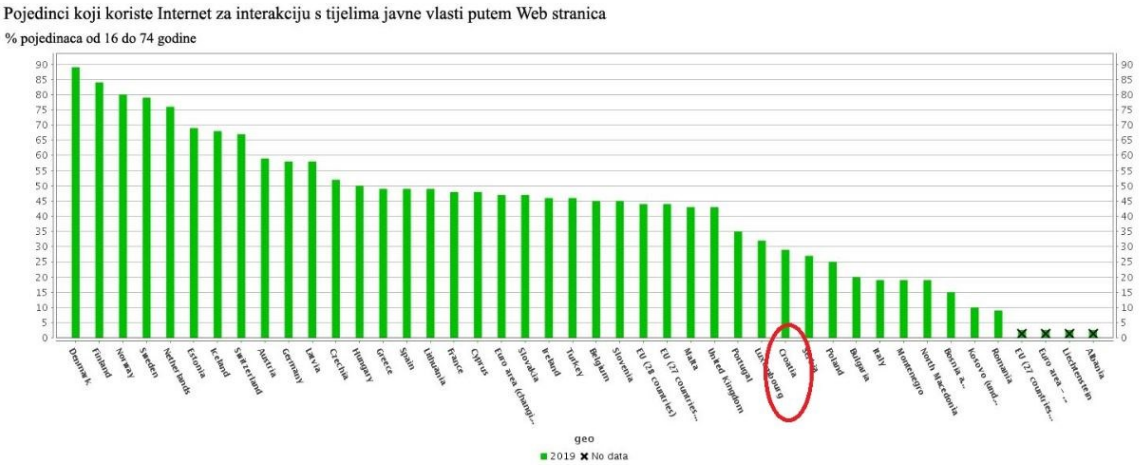


Grafikon 1: Postotak pojedinaca koji koriste Internet za participaciju na društvenim mrežama u zemljama EU28 i zemljama kandidatima u 2019. godini

Izvor: [20]

Grafikon 1. jasno pokazuje da 2019. godine oko 58 % građana Hrvatske koristi e-participacijske tehnologije u smislu korištenja društvenih mreža (oko 2 000 000 Hrvata aktivni su korisnici Facebook-a, broj Internet korisnika je nešto viši i iznosi 2 367 814) [21], [22].

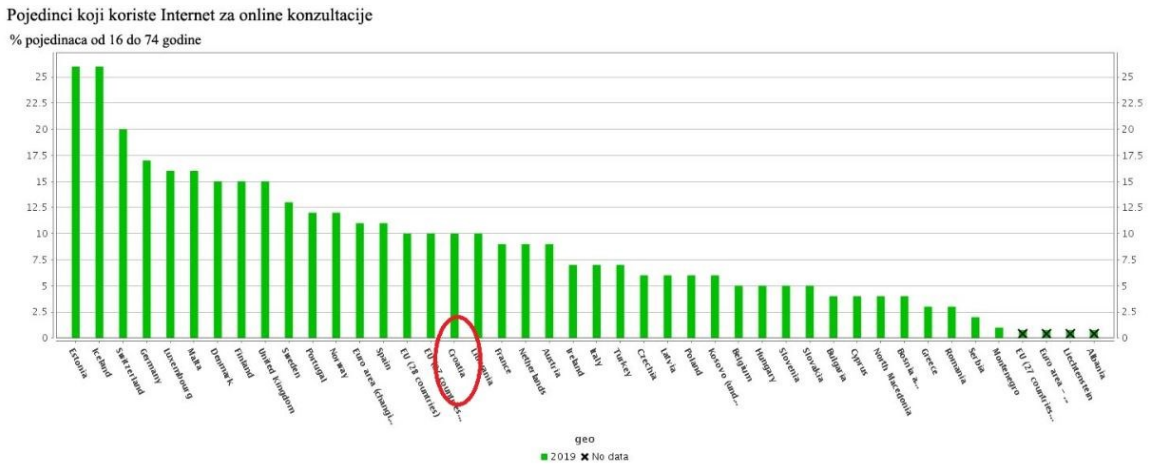
No kao što to pokazuje Grafikon 2., broj građana koji u 2019. godini koriste Internet za interakciju s tijelima javne vlasti već je puno manji i iznosi oko 29 %.



Grafikon 2: Postotak pojedinaca koji koriste Internet za interakciju s tijelima javne vlasti putem Web stranica u zemljama EU 28 i zemljama kandidatima u 2019. godini

Izvor: [23]

Uzme li se u obzir broj građana Hrvatske koji u 2019. godini koriste e-participacijske tehnologije (aplikacija za e-savjetovanje), postotak značajno pada i iznosi tek oko 9 % što je i prikazano na Grafikonu 3. Točnije, dana 1.9.2019. godine prema XML zapisu sa Portala otvorenih podataka Republike Hrvatske, broj registriranih korisnika e-Savjetovanja u sklopu sustava e-Građani bio je tek 7 486.



Grafikon 3: Postotak pojedinaca koji koriste Internet za online konzultacije u zemljama EU 28 i zemljama kandidatima u 2019. godini

Izvor: [24]

Općenito gledano, broj korisnika sustava e-Građani još uvijek je jako mali. Na dan 1.1.2020. godine, prema XML zapisu sa Portala otvorenih podataka Republike Hrvatske sustav e-Građani koristi 811 582 korisnika[6] što je oko 19 % svih stanovnika Hrvatske.[7] Ako pretpostavimo da bi svi građani jednog dana trebali biti korisnici sustava e-Građani i nastavi li broj građana u sustavu e-Građani rasti ovom brzinom, to će se ostvariti tek oko 2050. godine [26].[8]

Sve to upućuje na zaključak da se radi o zanimljivom paradoksu i pogodnim područjem za istraživanje. Taj paradoks između sporog rasta prihvaćanja javnih usluga Uprave 2.0 nasuprot brzom prihvaćanju Web 2.0 korisnički pokretanih aplikacija poslužio je kao početna motivacija u istraživanju [28], tim više jer se došlo do zaključka kako unatoč brojnim istraživanjima u području e-uprave, pitanja vezana uz nizak stupanj participacije građana u Upravi 2.0 nisu bila sistematski izučavana [6].

Istraživanja koja i postoje usmjerena su na tehnološku komponentu što nije dovoljno kad se radi o tako složenom fenomenu. Proširenjem modela e-participacije na ne-tehnološke čimbenike, odnosno dodavanjem novih konstrukata dobila bi se jasnija slika ovog fenomena. Konačno, prema Wills, „proučavanje čimbenika koji utječu na korisničko prihvaćanje tehnologije značajan je smjer u istraživanju informacijskih sustava“ [29].

1.3. Ciljevi istraživanja i istraživačko pitanje

Napredak u Internet tehnologijama doveo je do popularnosti različitih Web servisa. Nakon privatnih poduzeća sada i vlade država diljem svijeta ulažu znatna sredstva u digitalizaciju svojih usluga. U tom smislu, elektronička uprava definira se kao pružanje informacija i usluga građanima od strane državnih institucija koristeći Internet ili neke druge digitalne načine [8].

Očekivanja su velika, ali koliko su građani uopće zainteresirani za korištenje elektroničkim servisima državne uprave? Odnosno, odgovara li potražna strana uopće ponudi elektroničkih usluga državne uprave? Osim toga, zašto je to tako? Naime, dosta je istraživanja koja se bave tehničkom stranom ponude elektroničkih servisa, dok malo radova istražuje potražnu stranu. Činjenica je da ljudi ne usvajaju jednostavno i jednako brzo nove tehnologije kada one

[6] Broj jedinstvenih korisnika u sustavu e-Građani, odnosno ukupni broj različitih OIB-ova koji su se barem jednom prijavili na bilo koju od e-usluga putem NIAS-a.
[7] Da se radi o malom postotku priznaju i političari. Tako je na *Digital Transformation Conference* u Zagrebu koja je održana 6.- 8.11.2018.godine, pomoćnica ministra uprave Zrinka Bulić priznala da je to malo i da se zato uskoro kreće u redizajn e-Građana [25].
[8] Ovaj izračun baziran je na osnovu dostupnih statističkih podataka o kretanju broja korisnika sustava E-građani na stranicama Ministarstva uprave RH [27].

postanu dostupne. Činjenica je i da se to ne dešava u svakoj zemlji istim intenzitetom [12]. E-usluge državne uprave su u pravilu dostupne i države ih u pravilu nude, ali ih građani u pravilu ne koriste.[9] Pa se opravdano postavlja pitanje je li možda prihvaćanje usluga e-uprave višedimenzionalno pitanje, a ne samo tehničko? I gdje je Hrvatska u svemu tome?

Pretpostavi li se postojanje i ne-tehničkih čimbenika utjecaja, postojeći i često korišten Model prihvaćanja tehnologije (eng. *Technology Acceptance Model*, TAM) postaje preuzak za nadolazeće spoznaje. A kada postojeći model postane preuzak, potrebno ga je proširiti i takav, u pravilu kompleksniji model, potrebno u konačnici i istražiti.[10]

Prema Davis-u, dva su razloga istraživanja prihvaćenja tehnologije: prvi je predviđanje prihvaćanja, a drugi je utvrđivanje razloga ne prihvaćanja i poduzimanje potrebitih mjera kako bi se prihvaćanje postiglo [31]. U skladu s time, ciljevi ovog doktorskog istraživanja su slijedeći:

- razviti višedimenzionalni model prihvaćanja koji će biti korišten u objašnjavanju čimbenika utjecaja na namjeru korištenja građana Hrvatske javnim uslugama elektroničke participacije i
- razumjeti strukturu potražne strane za participacijskim uslugama Uprave 2.0.

Vezano uz prvi cilj, potrebno je identificirati čimbenike i razviti višedimenzionalni model prihvaćanja koji će biti korišten u objašnjavanju namjere korištenja građana Republike Hrvatske javnim uslugama e-participacije, odnosno proširiti originalni TAM model s društvenim utjecajem i povjerenjem i na taj način poboljšati razumijevanje ponašanja korisnika vezano uz javne usluge e-participacije.

Dodatno, vezano uz drugi cilj, potrebno je razumjeti strukturu potražne strane za javnim uslugama e-participacije vezano uz stupanj uključenosti građana (e-informacijska, e-konzultacijska i e-participacijska razina). Prema Organizaciji za ekonomsku suradnju i razvoj (eng. *Organisation for Economic Cooperation and Development*, OECD), informacijska razina predstavlja jednostranu vezu, odnosno samo je država ta koja proizvodi i dostavlja

[9] Zanimljivo je i da različite nacije različito prihvaćaju e-usluge državne uprave, odnosno, neke nacije brže prihvaćaju e-usluge servise od drugih. Mnogi autori u objašnjenju ovog fenomena koriste Hofstedove kulturne dimenzije, pa tako zemlje s visokom dimenzijom izbjegavanja neizvjesnosti teže izbjegavanju promjena i manje je vjerojatno da će takve kulture prihvaćati online tehnologije.

[10] Zato se i koristi PLS-SEM metoda u empirijskom dijelu istraživanja, jer kako kažu Hair i dr. „istraživači bi trebali koristiti PLS-SEM … kada je jedan od ciljeva bolje shvaćanje teorijskih proširenja postojećih teorija“ [30].

informacije, koje su osnova za političku participaciju, građanima na korištenje (npr. službena Web stranica nekog državnog tijela, blogovi, FAQ, Webcasts). Konzultacijska (savjetodavna) razina predstavlja obostranu vezu između države i građana, gdje država dobiva povratne informacije u formi mišljenja građana. Aktivna participacija predstavlja najvišu razinu kod koje postoji partnerski odnos između države i građana. Građani su aktivno uključeni u oblikovanje javnih politika i odlučivanja vezano uz te politike (npr. e-referendum, e-peticije, e-budžet, virtualno prisustvovanje različitim saslušanjima i sastancima) [32]. U podlozi toga je pretpostavka da, u pravilu, država razvija usluge za koje država misli da su građanima potrebne zanemarujući njihove stvarne potrebe. Naime, istraživanja su pokazala da države koje vode pažnju o potražnoj strani e-uprave bile su puno efikasnije u provedbi istih. Tako je Kanada često prvi vrhu ljestvica korištenja usluga e-uprave od strane građana. Vjerojatno je to zbog toga jer Kanada često provodi anketiranje građana o njihovim stavovima i potrebama [33].

I na kraju, a u skladu s ciljevima istraživanja, formulirano je istraživačko pitanje koje glasi: Postoji li empirijska potvrda povezanosti namjere korištenja javnih usluga e-participacije s čimbenicima kao što su to konstrukti teorija prihvaćanja tehnologija TAM-a, TPB-a i Modela povjerenja?

Provedenim istraživanjem dobivena je jasnija spoznaja o čimbenicima utjecaja, ali i potrebama građana vezano uz namjeru korištenja javnim uslugama e-participacije a u skladu s dobivenim podacima dane su i smjernice prema načinu unapređenja prihvaćanja usluga elektroničke uprave.

2. POVIJEST DIGITALNE TRANSFORMACIJE JAVNE UPRAVE

„Vlada bi trebala biti transparentna, participativna i suradnička“.
Barack Obama, 44-ti predsjednik SAD-a

Solis digitalnu transformaciju definira kao „prilagođavanje, odnosno ulaganje u novu tehnologiju, poslovne modele i procese kako bi se postigla nova vrijednost za kupce i zaposlenike i učinkovitije natjecalo u digitalnoj ekonomiji koja se stalno mijenja [34]. Transformacija nastaje kada poduzeće odluči mijenjati svoje poslovne modele, procese, strategije i aktivnosti, a sve s ciljem stvaranja bolje konkurentske prednosti na tržištu [35].

Naglasak na promjenu poslovnog modela kod definiranja digitalne transformacije toliko je jak da neki autori preferiraju umjesto pojma digitalna transformacija koristiti pojam digitalna poslovna transformacija [36].

Može li se ta promjena poslovnog modela uvjetovana primjenom digitalne tehnologije primijeniti i na javnu upravu? U tekstu koji slijedi pokazano je da je to itekako moguće.

Iako funkcija javne uprave nikad nije bila upitna, zbog razlika u pristupu inovaciji između organizacija javnog sektora i tvrtki realnog sektora, sve značajnije promijene događale su se u privatnom sektoru. Naime, postoji znatna razlika u pristupu inovacijama između privatnog sektora i javnog sektora. Iako inovacija i u jednom i u drugom sektoru ovisi o tehnološkim sposobnostima (eng. *technology push*) i tržišnim potrebama (eng. *market pull*) u javnom sektoru tržišne potrebe bitno su drugačije [37].



Slika 1: Tehnološke sposobnosti i tržišne potrebe kao čimbenici inovacije

Izvor: [38]

Država (ali i gradovi) ne boje se konkurencije pa *market pull* gotovo da i ne postoji. Vidljivo je to i prema zadnjem izvješću „Svjetskog ekonomskog foruma" o inovacijama u digitalnoj tehnologiji iz 2016. godine prema kojem je Hrvatska tek 124. po indikatoru „Vladina nabava napredne tehnologije" [39].

Kako je ekonomska kriza preokrenula odnos snaga, oči građana ponovno su okrenute u njihove vlade u očekivanju inovativnih rješenja za ubrzanje ekonomije i poboljšanje životnih standarda. Prema Sagraku, modernizirana i digitalizirana javna uprava pridonosi nacionalnoj konkurentnosti i zamašnjak je gospodarskog razvitka Hrvatske [40]. Naime, digitalna transformacija današnjeg društva i ekonomije promijenila je očekivanja i od javnog sektora zahtijevajući nove načine pružanja usluga [41].

2.1. Statički Web i Uprava 1.0

Korijeni elektroničke uprave mogu se pronaći puno prije pojave Interneta pa se tako primjena informacijskih tehnologija u državnoj upravi spominje već prije više od četrdeset godina. Tako se 1974. godine na nekolicini fakulteta u Njemačkoj uvodi znanstvena disciplina informatika u državnoj upravi (eng. *Governmental informatics*, njem. *Verwaltungsinformatik*). Potrebno je istaknuti Hermana Holleritha i njegov tabulirajući stroj na bušene kartice koji je odigrao ključnu ulogu u popisu stanovništva Sjedinjenih Američkih Država 1889. godine.



Slika 2: Tabulirajući stroj Hermana Holleritha

Izvor: [42]

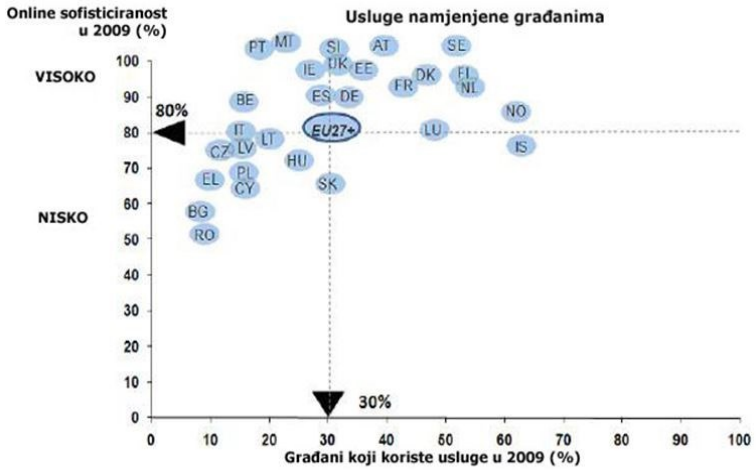
Elektronička uprava[11] predstavlja namjeru države da u potpunosti iskoristi prednosti informacijsko-komunikacijske tehnologije na način da omogući pružanje svojih inače tradicionalnih usluga građanima na siguran, jednostavan, profesionalan i iznad svega brz način. Ideja o dostupnosti tradicionalnih usluga javne uprave na Internetu nastala je prije 20-tak godina. Smatra se da nastanak elektroničke uprave bazirane na statičkim Web 1.0 tehnologijama započinje 1999. godine u Velikoj Britaniji, iako prvi pokušaji datiraju već iz 1994. godine [43].

Informacijske i komunikacijske tehnologije već su dugo prepoznate kao ključni pokretač modernizacije javne uprave. Na EU razini, elektronička uprava spominje se kao prioritet još od eEurope Akcijskog Plana 1999. godine [44].[12]

Ali elektronička uprava i razne strategije transformacije elektroničke uprave nisu donijele očekivane rezultate. Povijesno gledano, već je 2009. godine primijećen znatni nesrazmjer između stvarne ponude usluga e-uprave i stvarnog korištenja istih od strane građana. Grafikon 4. pokazuje da su već 2009. godine e-usluge državne uprave u pravilu bile dostupne, odnosno države su ih nudile, ali ih građani nisu koristili.

[11] U sinonime elektroničke uprave ulaze i pojmovi kao što su online uprava, *one-stop* uprava i u Americi vrlo čest naziv digitalna uprava.

[12] Bangemanov izvještaj iz 1994. godine nazvan prema Martinu Bangemannu, članu Europske komisije zaduženom za informacijske tehnologije i telekomunikacije, poslužio je kao temelj za akcijski plan. U tom su dokumentu sažete moguće mjere za poboljšanje informatizacijske infrastrukture u zemljama članicama EU, ali i u zemljama srednje i istočne Europe.



Grafikon 4: Nesrazmjer ponude i stvarnog korištenja e-usluga u EU27+

Izvor: [45]

2.2. Društveni mediji i Uprava 2.0

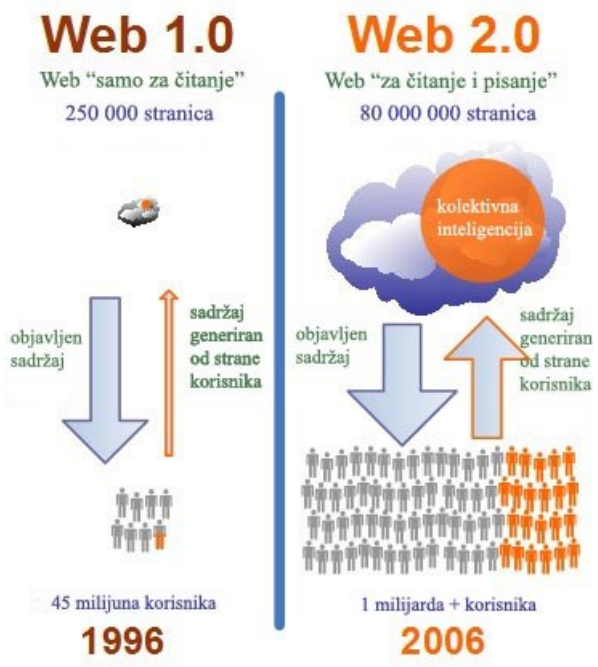
Početkom 2003. godine nova vrsta Web aplikacija sve više dobiva na važnosti. Te nove aplikacije temelje se na konceptu korisnika kao proizvođača sadržaja i nazivaju se Web 2.0 aplikacijama (pod korisnicima se smatraju i državni službenici i građani) [44].

Iako je termin Web 2.0 proslavio O'Reilly 2004. godine, sam termin Web 2.0 skovan je 1999. godine od strane DiNucci i predstavljao je ono što predstavlja i danas – drugu generaciju WWW-a fokusiranu na kolaboraciju, dijeljenje informacija, korisnički generiran sadržaj i interoperabilnost. Ne radi se toliko o značajnom tehnološkom napretku, već o novom, društvenom pogledu na Web, toliko različitom od statičkih HTML stranica zvanih Web 1.0.[13]

Naime, do tada Internet je bio sastavljen od statičkih Web stranica namijenjenih čitanju i pregledavanju objavljenih sadržaja. Prijelomna točka u klasičnom pristupu korištenja i razvoja Web stranica dogodila se 2005. godine kada su predstavljeni uzorci dizajna Weba 2.0 i kada je dominantan model statičkih Web stranica zamijenjen paradigmom društvenog Weba koji je sačinjen od dinamičkih, fleksibilnih i interaktivnih Web aplikacija [9].

[13] U Web 2.0 svijetu, gdje programiranje mora biti neovisno o platformi, PHP je najčešći odabir.

Web 2.0 aplikacije bazirane na društvenoj noti podrazumijevaju interaktivnu dvosmjernu komunikaciju gdje korisnik od pasivnog postaje aktivni sudionik (tzv. konverzacijski Web). Odnosno kako to kaže Osimo, „filozofija je to uzajamnog povećanja kolektivnog znanja, inteligencije i dodane vrijednosti za svakog sudionika dinamičkim stvaranjem i dijeljenjem informacija" [28]. Za razliku od Web 1.0, Web 2.0 korisnicima omogućava sudjelovanje u kreiranju sadržaja weba - posjetitelji više nisu publika, puki i pasivni primatelji informacija, već sudjeluju u njihovu stvaranju, dopunjavanju, modificiranju i prenošenju (pa tako neki Wikipediju nazivaju i najkorisnijom stranicom na svijetu što potvrđuje i njezin Alexa rang[14] kao pete najposjećenije stranice ikad).



Slika 3: Razlika između Web 1.0 i Web 2.0

Izvor: [46]

Iz gornje Slike 3. može se iščitati najbitnija karakteristika Web 2.0 aplikacija, a to je kolektivna inteligencija. Naime, 2007. godine Anderson govoreći o principima Web 2.0 aplikacija govori o njihovoj ključnoj ideji - snaga mnoštva (eng. *power of the crowd*) [47]. Anderson se u članku referira na knjigu „Mudrost mnoštva – zašto je većina uvijek pametnija od manjine i kako kolektivna mudrost utječe na poslovanje, ekonomiju, društvo i naciju"

[14] Alexa rang ključna je metrika Alexa Internet Analytics u vlasništvu Amazona. Rang odražava globalnu popularnost neke Web stranice.

Surowieckog gdje se prvi put iznosi ideja da je mnoštvo uvijek pametnije čak i od najpametnijih pojedinaca.[15]

Web 2.0 aplikacije temelje se na konceptu korisnik kao proizvođač sadržaja. I njihov najizrazitiji utjecaj je upravo na političku participaciju.

Godine 2005. Eggers osmišljava termin **Uprava 2.0** kojeg definira kao skup usluga elektroničke uprave temeljene na Web 2.0 tehnologijama [48][16]. Web 2.0 tehnologije transformirale su način na koji državne agencije nude informacije što je i dovelo do koncepta Uprave 2.0 [6]. Uprava 2.0 novi je koncept koji suradnju između tijela javne vlasti, ali i njihov iskorak prema građanima, podiže na novu razinu. U skladu s time, Uprava 2.0 predstavlja otvoreniju, društveniju, interaktivniju i korisnički usmjerenu elektroničku upravu. Diseminacija sadržaja više nije jednosmjerna, već mrežna, gdje korisnici komuniciraju direktno jedan sa drugim.

Godine 2007. Gartner izdaje nekoliko izvješća vezanih uz Web 2.0 i državnu upravu. Kao smjer kretanja predstavljen u Gartnerovom izvješću iz 2007. godine pod nazivom „*E-government HypeCycle* susreće Web 2.0“, elektronička uprava temeljena na Web 2.0 tehnologijama predstavlja kraj e-uprave kakvu poznajemo (*one stop shop portal* pristup toliko karakterističan za Upravu 1.0) i kao novi cilj zadaje intenzivno korištenje Web 2.0 tehnologija (društvene mreže nasuprot statičkog Web-a, Web orijentirana arhitektura nasuprot servisno orijentirane arhitekture) [50]. Iste godine, Gartner u izvješću „Uprava i Web 2.0“ zaključuje kako se država polako odmiče od pristupa kojeg su promicali *one stop shop* portali i okreće se prema korisnicima zanimljivijim *mashup* aplikacijama [51].[17]

U novije vrijeme i EU promovira korištenje Web 2.0 aplikacija elektroničke uprave u cilju povećanja građanske participacije i donošenja odluka [52]. Korištenje Web 2.0 aplikacija u domeni elektroničke uprave novija je ideja i velika prilika za državnu upravu čije potencijale tek treba istražiti.

Povijesno gledano, tek 2011. godine dolazi do značajnijeg utjecaja Web 2.0 tehnologija na državnu upravu kada američke agencije počinju koristit društvene medije kao alat za

[15] Poznato je istraživanje Francisa Galtona na seoskom sajmu gdje je ustanovljeno da je prosjek ocjena većeg broja građana bio bliži stvarnoj težini vola od prosjeka ocjena nekoliko gospodarskih stručnjaka.
[16] Pa tako Kanadska vlada koristi Second Life kod regrutacije vojnika, dok u Velikoj Britaniji društvene mreže pomažu lokalnoj upravi kod lokalnih problema, npr. popravka cesta i sl. [49].
[17] *Mashup* (hrv. miks) jest Web 2.0 tehnologija koja omogućava kombiniranje sadržaja s više različitih Web stranica na jednoj web stranici s ciljem stvaranja novog sadržaja (npr. informacije o vremenu, prometu, zemljopisne informacije iz različitih GIS-eva i sl).

dijeljenje znanja i koordinaciju[18]. Wiki i ostala kolaborativna radna mjesta rezultirala su bržim ciklusima odlučivanja i otkriveno je da društveni, kolaboracijski mediji omogućuju efektivno upravljanje znanjem u dinamičkom okruženju.

Očekivanja od takve elektroničke uprave vrlo su visoka. No činjenica je i da ljudi ne usvajaju jednostavno nove tehnologije kada one postanu dostupne. Odnosno upravo suprotno, opiru im se i pokušavaju umanjiti njihove dobrobiti. Stoga, građani moraju biti voljni i sposobni koristiti te iste usluge.

Stoga će stupanj prihvaćanja Web 2.0 aplikacija u elektroničkoj upravi također zavisiti od mnogobrojnih čimbenika, čiji će se jedan mali dio pokušati identificirati i u ovom radu. Naime, implementacija Web 2.0 u kontekstu državne uprave dolazi sa svojim izazovima. Prihvaćanje elektroničke uprave događa se gotovo uvijek u specifičnom socio-političkom okruženju što kao posljedicu ima kompleksni model istraživanja i traži da se pitanje prihvaćanja razmatra ne samo s tehnološke perspektive, već i s društvene, političke i kulturne [53].

Već je ranije elektronička uprava definirana kao korištenje informacijsko-komunikacijske tehnologije za pružanje tradicionalnih usluga državne uprave građanima *online*. Planira li se elektronička uprava strategijski (a trebala bi), koji je konačni strategijski cilj elektroničke uprave? Prema Al-Hujran, Al-Debei i Al-Lozi, glavni naglasak elektroničke uprave ne smije biti samo na tehnologiji, već na postizanju strategijskih ciljeva državne uprave uz pomoć tih tehnologija. A jedan od strategijskih ciljeva e-uprave jest upravo transformacija političkog sustava, odnosno tzv. e-demokracija [54].

A srž svake e-demokracije je e-participacija.

2.3. Uprava 3.0 – blockchain i transformacija uprave u digitalnom dobu

Pojam statičkog Weba 1.0 i s njime povezan pojam e-uprave objašnjen je u ranijim poglavljima, kao i pojam Web 2.0 i s njim povezan pojam Uprave 2.0. No koji su budući smjerovi kretanja? Postoji li Web 3.0 i u skladu s time Uprava 3.0? Ako je Web 1.0 bio skup statičnih podataka bez mogućnosti interakcije, a Web 2.0 participacijski Web zasnovan na interaktivnom sadržaju, koja je glavna karakteristika Web 3.0? I ako je već Web 2.0 bio toliko dobar, zašto je uopće potreban Web 3.0?

[18] Radi se o praćenju Arapskog proljeća i potresa na Haitiju.

Web 2.0 omogućio je veliku brzinu kreiranja sadržaja. Korisnik je sam mogao u nekoliko klikova kreirati sadržaj koji je prije u vrijeme Weba 1.0 zahtijevao prilična tehnička znanja što u korištenju *front-end* tehnologija, što u korištenju *back-end* tehnologija.[19] I u skladu s time, broj korisnika se eksponencijalno povećao.[20] Velike Internet kompanije ubrzo su shvatile važnost podataka i počele ih centralizirati na svojim serverima. No krađe lozinki sa servera Facebook-a, LinkedIn-a, Twitter-a ili Apple ID-a postala su uobičajena vijest.[21] Ljudi su, svjesno ili nesvjesno, žrtvovali sigurnosti za udobnost [56]. Sve ove probleme Weba 2.0 (centralizirani podaci pogodni za različite hakerske napade i pitanje vlasništva istih tih podataka od strane Internet kompanija) rješava novi koncept Weba – Web 3.0. A kao što će biti istaknuto na početku trećeg poglavlja, povjerenje u državu i političare od ključnog je značaja za participiranje građana.

Web 3.0 treća je generacija Interneta gdje su računala povezana u decentraliziranu mrežu ne oslanjajući se toliko na servere i centralizirane baze podataka. Ovaj „novi" Internet još je više siguran, privatan i bolje povezan. Naime, Web 3.0 nema centralne kontrole (*blockchain* tehnologija), vlasništvo nad podacima ponovno je u rukama korisnika i naprednim tehnikama kriptiranja krađa podataka je svedena na praktični nemoguću (SHA algoritam) [57].

Pojam *bitcoin* je tijekom 2017. i 2018. godine toliko ušao u svakodnevni govor da se čini kako je oduvijek bio sastavni dio našega života. Kriptovalute su svugdje oko nas. Procjenjuje se da je trenutačno u opticaju preko 2 000 različitih kriptovaluta s tržišnom kapitalizacijom preko 200 milijardi dolara. Kako kupiti, prodati, trgovati ili čak rudariti kriptovalute prilično je poznato. No manje je poznato da bi *blockchain*[22] (hrv. lanac blokova), tehnologija koja pokreće digitalne valute kao što je *bitcoin*, mogla imati snažan utjecaj na demokraciju u digitalno doba [58].

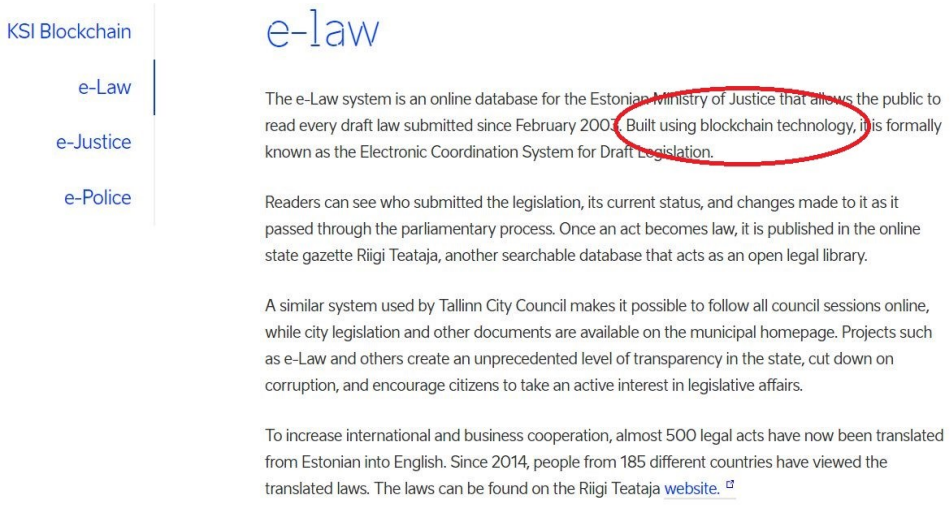
Blockchain tehnologija bazirana je na kriptografiji i kao takva predstavlja alternativu klasičnom, centraliziranom bankarskom sustavu i transakcijama u takvom sustavu. Kod klasičnih bankarskih transakcija, ako npr. osoba A želi poslati 1 000 kuna osobi B, banka igra centralnu ulogu nadzornika i bilježnika transakcija (eng. *Trusted Third Parties*), pa će tako

[19] Dok *front-end* tehnologije predstavljaju tzv. klijentsku stranu, odnosno ono što zovemo Web dizajn, *back-end* tehnologije usmjerene su na serversku stranu programiranja.
[20] U trenutku pisanja ovoga rada (11/2019), procijenjeni broj aktivnih korisnika Facebook-a je 2.5 milijardi, a ako ubrojimo i ostale Facebook proizvode (WhatsApp, Instagram, Messenger) brojka prelazi 3 milijarde korisnika što je blizu 50 % cjelokupne ljudske populacije [55].
[21] Procijenjeni troškovi ovakvih upada u sustave samo u Americi dostižu godišnje preko 2 milijarde dolara!
[22] *Blockchain* kao tehnologija prvi put je opisana 2008.godine kada je osoba pod pseudonimom Sotoshi Nakamoto objavio rad *Bitcoin: A Peer-to-Peer Electronic Cash System*. U trenutku posanja ovog rada (11/2018) još uvijek nije poznato tko se krije iza tog pseudonima.

osobi A smanjiti saldo na računu za 1 000 kuna dok će osoba B na računu imati 1 000 kn više. Sve se to zapisuje u glavnoj knjizi banke (eng. *ladger*) i funkcionira tako dugo dok osoba A i B imaju povjerenja u banku kao nezavisnog nadzornika i bilježnika, a to pak banci daje prilično moć i veliki izvor zarade. *Blockchain* predstavlja alternativu takvom klasičnom, centraliziranom sustavu, na način da eliminira centraliziranu stranu, odnosno banku. Glavna knjiga koja je zapravo jedna vrsta baze podataka sa svim transakcijama više nije centralizirana, već je distribuirana na mnogo mjesta.

U *blockchain* decentraliziranom sustavu banku (ili državu ako govorimo o državnim bazama podataka) zamjenjuje mreža decentraliziranih računala koja potvrđuju transakcije na bazi određenog algoritma [59]. Glavna knjiga (u osnovi replicirana baza podataka sa svim transakcijama) više nije samo u banci, već se nalazi distribuirana kod svih korisnika.

I to je otprilike cijela ideja *blockchain* tehnologije - decentralizirani sustav u koji se mogu upisivati podaci o financijskim transakcijama. No cijela bit i važnost *blockchain* tehnologije jest u tome da to ne moraju biti financijski podaci, već bilo koji podaci o bilo čemu. Monetarni aspekt samo je jedan od načina iskorištavanja *blockchain* tehnologije. Kao zemlja svijetski predvodnik u digitalizaciji državne uprave, Estonija je *blockchain* tehnologiju uspiješno implementirala u sustav zemljišnih knjiga (tzv. gruntovnica), kao i sustave pretraživanja zakonodavstva. Zainteresiran građanin može vidjeti tko je predložio zakon, zahtijevane izmjene i dopune kao i trenutni status.



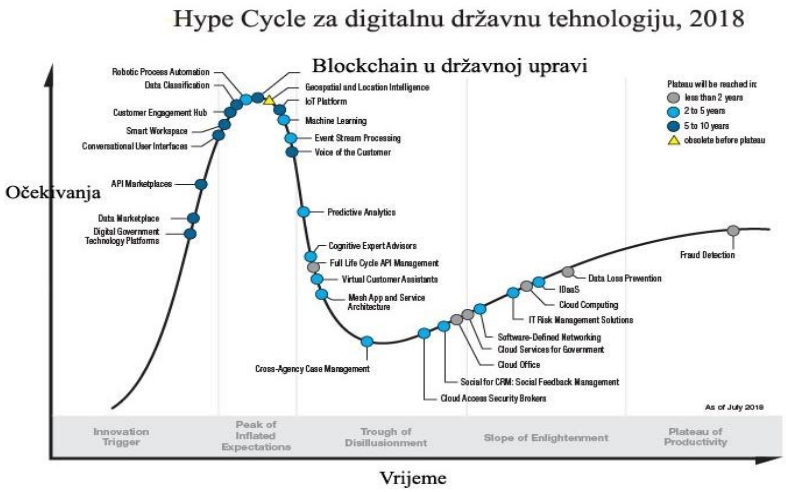
Slika 4: *Blockchain* i sudska praksa sudova u Estoniji

Izvor: [60]

Kako *blockchain* tehnologija može ojačati demokraciju u digitalnom dobu? Kao što je na početku poglavlja 3. utvrđeno, u današnjem svijetu demokracije povjerenje građana prema političkom sustavu (državi) na niskim je razinama. Povjerenje bi moglo biti obnovljeno na način da se implementira tehnologija koja onemogućava državu u bilo kakvim aktivnostima koja mogu naštetiti građanima.

Flux je naziv australske političke stranke koja ima za cilj radikalno unaprijediti demokraciju koristeći Flux aplikaciju zasnovanu na *blockchain* tehnologiji. Flux je alat koji „omogućuje građanima Australije direktnu participaciju sa parlamentom, stvarajući time da potreba za povjerenjem u izabrane predstavnike postane stvar prošlosti“ [61]. Ukrajinska vlada planira cijelu tehničku izbornu infrastrukturu prebaciti na *blockchain*. Već je 2016. godine potpisan memorandum kojim se vlada obavezuje na korištenje E-vox *blockchain* aplikacije, a sve s ciljem kreiranja „decentraliziranog, transparentnog i lako dostupnog sustava za grupno donošenje odluka baziranog na *blockchain* tehnologiji“ kojeg planiraju koristiti političke stranke tijekom izbora i za različite referendume i peticije [62].

Razmišljanja o *blockchain* tehnologiji u državnoj upravi potkrepljena su i Gartnerovim dijagramom za 2018. godinu gdje je *blockchain* tehnologija prikazana kao jedna od tehnologija od koje se očekuje najveći transformatorski efekt vezano uz poslovanje države u slijedećih deset godina (druga tehnologija je tzv. strojno učenje, eng. *machine learning*)[23].



Grafikon 5: Gartenerov Hype Cycle za digitalnu državnu tehnologiju u 2018. godini

Izvor: [63]

[23] Smarter With Gartner “Top Trends from Gartner Hype Cycle for Digital Government Technology, 2018,” 3 September 2018. https://www.gartner.com/smarterwithgartner/top-trends-from-gartner-hype-cycle-for-digital-government-technology-2018 .

3. ELEKTRONIČKA PARTICIPACIJA

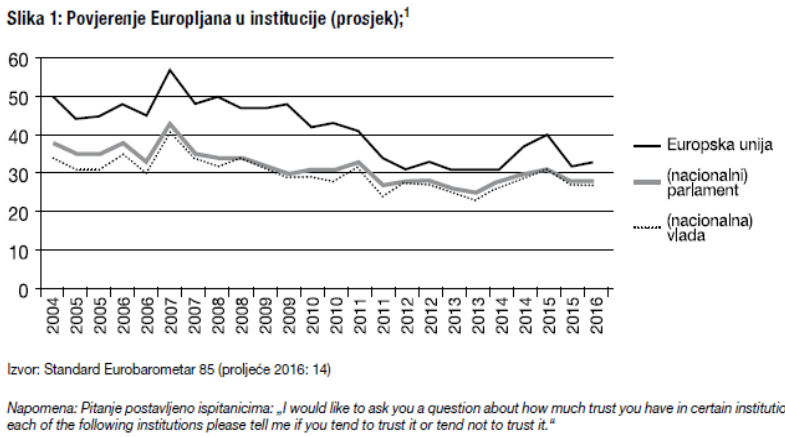
„Ako će građani više participirati između dva izbora,
onda će i više izlaziti na izbore“.
Prof.dr.sc. Ivan Koprić, Pravni fakultet u Zagrebu

Literatura otkriva razloge zašto su neki građani zainteresirani za *offline* političku participaciju, dok drugi to nisu. Ta se istraživanja oslanjaju na teoriju resursa tumačeći da politička participacija kao aktivnost ovisi o troškovima, vremenu i energiji – osobe sa više ovih resursa vjerojatnije će sudjelovati u participacijskim aktivnostima više od drugih. Stoga, prema trenutačnom modelu odnosa države i društva, želite li imati političkog utjecaja trebate imati novaca, vremena i svoj život posvetiti politici [64], [65]. Građani su još uvijek pasivni promatrači, a troškovi participacije u takvom sustavu za njih su vrlo visoki. Sve je to u suprotnosti s činjenicom da danas, više nego ikad prije, uz pomoć informacijsko-komunikacijskih tehnologija, građani svoje želje, ali i zabrinutosti, mogu izraziti lako, brzo i nadasve jeftino.

Tako Le Blanc u članku iz 2020. godine kaže da su Web 2.0 tehnologije smanjile troškove i uvele nove mogućnosti participacije. Npr. kreiranje konzultacija vezano uz prijedloge zakona na *online* javnoj platformi jeste u teoriji jeftina aktivnost, odnosno svakako jeftinija od održavanja konzultacijskih sastanaka sa svakom od zainteresiranih osoba [19].

Dana 3.1.2000. godine na parlamentarne izbore održane u Hrvatskoj izašlo je 2,82 milijuna birača (76.55 %). Šesnaest godina poslije, na izbore održane dana 11.9.2016.godine izašlo je 1,92 milijuna birača (52.59 %). Broj glasača u Hrvatskoj u ovom mileniju smanjio se za više od 900 000 [3]. Niska izlaznost na izbore baca sumnju i na samu legitimnost izabranih političara kao predstavnika naroda.[24] Kriza povjerenja u predstavničku demokraciju neosporno postoji.

[24] Npr. prema uvidu u službenu aplikaciju za provedbu izbora od strane autora ovog rada kao člana izbornog povjerenstva na izborima za župana Varaždinske županije, Radimir Čačić izabran je za župana Varaždinske županije s 17.87 % birača s pravom glasa.



Grafikon 6: Povjerenje Europljana u institucije

Izvor: [40]

Postojanje niskog povjerenja u nacionalne i nadnacionalne vlade i institucije potvrđuje i istraživanje Eurobarometra koje pokazuje da građani Europske unije sve manje vjeruju svojim nacionalnim vladama, parlamentima i institucijama EU. Iz gornjeg Grafikona 6. vidljivo je da je 2016. godine samo 27 % ispitanika izjavilo da vjeruje svojim nacionalnim vladama, dok je njih više od 70 % reklo da ne vjeruje svojoj vladi. Povjerenje u EU institucije je nešto bolje, ali također slabo pa se može zaključiti da su građani očito politički pasivizirani.

Zanimljivo je za istraživanje primijetit da gornji graf povjerenja prati i graf izlaznosti birača.



Grafikon 7: Izlaznost birača u Republici Hrvatskoj na parlamentarne izbore

Izvor: [66]

Kako preokrenuti ovaj trend imajući u vidu da se brojne zapadne demokracije suočavaju s povećanim brojem građana koji zahtijevaju jači utjecaj u političkom procesu [29]?

Informacijsko-komunikacijske tehnologije predstavljaju potencijalni način revitalizacije demokratskog procesa.

Velik broj autora smatra da upravo nove tehnologije otvaraju brojne mogućnosti za rješenje problema kroničnog nepovjerenja. Coleman i dr. u svom istraživanju zaključuju da građani iskazuju veće zanimanje za sudjelovanje u građanskim aktivnostima (glasovanje!) ako im se prethodno pruži Web platforma koju mogu lako koristiti i koja će im pružiti sve potrebne informacije o procesima koji ih zanimaju [40] [67].

Aichholzer i Allhutter smatraju da je jedini lijek protiv smanjenja broja glasača, udaljavanja građana od politike i nepovjerenja u političare upravo jačanje elemenata direktne participacije. Mogu li e-participacijske tehnologije (ili malo šire gledano, e-demokracijske tehnologije) utjecati na povećanje izlaznosti na izborima? Ovi autori smatraju da mogu. Naime, intenzivno korištenje novih tehnologija u političkoj sferi podiže interes građana i utječe na veću uključenost građana u političke procese [68].

Participativan sustav upravljanja osigurava efikasnost politika, kvalitetu odlučivanja, legitimitet odluka i možda najvažnije, jača povjerenje građana u institucije [69].

I prema Šiberu, izlaznost birača između ostalog ovisi o političkoj mobilizaciji [70]. Kao što je u uvodu ovog rada naglašeno, vrijeme političkih kampanja „od vrata do vrata“ je prošlo. *Whistle stop tour*[25] sve više gubi na važnosti, a politika se seli iz fizičkog u virtualni prostor. A participacijske Web 2.0 tehnologije tu su od ključnog značaja.



Slika 5: Whistle stop turneja Trumana 1948. godine

Izvor: [72]

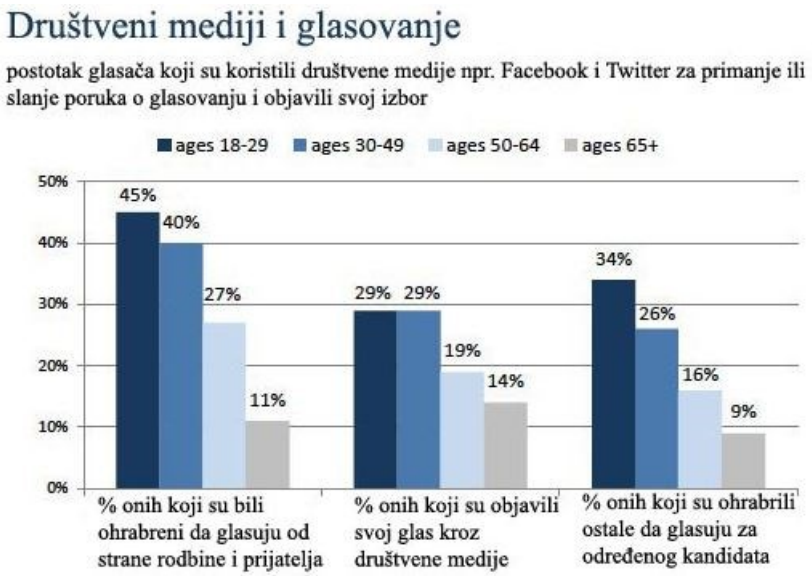
[25] Radi se o vrsti političke kampanje gdje političar nastoji u kratkom vremenu obići što više mjesta i održati što više govora [71].

Le blanc također smatra da je početkom 21. stoljeća u Europi e-participacija smatrana kao način ponovnog kreiranja povjerenja u javne institucije, povećanja njihovog legitimiteta i uključivanja građana u demokratske procese s ciljem smanjivanja indiferencije prema formalnom političkom procesu [19].

Tako je Barack Obama, 44-predsjednik Sjedinjenih Američkih Država, 2008. godine tijekom svoje prve izborne kampanje za savjetnika angažirao Chrisa Hughesa (suosnivač Facebook-a), dok su mu najbliži savjetnici bili Eric Schmidt (direkor Googla) i Craig Newmark (suosnivač Craiglista) [1].[26]

Važan je podatak da je 22 % građana koji su intenzivno pratili američke izbore 2010. godine preko Web-a na osnovu podataka dobivenih na raznim Web 2.0 platformama odlučilo uopće izaći na izbore, a dodatnih 42 % odlučilo je svoj glas dati/ne dati određenom kandidatu na osnovu informacija dobivenih *online* [74].

Imajući to na umu, Barack Obama je u svojoj drugoj predsjedničkoj kampanji 2012. godine zaposlio 100 ljudi kako bi upravljali njegovim Twitter računom. Je li Obamino aktivno uključivanje građana donijelo rekordnu izlaznost i pobjedu? Izgleda da jeste.[27]



Grafikon 8: Društveni mediji i glasovanje u SAD-u 2012. godine

Izvor: [75]

[26] Obaminu Web stranicu posjetilo je duplo više ljudi nego protukandidata McCaina, imao je četiri puta više pregleda na Youtube-u, pet puta više prijatelja na Facebook-u, ali i deset puta više zaposlenih stručnjaka za društvene mreže [73].

[27] Iako, kao što se i u poglavlju „8.4. Mogući daljnji smjerovi istraživanja“ raspravlja, moderne tehnologije obrade velikih količina podataka o korisnicima društvenih mreža mogu utjecati na razvoj događaja kao što su izbor američkog predsjednika i referendum o Brexitu.

Iz gornjeg Grafikona 8., kao i iz kvantitativnih podataka, vidljivo je da su Web 2.0 platforme društvenih medija postale zapaženo mjesto gdje ljudi pokušavaju uvjeriti svoje prijatelje da glasaju. Čak 30 % registriranih birača bilo je ohrabreno da glasuju za demokrata Baracka Obamu ili republikanca Mitta Romneyja od strane obitelji i prijatelja putem postova na društvenim medijima kao što su Facebook ili Twitter [75].

Iz analize kako prve tako i druge kampanje Baracka Obame, dvije se stvari mogu zaključiti:

- jasni su dokazi da informacijsko-komunikacijska tehnologija lako mobilizira građane i
- instrumenti potrebni za participaciju u informacijskom se dobu mijenjaju.

3.1. Definiranje i povijest elektroničke participacije

Trenutačni politički sustav u kojem svakih nekoliko godina biramo svoje predstavnike sasvim sigurno nije reprezentativan u smislu transfera mišljenja građana u proces donošenja odluka. Razlog je tome što, u ovako zamišljenom sustavu, građani ne mogu utjecati na način na koji ti predstavnici donose odluke. Može li to e-participacija promijeniti?

Veliki broj pojmova u računalnoj znanost koje je teško definirati nagnalo je američkog matematičara i dobitnika Turingove nagrade[28] Richarda Haminga da u svom govoru prilikom primanja nagrade primijeti da je i samu računalnu znanost[29] teško definirati. Nedostatak terminološke discipline u literaturi iz računalnih i informacijskih znanosti je očit, uzrokujući time nepostojanje uniformne definicije niti za jedan pojam. Zato je smisao ovog poglavlja da se prvo dobro definiraju pojmovi koje će se koristiti.

Kada govorimo o informacijsko-komunikacijskoj tehnologiji u javnom sektoru, pojam koji se prvi nameće jeste e-uprava. Ali što je e-uprava i kakav je odnos između e-uprave i e-participacije?

E-vladavinu (eng. *e-governance*) Ujedinjeni narodi (UN) odnosno njihov Program za razvoj (UNDP) definira kao korištenje informacijsko i komunikacijske tehnologije u cilju povećanja efikasnosti, pristupačnosti i demokratske odgovornosti javne uprave u procesu kolektivnog odlučivanja [76]. Kao koncept *e-governance* obuhvaća e-demokraciju, e-upravu i e-poslovanje. Sam engleski pojam *governance* (pa tako i *e-governance*) teško se prevodi, odnosno u pravilu se prevodi prema kontekstu. Najčešće je to kao „upravljanje“ ili

[28] Turingova nagrada ekvivalent je Nobela za računalne znanosti.
[29] Richard Feynman, slavni fizičar i nobelovac čak je zastupao tezu da računalna znanost uopće ne postoji.

„vladavina“. No kao što to kaže Miošić Lisjak „niti jedan od tih prijevoda na adekvatan način ne prenosi značenje tog pojma, pa se stoga često i ne prevodi“ [77].

Elektronička uprava (eng. *e-government*) u najširem smislu predstavlja korištenje informacijsko-komunikacijske tehnologije u javnoj upravi u svrhu povećanja efikasnosti i učinkovitosti u pružanju javnih usluga i funkcioniranja unutarnjih procesa, s jedne strane, te povećanja transparentnosti i odgovornosti [40]. Skup je to elektroničkih javnih usluga dostupnih građanima.

E-demokracija (eng. *e-democracy*) predstavlja korištenje informacijsko-komunikacijske tehnologije kao podršku svim demokratskim procesima pri donošenju odluka [78]. Prema Paryceku, demokratski proces sastoji se od tri podprocesa:

1) prikupljanje informacija,
2) formiranje mišljenja i
3) donošenje odluke [79].

E-demokracija dakle predstavlja korištenje informacijsko-komunikacijske tehnologije kao podršku demokratskim procesima, omogućavajući građanima stalnu povezanost s izabranim predstavnicima, sudjelovanje u formiranju politika, zakona kao i u samom procesu glasovanja.[30] Točnije, radi se o specifičnom poimanju implementacije demokracije – davanje glasa građanima i izvan regularnih izbora [80]. Najveći broj autora e-demokraciju definira kao nadskup e-participacije i specijalni tip elektroničke interakcije državne uprave prema građanima (eng. *Government to Citizen*) i pritom ju dijele na dva područja: e-participacija i e-glasovanje [81].

Općenito govoreći, politička participacija predstavlja specifično poimanje implementacije demokracije, odnosno davanje glasa građanima i izvan regularnih izbora (ideje, konzultacije i aktivna kontrola nad izabranim političarima) [82].[31]

Doda li se ovako definiranoj participaciji prefiks e, **e-participacija** (eng. *e-participation*) predstavlja korištenje alata (Internet, Web 2.0 aplikacije) u prethodno navedenom kontekstu participacije [83]. E-participacija u svojoj biti jest podskup e-demokracije. Naime, pozivajući

[30] Razlika ju u tome da elektronička uprava daje naglasak na državu kao davatelja usluge, dok je davatelj usluge kod e-demokracije građanin.
[31] Prema Klaićevom ruječniku stranih riječi, lat. *participare* znači biti dionik, udioništvovati, sudjelovati, učestvovati.

se na gore spomenutu definiciju e-demokracije kao podršku svim demokratskim procesima, prvi i drugi podproces demokratskog procesa (prikupljanje informacija, formiranje mišljenja) nazivamo e-participacijom, dok je treći podproces (donošenje odluke) obuhvaćen područjem e-glasovanja [79].

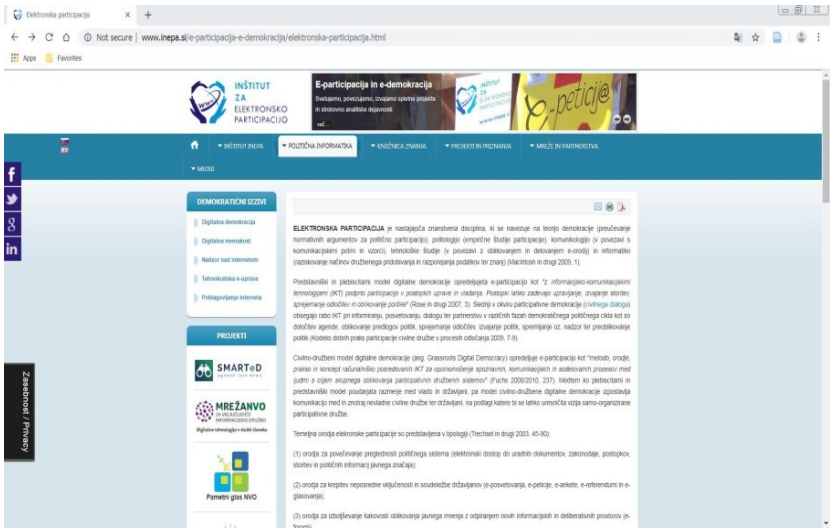
I definicije drugih autora daju za pravo razmišljati o e-participaciji kao, zajedno s e-glasovanjem, podskupu e-demokracije. Tako npr. dopis Vlade Ujedinjenog kraljevstva iz kolovoza 2002. godine kaže da se e-demokracija može podijeliti na dva odvojena područja - jedno koje se tiče e-participacije i jedno koje se tiče e-glasovanja, gdje se e-participacija definira kao konzultacije i dijalog između Vlade i građana [84].

Dakle, e-participacija predstavlja podskup e-demokracije, odnosno potpora svim demokratskim procesima (minus glasovanje). Kao koncept nalazi se i u temeljima EU. Naime, Lisabonski sporazum Čl. 8 A., St. 3, kaže da „Svaki građanin ima pravo participirati u demokratskom životu Unije“ (eng. *Every citizen shall have right to participate in the democratic life of an Union“*).

Ovakvo poimanje e-participacije potvrđuju Stieglitz i Brockmann kad kažu da elektronička uprava predstavlja nadskup e-demokracije, a e-demokracija pak ima dva podskupa - e-glasovanje i e-participaciju [17].

U stručnoj literaturi svakako najčešće korištena definicija e-participacije jest ona Ann Macintosh, profesorice emeritus digitalnog upravljanja sa sveučilišta u Leedsu koja kaže da je „e-participacija korištenje informacijske i komunikacijske tehnologije s ciljem proširivanja i produbljivanja političke participacije omogućujući građanima da međusobno komuniciraju jedni s drugim, kao i sa svojim izabranim zastupnicima“ [15].

Slovenski Institut za elektroničku participaciju e-participaciju smatra novom znanstvenom disciplinom koja povezuje teoriju demokracije, komunikologiju i informatiku [85].



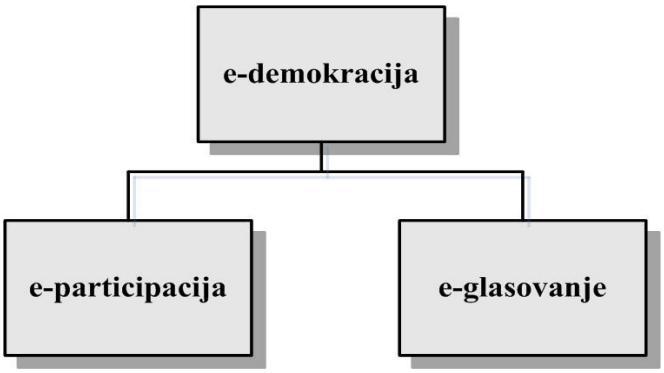
Slika 6: Web stranice slovenskog Instituta za e-participaciju

Izvor: [85]

Dakle, definicije se slažu oko jednog, e-participacija definira se kao tehnološki posredovana interakcija između sfere civilnog društva i formalne političke sfere [79]. Ovaj rad obuhvaća e-participaciju i to istraživanje čimbenika utjecaja na prihvaćanje javne usluge e-participacije u Republici Hrvatskoj.

U ovom radu e-participacija se definira kao upotreba informacijsko-komunikacijskih tehnologija za osnaživanje sudjelovanja građana i otvaranje komunikacijskih kanala u demokratskim postupcima između dva izbora. Prethodno navedeno uključuje sudjelovanje građana u procesu mijenjanja politike, zakonodavnog postupka, nadzoru izabranih predstavnika, oblikovanju politika u okviru političkih stranaka, kao i u svim ostalim procesima donošenja odluka koje su od javnog značaja [86].

Sličnu definiciju daje i Le Blanc kad kaže da je e-participacija korištenje informacijsko-komunikacijske tehnologije s ciljem uključivanja građana u procese donošenja odluka od javnog značaja [19].



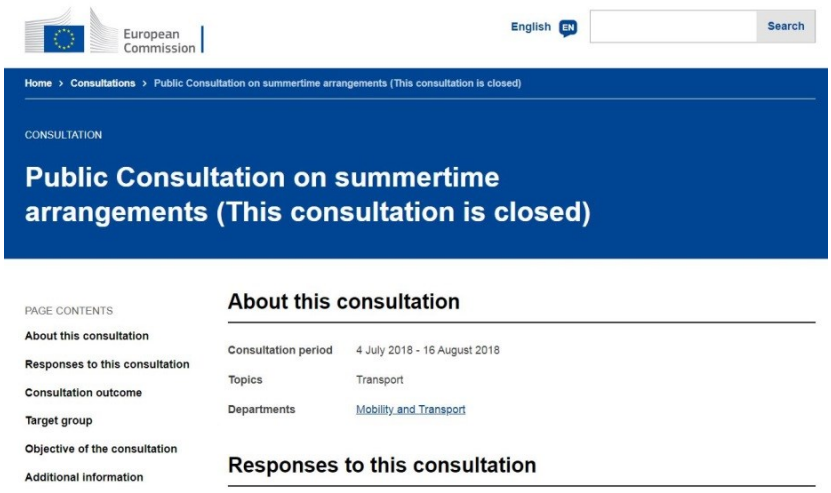
Slika 7: Grafički prikaz odnosa ključnih pojmova

Organizacija za ekonomsku suradnju i razvoj (eng. *Organisation for Economic Cooperation and Development*, OECD) definira tri razine e-participacije: informacijska, konzultacijska i razina aktivne participacije.[32]

Informacijska razina predstavlja jednostranu vezu, odnosno samo je država ta koja proizvodi i dostavlja informacije, koje su osnova za političku participaciju, građanima na korištenje (npr. službena Web stranica nekog državnog tijela, blogovi, FAQ, Webcasts). Europska unija radi na jačanju svih triju aspekata e-participacije pa tako i ovog. Tako je važnost korištenja informacijsko-komunikacijskih tehnologija za poboljšanje komunikacije prema građanima naglašena u raznim dokumentima kao što su to Akcijski plan za poboljšanje komuniciranja iz 2005. godine (eng. *Action plan to improve communicating*), D-plan za demokraciju, dijalog i debatu (eng. *Plan-D for Democracy, Dialogue and Debate*) i mnogi drugi [32].

Konzultacijska (savjetodavna) razina predstavlja obostranu vezu između države i građana, gdje država dobiva povratne informacije u formi mišljenja građana.[33] Država definira problem i želi čuti mišljenja građana (npr. *online* konzultacije o zakonskim prijedlozima, ankete). I ovu razinu EU snažno podupire, pa je tako 2002. godine EU definirala minimalne standarde za konzultacije, a 2015. godine e-konzultacije su dodatno definirane u vodiču za bolju regulaciju (eng. *Better Regulation Guidelines*) [32].

[32] Ova tri stupnja nekad se u literaturi spominju kao tzv. *e-enabling*, *e-engaging* i *e-empowering* stupanj [19]. No postoje i drugačija shvaćanja pa tako Sue Goss nudi širi model e-participacije od pet stupnjeva [87].
[33] Naime, Europska unija često koristi građane kao savjetodavce. Tako je za vrijeme pisanja ovog rada (9/2018) aktualno savjetovanje s građanima EU o potrebi ukidanja ljetnog ili zimskog računanja vremena. Rezultati glasovanja mogu se vidjeti oa ovom linku https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=CELEX:52018SC0406&from=HR .



Slika 8: Anketno ispitivanje građana EU o potrebi ukidanja ljetno/zimskog računanja vremena

Izvor: [88]

Aktivna participacija predstavlja najvišu razinu kod koje postoji partnerski odnos između države i građana. Građani su aktivno uključeni u oblikovanje javnih politika i odlučivanja vezano uz te politike (npr. e-referendum, e-peticije, e-budžet, virtualno prisustvovanje različitim saslušanjima i sastancima) [89]. Lisabonski sporazum omogućio je EU da poduzme prve korake prema e-odlučivanju pokrenuvši 2012. godine Europsku inicijativu građana (eng. *European Citizens Initiative*, ECI). Europska inicijativa građana predstavlja prvi službeni instrument za participacijsku demokraciju s jakom *online* komponentom [32].



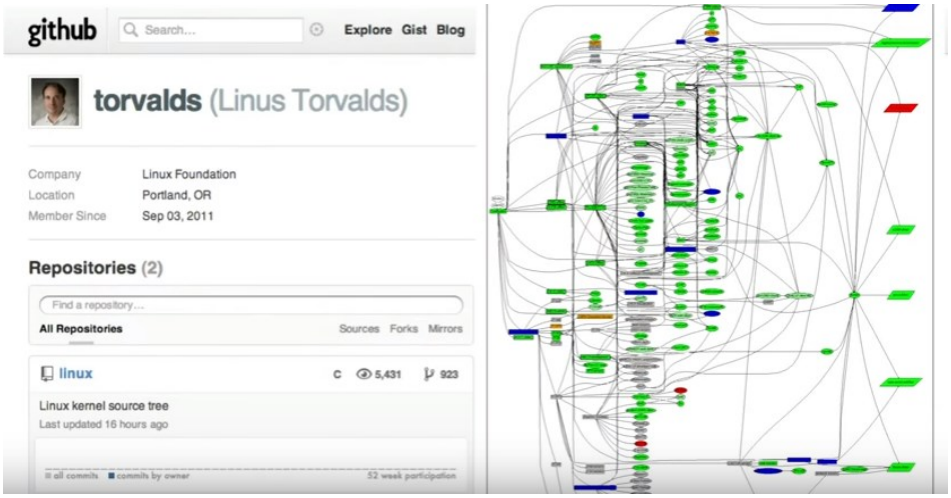
Slika 9: *Online* peticija za ostanak Velike Britanije u EU

Izvor: [90]

Prema enciklopediji informacijskih znanosti i tehnologije, znanstveno gledano, e-participacija predstavlja mlado, interdisciplinarno područje istraživanja od strane znanstvenika različitih profila (političke znanosti, informacijski sustavi, ekonomija, psihologija) a sve u cilju diseminacije političkog planiranja i odlučivanja (uključivanje građana u demokratske procese donošenja odluka) [91].

No povijesno gledano gdje su počeci e-participacije?

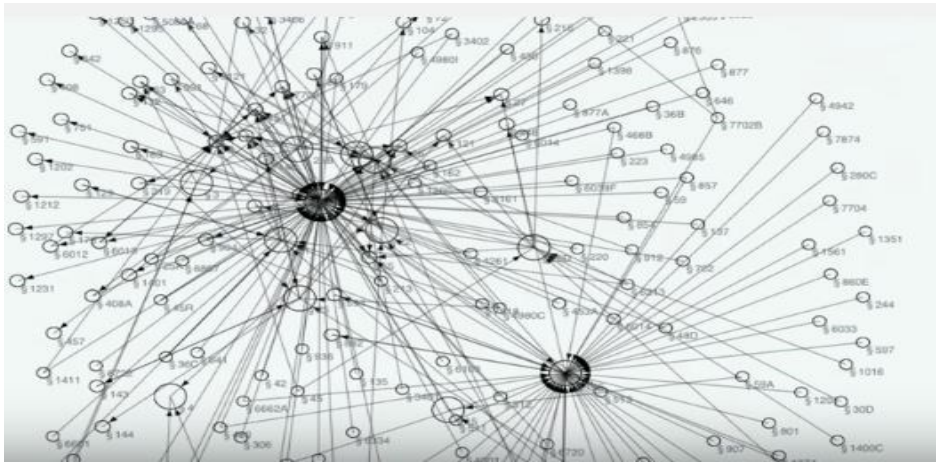
Open source zajednica zaslužna je za početak praktične primjene e-participacije. Naime, godine 2005. Linus Torvalds, slavni izumitelj Linuxa, kako bi si olakšao vođenje jednog velikog i kompleksnog projekta (razvoja Linux kernela), razvija distribuirani sustav za verzioniranje softvera nazvan Git. Git, kao sustav koji odgovara na pitanje kako omogućiti da dva programera koja se nalaze na raznim stranama svijeta mogu nešto zajedno stvarati (vodeći računa da unutar Linux-a pod dijelovi programa ovise o drugim pod dijelovima programa) jedan je od prvih praktičnih primjera e-participacije.



Slika 10: Mapa povezanosti i međusobne ovisnost pod programa u Linux-u

Izvor: [92]

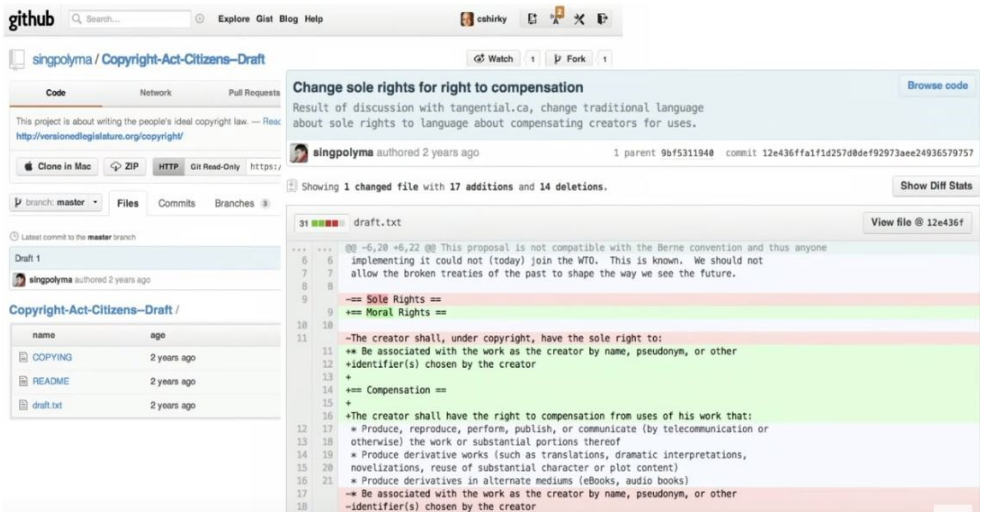
Otvara se pitanje, kojeg i Clay Shirky postavlja, koji je to još sustav međuzavisan i povezan (eng. *dependency related*) [92]? Pravo (zakonodavstvo) je sustav gdje je puno mišljenja u cirkulaciji, a trebaju biti sakupljena u jednom konačnom rješenju - zakonu. Torvalds se nije bavio zakonima, no može li se Git primijeniti na zakone? Odnosno, je li Git-ovo svojstvo „kooperacije bez koordinacije" primjenjivo i na pravnu domenu?



Slika 11: Mapa utjecaja američkog poreznog zakona na druge američke zakone

Izvor: [92]

Sve to zvuči dosta teoretsko, no može li se ova filozofija primijeniti praktično, npr. na konkretne zakone?[34] I je li to netko probao? Istina je da 99 % GitHub-a su *source code* projekti, ali pogledaju li se margine GitHub-a, dolazi se do zanimljivih zaključaka.



Slika 12: Zakon o *copyright*-u na GitHub-u

Izvor: [93]

Američka država Utah sve je svoje zakone stavila na GitHub omogućujući tako građanima da sudjeluju u izradi zakona (na Slici 12. desno se vidi tzv. *diff* koji pokazuje tekst kojeg mnogi ljudi editiraju, vidi se koja promjena je napravljena, tko ju je napravio i kad, slično kao

[34] Odnosno, da parafraziramo GitHub-ovu uzrečicu „*Build software (laws?) better, together*"!

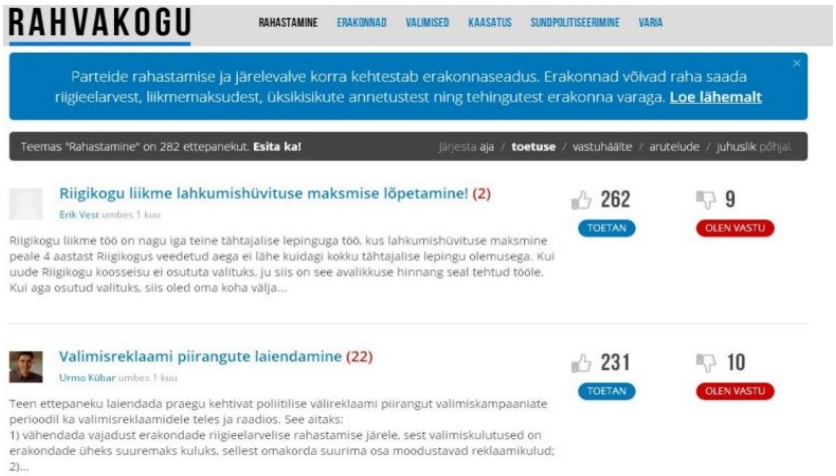
napredni *track changes* u Wordu). I Njemačka je napravila slično (točnije njemački politički aktivisti a ne država sama). Svi njemački zakoni su na GitHub-u, mogu se tzv. *forkati*[35] i raspraviti.

Postavlja se pitanje, ako postoje kolaboracijske metode za distribuirano i jeftino „verziranje" koje su usklađene s idealima demokracije, zašto se više ne koriste? Upravo to je i predmet istraživanja u ovome radu.

3.2. Primjeri elektroničke participacije

Politička participacija je područje gdje je utjecaj Web 2.0 tehnologija najviše vidljiv. Razni blogovi, e-peticije i društvene mreže pokazale su se ključnim i u nekim političkim kampanjama [94]. Uključivanje građana kao činitelja u procesu donošenja političkih odluka između dva izbora u fokusu je ovog istraživanja i navest će se par takvih uspješnih primjera.

Platforma https://rahvakogu.ee/ otvorena je za prijedloge i *crowdsourcing* s ciljem uključivanja građana Estonije u procese kreiranja zakona. Platforma je stvorena u kooperaciji između estonskih nevladinih udruga i vlade i dio je šireg procesa mijenjanja pravnog sustava.



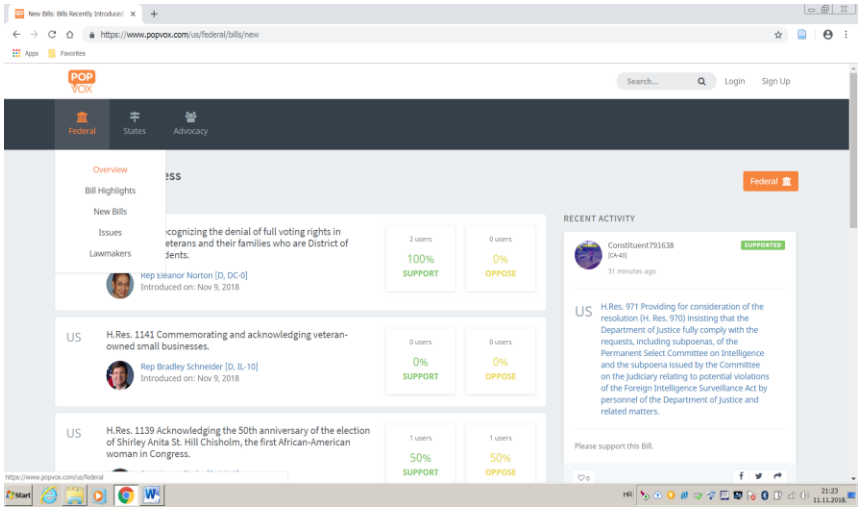
Slika 13: Platforma Rahvakogu

Izvor: [95]

Usluga https://www.popvox.com/ omogućava kontinuirano praćenje zakonodavstva u kongresu SAD-a. E-participacijska je to Web usluga koja omogućuje građanima da vide koji

[35] *Fork* je kopija nekog repozitorija koja nam omogućava slobodno eksperimentiranje s promjenama bez utjecaja na glavni projekt.

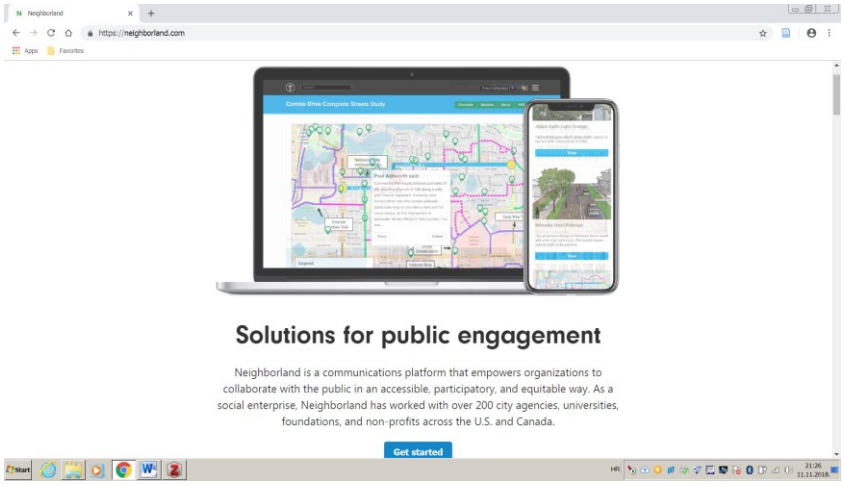
su zakoni u proceduri donošenja. Građani također mogu znati stajališta određenih lobističkih skupina i dati svoje mišljenje o materiji.



Slika 14: Web stranice usluge POPVOX

Izvor: [96]

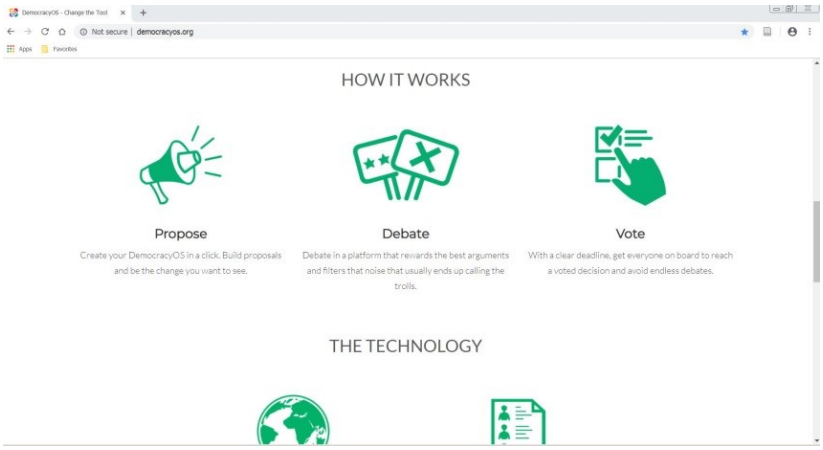
Web 2.0 e-participacijski portal https://neighborland.com/ služi kao forum za diskusiju članova lokalne zajednice. Na ovom forumu građani mogu dijeliti svoje zamisli o razvoju lokalne zajednice, pa ga tako čelnici grada Atlanta često koriste vezano uz strateško planiranje razvoja grada.



Slika 15: E-participacijski portal Neighborland

Izvor: [97]

Godine 2011. nastao je DemocracyOS, *open source* aplikacija napravljena u svrhu političke participacije građana. Dvije godine kasnije osniva se prva e-stranka u Argentini pod imenom Mrežna stranka (spa. *Partido de la Red*, eng. *Net Party*). Fokus ove stranke i dan danas je na dijeljenju vlasti s građanstvom (kohabitacija), formulaciji ideja i sakupljanju prijedloga smjera kretanja kako na lokalnom tako i na nacionalnom nivou [98].

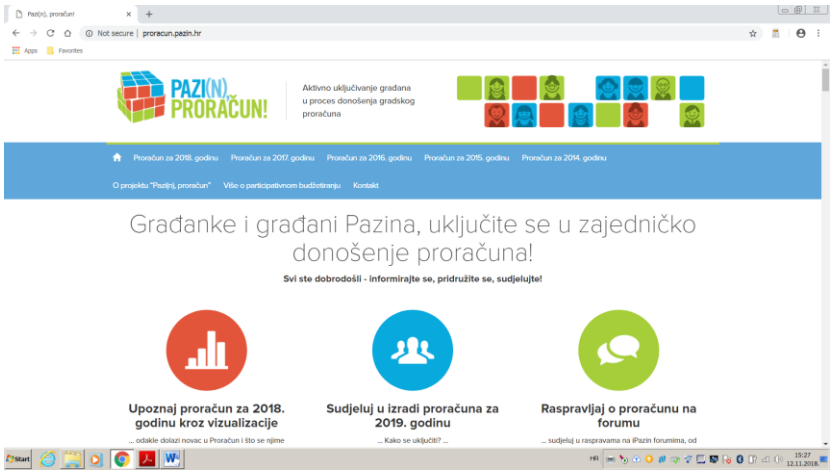


Slika 16: DemocracyOS

Izvor: [99]

Zanimljivost kod ove aplikacije jest u tome da se članovi stranke kandidati na izborima obvezuju, da ako budu izabrani, glasati prema konsenzusu postignutom u *online* debati. Radi se o principu tzv. tekuće demokracije (eng. *liquid democracy*) koja predstavlja mješavinu predstavničke i izravne demokracije.

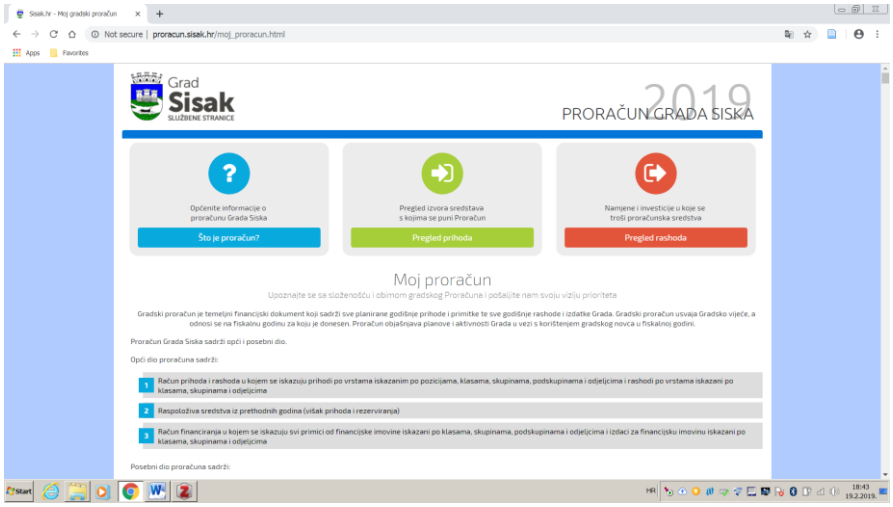
No i neki hrvatski gradovi mogu se pohvaliti s vrlo zanimljivim Web 2.0 e-participacijskim portalima. Svakako je tu potrebno spomenuti grad Pazin koji je jedan od prvih gradova u Hrvatskoj koji je uveo aplikaciju http://proracun.pazin.hr/ koja omogućuje građanima da budu dio procesa e-budžetiranja grada (tzv. *e-Participatory Budgeting*, e-PB). Radi se o uključivanju građana u proces upravljanja proračunom grada. Na taj način grad Pazin omogućio je veću demokraciju u načinu upravljanja gradom.



Slika 17: E-budžetiranje grada Pazina

Izvor: [100]

I Sisčani su napravili veliki iskorak u transparentnosti poslovanja svojeg grada. Tako građani grada Siska na stranici http://proracun.sisak.hr/ mogu aktivno participirati u izgradnji gradskog proračuna svojim prijedlozima i kritikama. Kao što gradonačelnica grada Siska kaže, cilj je „stavke proračuna koje u aplikaciji dobiju najviše izraženih sugestija i prijedloga preformulirat amandmanima na samoj sjednici Gradskog vijeća na kojoj će proračun biti usvojen u skladu s vašim željama“ [101].

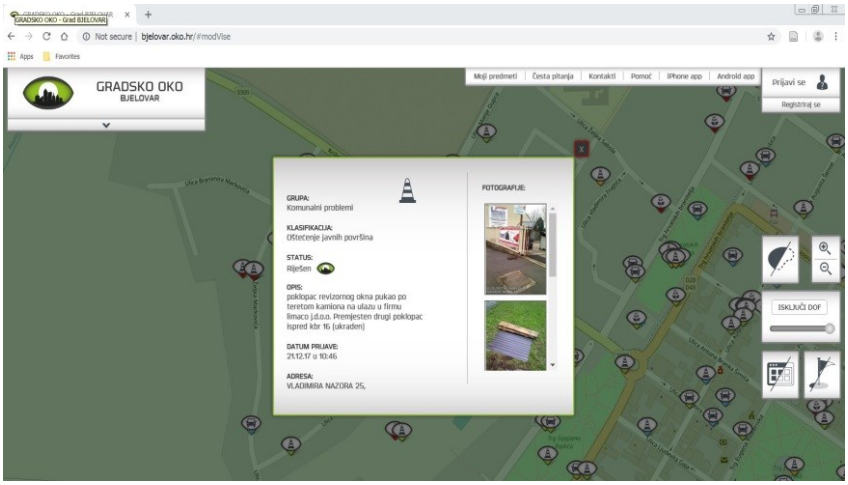


Slika 18: E-participativni proračuna grada Siska

Izvor: [101]

I grad Bjelovar na adresi http://bjelovar.oko.hr/ aktivno je uključio svoje sugrađane u rješavanje malih i velikih problema grada. Grad je izradio aplikaciju s mogućnošću

geolociranja problema koje muče pojedine građane kao i mogućeg davanja rješenja. Postoji i aplikacija za kontrolu trošenja novca iz gradskog proračuna.



Slika 19: E-participacija na stranicama grada Bjelovara

Izvor: [102]

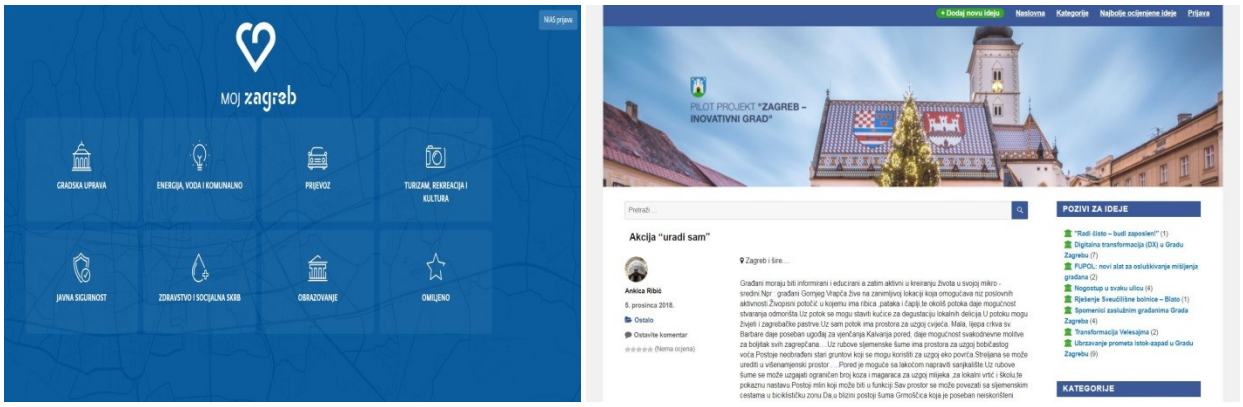
Na pitanje donese li uopće neku korist institucije koje promiču participaciju, velika brazilska studija daje jasan odgovor kad kaže da „općine koje nude participacijske programe poboljšavaju živote svojih građana“ [103].

3.3. Grad Varaždin i elektronička participacija

Informacijsko-komunikacijske tehnologije uvelike je promijenila način pružanja nekih usluga javne uprave, kako na razini državne uprave, tako i na razini lokalne samouprave. Pametni gradovi (eng. *smart cities*) novi je *buzzword* koji označava mnogo više od gradova koji se koriste modernom tehnologijom. Naime, davanje prava građanima da sudjeluju u demokratskim procesima odlučivanja o gradskim pitanjima važan je element koji čini grad pametnim [104].

Agencija „2thinknow“ već godinama provodi istraživanje i rangiranje inovativnosti gradova. Njihov inovacijski indeks gradova (eng. *Innovation Cities Indeks*) sastavljen od 162 indikatora svrstanih u 31 segment moguće je pratiti i na globalnoj razini. Tako je zadnji dostupni inovacijski indeks gradova iz 2018. godine grad Zagreb smjestio na 329, a grad Dubrovnik na 376 mjesto od 500 svjetskih gradova [105]. Za relativno dobar plasman grada Zagreba zaslužna je i aplikacija Moj Zagreb koja nudi određenu interaktivnost između

gradske uprave i građana, kao i *online* Web 2.0 e-participacijska aplikacija Zagreb – inovativan grad.



Slika 20: Usluge e-participacije grada Zagreba

Izvor: [106], [107]

Grad Varaždin slab je primjer takvog pametnog grada. Iako prema istraživanju *Doing Business* Svjetske banke za 2018. godinu grad Varaždin ima najsusretljiviju i najbržu birokraciju, u *online* komunikaciji s građanima Varaždin stoji loše. Grad na svojim službenim stranicama ima link pod nazivom „Savjetovanje s javnošću“, no razina elektroničke komunikacije s javnošću svodi se na *download* i popunjavanje Word obrazaca.

REDNI BROJ	NAZIV PRIJEDLOGA PROPISA, OPĆEG AKTA ILI DOKUMENTA ZA KOJI SE PROVODI SAVJETOVANJE	VRIJEME NJEGOVA DONOŠENJA ILI USVAJANJA	OKVIRNO VRIJEME PROVEDBE INTERNETSKOG SAVJETOVANJA	NAČINI NA KOJE SE NAMJERAVA PROVESTI SAVJETOVANJE	VRIJEME PROVEDENOG INTERNETSKOG SAVJETOVANJA
1.	**ODLUKA O IZMJENAMA I DOPUNAMA ODLUKE O STIPENDIRANJU UČENIKA I STUDENATA KOJI SE ŠKOLUJU NA SREDNJIM ŠKOLAMA I VISOKIM UČILIŠTIMA** Nacrt odluke o izmjeni i dopuni Odluke o stipendiranju učenika i studenata koji se školuju na srednjim školama i visokim učilištima Poziv javnosti na dostavu mišljenja, primjedba i prijedloga na Nacrt odluke o izmjeni i dopuni Odluke o stipendiranju učenika i studenata koji se školuju na srednjim školama i visokim učilištima Obrazac sudjelovanja u savjetovanju o Nacrtu odluke o izmjeni i dopuni Odluke o stipendiranju učenika i studenata koji se školuju na srednjim školama i visokim učilištima Obrazac - izvješće s savjetovanja - Izmjena i dopuna Odluke o stipendiranju	lipanj	svibanj	NE	14.05.2018.- 14.06.2018.

Slika 21: Usluge e-participacije grada Varaždina

Izvor: [108]

Prema Vrček i Musa, ovakvo savjetovanje s građanima predstavlja tek treću od mogućih pet faza na ljestvici informatiziranost javne uprave [109], [40] i daleko je od npr. e-participativnog budžetiranja grada Pazina gdje se građani mogu aktivno uključiti u zajedničko donošenje proračuna grada.[36]

Nakon svega navedenog, pitanje ima li potrebe da, s obzirom na razne probleme kojima se susreće, grad Varaždin napokon svoje poslovanje, prihode i rashode da građanima i cijeloj zainteresiranoj stručnoj javnosti na uvid postaje bespredmetno. Ako je grad Zaragoza već 2012. godine *crowdsourcingom* uspješno riješio problem visokih emisija CO^2 u gradu, je li problem varaždinskog smeća toliko drugačiji i poseban [110]?

3.4. Europska unija i elektronička participacija

Na sastanku Vijeća Europe održanom u Lisabonu u ožujku 2000. godine, premijeri EU15 država postavili su cilj tražeći da Europa postane najkonkurentnija ekonomija temeljena na znanju u svijetu, sposobna za održavajući ekonomski rast s više dobrih poslova i socijalne kohezije.[37] Godine 2005. obnovljeni Lisabonski ciljevi naglašavali su potrebe za daljnjim rastom i novim radnim mjestima, ali i snažnu podršku inovacijama baziranim na informacijsko-komunikacijskim tehnologijama [28],[111]. Informacijsko-komunikacijske tehnologije imaju ključnu ulogu u postizanju ciljeva Lisabonske strategije. Vidi se to i iz strategijskog okvira za Informacijsko društvo nastalog 2005. godine i nazvanog „i2010“ koji identificira tri prioriteta: završetak izgradnje jedinstvenog Europskog informacijskog prostora, jačanje inovacija i investicija u istraživanja informacijsko-komunikacijskih tehnologija i postizanje Europskog informacijskog društva koje se temelji na izgradnji modernijih javnih usluga [112].

Kao sastavni dio EU „i2010“ strategije, Europska komisija je iste 2005. godine usvojila „i2010 akcijski plan elektroničke uprave“ (eng. *i2010 eGovernment Action Plan*) s ciljem osmišljavanja konkretnih mjera, između ostalog i jačanje sudjelovanja javnosti u odlučivanju.

Što se konkretno Web-a 2.0 tiče, već 2007. godine na četvrtoj ministarskoj konferenciji u Lisabonu u organizaciji Europske komisije i Portugala kao zemlje predsjedateljice Vijećem

[36] Gradski reklamacijsko informativni centar (GRIC, http://gric.varazdin.hr/www_gric/cms.php?clsid=prijava) također ne predstavlja visok stupanj participacije. U svojoj suštini, radi se u biti o običnom e-mail prijavljivanju problema koristeći Web formu.
[37] Već je parametrima utvrđenim Bangemannovim izvještajem 1994. godine osmišljena ljestvica informatiziranosti javne uprave.

EU, jedan od ključnih fokusa bio je kako Web 2.0 tehnologije mogu pomoći u ostvarenju i2010 ciljeva.

I „Europski akcijski plan 2011 – 2015“ (eng. *European action plan 2011 – 2015*) također potiče korištenje participacijskih tehnologija u civilnom društvu [113].

Godine 2010. usvojena je i strategija „Europa 2020“ (eng. *Europe 2020*) koja se direktno nastavlja na Lisabonsku strategiju iz 2000. godine. U ovoj novoj strategiji revidirani su ciljevi iz Lisabonske strategije, ali su uvedeni i novi prioriteti i ciljevi te predstavljene nove smjernice za rast i razvoj gospodarstva temeljenog na znanju. Tako „Europa 2020“ kao krovni strateški dokument EU sadrži sedam vodećih inicijativa od kojih je osobito interesantna „Digitalna agenda za Europu“.



Slika 22: Naslovnica jedne od konferencija o Web 2.0 tehnologijama u javnom sektoru

Izvor: [114]

Unutar ove agende, postoji „Europski akcijski plan elektroničke uprave 2011-2015“ (eng. *European eGovernment Action Plan 2011-2015*) s posebno zanimljivim projektima kao što je e-SENS: digitaliziranje usluga javne uprave [115].

Godine 2016. Europska komisija donosi novi „Europski akcijski plan elektroničke uprave 2016-2020“ kojim još više potiče jačanje sudjelovanje javnosti u procesima odlučivanja.[38]

[38] Već je spomenuto da za vrijeme pisnja ovog rada (9/2018), Europska komisija upravo provodi anketu s građanima EU vezano uz promijenu ljetnog računanja vremena. Anketa se može preuzeti ovdje https://ec.europa.eu/eusurvey/runner/2018-summertime-arrangements?surveylanguage=HR

Iz svega prije navedenog, vidljivo je da EU smatra javni sektor ključnim za primjenu informacijsko-komunikacijskih tehnologija iz čisto praktičnih razloga jer javni servisi zasnovani na informacijsko-komunikacijskim tehnologijama mogu imati jak utjecaj na ekonomski rast i kvalitetu života [28]. Zato Web 2.0 postaje posebno važan alat u novim inicijativama Europske komisije. Skup popularnih Web 2.0 tehnologija kao što su to socijalne mreže (Facebook, Twitter), Wiki, blogovi i mreže za multimedijalno dijeljenje sadržaja (Youtube, Flicker) mogu promovirati otvorenu i na korisnike usmjerenu upravu.

Kako bi potaknula daljnji razvoj i ojačala svijest o potrebi uključivanja građana, Europska komisija od 2009. godine dan 7.5. obilježava kao Dan e-participacije.

Godine 2016. s ciljem ispitivanja potencijala i izazova e-participacijskih alata u Europskoj uniji Opći direktorat za unutarnje politike Parlamenta EU izdaje studiju „Potencijali i izazovi e-participacije u Europskoj uniji“ citiranu već u poglavlju „3.1. Definiranje i povijest elektroničke participacije“. Postavke ove studije slažu se s postavkama ovoga rada, odnosno u studiji je primijećeno da postoji rast nepovjerenja između građana i vlada na lokalnoj, nacionalnoj i europskoj razini što je i dovelo do smanjenja broja glasača. Kao reakciju na nezadovoljstvo građana, mnoge su zemlje EU počele proučavati potencijale informacijsko-komunikacijskih tehnologija u smislu jačanja participacijskih procesa s ciljem ponovne izgradnje povjerenja građana. Zaključna preporuka ove studije je da Europska unija treba raditi na poboljšanju postojećih e-participacijskih alata i poticati nove načine e-participacije [32].

Što se konkretnih EU participacijskih aplikacija tiče, ista studija govori o tri postojeća e-participacijska alata na EU razini: europska inicijativa građana (eng. *European Citizens' Initiative*) koja trenutačno broji 72 inicijative [116], *online* EU javne konzultacije (eng. *Online EU Public Consultations*) koje trenutačno broje 595 konzultacija kao npr. već u ovom radu spomenuto anketno ispitivanje građana EU o potrebi ukidanja ljetno/zimskog računanja vremena [117] i peticije Europskom parlamentu (eng. *Petitions to the European Parliament*) koje trenutačno broje 5 peticija [118].

Vijeće Europe također se aktivno se uključilo u promoviranje sudjelovanja građana u proces donošenja odluka.[39] Imajući u vidu kako je participacija građana u samoj srži ideje o

[39] Vijeće Europe formalno ne predstavlja instituciju EU, već se radi o najstarijoj europskoj organizaciji sa sjedištem u Strasbourgu. Bavi se nizom specifičnih društvenih tema vezanih uz suvremene izazove europskih društava.

demokraciji, dana 27.9.2017. godine Odbor ministara Vijeća Europe usvojio je „Smjernice za javno sudjelovanje u procesima donošenja odluka za 47 članica Vijeća Europe“, stvarajući time čvrsti temelj za uključivanje građana u procese donošenja odluka [119].

Prema Musa i Dobrić Jambrović, Vijeće Europe u svojim je aktima i dokumentima definiralo načelo participacije kao ključno demokratsko načelo na lokalnoj razini te poticalo njegovo ostvarivanje. Jedan od ključnih dokumenata pri tome je „Protokol o pravu na sudjelovanje u poslovima lokalne vlasti“ iz 2009. godine. Godine 2017. Odbor ministara kao jedna od ključnih institucija Vijeća Europe, donosi „Smjernice za sudjelovanje javnosti u političkom odlučivanju“ gdje građansku participaciju definira kao uključivanje pojedinaca, nevladinih organizacija i civilnog društva u proces donošenja odluka javnih vlasti [69].

Što se Hrvatske tiče, „Kodeks savjetovanja sa zainteresiranom javnošću u postupcima donošenja zakona, drugih propisa i akata“ iz studenog 2009. godine (NN 140/2009) eksplicite spominje potrebu suradnje, dijaloga i partnerstva javnih i državnih institucija s građanima i organizacijama civilnog društva, pruža smjernice odnosno „utvrđuje opća načela, standarde i mjere za savjetovanje s zainteresiranom javnošću u postupcima donošenja zakona, drugih propisa i akata državnih tijela kojima se uređuju pitanja i zauzimaju stavovi od interesa građana“ [120].

Nadalje, kao još jedan korak prema otvorenoj vlasti, 2013. godine Hrvatski sabor donosi „Zakon o pravu na pristup informacijama“ (NN 25/2013). Prema stavku 1. članka 11. ovog zakona tijela javne vlasti nadležna za izradu nacrta zakona i podzakonskih akata dužna su radi informiranja javnosti na svojim Internetskim stranicama (dakle, *online*) objaviti uz godišnji plan normativnih aktivnosti i plan savjetovanja o nacrtima zakona i drugih propisa koji se odnose na njihovo područje rada. Nacrte zakona i drugih propisa kojima se provodi javno savjetovanje s zainteresiranom javnošću, tijela javne vlasti prema ovom zakonu dužna su objaviti na Internetskoj stranici (dakle, također *online*) u trajanju od 30 dana. Nakon provedenog savjetovanja, tijela javne vlasti također su dužna o prihvaćenim i neprihvaćenim primjedbama obavijestiti zainteresiranu javnost putem svoje Internetske stranice i izvješće dostaviti Vladi Republike Hrvatske [121].

Sam sustav e-Savjetovanja uspostavljen je u travnju 2015. godine i njime je zainteresiranoj javnosti olakšano uključivanje u procese javnih savjetovanja. Prema Musa, „sudjelovanje javnosti u postupku donošenja propisa i općih akata te strateških i planskih dokumenata kroz proces savjetovanja s javnošću smatra se jednim od ključnih instrumenata za ostvarivanje

načela participacije, otvorenosti i transparentnosti kao stožernih elemenata dobrog upravljanja europskog upravnog prostora te općenito participativnog upravljanja“ [122].

U srpnju 2015. godine, tri mjeseca nakon uspostavljanja sustava e-Savjetovanja, Hrvatski sabor donosi izmjene i dopune „Zakona o pravu na pristup informacijama“. Tako članak 11. „Zakona o izmjenama i dopunama Zakona o pravu na pristup informacijama“ (NN 85/2015) propisuje potrebu da „tijela državne uprave, druga državna tijela, jedinice lokalne i područne (regionalne) samouprave i pravne osobe s javnim ovlastima dužne su provoditi savjetovanje s javnošću pri donošenju zakona i podzakonskih propisa, a pri donošenju općih akata odnosno drugih strateških ili planskih dokumenta kad se njima utječe na interese građana i pravnih osoba“. Prema ovim izmjenama, savjetovanje s javnošću tijela državne uprave sada provode preko središnjeg državnog Internetskog portala za savjetovanja s javnošću (sustav e-Savjetovanja), a druga državna tijela, jedinice lokalne i područne (regionalne) samouprave i pravne osobe s javnim ovlastima preko svoje Internetske stranice ili također korištenjem središnjeg državnog Internetskog portala za savjetovanje s javnošću [123].

I „Strategija suzbijanja korupcije za razdoblje od 2015. do 2020. godine“ iz veljače 2015. godine spominje da je „Zakonom o pravu na pristup informacijama“ osiguran temelj za daljnji napredak u području savjetovanja s zainteresiranom javnošću [124]. U zadnjem „Akcijskom planu za 2019. i 2020. godinu uz Strategiju suzbijanja korupcije za razdoblje od 2015. do 2020. godine“ iz travnja 2019. godine spominje se potreba daljnjeg unaprjeđenja provedbe savjetovanja sa zainteresiranom javnošću u smislu provođenja edukacija o korištenju sustava e-Savjetovanja.

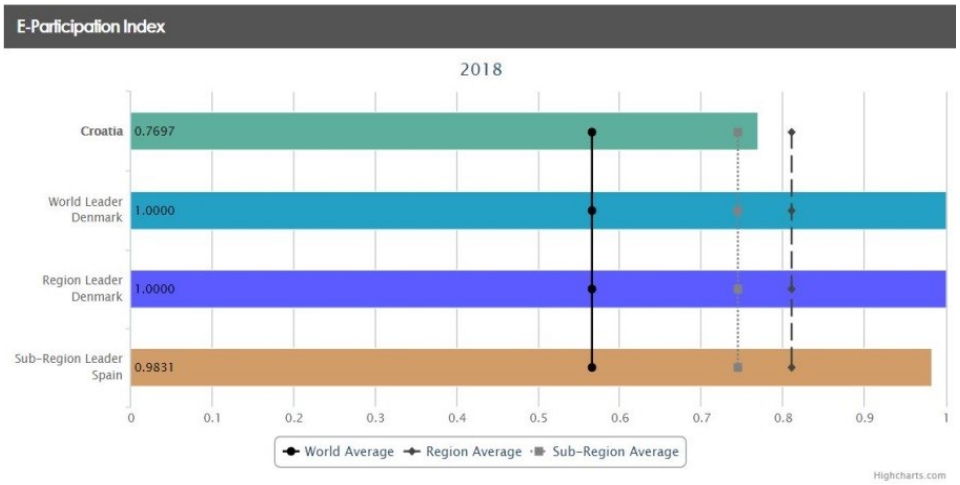
I „Zakon o procjeni učinaka propisa“ iz 2017. godine „uređuje postupak procjene učinaka propisa, način planiranja zakonodavnih aktivnosti, tijela nadležna za postupak procjene učinaka propisa, način savjetovanja s javnošću u tom postupku te druga pitanja s tim u vezi“ [125].

U „Akcijskom planu za provedbu inicijative Partnerstvo za otvorenu vlast[40] u razdoblju do 2020. godine“ usvojenom od strane Vlade Republike Hrvatske u prosincu 2018. godine, spominje se potreba provođenja Mjere 12. Dodatno unaprjeđenje provedbe savjetovanja s

[40] „Partnerstvo za otvorenu vlast je multilateralna inicijativa čiji je cilj osigurati konkretan napredak na području transparentnosti i otvorenosti rada tijela javne vlasti, uključivanja i osnaživanja građana i civilnoga društva, borbe protiv korupcije te korištenja novih tehnologija za poboljšanje kvalitete usluga koje javna uprava pruža građanima“ [126]. Inicijativu vodi Upravni odbor, a od 2014. godine članica Upravnog odbora je i Republika Hrvatska.

javnošću i u skladu s tom mjerom potreba za „dodatno informirati i potaknuti građane da se uključe u praćenje i komentiranje dokumenata koji se objavljuju na e-Savjetovanjima“ [127].

Što se tiče strategije e-Hrvatska kao jednog od strateških dokumenata koji su preduvjet za korištenje strukturnih fondova Europske unije, niti zadnja „Strategija e-Hrvatska 2020“ Ministarstva uprave RH iz 2017. godine ne spominje niti u jednom svom dijelu e-participaciju eksplicite, kao niti Web 2.0 usluge općenito pa se može zaključiti da ne postoji strateško promišljanje pristupu razvoja javnih e-participacijskih usluga [128].[41] Da je tome tako pokazuju i statistički podaci pa je tako prema najnovijim UN-ovim statistikama za 2018. godinu Hrvatska prema e-participacijskom indeksu[42] tek 58 od 194 zemalja obuhvaćenih istraživanjem i to daleko ispod regionalnog lidera Danske, što govori u prilog činjenici da je uključenost građana u e-participacijske aktivnosti na niskoj razini.



Grafikon 9: E-participacijski indeks Hrvatske u odnosu na regionalnog i svjetskog lidera Dansku

Izvor: [129]

[41] Opisano je postojanje usluge eSavjetovanja, a korištenje Web 2.0 usluga nema pod poglavljem 6.1. Strateški ciljevi i prioriteti.

[42] UN-ov indeks e-participacije (eng. *E-Participation Indeks*, EPI,) mjeri korištenje online usluga i to samo za pristup informacijama uprave (eng. *e-information sharing*), interakciju s dionicima (eng. *e-consultation*) i uključivanje u procese odlučivanja (eng. *e-decision making*).

Prema Vrček i Musa, važno je ovdje ipak napomenuti da je od 2014. godine i tadašnjeg 97. mjesta Hrvatska znatno napredovala. Najveći pozitivni skok u broju bodova dogodio se upravo u području e-konzultacija, što je zasigurno uzrokovano uvođenjem središnjeg državnog Internetskog portala za savjetovanje s javnošću (odnosno e-Savjetovanja) 2015. godine [40].

4. TEORIJSKI MODELI PRIHVAĆANJA TEHNOLOGIJA - POČECI, RAZVOJ I MOGUĆA BUDUĆA KRETANJA

"Komunikacijski alati ne postaju društveno interesantni
sve dok ne postanu tehnološki dosadni."
Clay Shirky, američki pisac

Elektroničke usluge državne uprave bazirane na Internetu kao posrednom mediju sve su više dostupne potrošačima (građanima)[43] što posredno stvara potrebu za istraživanjima o čimbenicima koji su povezani s prihvaćanjem istih. Naime, još uvijek je slabo poznato što utječe na potencijalno prihvaćanje ovih usluga od strane građana. No što uopće znači prihvaćanje neke tehnologije? Kupnja određenog proizvoda uz pomoć za tu svrhu razvijene elektroničke usluge ne predstavlja prihvaćanje te elektroničke usluge. Prihvaćanje neke elektroničke usluge definira se kao kompleksnija, dugoročnija veza između korisnika i ponuđača te usluge [131]. Istraživanje prihvaćanja tehnologije (pa tako i tehnologija javnih usluga e-participacije) moguće je provesti uz pomoć više različitih modela.

Godine 2003. Venkatesh i dr. kreirali su Objedinjenu teoriju prihvaćanja i upotrebe tehnologije (eng. *Unified Theory of Acceptance and Use of Technology*, UTAUT) na temelju osam prethodno razvijenih modela prihvaćanja tehnologije. Ovo poglavlje prezentira, prema kronološkom vremenu nastanka, tih osam teorijskih modela razvijenih u različitim disciplinama i korištenih za predviđanje, objašnjavanje i razumijevanje prihvaćanja tehnologija od strane pojedinaca. Ovo je poglavlje temelj za kasniji razvoj modela istraživanja a sve u skladu s prvim ciljem istraživanja navedenim u poglavlju „1.3. Ciljevi istraživanja i istraživačko pitanje". Veći je naglasak stavljen na teorije koje će biti korištene u konceptualnom modelu istraživanja.

[43] Ovaj rad temelji se na istraživanju prihvaćanja IT od strane pojedinaca. Kod istraživanja prihvaćanja IKT od strane organizacija postoje drugi načini razmišljanja. Tako Taylor i Todd navode makroeknomski pristup i pristup koji ispituje odnos između IKT troška i uspješnosti organizacije [130].

Tablica 1: Kronološki poredak nastanka modela prihvaćanja tehnologije

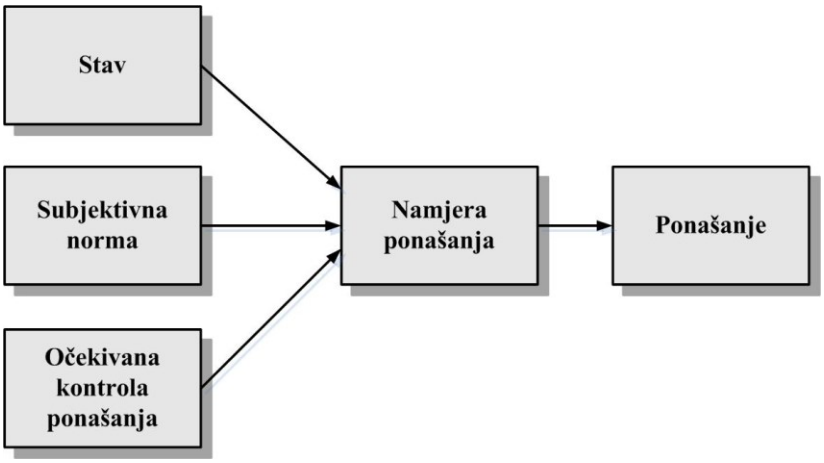
R. br.	Godina	Autori	Teorija
1.	1962.	E.M. Rogers	Teorija difuzije inovacija (eng. *Diffusion of Innovation Theory*, DOI)
2.	1975.	M. Fishbein, I. Ajzen	Teorija razložne akcije (eng. *Theory of Reasoned Action*, TRA)
3.	1985.	I. Ajzen.	Teorija planiranog ponašanja (eng. *Theory of Planned Behavior*, TPB)
4.	1986.	F.D. Davis	Model prihvaćanja tehnologije (eng. *Technology Acceptance Model*, TAM)
5.	1986.	A. Bandura	Socijalno kognitivna teorija, društveno spoznajna teorija (eng. Social Cognitive Theory, SCT)
6.	1991.	R. L. Thompson	Model korištenja PC-a (eng. *Model of PC Utilization*, MPCU)
7.	1995.	S. Taylor, P. A. Todd	Kombinirani model prihvaćanja tehnologije i teorije planiranog ponašanja (eng. *Combined Technology Acceptance Model and Theory of Planned Behavior*, C-TAM-TPB)
8.	1997.	R.J. Vallerand	Motivacijski model (eng. *Motivation Model*, MM)
9.	2003.	V. Venkatesh, M. Morris, G.B. Davis, F.D. Davis	Objedinjena teorija prihvaćanja i upotrebe tehnologije (eng. *Unified Theory of Acceptance and Use of Technology*, UTAUT)

Teorija difuzije inovacija (eng. *Diffusion of Information*, DOI) najstarija je teorija razvijena još 1962. godine. Rogers difuzijom naziva proces kojim se uz pomoć određenih kanala inovacija prenosi između članova neke društvene zajednice. Zadaća je ove teorije objasniti kako tijekom vremena neka ideja ili proizvod dobiva na važnosti i širi se unutar određene populacije. Krajnji rezultat ovakve difuzije jest prihvaćanje ideje (ponašanja, proizvoda) od strane građana. Model difuzije inovacija u sebi uključuje slijedeće varijable: relativna prednost, kompleksnost, kompatibilnost, *triability* (teško prevodljiv pojam, radi se o stupnju do kojeg se inovacija može testirati prije konačnog prihvaćanja) i *observability* (također teško prevodljiv pojam, radi se o stupnju do kojeg inovacija osigurava opipljive rezultate) [132]

[133]. Iako teorija difuzije informacija osigurava dobro definirane koncepte primjenjive na istraživanje prihvaćanja tehnologije, ne uzima u obzir stav korisnika na konačno na prihvaćanje/odbacivanje neke tehnologije [134].

Slijedila je **Teorija razložne akcije** (eng. *Theory of reasoned action*, TRA) osmišljena 1975. godine od strane Fishbeina i Ajzena i kao takva predstavlja korijen mnogim drugim teorijama. Tri su komponente od kojih se sastoji ova teorija: a) namjera ponašanja (eng. *behavioral intention*, BI), b) stav (eng. *attitude*, A) i c) subjektivna norma (eng. *subjective norm*, SN). Formula koju promovira ova teorija glasila bi: namjera ponašanja = stav + subjektivna norma. Sam Ajzen definira subjektivnu normu kao "očekivani društveni pritisak za obavljanje odnosno ne obavljanje određene radnje“ [135]. Odnosno, TRA opisuje da namjera ponašanja neke osobe ovisi o njezinom stavu prema ponašanju i subjektivnoj normi. Ova se teorija još uvijek često koristi za predviđanje ponašanja kupaca [136] [137]. Najveći nedostatak ove teorije očituje se u činjenici da ne poznaje pojam iracionalnih odluka, odnosno teorija uvijek pretpostavlja postojanje kontroliranog ponašanja [134].

Teorija planiranog ponašanja (eng. *Theory of planned behaviour*, TPB) jedna je od najutjecajnijih teorija u proučavanju ljudskog ponašanja. Predstavlja reviziju teorije razložne akcije koja nastoji ukloniti njezine uočene nedostatke i to na način da se dodaje još jedna prediktorska varijabla, očekivana kontrola ponašanja. Reviziju je izvršio 1985. godine sam Ajzen, jedan od tvoraca Teorije razložne akcije [138]. Teorija planiranog ponašanja često se koristi za objašnjavanje prihvaćanja različitih informacijskih sustava i aplikacija od strane krajnjih korisnika. TPB opisije da je stvarno ponašanje rezultat intencije (namjere) ponašanja, a da je intencija (namjera) ponašanja pod utjecajem tri nezavisne determinante: a) stava prema ponašanju, b) subjektivne norme i c) očekivane kontrole ponašanja [139] [54].



Slika 23: Konstrukti Teorije planiranog ponašanja

Izvor: [139]

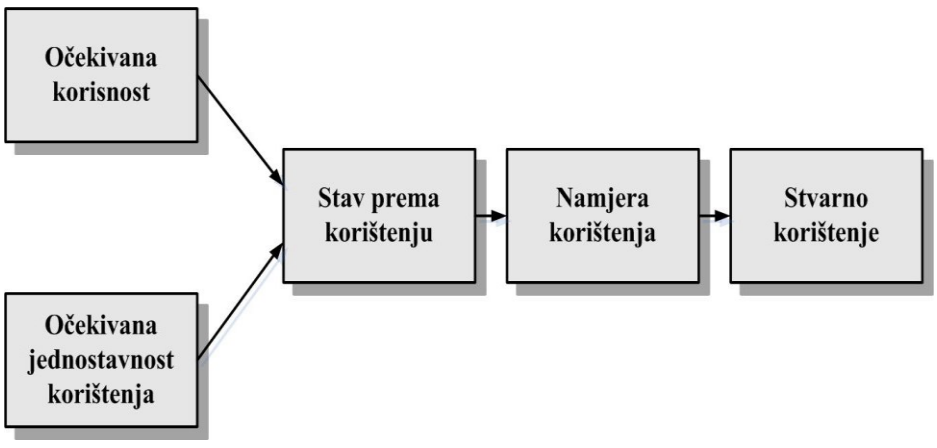
Odnosno, prema TPB, individualna, stvarna upotreba specifične IT usluge ili servisa odraz je utjecaja tri neovisne varijable koje konceptualno određuju intenciju ponašanja pojedinca. To su:

- stavovi prema specifičnom ponašanju (eng. *attitudes*) koji su formirani od osobnih vjerovanja i prosudbi o očekivanjima izlaznih rezultata upotrebe IT usluge ili servisa[44] (u ovom su slučaju to stavovi prema namjeri korištenja javnih usluga e-participacije),
- subjektivne norme formirane od osobnih vjerovanja koliko je bitno očekivanje okoline da pojedinac upotrebljava određene IT servise ili usluge, odnosno faktor je to koji se odnosi na percipirani društveni pritisak vezan za obavljanje određenog zadatka i
- očekivana kontrola ponašanja formirana od osobnih vjerovanja o granicama vlastitih mogućnosti aktualne uporabe IT usluge ili servisa[45]. Očekivana kontrola ponašanja je definirana kao težina (jednostavno ili kompliciranо) očekivanog izvođenja [140].

I Teorija planiranog ponašanja podložna je kritikama, odnosno posjeduje specifična ograničenja. Eagli i Chaiken 1993. godine iznose kritiku Teorije planiranog ponašanja navodeći svoje spoznaje da navika, očekivana moralna obveza kao i ekonomski faktori također utječu na namjeru ponašanja što su varijable koje nisu uključene u TPB [141].

[44] Odnosno, stavovi pojedinca prema ponašanju koji su pod izravnim utjecajem uvjerenja osobe o posljedicama njezinog ponašanja i prosudbe o posljedicama ponašanja.
[45] Odnosno, precipirana kontrola ponašanja predstavlja percepciju pojedninca o tome koliko se lako ili teško upustiti u određeno ponašanje.

Prihvaćanje tehnologije od strane korisnika važno je područje istraživanja u zadnjih dva desetljeća. Iako su tijekom vremena predloženi mnogi modeli, **Model prihvaćanja tehnologije** (eng. *Technology acceptance model*, TAM) privukao je najviše pažnje, posebno ljudi koji se bave informacijskom tehnologijom. Porastom potreba za tehnologijom u 1970-tim godinama i porastom slabog prihvaćanja te iste tehnologije u organizacijama, predviđanje korištenja sustava postalo je značajno područje istraživanja. TAM je razvijen 80-tih godina jer radnici nisu koristili IT koja im je bila dostupna (originalno istraživanje od strane Davisa ispitivalo je korištenje elektroničke pošte i editora datoteka od strane zaposlenih u IBM Kanada) [142]. 1985. godine Davis predlaže TAM u svom doktorskom radu na MIT-u [143]. Davis opisuje da je korištenje nekog sustava odgovor (odaziv) koji može biti objašnjen, odnosno može ga se predvidjeti motivacijom korisnika na koju pak direktno utječu eksterni stimulansi (podražaji) koji predstavljaju stvarne karakteristike i mogućnosti sustava [144]. TAM se također koristi kod istraživanja percepcije i prihvaćanja *online* usluga i kao model već je dokazano sredstvo istraživanja prihvaćanja usluga elektroničkog trgovanja. Model objašnjava intenciju (namjeru) nekog pojedinca za stvarnim korištenjem neke tehnologije ili usluge. Model prihvaćanja tehnologije opisuje da stvarno ponašanje (korištenje, uporaba) ovisi o intenciji ponašanja koja je pak rezultat stava prema korištenju. TAM pretpostavlja da su nečije namjere prema korištenju neke tehnologije determinirane kroz dva vjerovanja: očekivanom korisnošću i očekivanom jednostavnošću upotrebe te iste tehnologije. Time stavlja veći naglasak na ulogu tehnologije kod objašnjavanja namjere korištenja [54].



Slika 24: Konstrukti Modela prihvaćanja tehnologije

Izvor: [143]

- Očekivana korisnost je konstrukt koji se definira kao „stupanj do kojeg osoba vjeruje da koristeći određeni sustav može povećati svoju učinkovitost obavljanja posla“. I mnoga prethodna istraživanja pokazala su da građani tvore pozitivne stavove prema tehnologiji ako tu istu tehnologiju percipiraju korisnom [54], [145].
- Očekivana jednostavnost upotrebe objašnjava razinu osobnog vjerovanja da će upotreba neke nove tehnologije biti bez ulaganja dodatnih napora (tako npr. mnoge studije pokazuju da već kompleksnost korisničkog sučelja značajno smanjuje prihvaćanje sustava) [54]. Vjeruje se da će građani imati pozitivne stavove prema e-participaciji ako korištenje sustavima e-participacije neće zahtijevati veliki dodatni napor.

Sumarno, prema TAM-u, što je tehnologija jednostavnija za korištenje i što je veća očekivana korisnost neke tehnologije, pozitivniji je stav korisnika prema toj tehnologiji i u skladu s time, povećava se i korištenje te tehnologije [130].

Originalni TAM baziran je na Aizenovom TRA modelu i nije uključivao varijablu Subjektivne norme. Model prihvaćanja tehnologije 2 (eng. *Technology Acceptance Model2*, TAM2) predstavlja proširenje originalnog TAM-a dodajući nove determinante Očekivane korisnosti i Namjere korištenja [9].

Nad TAM-om, kako bi zadovoljio potrebe specifičnog konteksta, često je potrebno napraviti reviziju u smislu dodavanja dodatnih varijabla unutar specifičnog konteksta. U kontekstu e-participacijskih tehnologija, društvena perspektiva i povjerenje smatraju se opravdanim dodatnim varijablama. Naime, ponašanje pojedinaca, kako to tumače socijalne teorije, snažno je uvjetovano i društvenim utjecajima [18]. Kao što je to ustanovljeno od više istraživača informacijskih sustava, TAM nije kompletan zbog jedne stvari. Malhotra i Galletta u članku “Proširenje modela prihvaćanja tehnologije s društvenim utjecajem: teorijska osnova i empirijska validacija“ pokazali su da je velik nedostatak što TAM ne poznaje društveni utjecaj (eng. *social influence*) kao čimbenik kod prihvaćanja novih informacijskih sustava [146].[46]

Socijalno kognitivna teorija (eng. *Social Cognitive Theory*, SCT), u nekim prijevodima poznata i kao društveno spoznajna teorija, proizašla je iz teorije socijalnog učenja. Naime,

[46] Zato se u istraživanju koristili i TPB koja to sa svojim subjektivnim normama pokriva.

izraz društveno spoznajna teorija prvi su u svom radu koristili Miller i Dollard, govoreći o tzv. učećoj teoriji (eng. *learning theory*) koja polazi od pretpostavke da ljudi uče na način da promatraju druge ljude što i kako rade. Tijekom vremena mnogi su dali svoj doprinos poboljšanju teorije socijalnog učenja. Posebno se ističe Albert Bandura koji je u teoriju uveo mnogo noviteta i preimenovao ju u Socijalno kognitivnu teoriju. Socijalno kognitivna teorija bazira se na pretpostavci da se učenje odvija u socijalnom kontekstu i da je velik postotak naučenog dobiven kroz promatranje, odnosno oponašanje. Godine 1986. Bandura je izradio model koji povezuje tri glavna konstrukta: osobne činitelje, ponašanje i činitelje okoline koji međusobno djeluju jedan na drugoga [147]. Kao jedno od važnijih ispitivanja na pretpostavkama društveno spoznajne teorije navodi se istraživanje od Compeau i Higgins kojim je istraživana predikcija upotrebe računala i informatičke tehnologije među općom populacijom [148].

Godine 1991. Thompson predlaže **Model korišenja PC-a** (eng. *Model of PC Utilization*, MPCU). U svojem modelu Thompson smatra da će korištenje osobnog računala biti pod utjecajem individualnih osjećaja prema korištenju osobnog računala, socijalnim normama, navikama, očekivanim posljedicama i olakšavajućim uvjetima [149], [150].

Kombinirani model prihvaćanja tehnologije i teorije planiranog ponašanja (eng. *Combined Technology Acceptance Model and Theory of Planned Behavior*, C-TAM-TPB) hibridni je model kojeg su 1995. godine uveli Taylor i Todd na način da su povezali konstrukt očekivana korisnost iz TAM modela te stav spram ponašanja, subjektivne norme i očekivana kontrola ponašanja iz TPB u cilju predikcije namjere upotrebe [130]. Naime, razna su prethodna istraživanja potvrdile društveni utjecaj i činitelje kontrole ponašanja kao bitne činitelje za prihvaćanje IT servisa i usluga [151], [152].

Motivacijski model (eng. *Motivation Model*, MM) predlaže da se motivacija promatra s više dimenzija. Tako postoji osobni stupanj, stupanj okruženja i situacijski stupanj. Korištenjem ove teorije na primjeru namjere korištenja računala na radnom mjestu dalo je rezultate koji kažu da korištenje ovisi o percepciji korisnosti računala u smislu povećanja radnih performansi i stupnju ugode prilikom korištenja računala [150].

Opća teorija prihvaćanja i korištenja tehnologijom (eng. *Unified Theory of Acceptance and Use of Technology*, UTAUT) nastala je 2003. godine kao rezultat istraživanja tijekom kojeg su Venkatesh i dr. na osnovi podataka prikupljenih od četiri organizacije uspoređivali metrijske kvalitete osam prethodno opisanih relevantnih modela te njihovom analizom došli

do spoznaje da je s ciljem objašnjenja i predikcije prihvaćanja novih tehnoloških servisa moguće razlikovati pet latentnih čimbenika: očekivanje učinka upotrebe tehnologije (izvođenja), očekivani napor, društveni utjecaj, osobni stav i intencija upotrebe, te četiri činitelja osobne različitosti (dob, spol, iskustvo i voluntarizam korištenja, tzv. moderatorske varijable) [153]. Model je stvoren s razlogom da prikaže najkompletniju sliku procesa prihvaćanja tehnologije i to bolje nego su osam prethodnih modela uspijevali. Godine 2003. Venkatesh je prezentirao rezultate šest mjesečnog istraživanja u kojima ističe da osam prethodno navedenih modela objašnjava 17 do 53 % varijance vezano uz namjeru korištenja informacijske tehnologije, dok UTAUT ima R^2 vrijednost od 69 % [154], [155].

Godine 2012. u recentnom proširenju opće teorije prihvaćanja i korištenja tehnologijom koja se u literaturi spominje pod akronimom UTAUT2, pretpostavljeno je da na namjeru ponašanja 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. 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 [156], [153].

Važno je i istaknuti kako će se u ovom istraživanju namjera ponašanja koristi kao indikator stvarnog korištenja javnih usluga e-participacije. Naime, relacija između namjere korištenja i stvarnog korištenja toliko je dobro potvrđena tako da je nema više smisla istraživati [157].

5. KONCEPTUALNI OKVIR ISTRAŽIVANJA

„Znanosti ne pokušavaju objasniti, one jedva da pokušavaju tumačiti,
one uglavnom stvaraju modele“.
John Von Neumann, mađarski matematičar

U ovom radu istraživanje se dijeli na teorijski i empirijski dio pri čemu je empirijski dio podijeljen na predistraživanje i istraživanje. U teorijskom dijelu istraživanja koristit će se relevantna recentna literatura za prikupljanje podataka o modelima i teoriji prihvaćanja tehnologija kao i čimbenicima koji bi mogli biti povezani s prihvaćanjem usluga e-participacije od strane građana. Dok teorijski okvir pruža širu sliku i baziran je na već postojećoj teoriji koja je povezana s područjem istraživanja, konceptualni okvir (zvan još i istraživačka paradigma), kao sastavni dio teorijskog okvira, počiva isključivo na ideji istraživača i opisuje veze između glavnih koncepata istraživanja [158]. Konceptualni okvir između ostalog opisuje ključne varijable ili konstrukte koje će se istraživati, a veze između njih moguće je prikazati u narativnoj ili grafičkoj formi. Dijagrami u konceptualnom okviru kreirani su za jasno definiranje konstrukata ili varijabli istraživačkog područja i njihove su veze označene strelicama. Unutar konceptualnog okvira istraživači mogu koristiti postojeće teorije, ali trebaju ih modificirati kako bi pristajali kontekstu istraživanja. Također, cilj je objasniti logiku oblikovanja konceptualnog modela i opravdanost varijabli [159]. U empirijskom se dijelu istraživanja, pojave i činjenice spoznaju vlastitim iskustvom, odnosno provođenjem istraživanja.

5.1. Istraživačka filozofija i korištene vrste istraživanja

Postoji više paradigmi i dihotomija na kojima se temelje kako istraživanja u području informacijskih sustava tako i općenito istraživanja u društvenim znanostima [160]. No ipak dvije istraživačke filozofije dominiraju suvremenim društvenim istraživanjima: pozitivizam i interpretativna filozofija [161]. Tako pozitivizam pretpostavlja korištenje više istraživačkih metoda kao što su to ankete ili razni eksperimenti i traži veće količine podataka a samim time i određene statističke metode za obradu istih. S druge strane, interpretativizam se bazira na studijama slučajeva i etnografskim studijama [160]. Pristup usvojen u ovom istraživanju jest primarno pozitivistički deduktivan pristup.

Što se tiče metodološkog pristupa, istraživanje je provedeno kombiniranom kvantitativno – kvalitativnom metodologijom [162].

U odnosu na klasifikaciju istraživanja prema prirodi istraživanja, odnosno s obzirom na vrstu podataka koji se proučavaju, dijelimo ih na teorijska i empirijska istraživanja [161]. I jedna i druga vrsta korištene su tijekom izrade ovog rada.

5.2. Pitanje digitalnog jaza

Ako je e-participacija instrument za poboljšanje komunikacije između javnosti i države, kao i davanje legitimiteta političkim odlukama, ne bi li svi potencijalni učesnici (građani) trebali imati iste mogućnosti pristupa tim instrumentima [163]?

Pojam digitalni jaz prvi se puta spominje 1999. godine u srpanjskom izvješću Nacionalne uprave za telekomunikacije i informacije američkog Ministarstva trgovine (eng. *US Department of Commerce's National Telecommunications and Information Administration*) [164]. Široko prihvaćena definicija digitalnog jaza jeste ona Organizacije za ekonomsku suradnju i razvoj (eng. *Organisation for Economic Cooperation and Development,* OECD) u kojoj se kaže da je digitalni jaz „jaz između pojedinca, kućanstava i zemljopisnih područja vezano uz pristup informacijsko-komunikacijskim tehnologijama i Internetu [165]. Iako postoje i druge definicije digitalnog jaza, digitalni je jaz i u ovom radu pojam koji označava razliku između građana koji imaju pristup modernim informacijsko-komunikacijskim tehnologijama i onima koji to nemaju. Danas se pod modernim tehnologijama primarno misli na Internet [166], [167].

Broj Internet korisnika na svjetskoj razini bilježi dramatičan rast i prema najnovijim statistikama iznosi 3,408 milijarde korisnika što je po nekim izračunima 53 % svjetske populacije. Rast je ubrzan u svim regijama pa tako danas i Subsaharska Afrika bilježi 468 milijuna korisnika, a posebno se ističe Južna Afrika s penetracijom Interneta od 51,92 %.[47] Od europskih zemalja lider je Norveška s penetracijom Interneta od 96,81 % [168].

U ranije spomenutom inicijalnom izvješću Uprave za nacionalne telekomunikacije i informacijsku upravu američkog Ministarstva trgovine identificiran tek mali broj korisnika Interneta u Sjedinjenim Američkom Državama, posebno u afroameričkoj i latinoameričkoj zajednici. No novija istraživanja ove iste Uprave ukazuju na to da se u Americi ovaj jaz u 2019. godini znatno smanjio pa tako trenutno blizu 80 % stanovništva u Americi koriste Internet, dok je taj broj u latinoameričkoj zajednici 72 % [169], [170].

[47] Penetracija Interneta predstavlja postotak građana neke zemlje koje koriste Internet.

Stanje mobilnog širokopojasnog (eng. *mobile broadband)* pristupa Internetu još je bolje. Tako je npr. od prosinca 2017. godine u 36 zemalja članica OECD-a broj mobilnih *broadband* pretplatnika veći i od broja stanovnika [171].

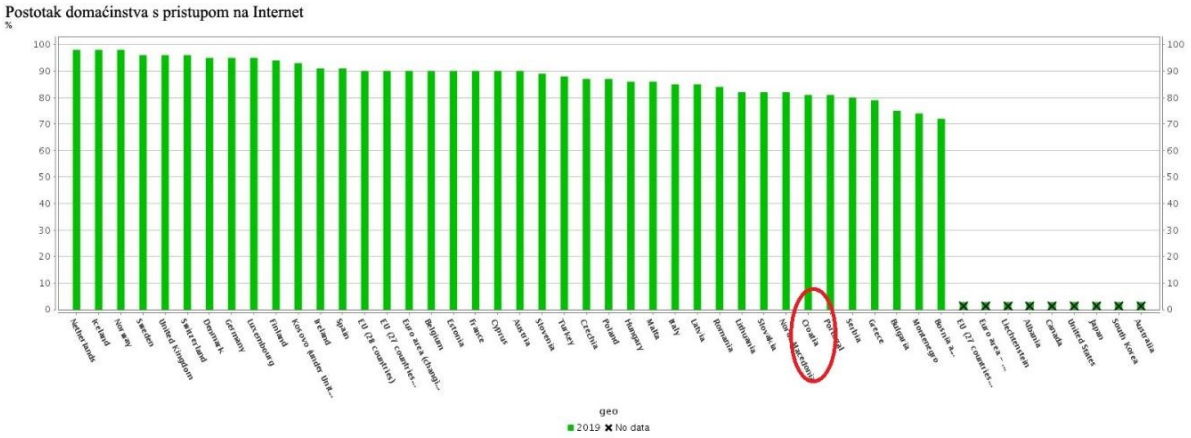
Kakvo je stanje u Hrvatskoj?

Činjenica je da je 2019. godine prema Eurostatu 81 % kućanstava u Hrvatskoj imalo pristup Internetu što je vidljivo i na Grafikonu 10. Čak i kad gledamo broj osoba korisnika Interneta brojke su visoke. Prema Europskoj Komisiji, u 2019. godini oko 90 % građana Hrvatske koristilo je barem jednom Internet unutar tri mjeseca (Prosjek EU je 93 %, dok je Švedska prva na ljestvici s 99,9 % građana korisnika Interneta) [172]. I prema priopćenju Državnog zavoda za statistiku Republike Hrvatske iz prosinca 2018. godine, uporaba Interneta kod pojedinaca između 16 i 44 godina iznosi više od 90 % (čak 100 % u dobnoj skupini između 16 – 24 godine) [173].

Uzmemo li još u obzir vjerojatna buduća kretanja, odnosno da je prema ICT Businessu u Hrvatskoj širokopojasni Internet dostupan za 94,2 % kućanstava [174][48], kao i da je od 1.1.2015.godine Hrvatska postala treća zemlja na svijetu gdje je brzi Internet postao zakonsko pravo svakog građana[49] [176], smatra se opravdanim da se danas, 2019. godine, u istraživanju ne razmatra postojanje digitalnog jaza. Odnosno, ako i u manjem postotku postoji, digitalni jaz toliko se brzo smanjuje da nije značajan za dugoročnija razmatranja.

Naime, digitalni jaz tradicionalno se smatrao kao pitanje imanja ili neimanja pristupa informacijsko-komunikacijskim tehnologijama. No trenutačna penetracija mobitela na svjetskoj razini iznosi 95 % i digitalni jaz sve više postaje jaz između onih s manje i onih s više *bandwitha*[50] i onih s manje i više znanja korištenja tehnologijama [178]. Čak je i ovaj jaz neprimjenjiv kod priče o Web 2.0 e-participacijskim tehnologijama. Naime, jedna od osnovnih karakteristika Web 2.0 tehnologija jest da su ne zahtjevne za korištenje. Dakle, digitalni jaz, kako god ga definirali, kod korisnički ne zahtjevnih participacijskih Web 2.0 tehnologija u Hrvatskoj i ne predstavlja neki problem.[51]

[48] Točnije 99 % prema najnovijem Izvješću o DESI indeksu digitalnoga gospodarstva i društva za 2018.godinu.
[49] Osim Hrvatske*, broadbend* Internetska veza postala je građansko pravo i u Finskoj i Španjolskoj [175].
[50] *Bandwith gap* s druge strane predstavlja razliku između građana (regija, država) u brzini *bandwitha*. Tako je FCC (eng. *Federal Communications Commision*) 2015.godine definirala *broadband* Internet kao vezu s najmanjom brzinom *downloada* od 25 Mb/s i *uploada* od 3 Mb/s [177].
[51] Japan nema problem s klasičnim digitalnim jazom. U Japanu je pak primjećena nova vrsta digitalnog jaza – između onih koji znaju koristiti tipkovnicu i onih koji to ne znaju! Naime kako su pametni telefoni postali vrlo prisutni, građani se sve slabije znaju služiti klasičnim tipkovnicama [179].



Grafikon 10: Postotak domaćinstava s pristupom na Internet u zemljama EU 28 i zemljama kandidatima u 2019. godini

Izvor: [180]

Dodatno, Ministarstvo uprave Republike Hrvatske, zajedno s knjižnicama na području Hrvatske provodi projekt „Postanite e-Građani uz pomoć knjižnice“ s ciljem dodatnog ublažavanja nemogućnosti pristupa *online* uslugama državne uprave.



Slika 25: Knjižnice kao dionici e-demokracije

Izvor: [181]

Pretpostavka o nepostojanju digitalnog jaza među građanima Republike Hrvatske biti će važna u poglavlju „6.3.1. Populacija i uzorak glavnog empirijskog istraživanja“ koje se bavi pitanjem uzorka glavnog istraživanja. Naime, u glavnom se istraživanju razmatra populacija građani Republike Hrvatske aktivni korisnici Interneta.

5.3. Izgradnja konceptualnog modela - racionalnost teorijske integracije

Baveći se pitanjem prihvaćanja novih tehnologija općenito, većina autora traži da se prihvaćanje tehnologija (pa tako i različitih tehnologija e-uprave) ne razmatra samo s tehnološke perspektive, već smatra da se prihvaćanje događa gotovo uvijek u specifičnom socio-političkom okruženju što kao posljedicu mora imati kompleksniji model istraživanja [54], [18], [182].

Slično je i s e-participacijom.

Da je prirodu e-participacije potrebno sagledati iz više perspektiva potvrđuju i dimenzije e-participacije. Na postavkama Kontrolnih ciljeva za informatičku i slične tehnologije (eng. *Control Objectives for Information and Related Technology*, COBIT), *United Nations Information Servis-a* i Biroa internacionalnih informacijskih programa američkog Ministarstva vanjskih poslova, Funilkul i Chutimaskul, došli su do spoznaje da ključne dimenzije elektroničke participacije čine tehnologija, okruženje i zainteresirani sudionici [182].

Iako je e-participacija bazirana na informacijsko-komunikacijskoj tehnologiji, pokazuje se da postojanje potrebne tehnologije predstavlja, matematičkim rječnikom, nužan, ali ne i dovoljan uvjet u širenju e-participacije. Naime, iako je jasno da je e-participacija sama po sebi tehnološki uvjetovana, istraživanja pokazuju kako tehnologija, iako bitna, većinom ne predstavlja odlučujući čimbenik kod prihvaćanja e-participacije. Već su 2008. godine Macintosh i Whyte u svojem članku došli su do zaključka da, iako dostupni, tehnološki alati nisu dovoljni za povećanje elektronske participacije građana [183]. Slaže se s tim i Magro u svom radu iz 2012. godine kada kaže da „samo postojanje i mogućnost pristupa tehnologiji neće uzrokovati pojačanu e-participaciju“ [184].

Ne-tehnološki čimbenici često igraju veću ulogu na ponašanje ljudi, pa tako i prilikom prihvaćanja novih tehnologija. Ovo istraživanje bavi se i s tim, slabije istraženim ne-tehnološkim čimbenicima.[52]

Bez razumijevanja što motivira građane da počnu koristiti tehnologije, država neće znati provesti strateške aktivnosti kako bi poboljšala njihovu razinu prihvaćanja. Stoga je cilj ovog rada adresirati problem prihvaćanja e-participacije na način da se provede empirijsko istraživanje i ne-tehnoloških faktora utjecaja na namjeru korištenja javnih usluga e-participacije. Više je različitih načina na koje je moguće pristupiti ovom problemu. Prihvaćanje informacijsko-komunikacijskih tehnologija/informacijskih sustava moguće je proučavati s različitih smjerova, pa se tako neki autori koncentriraju na makroekonomski pristup, dok drugu proučavaju odnos troška informacijsko-komunikacijskih tehnologija i uspjeha neke organizacije [130].

No u nastojanju da konačan model ima visoku moć predikcije i objašnjenja, modeli prihvaćanja tehnologije predstavljaju dobru osnovu za takva istraživanja [54]. Gledajući nove tehnologije općenito, u većem broju ranijih istraživanja uočila se potreba za upotrebom više različitih modela u istraživanju prihvaćanja tih istih tehnologija [54], [81], [185]. Ovo istraživanje uzima u obzir neke od tih faktora kao potencijalne determinante koje utječu na stav prema e-participaciji potpomognutoj Web 2.0 tehnologijama.

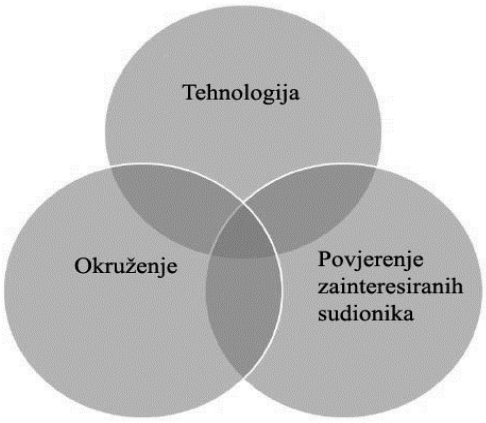
Temeljem analize većeg broja znanstvenih istraživanja vezanih uz teorije i modele namjere korištenja informacijskih tehnologija općenito, kao i osobnog iskustva, definiran je novi model istraživanja namjere korištenja javnih usluga e-participacije na način da će se izdvojiti one varijable koje bi mogle značajnije utjecati na prihvaćanje javnih usluga e-participacije.

Model predložen u ovom radu integrira konstrukte različitih modela prihvaćanja tehnologije identificiranih u pregledu recentne literature imajući na umu ranije spomenutu višedimenzionalnost e-participacije. Naime, višedimenzionalna priroda e-participacije zahtijeva i višedimenzionalni model!

„Model korištenja javnim uslugama e-participacije“ (eng. *Public E-Participation Services Intention to use Model*, PEPSIM) temelji se na pretpostavci da:

[52] U skladu s time, a kao što je to već naglašeno u poglavlju definiranja e-participacije, Web 2.0 tehnologije ne predstavljaju tehnološki napredne aplikacije, radi se u većini slučajeva o klasičnim PHP *based* aplikacijama.

a) karakteristike IKT/IS sustava utječu na namjeru korištenja tog istog IKT/IS,
b) društveni utjecaj (okruženje) važan je u namjeri prihvaćanja istih IKT/IS sustava i
c) društvena interakcija nemoguća je bez određenog stupnja povjerenja.



Slika 26: Vennov dijagram čimbenika utjecaja na namjeru korištenja javnim uslugama e-participacije

Ovaj rad predviđa da bi konstrukti ove tri dimenzije mogli u dobroj mjeri objašnjavati namjeru korištenja javnim uslugama e-participacije (zbog te je predviđajne prirode i korišten PLS-SEM pristup). U skladu s time, izabrani su modeli i njihovi konstrukti koji reflektiraju ove pretpostavke.

Kako bi obuhvatili dimenziju „tehnologija“, ovo istraživanje koristi Davis-ov Model prihvaćanja tehnologija (eng. *Technology acceptance model*, TAM), kao model koji pretpostavlja da je namjera korištenja pojedinca vezano uz korištenje nekog informacijskog sustava uvjetovana očekivanom korisnošću i očekivanom lakoćom korištenja. Ranija istraživanja upućuju na to da je TAM jedan od najutjecajnijih, često korištenih i visoko prediktivan model [186]. TAM veći naglasak stavlja na ulogu tehnologije vezano uz namjeru ponašanja korisnika. Odnosno, TAM pretpostavlja da je nečija namjera ponašanja determinirana dvjema tehnološki uvjetovanim faktorima prihvaćanja - očekivanom korisnosti i očekivanom jednostavnosti upotrebe [187]. Cilj je TAM-a predvidjeti prihvaćanje neke informacijske tehnologije iz tehnološke perspektive. Drugim riječima, TAM se fokusira na karakteristike dizajna IT sustava [54].

No kao što je već navedeno, teško je za povjerovati da bi u današnjem društvu isključivo TAM-ovi konstrukti mogli objasniti nečiju namjeru korištenja nekim IT sustavom a da nisu integrirani s društvenim faktorima. Ajzenova Teorija planiranog ponašanja (eng. *Theory of*

planned bihavior, TPB) pomoći će u proučavanju utjecaja društvene dimenzije, odnosno okruženja na namjeru korištenja javnim uslugama e-participacije. TPB opisuje osobne, nesvjesne aspekte prihvaćanja IT i kao takva nadopunjuje tehnološki pogled TAM-a. Prema ovoj teoriji najbolji prediktor ponašanja jest namjera ponašanja a pokazatelji namjere, odnosno konstrukti TPB-a su „Stav prema ponašanju", „Subjektivna društvena norma" i „Očekivana kontrola ponašanja" i kao takvi predstavljaju čimbenike društvenog utjecaja.

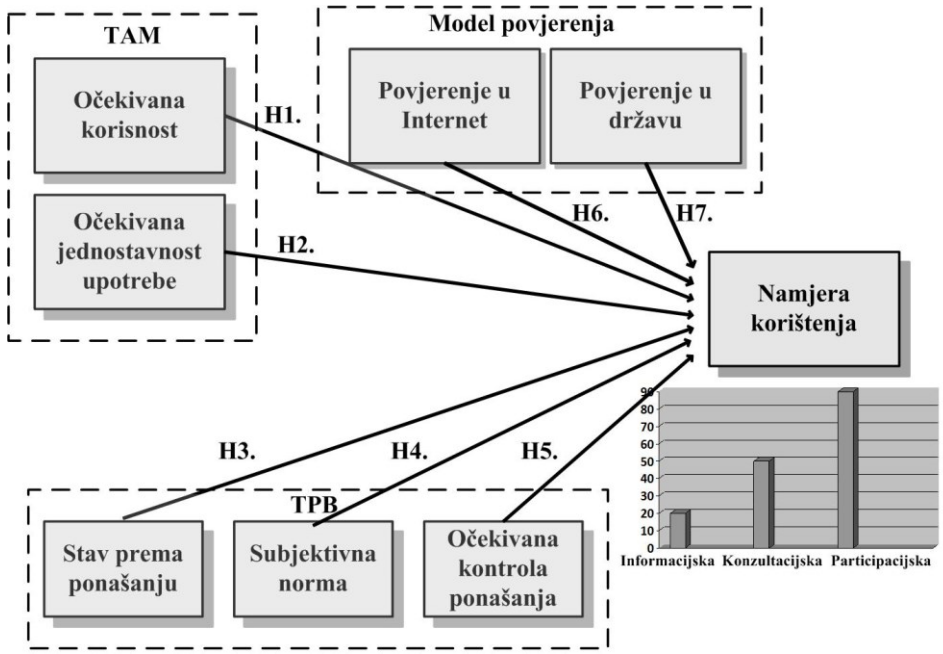
Kako TPB uzima u obzir samo društvene, a TAM tehnološke čimbenike kod predviđanja prihvaćanja tehnologije od stane pojedinaca, smatra se logičnim i opravdanim objedinjavanje ova dva modela u jedan višedimenzionalni model što će u konačnici omogućit bolje shvaćanje predmeta istraživanja sa socio-tehnološkog stajališta s ciljem poboljšanja eksplanatorne snage modela [54].

I na kraju u konceptualni model uvedeno je povjerenje. Naime, e-participacija samo po sebi predstavlja digitalnu interakciju, a „povjerenje je središnji aspekt svih društvenih i ekonomskih interakcija" [188]. Naime, uvađanje nove tehnologije uključuje kako korisnosti tako i moguće rizike kod zainteresiranih sudionika. Prije odlučivanja o prihvaćaju tehnologije, osoba želi odvagnuti korisnosti i rizike. Usluge elektroničke participacije ne odskaču od takvog shvaćanja. Zato je također uvršten i Model povjerenja (eng. *Trust model*, TM). Naime, Alrashedi, Persaud i Kindra smatraju kako dostupnost alata za e-participaciju automatski ne rezultira većom e-participacijom već je potrebno uključiti i povjerenje zainteresiranih sudionika [18]. I Chadwick u svom radu smatra da je povjerenje sudionika najvažnija osobina *online* politike [189].[53] Prema Welch i Hinnant, povjerenje u domeni usluga e-uprave svodi se na dvije kategorije: a) povjerenje u državu kao pružatelja usluga i b) povjerenje u Internet kao tehnologiju [191]. Slaže se s tim i Le Blanc kad kaže da „snažniji rast i kontinuirano korištenje e-participacije u značajnoj mjeri ovisi o povjerenju u državu, ali i povjerenju u Internet i društvene medije" [19].

Ovaj višedimenzionalni konceptualni model prihvaćanja javnih usluga e-participacije bit će operacionaliziran u anketni upitnik kao glavni instrument empirijskog istraživanja.

[53] Zielinski u svom radu „Zaštita privatnosti u e-participaciji" predstavlja tzv. ANOPI model kao podršku anonimizaciji osobnih podataka građana [190].

Ovaj model sveobuhvatniji je od pojedinačnih teorijskih modela i ima cilj prikazati kompleksne veze kod prihvaćanja e-participacijskih tehnologija.[54] Model je slikovno prikazan na Slici 27. dok su definicije konstrukta sumirane u Tablici 2.



Slika 27: Konceptualni model za potrebe istraživanja u doktorskom radu

Dodatno, s ciljem upoznavanja strukture potreba, anketni upitnik kreiran za potrebe ovoga rada ispitat će i potražnju građana za različitim razinama e-participacijskih usluga (participacijska, konzultacijska, informacijska).

Model čini osam konstrukata koji će biti operacionalizirani kroz primjenu skala. Iako neki radovi ne prave razliku, konstrukti i varijable nisu jedno te isto. Varijable se koriste za operacionalizaciju (odnosno davanje stvarne mjere, npr. vrijednosti na skali) konstrukata. Sedam konstrukata postati će nezavisne, u statističkoj analizi poznate i kao prediktorske, eksperimentalne, varijable, dok namjera korištenja kao osmi konstrukt predstavlja zavisnu varijablu, u statističkoj analizi poznatu i kao kriterijska varijabla [193], [194].

[54] U model nisu uključene moderatorske varijable kao što su to npr. spol, stupanj obrazovanja, prihod, jer prema Krugeru, „ako je digitalni jaz prevaziđen, one postaju irelevantne“ [192].

Tablica 2: Definicije konstrukta istraživačkog konceptualnog modela

Konstrukt	Definicija	Referenca
Očekivana (percipirana) korisnost (OK)	Prema TAM-u, prva od dvije ključnih determinanti kod prihvaćanja IT/IS sustava. Sam je tvorac TAM-a Davis u originalnom radu iz 1986. godine očekivanu korisnost općenito definirao kao „stupanj vjerovanja pojedinca da će korištenjem određene IT/IS povećati svoj radni učinak“ [31]. Naime, neka prijašnja istraživanja ukazuju da građani imaju namjeru korištenja neke tehnologije onda ako misle da je ta tehnologija korisna [54], [145], [185]. U kontekstu ovog rada, smatra se da je korištenje javnih usluga e-participacije korisno jer ih vlade mogu koristiti kako bi građanima omogućili brže i lakše izražavanje mišljenja, poboljšavajući tako interakciju s građanima.	[54]
Očekivana (percipirana) jednostavnost upotrebe (OJU)	Prema TAM-u, druga ključna determinanta prihvaćanja IT/IS sustava. Stupanj vjerovanja pojedinca da će moći koristiti određeni sustav bez dodatnog fizičkog ili mentalnog napora.	[54]
Povjerenje u Internet (PUI)	Konstrukt kojim se ispituje utječe li na zavisnu varijablu povjerenje građana u Internet tehnologije.	[133]
Povjerenje u državu (PUD)	Konstrukt koji postoji jer se smatra da uspješno prihvaćanje usluga elektroničke uprave zahtjeva povjerenje građana u kompetenciju, integritet države kao pružatelja usluga.	[133]
Stav prema ponašanju (SPP)	Prema TPB-u, jedna od tri determinanti kod prihvaćanja IT/IS sustava. Stupanj pozitivnog ili negativnog vrednovanja određenog ponašanja. Naime, stavovi pojedinca definirani su kao skup uvjerenja o konkretnom ponašanju pod utjecajem vrednovanja tih uvjerenja.	[54]
Subjektivna norma (iliti društveni utjecaj) (SN)	Prema TPB-u, druga od tri determinanti kod prihvaćanja IT/IS sustava. Subjektivna norma se odnosi na očekivanja osobe o tome što drugi važni ljudi iz njihova života misle da bi oni trebali učiniti u pogledu akcije (izvesti je ili ne). To je konstrukt koji se odnosi na percipirani društveni pritisak vezan za obavljanje određenog ponašanja. Utjecaj koji na ponašanje pojedinca ima društvena okolina.	[54]
Očekivana (percipirana) kontrola ponašanja (OKP)	Prema TPB-u, treća od tri determinanti kod prihvaćanja IT/IS sustava. Mjera koja pokazuje koliko je osobi teško ili lako ostvariti određeno ponašanje. Percipirana kontrola ponašanja predstavlja percepciju pojedinca o tome koliko se lako ili teško upustiti u određeno ponašanje. Temelji se na tome da pojedinci neće imati snažnu namjeru uključiti se u određeno ponašanje ako procjenjuju da nemaju resurse i mogućnosti da ih izvedu, čak i kad imaju pozitivne stavove prema tom ponašanju i znaju da osobe koju su im važne, odobravaju to ponašanje.	[54]

Na kraju poglavlja o racionalizaciji predloženog modela važno je istaknuti da je u ovom radu namjera korištenja izjednačena je sa stvarnim korištenjem. Naime, ovaj međusobni odnos toliko je potvrđen u svim dosadašnjim istraživanjima da ga nema smisla ponovno ispitivati [157].

5.4. Hipoteze u istraživanju

Kako je metodološki pristup u ovom radu primarno pozitivistički deduktivan, on zahtijeva testiranje određenih hipoteza koje moraju opisivati svojstva modela koji će se razviti. U ovom slučaju, korisničko prihvaćanje zavisna je varijabla proizašla iz teorijskog okvira dobivenog pregledom literature.

Vezano uz e-participaciju, Hrvatska se na ljestvici Ujedinjenih naroda (UN) nalazi prilično nisko. Od 193 zemlje, prema UN istraživanju, Hrvatska je rangirana kao 57 s e-participacijskim indeksom 0.7697 (eng. *e-participarion indeks,* EPI) [195]. Vidljivo je zaostajanje u usporedbi sa zemljama u okruženju (Srbija i Slovenija 48, Austrija 45, Italija 15). Postavlja se pitanje kojim varijablama je potrebno upravljati kako bismo dobili jače sudjelovanje građana u korištenju javnim uslugama e-participacije?

Tablica 3: Istraživačke hipoteze

Hip. #	Hipoteza	Konstrukt[55]
H1.	Očekivana korisnost javnih usluga e-participacije pozitivno je povezana s namjerom korištenja tih usluga.	OK
H2.	Očekivana jednostavnost upotrebe javnih usluga e-participacije pozitivno je povezana s namjerom korištenja tih usluga.	OJU
H3.	Povjerenje u Internet pozitivno je povezano s namjerom korištenja javnih usluga e-participacije.	PUI
H4.	Povjerenje u državu pozitivno je povezano s namjerom korištenja javnih usluga e-participacije.	PUD
H5.	Stav prema ponašanju je pozitivno povezan s namjerom korištenja javnih usluga e-participacije.	SPP
H6.	Subjektivna norma je pozitivno povezana s namjerom korištenja javnih usluga e-participacije.	SN
H7.	Očekivana kontrola ponašanja je pozitivno povezana s namjerom korištenja javnih usluga e-participacije.	OKP

Prema Vujeviću, postavljanje hipoteza zadnja je faza teorijskog dijela istraživanja nakon čega slijede faze empirijske aktivnosti [197]. Naime, dok se u teorijskom istraživanju pojave i činjenice spoznaju proučavanjem tuđih teorija i modela, u empirijskim istraživanjima pojave i činjenice spoznaju se provođenjem primarnog istraživanja [161]

[55] Konstrukt kao element znanstvene teorije (i kao što smo ranije utvrdili, element svakog konceptualnog modela), kao vrlo općenit pojam potrebno je operacionalizirati. Teorijski konstrukti operacionaliziraju se česticama anketnog upitnika [196]. U istraživanju svaki konstrukt bit će operacionaliziran kroz jednu skalu anketnog upitnika, odnosno česticama te skale. Točnije, teorijski konstrukti operacionalizirani su koristeći se česticama iz prijašnjih istraživanja.

6. METODOLOGIJA EMPIRIJSKOG ISTRAŽIVANJA

„Ako su blogovi i wikiji za vas Web 2.0, onda je to od ljudi prema ljudima. A to je ono što je Web trebao biti od početka.“
Tim Berners-Lee, izumitelj World Wide Weba

Ovaj se rad bavi tranzicijom elektroničke uprave prema Upravi 2.0 i novim shvaćanjima upotrebe informacijskih tehnologija u svrhu pristupa uslugama javne uprave. U empirijskom istraživanju, predmet istraživanja jest identifikacija čimbenika utjecaja na korisničko prihvaćanje javnih usluga e-participacije. Dodatno, rad se bavi i utvrđivanjem strukture potreba za različitim razinama e-participacijskih usluga.

Definira li se empirijsko istraživanje kao istraživanje tijekom kojeg se činjenice spoznaju vlastitim iskustvom, empirijsko istraživanje započinje provođenjem pilot istraživanja. No kako bi provođenje pilot istraživanja uopće bilo moguće, već je ranije naglašena potreba operacionalizacije konstrukta konceptualnog modela u anketni upitnik.

6.1. Razvoj mjernih skala anketnog upitnika

U ovom istraživanju, literatura vezana uz svaki konstrukt modela korištena je kao putokaz u razvoju upitnika. Dakle, kao i u nekim prijašnjim istraživanjima, teorijski konstrukti[56] operacionalizirani su koristeći se česticama iz prijašnjih istraživanja [198]. Slaže se s time i Churchill kad kaže da pregled i preuzimanje čestica iz literature predstavlja legitimni način kreiranja početnih čestica skale [199] [200]. I prema Korb, tri su načina kreiranja čestica u anketnim istraživanjima: doslovno tzv. verbatim preuzimanje (eng. *verbatim adopt*), prilagođavanje (eng. *adapt*) i kreiranje potpuno novih čestica (eng. *develop*) [201]. Dapače prema istoj autorici, preuzimanje čestica poželjnije je od prilagođavanja i kreiranja zbog više razloga. Prvo, kada je instrument preuzet, tada se pouzdanost i valjanost instrumenta[57] može primijeniti i na novo istraživanje kao što to većina autora i čini (vidjeti npr. [54] [145] [8] [81]). Odnosno, kao što i drugi autori čine, valjanost je ojačana opsežnim pregledom literature [203]. Drugo, preuzimanje čestica iz drugih istraživanja povezuje vlastito istraživanje s drugim istraživanjima koja su koristila isti instrument. I treće, preuzimanje čestica štedi

[56] Davanjem stvarnih mjera konstruktima (npr. vrijednosti na skali) konstrukti postaju varijable. Odnosno, razlika između pojma „konstrukt“ i pojma „varijabla“ povezana je samo sa mjerenjem [193] .
[57] Dvije su najvažnije metrijske (mjerne) karakteristike mjernog instrumenta istraživanja: valjanost i pouzdanost. Mjerni instrument je valjan ako mjeri ono što se smatra da mjeri (temeljne vrste valjanosti su sadržajna, konstruktna i kriterijska). Pouzdanost je metrijska karakterstika koja se odnosi na točnost, preciznost mjerenja [202].

vrijeme koje bi istraživač potrošio na potvrđivanje onog što su mnogi prije njega već potvrdili (tako su npr. u ovom radu skale za „Očekivanu korisnost“ i „Očekivanu jednostavnost upotrebe“ kao konstrukti Modela prihvaćanja tehnologije preuzete valjane mjerne skale iz članka samog autora Modela prihvaćanja tehnologije Davis-a) [31].

Prema Korb, kod preuzimanja čestica dozvoljene su sitne preinake kako bi se reflektirala specifična situacija u kojoj se istraživač nalazi (ne radi se o prilagođavanju čestica). Važno je da se suština čestice ne mijenja, samo referenca na određenu aktivnost (npr. *e-commerce*, *e-democracy*, *e-participation*). Neki autori dodaju još uvjet kako bi preuzete čestice ipak trebale biti iz kontekstualno sličnog područja, što je uvjet koji će u ovom radu biti ispoštovan.

Iako je upitnik definiran na temelju već razvijenih i testiranih ljestvica koje zadovoljavaju potrebne metrijske karakteristike, kako bi se još jednom potvrdilo da mjerne čestice mjere isti konstrukt, analizom literature primijećeno je da većina autora, čak i kad su čestice anketnog upitnika doslovno preuzete, još jednom provodi provjeru pouzdanosti instrumenta. Naime razlog je tome da su preuzete skale iz sličnog, ali ne i iz istog konteksta. I ovaj uvjet biti će u ovom radu ispoštovan.

Instrument istraživanja sastavljen je od skupa tvrdnji na koje su ispitanici odgovarali izražavajući svoje slaganje/neslaganje s predloženim tvrdnjama. Korištene su zatvorene čestice s unaprijed ponuđenim odgovorima. S obzirom da je riječ o ordinalnim podacima, ispitanici su svoj stupanj slaganja iskazivali na semantičkoj ordinalnoj ljestvici Likertovog tipa od pet stupnjeva i to:

1. u potpunosti se ne slažem
2. ne slažem se
3. niti se slažem niti se ne slažem
4. slažem se
5. u potpunosti se slažem.

Čestice vezane uz sociodemografske karakteristike zatvorenog su tipa i mjerene na kategoričkoj (nekad zvanoj i nominalnoj) ljestvici.

U tablicama koje slijede navedene su preuzete čestice koje će se koristiti u anketi (pregled izjava za svaki konstrukt), izvori iz kojih su preuzete i redni brojevi na kojima se nalaze u konačnom obliku ankete.

Naime, ako je instrument preuzet, važno je na odgovarajući način preuzeti instrument i opisati. Stvar je dobre prakse navesti redom: tko je razvio instrument, tko je potvrdio instrument i koja su istraživanja već koristila instrument.

Tablica 4: Operacionalizacija reflektivne egzogene latentne varijable „Očekivana korisnost“

Konstrukt	Oznaka čestice	Mjerne čestice	Izvor
Očekivana korisnost (OK)	OK-1	Korištenje online javnih usluga e-participacije omogućava mi da određene aktivnosti obavim brže.	Razvio: [31] Potvrdio i koristio: [31], [204], [205] [54], [206], [207] Pitanja vezana uz „Očekivanu korisnost“ pojavljuju se kao čestice 1, 2, 3, 7, 4 i 10 u anketi.
	OK-2	Korištenje online javnih usluga e-participacije podiže moju efikasnost.	
	OK-3	Korištenje online javnih usluga e-participacije za mene je praktično.	
	OK-4	Korištenje online javnih usluga e-participacije za mene ima puno prednosti.	
	OK-5	Korištenje online javnih usluga e-participacije učinit će moj život udobnijim.	
	OK-6	Općenito gledano, korištenje online e-participacijskih javnih usluga za mene je korisno.	

Tablica 5: Operacionalizacija reflektivne egzogene latentne varijable „Očekivana jednostavnost upotrebe“

Konstrukt	Oznaka čestice	Mjerne čestice	Izvor
Očekivana jednostavnost upotrebe (OJU)	OJU-1	Naučiti upotrebljavati online javne usluge e-participacije za mene je lako.	Razvio: [31] Potvrdio i koristio: [31], [204], [205], [206], [207], [54], [208] Pitanja vezana uz „Očekivanu jednostavnost upotrebe“ pojavljuju se kao čestice 5, 6, 8, 9, 11 i 12 u anketi.
	OJU-2	Komuniciranje preko online javnih usluga e-participacije ne zahtijeva mnogo mentalnog napora.	
	OJU-3	Moja interakcija s online javnim uslugama e-participacije jednostavna je i razumljiva.	
	OJU-4	Komuniciranje preko online javnih usluga e-participacije je prilagodljivo.	
	OJU-5	Mogu lagano postati vješt u korištenju online javnih usluga e-participacije.	
	OJU-6	Općenito, online javne usluge e-participacije jednostavne su za upotrebu.	

Tablica 6: Operacionalizacija reflektivne egzogene latentne varijable „Povjerenje u Internet“

Konstrukt	Oznaka čestice	Mjerne čestice	Izvor
Povjerenje u Internet (PUI)	PUI-1	Osjećam se sigurno jer sam pravno i tehnički dobro zaštićen od problema na Internetu koristeći online javne e-participacijske usluge.	Razvio: [209] Potvrdio i koristio: [209], [204], [210], [209] Pitanja vezana uz „Povjerenje u Internet“ pojavljuju se kao čestice 25, 26, 32, 27 i 28 u anketi.
	PUI-2	Internet ima dosta sigurnosnih mehanizama kako bi se osjećao ugodno tijekom aktivnosti na stranicama online javnih e-participacijskih usluga.	
	PUI-3	Vjerujem da mi enkripcija i ostala tehnološka dostignuća na Internetu omogućavaju sigurnu komunikaciju na stranicama online javnih e-participacijskih usluga.	
	PUI-4	Vjerujem da su tehnologije koje podržavaju online javne e-participacijske usluge pouzdane cijelo vrijeme.	
	PUI-5	Općenito gledano, vjerujem da je Internet sigurno okruženje za interakciju s online javnim e-participacijskim uslugama.	

Tablica 7: Operacionalizacija reflektivne egzogene latentne varijable „Povjerenje u državu“

Konstrukt	Oznaka čestice	Mjerne čestice	Izvor
Povjerenje u državu (PUD)	PUD-1	Država je sposobna tijekom korištenja online javnim uslugama e-participacije moje privatne informacije održati tajnima.	Razvio: [209] Potvrdio i koristio: [209], [204], [210], [211] Pitanja vezana uz „Povjerenje u državu“ pojavljuju se kao čestice 29, 30, 31 i 33 u anketi.
	PUD-2	Država kao davatelj usluga ulijeva mi povjerenje prilikom korištenja online javnim uslugama e-participacije.	
	PUD-3	Državne agencije imaju znanja i vještine za provođenje online javnih usluga e-participacije.	
	PUD-4	Vjerujem da tijekom korištenja online javnih usluga e-participacije država neće djelovati na način koji bi mi naštetio.	

Tablica 8: Operacionalizacija reflektivne egzogene latentne varijable „Stav prema ponašanju“

Konstrukt	Oznaka čestice	Mjerne čestice	Izvor
Stav prema ponašanju (SPP)	SPP-1	Korištenje online javnih usluga e-participacije za mene je korisno.	Razvio: [212] Potvrdio i koristio: [212], [213], [54], [207] Pitanja vezana uz „Stav prema ponašanju“ pojavljuju se kao čestice 13, 14, 18 i 15 u anketi.
	SPP-2	Korištenje online javnih usluga e-participacije za mene je pametna ideja.	
	SPP-3	Sviđa mi se ideja o korištenju online javnih usluga e-participacije.	
	SPP-4	Imam pozitivno mišljenje o korištenju online javnih usluga e-participacije.	

Tablica 9: Operacionalizacija reflektivne egzogene latentne varijable „Subjektivna norma“

Konstrukt	Oznaka čestice	Mjerne čestice	Izvor
Subjektivna norma (SN)	SN-1	Osobe iz moje obitelji smatraju da bih se trebao koristiti online javnim e-participacijskim uslugama.	Razvio: [212] Potvrdio i koristio: [212], [213], [130], [214], [54] Pitanja vezana uz „Subjektivnu normu“ pojavljuju se kao čestice 16, 17, 22 i 19 u anketi.
	SN-2	Osobe koje su meni važne misle da bih se trebao koristiti online javnim e-participacijskim uslugama.	
	SN-3	Osobe čije mišljenje cijenim željele bi da se koristim online javnim e-participacijskim uslugama.	
	SN-4	Osobe koje utječu na moje ponašanje smatraju da bih se trebao koristiti online javnim e-participacijskim uslugama.	

Tablica 10: Operacionalizacija reflektivne egzogene latentne varijable „Očekivana kontrola ponašanja“

Konstrukt	Oznaka čestice	Mjerne čestice	Izvor
Očekivana kontrola ponašanja (OKP)	OKP-1	Vjerujem da imam kontrolu nad korištenjem online javnim e-participacijskih usluga.	Razvio: [212] Potvrdio i koristio: [212], [215], [216] [217] Pitanja vezana uz „Očekivanu kontrolu ponašanja“ pojavljuju se kao čestice 20, 21, 23 i 24 u anketi.
	OKP-2	Vjerujem da bi mogao koristit online javne e-participacijske usluge kada bi to htio.	
	OKP-3	Korištenje online javnim e-participacijskim uslugama ovisi samo o meni.	
	OKP-4	Vjerujem da imam znanja za korištenje online javnim e-participacijskim uslugama.	

Tablica 11: Operacionalizacija reflektivne endogene latentne varijable „Namjera korištenja“

Konstrukt	Oznaka čestice	Mjerne čestice	Izvor
Namjera korištenja (NK)	NK-1	Namjeravam se koristiti online javnim e-participacijskim uslugama.	Razvio: [146] Potvrdio i koristio: [146], [145], [218], [208] Pitanja vezana uz „Namjeru korišrenja“ pojavljuju se kao čestice 34, 35 i 36 u anketi.
	NK-2	Planiram često se koristiti online javnim e-participacijskim uslugama.	
	NK-3	Preporučio bih drugima korištenje online javnim e-participacijskim uslugama.	

Što se tiče redoslijeda postavljanja pitanja u anketi, različiti autori imaju različita shvaćanja o ovoj temi. Većina autora čestice (pitanja) anketnog upitnika nasumično raspoređuje kako bi se izbjegao tzv. učinak reda (eng. *order effect*). Ovi autori smatraju da kontekst istraživanja ispitanicima ne bi smio biti poznat. S druge strane, postoje argumenti koji govore da bi u upitnicima trebalo biti jasno naznačeno koja pitanja se odnose na koji konstrukt. Iako je u

konačnici istraživanje Davisa i Vankatesha pokazalo da nema statistički značajnih razlika u rezultatima ovisno o redoslijedu postavljanja pitanja, u istraživanju će se usvojiti i ta preporuka i pitanja će biti isprepletena [219].

Prethodno navedene skale koriste se prilikom potvrđivanja hipoteza, odnosno ispitivanja povezanosti različitih čimbenika na namjeru korištenja javnih e-participacijskih usluga od strane građana Republike Hrvatske. Početni anketni upitnik u pilot istraživanju sastoji se od 36 manifestne varijable[58] Likertovog tipa od pet stupnjeva. Manifestne varijable identificirane su, kao što je ranije objašnjeno, pregledom literature. No drugi cilj ovog doktorskog rada dodatno zahtijeva još i utvrđivanje strukture potražne strane za javnim e-participacijskim uslugama.[59]

Naime, kao što je već objašnjeno u poglavlju „3.1. Definiranje i povijest elektroničke participacije“, OECD definira tri moguće razine složenosti e-participacijskih usluga - informacijska, konzultacijska i razina aktivne participacije. U skladu s time, ispitanicima će biti postavljena dodatna tri pitanja:

- Koristio bih online javne usluge e-participacije na Web stranicama tijela državne uprave samo za e-informiranje (npr. službena Web stranica nekog državnog tijela, blogovi, FAQ, Webcasts),
- Koristio bih online javne usluge e-participacije na Web stranicama tijela državne uprave i za davanje svojeg mišljenja (npr. e-konzultacije o zakonskim prijedlozima) i
- Koristio bih javne usluge e-participacije na Web stranicama tijela državne uprave i za aktivno uključivanje u oblikovanje javnih politika (npr. e-referendum, e-peticije, e-budžet, virtualno prisustvovanje različitim saslušanjima i sastancima).

Anketni upitnik izrađen je u Google Forms-ima, što je omogućilo laganu daljnju obradu eksportirajući rezultate u .xlsx, a zatim u za SmartPLS pogodan .csv format.

[58] Manifestne varijable su početne varijable, opažljivi kvantitativni podaci prikupljeni promatranjem, intervjuom, upitnikom ili nekim drugim mjernim instrumentom ili empirijskom metodom. U literaturi se kao sinonim za manifestne varijable upotrebljavaju pojmovi čestice i indikatori [10].

[59] „Razviti višedimenzionalni model prihvaćanja koji će biti korišten u objašnjavanju čimbenika utjecaja na namjeru korištenja građana Hrvatske uslugama elektroničke participacije i razumjeti strukturu potražne strane za participacijskim uslugama Uprave 2.0.“

6.2. Predistraživanje – validacija anketnog upitnika kao glavnog mjernog instrumenta empirijskog istraživanja

Empirijski dio istraživanja započinje predistraživanjem (eng. *pre research, pilot research*) na ne-probabilističkom, ne-slučajnom uzorku ispitanika dobivenih tehnikom snježne grude (eng. *non-probability, non-random snowball sampling*). Naime, prije početka stvarnog istraživanja dobro je provesti pilot istraživanje čime se osigurava da eksperiment mjeri uistinu varijable koje želimo istražiti [220]. Anketna metoda poseban je oblik ne-eksperimentalnog istraživanja[60] koja kao osnovni izvor podataka koristi osobni iskaz o mišljenjima, uvjerenjima, stavovima i ponašanju, pribavljen odgovarajućim standardiziranim nizom pitanja. Za razliku od opažanja koje također predstavlja ne-eksperimentalnu metodu istraživanja, u anketi ponašanje se mjeri neizravno, na temelju odgovora koje daju ispitanici, a ne na temelju izravnog promatranja [196]. Znanstvena metoda anketnog istraživanja, kao jedna od najčešćih i najpriznatijih metoda za prikupljanje podataka u društvenim istraživanjima, bit će korištena kako u predistraživanju tako i u glavnom istraživanju. Svaka znanstvena metoda koristi u svojim okvirima specifične tehnike. U ovom radu, unutar znanstvene metode anketnog istraživanja, tehnika *online* ankete koristi se kako u predistraživanju tako i u glavnom istraživanju. Anketa je strukturirani upitnik kojeg čine unaprijed određena pitanja koja se postavljaju ispitaniku i u ovom radu predstavlja glavni mjerni instrument kako pred tako i glavnog empirijskog istraživanja.[61] S obzirom na način provedbe, anketiranje se i u predistraživanju i u glavnom istraživanju provodi isključivo u digitalnoj formi. Struktura anketnog upitnika objašnjena je u poglavlju „6.1. Razvoj mjernih skala anketnog upitnika“ dok je sam anketni upitnik sastavni dio Priloga A ovoga rada.

6.2.1. Populacija i uzorak predistraživanja

Anketni upitnik predistraživanja u potpunosti je bio u digitalnom obliku. Što se tiče metode uzorkovanja, korištena je neprobabilistička, neslučajna metoda snježne grude (eng. *non-probability, non-random snowball sampling).* Neprobabilističke metode uzorkovanja česte su (prema nekim autorima i poželjne) prilikom provođenja predistraživanja [221], [222]. Inicijalni pokretači uzorkovanja metodom snježne grude odabrani su iz prigodnog uzorka. Podaci su prikupljani tijekom siječnja 2019. godine.

[60] Nasuprot ne-eksperimentalnim istraživanjima stoje eksperimentalna istraživanja. Pripisivanje promjena u zavisnoj varijabli djelovanju nezavisne varijable najmanje je dvojbeno u istinskim eksperimentalnim istraživanjima koje odlikuje mogućnost upravljanja nezavisnom varijablom. U psihologiji i ostalim društvenim istraživanjima, grupni nacrt najčešća je eksperimentalna metoda [196].

[61] Osim ankete, glavne vrste mjernih instrumenata još su i test, upitnik ličnosti i skala procijene.

Ne postoje formalni standardi vezani uz veličinu uzorka predistraživanja [223]. Iako literatura obiluje tzv. iskustvenim pravilima (eng. *rules of thumb*) zajedničko, opće prihvaćeno stajalište o veličini uzorka potrebnog za uspješno provođenje predistraživanja ne postoji. Tako npr. Hill smatra da je za predistraživanje opravdana upotreba malih uzoraka veličine već od 10 do 30 ispitanika [224]. Hertzog navodi brojku od 10 do 40 ispitanika [225]. No većina autora smatra da se ispod preporuka Lackey i Wingate (10 % od veličine uzorka glavnog istraživanja) ne bi smjelo ići [225]. U ovom slučaju to konkretno znači 40 ispitanika (kao što će se u jednom od slijedećih poglavlja pokazati, 400 ispitanika predstavlja zadovoljavajući broj ispitanika za glavno istraživanje).

Dakle, u predistraživanje je uključeno 40 ispitanika. Podaci dobiveni u predistraživanju nisu uključeni u glavno istraživanje. Kao što je i ranije napomenuto, anketni upitnik izrađen je u Google Forms-ima, što je omogućilo laganu daljnju obradu eksportirajući rezultate u .xlsx a zatim u .csv format.

6.2.2. Pouzdanost instrumenata u predistraživanju – Cronbachov alfa

Što se tiče pouzdanosti (eng. *reliability*), metrijska je to karakteristika koja se odnosi na preciznost mjerenja i definira se na dva načina: a) mjerni instrument je pouzdan ako se u ponovljenom mjerenju dobiju u osnovi isti rezultati i b) mjerni instrument je pouzdan ako svim svojim dijelovima dosljedno mjeri isti konstrukt [202][62]. Pouzdanost je povezana s reproduktivnošću, odnosno neki je test pouzdan ako se ponovnim korištenjem tog istog testa pod istim uvjetima dolazi do istog rezultata. Vezano uz pouzdanost, za pred istraživanje bit će provedeno ispitivanje unutarnje dosljednosti, odnosno interne konzistentnosti koristeći Alfa koeficijent (popularno zvan Cronbachov alfa). Drugim riječima, Cronbachov alfa koeficijent mjera je sukladnosti odgovaranja na pitanja koji imaju isti predmet mjerenja. Temelji se na tzv. unutarnjoj konzistenciji skala, odnosno na prosječnoj korelaciji među česticama skale. Pretpostavka je da ako sve čestice mjere isti predmet mjerenja onda će i njihova prosječna interkorelacija biti visoka, skala ima visoku internu konzistentnost ako sve čestice skale mjere isti konstrukt. Veliki broj autora za pouzdanost mjerne ljestvice preporučuje minimalnu vrijednost Cronbachovog alfa od 0.7 [30], [226], [227].

Zaključno, kada je upitnik pouzdan, identični građani (u smislu njihovog stava prema utjecaju npr. povjerenja u državu na namjeru korištenja javnih usluga e-participacije) trebali bi dobiti

[62] Neki autori smatraju da nije pravilno reći da su instrumenti odnosno skale pouzdani. Rezultati su pouzdani. Dakle, prema nekim autorima, pravilno bi bilo reći „pouzdanost rezultata skale“.

iste rezultate, a različiti građani različite rezultate. Odnosno, pouzdanost se odnosi na dobivanje sličnih rezultata tijekom više uzastopnih mjerenja (replikabilnost) bez obzira na to što se njime zapravo mjeri. Analiza dobivenih podataka provedena je koristeći SPSS 17.0 softver.

6.2.3. Valjanost instrumenta u predistraživanju

Iako u popis aktivnosti koje je potrebno provesti tijekom predistraživanja spada i provjera valjanosti (eng. *validity*), kao što je prije navedeno, zbog specifičnosti odabira čestica u ovom istraživanju provjera valjanosti neće se istraživati i ovo podpoglavlje postoji samo zbog logičke dosljednosti rada. Naime, tri su osnovne vrste valjanosti, sadržajna (eng. *content*), konstruktna (eng. *construct*) i kriterijska (eng. *criterion-related*). Sadržajna valjanost ojačana je provođenjem opsežnog i sistematskog pregleda literature, a kada su čestice preuzete iz valjanih i prethodno prihvaćenih instrumenata, konstruktnu i kriterijsku valjanost nije potrebno utvrđivati [228] [229].

6.3. Glavno istraživanje – validacija konceptualnog modela

Što se tiče metrijskih karakteristika mjernog instrumenta glavnog istraživanja, strukturno anketni upitnik čini osam skala (eng. *scale*), odnosno za svaku nezavisnu varijablu postoji jedna skala pitanja koja se sastoji od određenog broja čestica (eng. *items*). Dodatno, za mjerenje zavisne varijable namijenjena je skala od tri čestice. Od psihometrijskih skala, koristit će se ordinalna ljestvica Likertovog tipa od pet stupnjeva koju možemo definirati kao skup tvrdnji s kojima ispitanik izražava svoje slaganje odnosno neslaganje. Drugim riječima, Likertova skala suma je odgovora na Likertove čestice [65]. Tvrdnjama se obično pridodaju vrijednosti od 1 do 5 koji označavaju stupanj slaganja (u potpunosti se ne slažem, ne slažem se, niti se slažem niti se ne slažem, slažem se, u potpunosti se slažem). Dosadašnjim istraživanjima se došlo do zaključka da čovjek najbolje diferencira najviše pet stupnja (otud i raspon školskih ocjena od jedan do pet). Kao i u predistraživanju, čestice (pitanja) anketnog upitnika nasumično su raspoređene kako bi se izbjegao tzv. učinak reda (eng. *order effect*).

Modeliranje strukturnim jednadžbama (eng. *Structural Equation Modeling*, SEM) statistička je tehnika koja se koristi za testiranje konceptualnog modela i evaluaciju hipoteza, odnosno u konkretnom slučaju povezanost čimbenika „Očekivane korisnosti“, „Očekivane jednostavnosti upotrebe“, „Povjerenja u Internet“, „Povjerenja u državu“, „Stava prema ponašanju“, „Subjektivne norme“ i „Očekivane kontrole ponašanja“ s „Namjerom korištenja javnih usluga e-participacije“ provjerena je metodom modeliranja strukturnim jednadžbama.

6.3.1. Populacija i uzorak glavnog empirijskog istraživanja

Kako gotovo nikad, iz praktičnih razloga, ne postoji mogućnost ispitati cjelokupnu skupinu čije nas mišljenje zanima, koristi se uzorkovanje. Na temelju uzorka kao manjeg, odabranog skupa osoba, nastoje se utvrditi okviri unutar kojih se vjerojatno kreće mišljenje šire zajednice (populacije) iz koje je uzorak izvučen [196]. Odnosno, uzorak je podskup populacije izdvojen s ciljem istraživanja.

Vezano uz uzorak, važno je još jednom naglasiti da se istraživanje ne bavi pitanjem dostupnosti informacijskim tehnologijama, odnosno pristupa Internetu. Dakle, izbjegnuto je pitanje digitalnog jaza. Naime, populacija koja se u ovom radu razmatra jesu građani Republike Hrvatske aktivni korisnici Interneta[63] i da nisu mlađe od 16 niti starije od 74 godina.[64] Podaci su prikupljani tijekom veljače 2019. godine.

Razlog zašto su za istraživanje odabrani aktivni korisnici Interneta leži u činjenici da su neka prijašnja istraživanja o uzrocima i namjeri korištenja uslugama elektroničke uprave bila fokusirana primarno na probleme pristupa i dostupnosti, fokusirajući se tako na probleme digitalnog jaza, a ne na društvene i bihevioralne razloge, odnosno potrebe građana [33], [230]. Ovakav uzorak je moguć jer u poglavlju „5.2. Pitanje digitalnog jaza“ pretpostavljeno je nepostojanje, za istraživanje i generaliziranje rezultata istraživanja, značajnije razlike u mogućnosti pristupa uslugama elektroničke uprave od strane građana Republike Hrvatske. Odnosno, ne istražuju se osobe koje nisu sposobne elektronski pristupiti istraživanim uslugama, već istraživanje u ovom radu počiva na teorijskim modelima proizašlim primarno iz socijalne psihologije baveći se tako pitanjima motivacije i stavova prema namjeri korištenja javnim uslugama elektroničke uprave.

Ovim istraživanjem podaci su prikupljeni koristeći ne-probabilistički, ne-slučajan uzorak (eng. *non-probability, non-random sampling)* i to uzorkovanjem tzv. tehnikom snježne grude (eng. *snowball sampling*). Uzorkovanje tehnikom snježne grude lančani je pristup gdje autor koristi svoje društvene kontakte kao inicijalne pokretače (eng. *initial seed*). Kod ove metode ispitanicima se pristupa korištenjem osobnih kontakata ili društvenih mreža. Istraživač na početku identificira malu skupinu pojedinaca koji imaju tražene karakteristike i koji zatim služe kao poveznica s drugima koji ispunjavaju uvijete za uključivanje. Odnosno,

[63] Prema EuroStat-ovoj definiciji, pod aktivnim korisnicima Interneta smatraju se osobe koje pristupaju Internetu barem jedanput tjedno.
[64] Isti raspon godina koristi i EuroStat u svojim statistikama. Nije dostupna informacija zašto baš taj raspon godina.

uzorkovanje tehnikom snježne grude temelji se na početnom odabiru uskog kruga ljudi potrebnih karakteristika koji sami šire uzorak do potrebne veličine. Kako navodi Milas, „uzorak se širi i raste poput snježne grude te otuda i naziv tehnike“ [196].

Iako probabilistički uzorci imaju prednost pred ne-probabilističkim uzorcima, u velikom broju istraživanja zbog ekonomičnosti, manjih izdataka i kraćem potrebnom vremenu, često se koriste i ne-probabilistički uzorci što je najviše uvjetovano raspoloživim resursima [231], [232], [233]. Prema „SAGE enciklopediji metoda kvalitativnih istraživanja“, iako ne-probabilističke tehnike uzorkovanja podižu neke zabrinutosti (pristranost kod odabira učesnika, eng. *bias*) one kao takve „predstavljaju valjane tehnike provođenja istraživanja“ [234]. U praksi nedostatak *snowball* uzorkovanja očituje se u činjenici da npr. i građanin Republike Hrvatske koji udovoljava traženim karakteristikama, zbog činjenice da nije ni na kakav način povezan sa skupinom koja inicira ili širi uzorak, neće biti uključen u uzorak. No postoje preporuke koje valja poštovati kako bi se negativni efekti ovog uzorkovanja maksimalno smanjili. Tako Morgan preporuča da „najbolja obrana od nedostatka različitosti (eng. *sample diversity*) u *snowball* uzorku jeste da inicijalni pokretači budu maksimalno različiti“ [234] [235].[65] Literatura ne nudi odgovor na pitanje što to točno znači da kod anuliranja negativnih karakteristika *snowball* uzorka inicijalni pokretači moraju biti maksimalno različiti, već samo spominje anegdotalne preporuke [235]. Ako je definicija probabilističkih tehnika uzorkovanja da nude jednaku vjerojatnost ulaska u uzorak svim članovima populacije (a u ovom slučaju, članovi populacije svi su građani Republike Hrvatske traženih karakteristika), nameće se logičnim da početni skup sudionika bude maksimalno različit u smislu stručne spreme, dobi, spola, ali i raspoređenosti po hrvatskim županijama. Tako su inicijalni pokretači u ovom istraživanju bili 15 građana Republike Hrvatske različitih stručnih sprema, dobi i spola ravnomjerno raspoređeni po svim hrvatskim županijama a koji su ispunjavali prije definirane karakteristike za uključivanje.[66]

[65] Nije neobično koristiti *snowball sampling* u istraživanjima vezanim uz e-demokraciju i e-participaciju. Tako i Lappas i dr. u članku naziva “Lokalna e-uprava i e-demokracija: evaluacija grčkih općina“ koristi ovu vrstu uzorkovanja [233].

[66] „Pojam reprezentativnosti uzorka nema svoje tehničko značenje i predstavlja uvelike subjektivnu ocjenu osobe koja ga rabi. Ne postoji naime objektivni kriterij prema kojem bi se prosuđivalo je li neki uzorak reprezentativan ili ne [196] prema [236].

Što se tiče veličine uzorka, literatura opisuje više strategija pogodnih za utvrđivanje veličine uzorka [237], [238], [239]:

a) korištenje cijele populacije ako se radi o maloj populaciji (tzv. cenzus),
b) transferiranje veličine uzorka iz sličnih istraživanja i
c) korištenje formula za izračunavanje uzorka. [67]

Strategija a), odnosno korištenje cijele populacije, u ovom istraživanju nije moguća jer je populacija koju razmatramo prilično velika (broj aktivnih Internet korisnika u Hrvatskoj procjenjuje se na 2 000 000) [14].

Za potrebe empirijskog istraživanja, veličina uzorka formirana je koristeći strategiju c), odnosno korištenjem formule za izračunavanjem uzorka. Točnije, veličina uzorka formirana je koristeći Cochran-ovu formulu za izračunavanje uzorka iz populacijskog skupa [240], [241], [237]. Mnogi autori u PLS-SEM istraživanjima koriste formule za izračun uzorka. Tako u poglavlju o uzorku i relevantnosti dobivenih podataka, Bosilj u svom istraživanju koristi Cochran-ovu formulu za potvrđivanje validativnosti uzorka [242]. Ayele i Birhanie u PLS-SEM analizi čimbenika prihvaćanja i korištenja sustava e-učenja, veličinu uzorka također procjenjuju koristeći Cochran-ovu formulu [243], kao i Langerodi i Dinpanah u modeliranju strukturalnim jednadžbama participacije građana u zaštiti okoliša [244]. Rezaei i dr. u SEM analizi o participaciji roditelja vezano uz školska pitanja kako bi došli do traženog broja subjekata u uzorku također koriste istu formulu [245].

Cochran-ova formula za izračunavanje uzorka iz populacijskog skupa glasi [237], [246]:

$$n_0 = \frac{Z^2 pq}{e^2}$$

gdje je

$n_0 =$ veličina uzorka,

e = stupanj preciznosti (eng. *level of precision, sampling error, margin error, confidence interval*), parametar koji definira rizik, grešku, koju je istraživač spreman preuzeti u istraživanju s obzirom da istražuje samo mali dio populacije. Npr. kod odabira stupnja preciznosti od +-5 postotna boda, ako 60 % ispitanika odabere određeni odgovor možemo

[67] Već izračunate vrijednosti za određenu veličinu populacije i određen stupanj pouzdanost i preciznosti mogu se naći i u tablicama [237], [238].

pretpostaviti da bi 55 % do 65 % cijele populacije odabralo isti taj odgovor (odabere li se još pritom stupanj pouzdanosti od 95 %, to bi značilo da ako istraživač više puta ponovi svoje istraživanje, u 95 % slučajeva dobiti će iste rezultate),

Z = ovisi o stupnju pouzdanosti (eng. *degree of confidence, level of confidence, risk level*), kojeg želimo, za stupanj pouzdanosti od 95 % koji je standardan u većini društvenih istraživanja Z = 1,96,

p = stupanj varijabilnosti (eng. *degree of variability*), u ovoj formuli predstavlja postotak pojavnosti kako će npr. određeno pitanje biti odgovoreno u uzorku, u društvenim istraživanjima Bartlet predlaže pretpostaviti maksimalnu varijabilnost, odnosno koristiti 50 % kao procjenu za p [240] [239], dok je q = 1 – p.

Uvrste li se tražene vrijednosti u jednadžbu dobiva se vrijednost

$$n_0 = \frac{(1{,}96)^2(0{,}5)(0{,}5)}{0{,}05^2}$$

$$n_0 = 384{,}16$$

Na osnovu dobivene vrijednosti, možemo zaključiti da bi veličina uzorka od 400 ispitanika bila dobra brojka za provođenje glavnog istraživanja.

Kako bi dodatno potvrdili odabranu veličine uzorka, moguće je promatrati kakve rezultate daje strategija b), odnosno transferiranje veličine uzorka iz sličnih istraživanja?

- 400 je broj ispitanika u radu Alshehri i dr. pod nazivom „Analiza prihvaćanja usluga e-uprave od strane građana: korištenje UTAUT modela“ (eng. *Analysis of citizens acceptance for e-government services: applaying the UTAUT model*) [157],
- 302 je broj ispitanika u radu Lee i dr. pod nazivom „Efekt povjerenja i očekivanog rizika vezano uz prihvaćanje IKT usluga od strane korisnika“ (eng. *The effects of trust and perceived risk on users acceptance of ICT services*) [247],
- 373 je broj ispitanika u radu Mohammed pod nazivom „Čimbenici namjere korištenja *online* kupovine kod mlađih potrošača“ (eng. *Determinants of young consumer online shopping intention*) [248].

Može se zaključiti kako se u sličnim istraživanjima veličina uzorka kreće oko 400 ispitanika.

Na temelju razmatranih strategija procijene uzorka, pretpostavka je kako veličina uzorka od 400 ispitanika predstavlja dobru brojku.

Gornja brojka u skladu je i s iskustvenim pravilima (eng. *rules of thumb*) vezano uz izračun minimalne veličine uzorka kojeg zahtjeva PLS-SEM. Više je preporuka vezano uz minimalnu veličinu uzorka u PLS-SEM istraživanjima. PLS-SEM pristup zahtijeva minimalni uzorak deset puta veći od konstrukta s najvećim brojem formativnih indikatora (kojih u ovom istraživanju nema) ili broja nezavisnih konstrukta koji su povezani sa zavisnim konstruktom [249], [248], [250]. Slaže se s time Chin u svojem radu „PLS pristup modeliranju strukturalnim jednadžbama“ (eng. „*The Partial Least Squares Approach to Structural Equation Modeling)*“ [251] kao i Saunders [252]. Koristeći ovaj kriterij, ovaj rad zahtijeva najmanji uzorak od 7 x 10 = 70[68] što je višestruko prekoračeno korištenim uzorkom od 400 građana.

6.3.2. Metoda analize dobivenih podataka – modeliranje strukturalnim jednadžbama i testiranje hipoteza

Kao što kaže Churchill, „nakon što je početni bazen čestica pažljivo prilagođen, za dodatno usavršavanje potrebni su stvarni podaci“ [200]. U skladu s time, nakon preuzimanja čestica, provedeno je predistraživanje na podskupu populacijskog skupa. Predistraživanje je poslužilo kako bi se dodatno potvrdila pouzdanost (eng. *reliability*) kao jedna od mjernih karakteristika anketnog upitnika. Kao što je i detaljnije opisano u poglavlju „7.1.1.Populacija i uzorak predistraživanja“, predistraživanje je provedeno nad 40 ispitanika.

Nakon što je upitnik u pilot fazi zadovoljio sve potrebne kriterije, pristupilo se provođenju glavnog dijela istraživanja. Modeliranje strukturalnim jednadžbama korišteno je kao evaluacijska tehnika empirijske analize.

Modeliranje strukturalnim jednadžbama (eng. *Structural equation modeling*, SEM) predstavlja skup statističkih tehnika koje omogućavaju da odnosi između jedne ili više „nezavisne“ varijable i jedne ili više „zavisne“ varijable budu ispitani [253]. U SEM-u, mjerenje nekog fenomena koji nije direktno opažljiv odvija se preko indikatora, odnosno kombinacijom nekoliko čestica na skali apstraktni koncept interesa mjeri se indirektno.

[68] Naime, u ovom modelu, sedam egzogenih latentnih „nezavisnih“ varijabli direktno utječe na jednu endogenu latentnu „zavisnu“ varijablu.

Modeliranje strukturalnim jednadžbama, kao uostalom i svaka druga statistička analiza, koristi svoju terminologiju. Kod SEM-a više se ne koriste termini „zavisna“[69] i „nezavisna“[70] varijabla, već SEM poznaje samo endogene (unutarnje) i egzogene (vanjske) latentne varijable.[71] Egzogene (vanjske, „nezavisne“) varijable su one koje nisu uzrokovane drugim varijablama u modelu dok su endogene (unutarnje, „zavisne“) one koje su uzrokovane drugima [196]. Egzogena (vanjska) varijabla ima strelice putanje koje pokazuju prema van i ni jedna ne vodi do njih, dok endogene (unutarnje) varijable imaju barem jedan smjer koji vodi do njih i predstavlja efekt druge varijable [227]. U ovom slučaju, „Očekivana korisnost“, „Očekivana jednostavnost upotrebe“, „Stav prema ponašanju“, „Subjektivna norma“, „Očekivana kontrola ponašanja“, „Povjerenje u Internet“ i „Povjerenje u državu“ predstavljaju egzogene (vanjske) varijable dok“ Namjera korištenja“ predstavlja endogenu (unutarnju) varijablu.

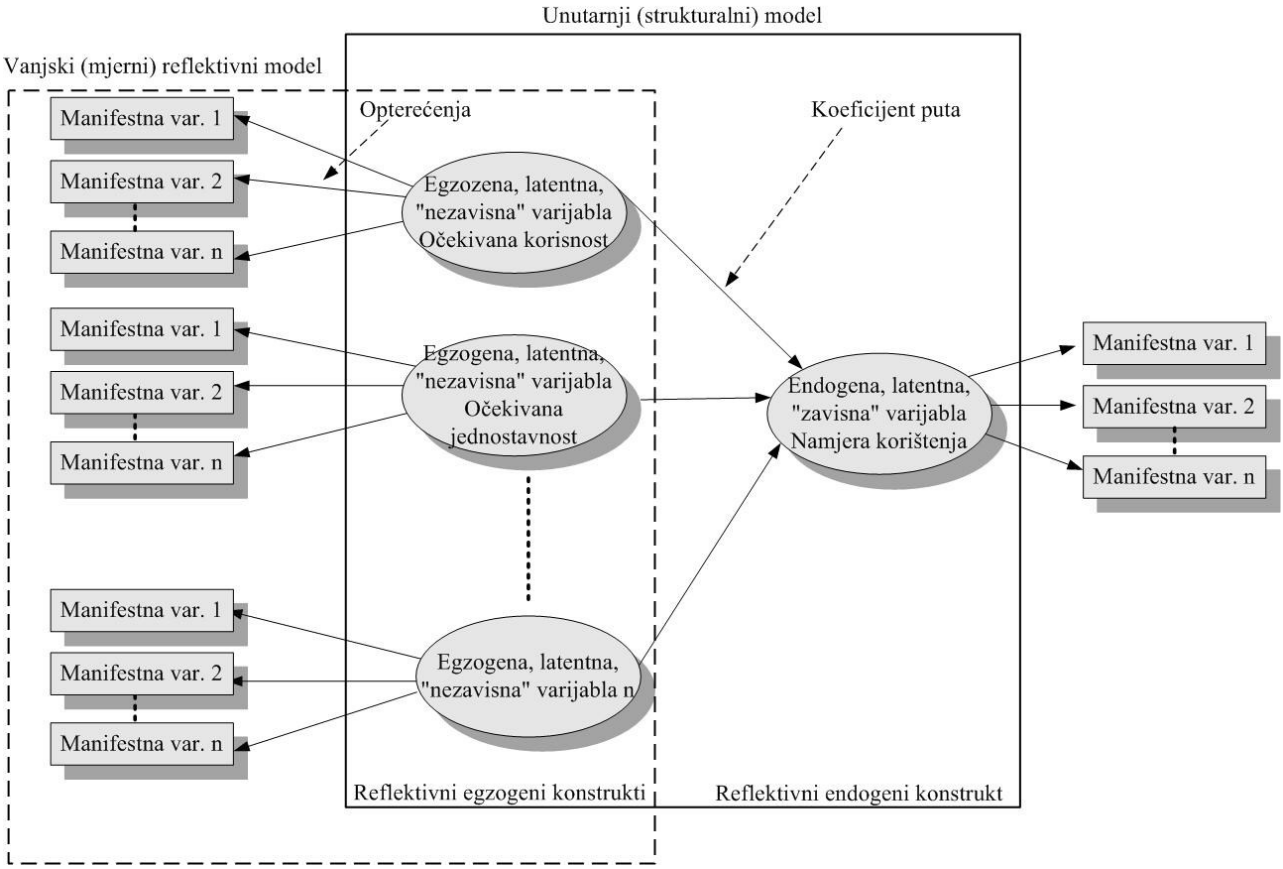
Nadalje, SEM dozvoljava istraživaču da identificira izravne i neizravne utjecaje nad varijablama. Direktni utjecaji predstavljaju neposredan odnos između „zavisne“ varijable koju želimo objasniti i „nezavisne“ varijable za koju mislimo da je povezana za „zavisnom“ varijablom. Indirektni utjecaj dešava se kad jedna „nezavisna“ varijabla ima utjecaj na „zavisnu“ varijablu preko neke druge varijable [254]. U ovom slučaju, postoje samo direktni utjecaji nad varijablama (iako čitatelj može primijetiti da originalni TAM, na kojem se bazira i ovaj model osim varijable „Namjera korištenja“ ima još i varijablu “Stvarno korištenje“ no ta veza između „Namjere korištenja“ i „Stvarnog korištenja“ toliko je puta potvrđena u prijašnjim istraživanjima da je nema smisla nanovo potvrđivati, pa je tako, kao što smo je i ranije naglašeno, u ovom radu namjera korištenja izjednačena sa stvarnim korištenjem nekog sustava).

Dodatno, dva su podmodela SEM modela, unutarnji (strukturalni) model i vanjski (mjerni) model. Unutarnji model označava (reflektira) veze između „nezavisnih“ i „zavisnih“ latentnih varijabli, dok vanjski model označava veze između latentnih varijabli (konstrukta) i njihovih opaženih indikatora (čestica, manifesnih varijabli, opaženih varijabli) [227]. Lokacija i slijed konstrukta u strukturalnom modelu bazirana je na teoriji i znanju samog istraživača.

[69] U statističkoj analizi poznata još i kao kriterijska varijabla (eng. *target, dependent, criterion, response variable*).
[70] U statističkoj analizi poznata još i kao prediktorska varijabla (eng. *independent, predictior, controlled, regressor variable*)
[71] U terminologiji ekspermintalnih metoda, egzogene varijable nazivaju se nezavisnima, a endogene zavisnima. Kod većine autora nedostaje terminološke discipline pa neki autori ipak koriste te nazive i u ne-eksperimentalnim istraživanjima. Koristit će se i u ovom radu pod navodnim znakovima jer ipak intuitivno naznačuju prirodu konstrukta.

Dijagram puta (eng. *path diagram*) ili prema nekim hrvatskim prijevodima dijagram traga, grafički je prikaz sustava jednadžbi koji se redovito koristi u SEM-u. Osnovna prednost je mnogo veća jasnoća i razumljivost slikovnog nacrta u odnosu na matematičke jednadžbe. Takav dijagram ima i neke svoje konvencije. Čimbenici (često zvani i latentne varijable, konstrukti ili neopažene varijable)[72] označavaju se kružnicama ili elipsama. Mjerne varijable (često zvane indikatori, manifestne ili opažene varijable, te mjerne varijable u biti su pitanja na skali)[73] označavaju se sa pravokutnicima. Crte sa strelicama označavaju odnose između varijabli, odnosno ako crta ne postoji tada ne postoji niti pretpostavljena povezanost. Varijabla prema kojoj pokazuje strelica predstavlja „zavisnu" varijablu [255].

Sumira li se sve gore navedeno i kada se to slikovno prikaže, SEM dijagram puta za ovo istraživanje izgledao bi kao na Slici 28.



Slika 28: SEM dijagram puta

[72] Iako se konstrukti nekad poistovjećuju sa varijablama, to nisu sinonimi. Razlika je suptilna i vezana je uz mjerenje. Naime, davanjem stvarne mjere (npr. vrijednosti na skali), konstrukt postaje varijabla [193]. Faktor u faktorskoj analizi = latentna varijabla u SEM-u.
[73] S druge strane, indikatori se mogu mjerit direktno.

Prikupljeni podaci analizirani su korištenjem statističkog paketa za društvene znanosti IBM SPSS 17.0. i SmartPLS v. 3.2.8. softvera. Za dodatno oblikovanje i grafičko prikazivanje dobivenih podataka intenzivno je korišten Microsoft Excel 2016.

Literatura podržava korištenje SEM-a u društvenim znanostima, pogotovo u IT/IS području [253]. SEM dozvoljava istraživačima simultano istraživanje mjernog i strukturalnog modela. Više je različitih pristupa provođenja SEM analize. Tako postoji na kovarijanci bazirani SEM (eng. *covariance based SEM, CB-SEM*) koristeći softvere kao što su AMOS i LISREL, zatim na varijanci bazirani SEM (eng. *variance based SEM, component based SEM*) s dva smjera, Generalized Structured Component Analysis (eng. *GSCA*) koristeći softvere kao što su VisualGSCA i puno poznatiji smjer parcijalnih najmanjih kvadrata (eng. *partial least squares, PLS-SEM, PLS path modeling*) [142] koristeći softvere kao što su PLS-Graph i SmartPLS i na kraju nelinearno univerzalno strukturalno relacijsko modeliranje (koristeći NEUSREL softver) [227].[74]

U ovom istraživanju, PLS-SEM metoda korištena je za validiranje veza u predloženom modelu prihvaćanje javnih usluga e-participacije. Više je razloga za to:

- Prema Ringle i Sarstedt, PLS-SEM pristup posebno je koristan kada je cilj istraživanja bolje razumijevanje povećane kompleksnosti teorijskih proširenja poznatih teorija, kao što je to TAM model i njegova različita proširenja [257], [30],
- PLS-SEM pristup često se koristi prilikom razvoja neke teorije (pa tako i slabo razvijene teorije o faktorima utjecaja na prihvaćanje javnih usluga e-participacije)[75] i potrebno ga je koristiti kada se analiza bavi testiranjem teorijskog okvira iz perspektive predviđanja, odnosno kada je cilj predviđanje/istraživanje (eng. *prediction/explanation*) proširenja postojećih teorija [258],
- U skladu s time, a kao što se u poglavlju „Klasifikacija indikatora – reflektivni i formativni konstrukti„ svi su konstrukti reflektivni jer prema Chin „ako je cilj predviđanje/istraživanje, potrebno je koristiti reflektivni dizajn indikatora“ [259],
- Kada je u istraživanju uzorak mali (što je u ovom radu i slučaj, *non-random* uzorak od 400 građana iz populacije veličine 2 000 000 građana, dakle uzorak je 0.02 % populacije),

[74] Kock u svojem članku iz 2019.godine predlaže najnoviju PLSF metodu SEM-a (eng. *PLS-SEM with factor estimation*) [256].
[75] Cilj je predviđanje ključnih konstrukata koji bi mogli utjecati na prihvaćanje ovih informacijskih sustava integracijom više različitih teorija prihvaćanja što je jedna karakteristika PLS-SEM metode.

- Također, pojedini konstrukti mjere se malim brojem čestica (4 čestice u ovom radu),
- Wold drži uopće upitnim primjenjivost CB-SEM-a u društvenim znanostima gdje u pravilu priroda distribucije podataka nije poznata, teorija je u nastajanju i znanje je ograničeno [249].

Postoje dvije različite teorije koje se testiraju kada se donose kauzalne tvrdnje. Prva se naziva mjernom teorijom i ocjenjuje se pomoću mjernog modela.[76] Druga teorija je uzročna teorija i ocjenjuje se pomoću strukturalnog modela. Strukturalni model uključuje testiranje tvrdnji u obliku hipoteza [260] [261]. Analiza dobivenih podataka provedena je dvostupanjskom metodologijom koristeći SmartPLS v. 3.2.8. softver.[77]

6.3.3. Klasifikacija indikatora – reflektivni i formativni konstrukti

Ovisno o teorijski utemeljenoj perspektivi uzročno-posljedičnih veza među latentnim i manifestnim varijablama, moguće je razaznati vanjski (mjerni) reflektivni i vanjski (mjerni) formativni model [9]. Edwards i Bagozzi u svom članku „*On the Nature and Direction of Relationships Between Constructs and Measures*" smatraju kako „autori tijekom razvoja neke teorije prevelik naglasak stavljaju na utvrđivanje veza između konstrukata, a premalo na vezu između konstrukata i opaženih mjera". U istom članku oni daju smjernice za određivanje veza između konstrukata i opaženih mjera [10]. O postupku razvoja skale mjerenja pa samim time i svojstvima čestica skale govori i rad Abbassi i dr. pod nazivom „*Engagement in Games: Developing an Instrument to Measure Consumer Videogame Engagement and Its Validation*". Prema ovim autorima, ako se radi o reflektivnom konstruktu[78], čestice će imati zajedničku temu (eng. *common theme*), bit će zamjenjive, a brisanje ili dodavanje čestice neće mijenjati značenje konstrukta. Nasuprot tome, ako je konstrukt formativan[79], čestice nemaju zajedničku temu, nisu zamjenjive i brisanje ili dodavanje čestice mijenja značenje samog konstrukta [199].

Dakle, sumarno pravilo je da ako indikatori egzogene latentne varijable nisu međusobno zamjenjivi, oni su formativni, odnosno ako su indikatori zamjenjivi, visoko korelirani i međusobno ovisni, oni su reflektivni što znači da njihova pouzdanost (eng. *reliability*) i valjanost (eng. *validity*) treba biti ispitana [227].

[76] Kod PLS-SEM-a reflektvni mjerni model često se naziva Modom A, a formativni Modom B [258].
[77] Ringle, C. M., Wende, S., and Becker, J.-M. 2015. "SmartPLS 3." Boenningstedt: SmartPLS GmbH, http://www.smartpls.com.
[78] U literaturi zvan još i *principal factor model* [262].
[79] U literaturi zvan još i *composite latent variable model* [262].

U ovom su slučaju konstrukti uzroci mjera[80], indikatori su međusobno zamjenjivi i dijele zajedničku temu (mjere isti temeljni fenomen) te promjena u jednom indikatoru implicira promjenu kod drugog indikatora, što znači da su u ovom istraživanju svi konstrukti reflektivni. Slaže se sa time i Petter i dr. kada kažu da se „reflektivni konstrukti koriste u literaturi o informacijskim sustavima za koncepte kao što su to očekivana jednostavnost upotrebe, očekivana korisnost i zadovoljstvo“ [263], [264]. I Pousttchi tvrdi isto kad kaže da su „reflektivni indikatori puno češće korišteni u istraživanju informacijskih sustava, pa su tako korišteni i od strane Davisa i Ajzena u njihovim modelima (TAM i TPB, op.a.)“ [265].[81] Uostalom, prema TAM modelu kao modelu na kojem je ovo istraživanje i bazirano, stvarno ponašanje (korištenje, upotreba) uvijek ovisi o namjeri ponašanja (koju mi ispitujemo) a koja je pak uvijek rezultat stava prema korištenju. A stavovi se, prema Haenlein i Kaplan uvijek opisuju reflektivnim česticama [267].[82]

6.3.4. Procjena mjernog (vanjskog) modela – mode A

Kao što je vidljivo i na SEM dijagramu puta, mjerni model prikazuje prirodu veza između manifestnih varijabli (indikatora) i latentnih varijabli korištenog modela. Procjena (evaluacija, vrjednovanje) mjernog (vanjskog) modela, kao prvi korak u dvostupanjskoj metodologiji, sastoji se od ispitivanja svojstva pouzdanosti i valjanosti prema određenim kriterijima [258]. Naime, reflektivni konstrukti obuhvaćaju pretpostavke klasične teorije testiranja, što znači da je potrebno izvršiti utvrđivanje konstruktne valjanosti uz pomoć konfirmatorne faktorske analize (odnosno drugim riječima, utvrditi konvergentnu i diskriminantnu valjanost) kao i testirati pouzdanost [268].

Hair zajedno s Ringle kao jednim od originalnih autora popularnog softvera SmartPLS, u članku pod nazivom „Kada koristiti i kako izvještavati o rezultatima PLS-SEM“ spominju metrike koje je potrebno primijeniti kako bi se procijenili PLS-SEM rezultati (tzv. PLS-SEM evaluacijski kriteriji) i cjelokupni proces evaluacije mjernog modela raščlanjuju na četiri koraka [30].[83]

[80] Što to u stvari znači? To znači da promjena u odgovorima kod npr. latentnog konstrukta „Očekivana jednostavnost promijene“ uzrokovat da sve opažene mjere reflektiraju tu promjenu.
[81] Icek Ajzen, idejni tvorac TPB, u svojim radionicama pod nazivom „Teorija planiranog ponašanja susreće modeliranje strukturalnim jednadžbama“ između ostalog podučava znanstvenike i doktorande kako konstruirati TPB upitnik s reflektivnim indikatorima [266].
[82] Velika većina radova potvrđuje ovakav smjer razmišljanja. Tako i u radovima gdje se ispituje namjera korištenja Web e-lerning sustava u pravilu koriste samo reflektivne čestice [218].
[83] U ovom radu, prema uputama za pisanje i objavljivanje znanstvenih i stručnih radova, standardne metode pa tako i PLS-SEM ne opisuju se detaljno, već se navode imenom i referencom [269].

Prema istim autorima, kod procijene reflektivnog mjernog modela **prvi korak** je ispitati pouzdanost pojedine čestice tj. indikatora, odnosno ustanoviti vanjska opterećenja indikatora (eng. *indicator outer loadings*) [30]. U svome radu, Hair i dr. traže da se čestice s vanjskim opterećenjem ispod 0,40 uklone iz daljnje analize, kao i čestice s vanjskim opterećenjem 0,40 - 0,70 ali samo ako njihovo brisanje pozitivno utječe na prosječnu ekstrahiranu varijancu [261]. Identificirane su takve čestice i uklonjene iz daljnje analize. U nastavku analize koristio se takav pročišćeni model.

Prema Hair i dr., **drugi korak** je ispitivanje pouzdanosti konstrukta, odnosno procjena pouzdanosti unutarnje konzistencije (eng. *internal consistency reliability*) koju je moguće utvrđivati preko Cronbachovog alfa koeficijenta (eng. *Cronbachs alpha*) i kompozitne pouzdanosti (eng. *composite reliability)* [261].[84] Hair i dr. predložili su da je pouzdanost skale prihvatljiva ako je vrijednost Cronbachovog alfa i kompozitne pouzdanosti za svaki konstrukt u rasponu od 0,60 i više [270] [271]. Tražene vrijednosti prikazane su u Tablici 23.

Valjanost mjernog modela moguće je mjeriti konvergentnom i divergentnom valjanošću pa se tako **treći korak** procijene reflektivnog mjernog modela bavi pitanjem konvergentne valjanosti svakog konstrukta. Metrika koja se koristi za procjenu konvergentne valjanosti konstrukta je prosječna ekstrahirana (izlučena) varijanca (eng. *Avarage Variance Extracted,* AVE). Prihvatljiva vrijednost za AVE je 0,50 i više što indicira da konstrukt u prosjeku objašnjava 50 % ili više varijance pridruženih manifestnih varijabli) [270].

Četvrti korak kao završni korak je procjena diskriminantne valjanosti prema kriterijima koje su predložili Fornell i Larcker u svojem često citiranom članku iz 1981. godine [272]. Prema tome kriteriju, diskriminantna valjanost[85] nekog konstrukta uspostavljena je kada je vrijednost drugog korijena od AVE ($\sqrt{AVE}$) određenog konstrukta veća od korelacije između tog konstrukta i drugih konstrukta u vanjskom reflektivnom modelu [54] [273].

Drugi popularni pristup utvrđivanju diskriminantne valjanosti jeste izračun unakrsnih opterećenja (eng. *cross-loadings*) što se još naziva i diskriminantna valjanost na razini čestice [274]. Manifestne varijable trebale bi imati veći stupanj korelacije s latentnom varijablom koju opisuju u odnosu na druge latentne varijable. I ove su vrijednosti izračunate i prikazane u prikladnoj tablici.

[84] Neki autori kompozitnu pouzdanost vrijednost promatraju u okviru konvergentne valjanosti, kao npr. [270]. No ovaj rad u potpunosti prati preporuke Hair i dr.
[85] Neki autori koriste izraz divergentna valjanost.

Treći pristup je novijeg datuma, odnosno recentni radovi zahtjevaju korištenje heterotrait-monotrait omjera korelacije (eng. *Heterotrait-Monotrait Ratio of Correlations*, HTMT) kao novog kriterija za provjeru diskriminantne valjanosti kod PLS-SEM analize. I ovaj je omjer izračunat i prikazan u prikladnoj tablici.

6.3.5. Procjena strukturalnog (unutarnjeg) modela i testiranje hipoteza

Strukturalni model prikazuje uzročnu vezu između latentnih varijabli. Testiranje i procjena rezultata strukturnog modela, kao drugi korak u dvostupanjskoj metodologiji, omogućava određivanje sposobnosti modela u predviđanju jednog ili više ciljnih konstrukta [258] [184].

Prije procjene strukturalnih veza, kao **prvi korak** neki autori smatraju kako je poželjno provjeriti kolinearnost, pa je tako prije testiranja povezanosti latentnih konstrukata strukturalnog modela ispitana kolinearnost između latentnih konstrukata uz pomoć faktora inflacije varijance (eng. *variance inflation factor*, VIF). I u ovom slučaju literatura obiluje različitim iskustvenim pravilima (eng. *rules of thumb*). Iako literatura nudi više referentnih vrijednosti (negdje i VIF < 10), većina autora smatra kako za reflektivne mjerne modele vrijednosti manje od 5 ne predstavljaju problem u daljnjoj analizi [275]. U ovom radu korišteni SmartPLS v. 3.2.8. softver također vrijednosti manje od 5 ne smatra kritičnim (ne boja ih u crveno).

Prema smjernicama za korištenje PLS-SEM-a u istraživanjima informacijskih sustava, **drugi korak** kod evaluacije PLS modela jeste izračun koeficijenta determinacije R^2 endogenog konstrukta. R^2 vrijednost predstavlja mjeru eksplanatorne (prediktivne) snage (hrv. objasnidbene snage) i upućuje na količinu varijance u konstruktu (endogenoj varijabli) koja je objašnjena prethodnim varijablama u strukturalnom modelu [276]. Prema tome, R^2 ukazuje na kvalitetu prilagođenog modela [277].

Nadalje, Cohen-ov f^2 koeficijent govori o jačini utjecaja, efekta (eng. *effect size*) pojedinih koeficijenata puta strukturalnog modela. Jačina efekta mjeri imali nezavisna latentna varijabla značajni utjecaj na zavisnu. Vrijednost 0,02 predstavlja malu, 0.15 srednju a 0.35 veliku jačinu utjecaja [278].

Hair i dr. spominju i druge načine procjene prediktivne točnosti PLS modela puta kao što je to npr. izračun Stone-Geisser indikatora Q^2. Ova je metrika bazirana na tzv. *blindfolding* proceduri. Već Q^2 vrijednost veća od 0 implicira da model ima prediktivnu relevantnost, dok

vrijednosti veće od 0, 0,25 i 0,50 predstavljaju vrijednosti male, srednje i velike prediktivne točnosti (relevantnosti) nekog PLS modela [30].

Kao **treći korak**, literatura govori o potrebi izračunavanja relevantnosti koeficijenata puta (eng. *path coeficioents*) i njihove statističke signifikantnosti. Vrijednost (težina) koeficijenata puta omogućava rangiranje njihove relativne statističke važnosti. Odnosno, ako je jedan koeficijent puta veći od drugog, veći je i njegov utjecaj na endogenu varijablu [227]. Koeficijenti puta modela strukturalnih jednadžbi predstavljaju standardizirane regresijske koeficijente i prikazuju direktan utjecaj nezavisne varijable na zavisnu, odnosno pokazuju udio pojedinih endogenih latentnih varijabli u objašnjavanju zajedničke varijance. Vrijednosti *path* koeficijenata u rasponu su od -1,00 do +1,00 i vrijednost bliže +1,00 predstavljaju statistički jaku pozitivnu vezu među varijablama (veća relativna važnost) [261].

Analizom strukturalnog modela može se zaključiti kako su veze među varijablama različite jačine, no kako znamo jesu li koeficijenti puta signifikantni?

Da bi se utvrdila statistička signifikantnost i važnost strukturalnih putanja, PLS-SEM koristi tzv. *bootstraping* proceduru. *Bootstrapping* procedura ponovnog uzorkovanja izvorno je namijenjena vrednovanju značajnosti koeficijenata puta između egzogenih i endogenih latentnih konstrukata u unutarnjem modelu. *Bootstrapping* uzorci generiraju se na način da se opažanja iz originalnog uzorka odabiru nasumično i nakon toga PLS algoritam za sve *bootstrapping* uzorke izračunava koeficijente puta, tvoreći tako *bootstrap* distribuciju procjenjenih koeficijenata puta. Bazirajući se na toj distribuciji, algoritam računa standardnu pogrešku i standardnu devijaciju procijenjenih koeficijenata. Vrijednosti dobivene *bootstrapping* procedurom omogućuju izračun t-statistike koristeći formulu

$$t_i = \frac{w_i}{se\,(w_i)}$$

gdje t_i gdje 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 pogreška [259], [9].

Iako je signifikantnost nekog koeficijenta puta moguće utvrđivati i na osnovu empirijskih t-vrijednosti (ukoliko je empirijski utvrđena t-vrijednost veća od npr. referentne vrijednosti 1,96 za stupanj signifikantnosti $\alpha = 5$ %, pretpostavljamo da je koeficijent puta signifikantno drugačiji od nule i prihvaća se hipoteza o značajnosti koeficijenta puta), Hair i dr. ističu da

većina autora koristi p-vrijednosti za procjenu signifikantnosti [279], [261]. *Bootstraping* algoritam paralelno s t-vrijednostima daje i p-vrijednosti (eng. *p-values*, *probability values*) uz pomoć kojih je također moguće potvrditi ili ne potvrditi neku hipotezu, odnosno postojanje povezanost između dvije varijable.

Naime, ako se nultom hipotezom tvrdi da ne postoji veza između izmjerenog fenomena (zavisne varijable) i nezavisne varijable, p-vrijednost predstavlja vjerojatnost pogrešnog odbacivanja točne nulte hipoteze (tj. pretpostavljajući signifikantan učinak iako ga u biti nema). U većini se istraživanja, pa tako i u ovom, pretpostavlja stupanj signifikantnosti od 5 %[86], što znači da p-vrijednost mora biti manja od 0,05 kako bi se odnos koji se promatra proglasio signifikantnim (odnosno, odbacila nulta hipoteza i potvrdila alternativna hipoteza[87]) [261].

Sumarno, ako je dobivena p-vrijednost manja od zadanog stupnja signifikantnost α, hipoteza se potvrđuje. Odnosno, u slučaju da je α = 5 %, p-vrijednost manja od 0,05 statistički je signifikantna i indicira jak dokaz protiv nulte hipoteze (tek je manje od 5 % vjerojatnosti da je nulta hipoteza točna, tako da se odbacuje nulta hipoteza i potvrđuje alternativna) [281].[88]

[86] Vjerojatnost počinjenja greške tipa I. (odbacivanje nulte hipoteze dok je u biti točna) zove se α, odnosno stupanj statističke signifikantnosti. Što se tiče stupnja signifikantnosti (eng. *level of significance*), najčešće korišteni stupanj signifikantnost upravo je 0,05 (ili 5 %) što znači da postoji 5 % vjerojatnost da će se testiranjem odbaciti točna nulta hipoteza (hipoteza da je koeficijent puta jednak nuli, odnosno da ne postoji povezanost zavisne i nezavisne varijable). Stupanj signifikantnosti lako se prevodi u 95 % stupanj pouzdanosti (eng. *level of confidence*) s značenjem da provođenjem niza testiranja hipoteza, u 95 % slučajeva neće doći do greške tipa I. [280].

[87] Izvorna hipoteza istraživača u radu.

[88] To ne znači da je 95 % vjerojatnost da je izvorna hipoteza u istraživanju točna.

7. REZULTATI EMPIRIJSKOG ISTRAŽIVANJA

„U osnovi svi su modeli krivi, no neki su korisni“.

George E.P. Box, engeski statističar

U empirijskim se istraživanjima istina, odnosno pojave i činjenice, spoznaju vlastitim iskustvom, odnosno provođenjem primarnog istraživanja.

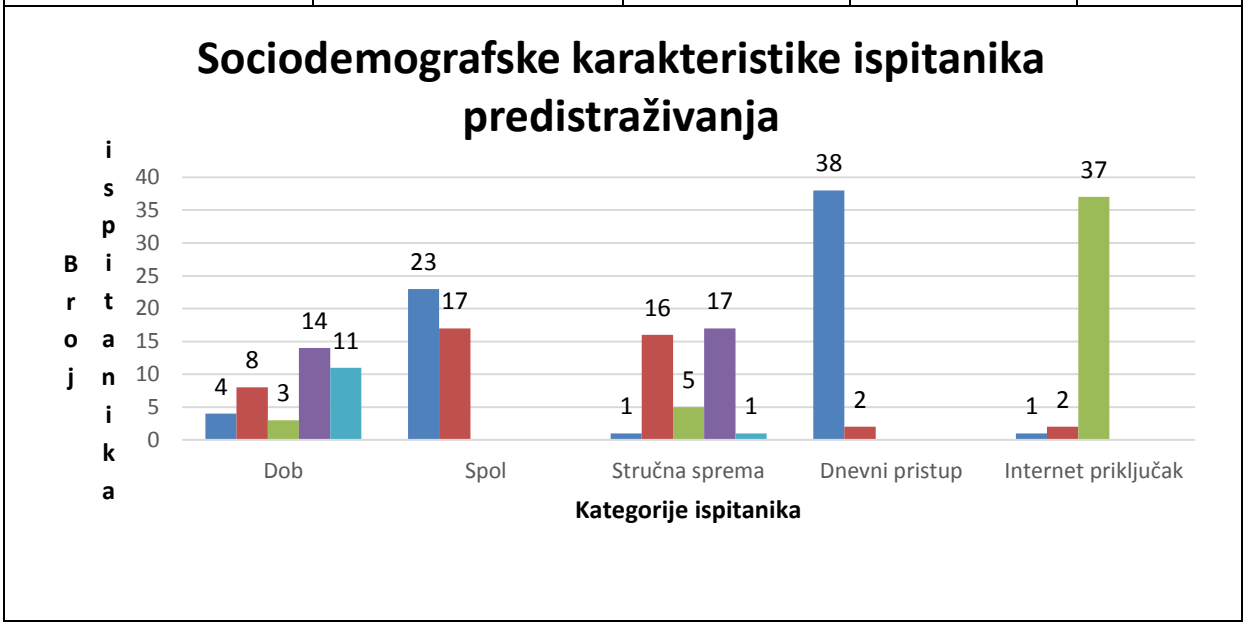
Hipotezama na temelju integriranog modela pokušat će se pokazati da li pojedine varijable proširenog modela utječu na namjeru korištenja usluga elektroničke uprave. Nadalje, analiza podataka vezana uz strukturu namjere korištenja pokazala bi naglašene potrebe građana za određenom razinom javnih usluga e-participacije.

7.1. Predistraživanje - sociodemografske karakteristike ispitanika

U ovom se dijelu rada prezentiraju sociodemografske karakteristike ispitanika predistraživanja.

Tablica 12: Karakteristike uzorka – distribucija frekvencija u predistraživanju

Varijabla	Kategorija	Frekvencija	Postotak	Legenda
Dob	16 – 26	4	10 %	
	27 – 35	8	20 %	
	35 – 42	3	7,5 %	
	43 – 50	14	35 %	
	50 – 74	11	27,5 %	
	Total	40	100 %	
Spol	M	23	57,5 %	
	Ž	17	42,5 %	
	Total	40	100 %	
Stručna sprema	NSS	1	2,5 %	
	SSS	16	40 %	
	VŠS (bacc.)	5	12,5 %	
	VSS (mag.)	17	42,5 %	
	Mr.sc./Dr.sc.	1	2,5 %	
	Total	40	100 %	
Dnevni pristup	Da	38	95 %	
	Ne	2	5 %	
	Total	40	100 %	
Internet priključak	Samo kod kuće	1	2,5 %	
	Samo na poslu	2	5 %	
	Oboje	37	92,5 %	
	Total	40	100 %	



Iz Tablice 12. vidljivo je da je najveći postotak ispitanika u predistraživanju, njih čak 35 %, spadao je u kategoriju ispitanika od 43 do 50 godina starosti. Nešto je više bilo muškaraca (57,5 %, 15 % više nego žena) i prevladavala je visoka stručna sprema (42,5 %). Što se tiče dnevnog pristupa Internetu, 95 % ispitanika u predistraživanju odgovorilo je da dnevno pristupa Internet stranicama, dok 92,5 % ispitanika Internet priključak posjeduje i kod kuće i na poslu.

7.1.1. Pouzdanost instrumenta u predistraživanju – Cronbachov alfa

Tablica 13. Cronbachov alfa koeficijent pouzdanosti skala korištenih u predistraživanju

Konstrukt	Broj čestica	Cronbachov alfa
Očekivana korisnost (OK)	6	0,718
Očekivana jednostavnost upotrebe (OJU)	6	0,733
Povjerenje u Internet (PUI)	5	0,854
Povjerenje u državu (PUD)	4	0,896
Stav prema ponašanju (SPP)	4	0,762
Subjektivna norma (SN)	4	0,777
Očekivana kontrola ponašanja (OKP)	4	0,833
Namjera korištenja (NK)	3	0,903

Najveći broj autora za potvrđivanje pouzdanost mjerne ljestvice preporučuje minimalnu vrijednost Cronbachovog alfa od 0.7 [226], [30]. Dobivene vrijednosti prikazane su u Tablici 13. i kreću se u rasponu od 0,718 do 0,903 što ukazuje na zadovoljavajući stupanj unutarnje konzistencije, odnosno dosljednosti skala.

Kao što je u poglavlju „6.2.3. Valjanost instrumenta u predistraživanju“ već naglašeno, zbog specifičnosti odabira čestica u ovom istraživanju provjera valjanosti skala nije provedena.

U skladu s time, može se zaključiti da je tijekom predistraživanja anketni upitnik kao glavni instrument istraživanja zadovoljio zahtijevane evaluacijske kriterije.

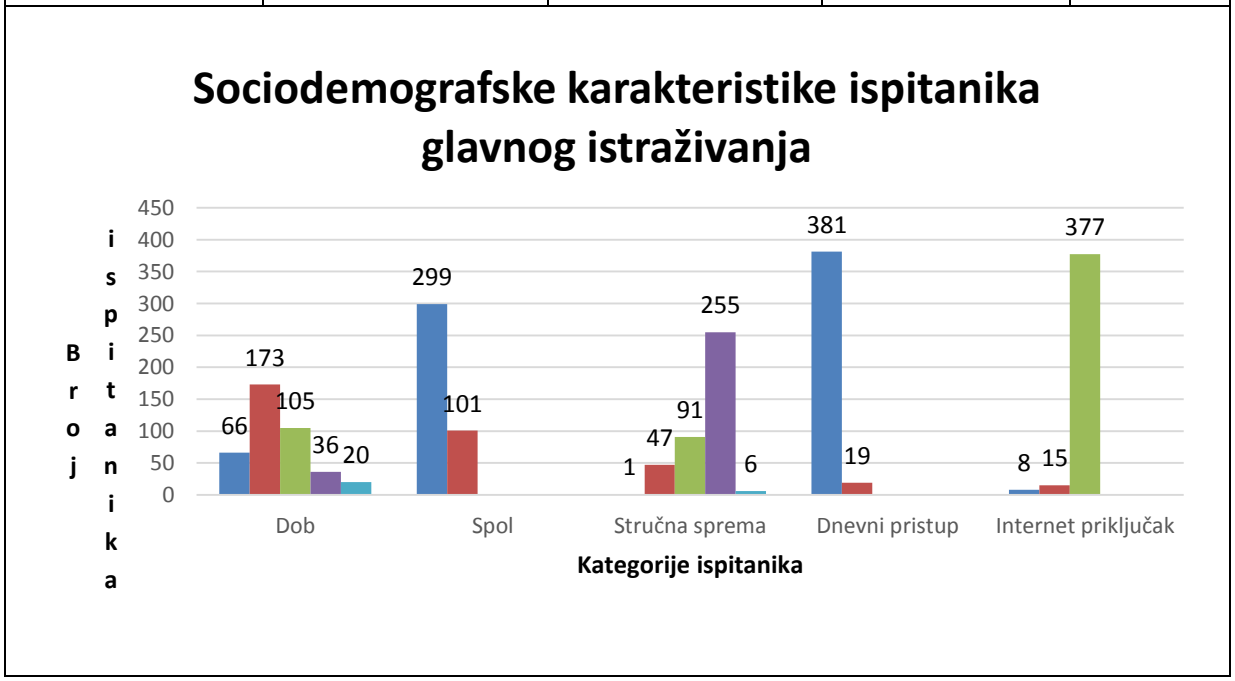
7.2. Glavno istraživanje - sociodemografske karakteristike i deskriptivna statistika ispitanika

Ovo poglavlje bavi se analizom prikupljenih podataka iz *online* ankete. U poglavlju „6.1. razvoj mjernih skala anketnog upitnika“ predstavljene su čestice ankete kao i njihov poredak. U ovom se pod poglavlju prezentira deskriptivna statistika glavnog istraživanja, odnosno analiziraju se i opisuju podaci (odgovori) glavnog anketnog istraživanja.

Tablica 14. daje osnovne podatke učesnika u anketi vezano uz dob, spol, stručnu spremu, dnevno pristupanje i podatak vezano uz Internet priključak.

Tablica 14: Karakteristike uzorka – distribucija frekvencija u glavnom istraživanju (N=400)

Varijabla	Kategorija	Frekvencija	Postotak	Legenda
Dob	16 – 26	66	16,5 %	
	27 – 35	173	43,3 %	
	35 – 42	105	26,2 %	
	43 – 50	36	9 %	
	50 - 74	20	5 %	
	Total	400	100 %	
Spol	M	299	74,8 %	
	Ž	101	25,2 %	
	Total	400	100 %	
Stručna sprema	NSS	1	0,3 %	
	SSS	47	11,8 %	
	VŠS (bacc.)	91	22,8 %	
	VSS (mag.)	255	63,8 %	
	Mr.sc./Dr.sc.	6	1,3 %	
	Total	400	100 %	
Dnevni pristup	Da	381	95,3 %	
	Ne	19	4,7 %	
	Total	400	100 %	
Internet priključak	Samo kod kuće	8	2 %	
	Samo na poslu	15	3,7 %	
	Oboje	377	94,3 %	
	Total	400	100 %	



Iz Tablice 14. vidljivo je da je najveći postotak ispitanika u glavnom istraživanju, njih čak 43,3 %, spadao je u kategoriju ispitanika od 27 do 35 godina starosti. Znatno je više bilo muškaraca (74,8 %, gotovo 50 % više nego žena) i prevladavala je visoka stručna sprema (63,8 %). Što se tiče dnevnog pristupa Internetu, 95,3 % ispitanika u glavnom istraživanju

odgovorilo je da dnevno pristupa Internet stranicama, dok 94,3 % ispitanika Internet priključak posjeduje i kod kuće i na poslu.

Deskriptivna statistika opisuje osnovne osobine podataka prikupljenih u istraživanju. No pitanje deskriptivne statistike anketnog istraživanja baziranog na ordinalnoj ljestvici Likertovog tipa kao sumi odgovora na Likertove čestice i nije tako jednostavno kao što se to na prvi pogled čini. Većina autora koristi aritmetičku sredinu i standardnu devijaciju u deskriptivnom opisivanju prikupljenih podataka. Izjavi „u potpunosti se ne slažem“ se tako pridodaje broj jedan (1), izjavi „ne slažem se“ broj dva (2) itd. sve do najvećeg broja koji označava izjavu „u potpunosti se slažem“ i u ovom slučaju to je broj pet (5). Na kraju se izračunava aritmetička sredina i ako je ona veća od 3, autor zaključuje da se radi o općenitom prihvaćanju neke izjave.

Međutim, sve su brojniji kritičari takvog deskriptivnog opisivanja ljestvice Likertovog tipa koja je u svojoj biti ordinalna skala, odnosno brojevi u ljestvici Likertovog tipa nisu prirodni brojevi u pravom smislu riječi, već način rangiranja odgovora [282]. Uostalom, koji je prosjek odgovora izjava „u potpunosti se slažem i „ne slažem se“ [283]?[89]

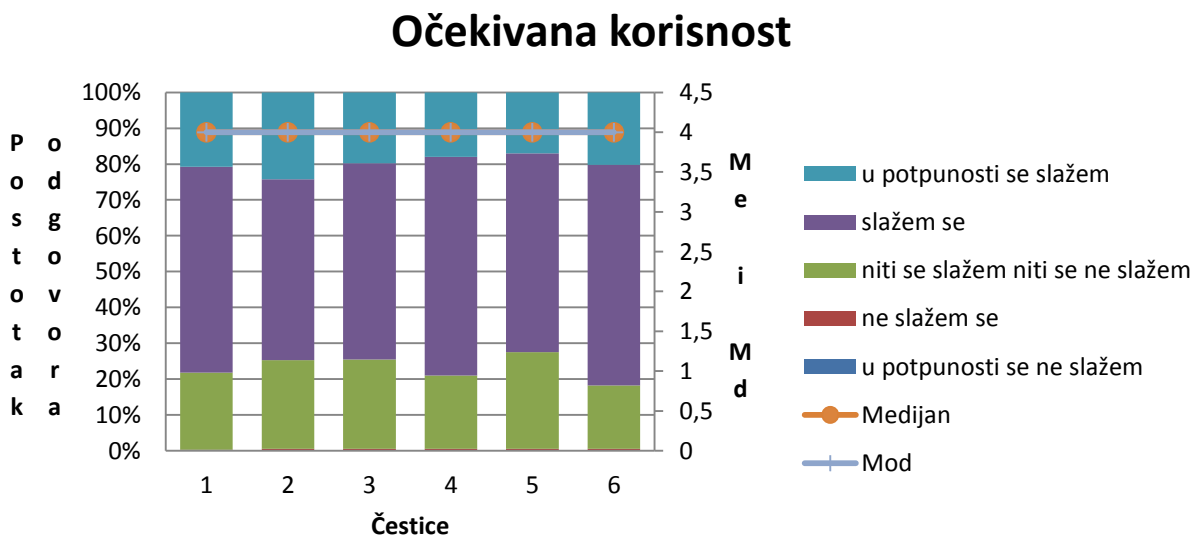
Odnosno kako to Jamieson kaže, „prosjek od „zadovoljavajuće“ i „dobro“ nije „polu-zadovoljavajuće čak i kad iskazima „zadovoljavajuće“ i „dobro“ pridodamo prirodne brojeve“ [284].

Ta druga struja autora (kojoj i autor ovog rada pripada) smatra da postoji i konstruktivniji način pristupa analizi podataka dobivenih iz ordinalnih ljestvica Likertovog tipa, a to je preko medijana i moda kao mjera središnje tendencije i s stupčanim grafikonom kao najboljim grafičkim načinom prikazivanja distribucije odgovora [285] [284]. Medijan, kao u ostalom i srednja vrijednost i mod, mjera je središnje tendencije niza podataka. Medijan je vrijednost koja se nalazi točno na sredini niza vrijednosti (prilikom računanja, podatke je prvo potrebno sortirati po veličini). Mod je najčešća, dominantna vrijednost niza, odnosno najčešći odgovor na svaku izjavu (prilikom računanja, podatke je korisno, ali ne i nužno, poredati po veličini).

[89] “*The average of ‘fair’ and ‘good’ is not ‘fair-and-a-half’; which is true even when one assigns integers to represent ‘fair’ and ‘good*’!” [284].

Tablica 15. Deskriptivna statistika skale „Očekivana korisnost“

Izjave	„u potpunosti se ne slažem“ (1)	„ne slažem se“ (2)	„niti se slažem niti se ne slažem“ (3)	„slažem se“ (4)	„u potpunosti se slažem“ (5)	Medijan	Mod
Očekivana korisnost (OK)							
1. Korištenje online javnih usluga e-participacije omogućava mi da određene aktivnosti obavim brže.	0 %	0.3 %	21,5 %	57,5 %	20.8 %	4	4
2. Korištenje online javnih usluga e-participacije podiže moju efikasnost.	0 %	0,5 %	24,8 %	50,5 %	24,3 %	4	4
3. Korištenje online javnih usluga e-participacije za mene je praktično	0 %	0,5 %	25,0 %	54,8 %	19,8 %	4	4
4. Korištenje online javnih usluga e-participacije za mene ima puno prednosti.	0 %	0,5 %	20,5 %	61,0 %	18,0 %	4	4
5. Korištenje online javnih usluga e-participacije učinit će moj život udobnijim.	0 %	0,5 %	27,0 %	55,5 %	17,0 %	4	4
6. Općenito gledano, korištenje online e-participacijskih javnih usluga za mene je korisno.	0 %	0,5 %	17,8 %	61,5 %	20,3 %	4	4

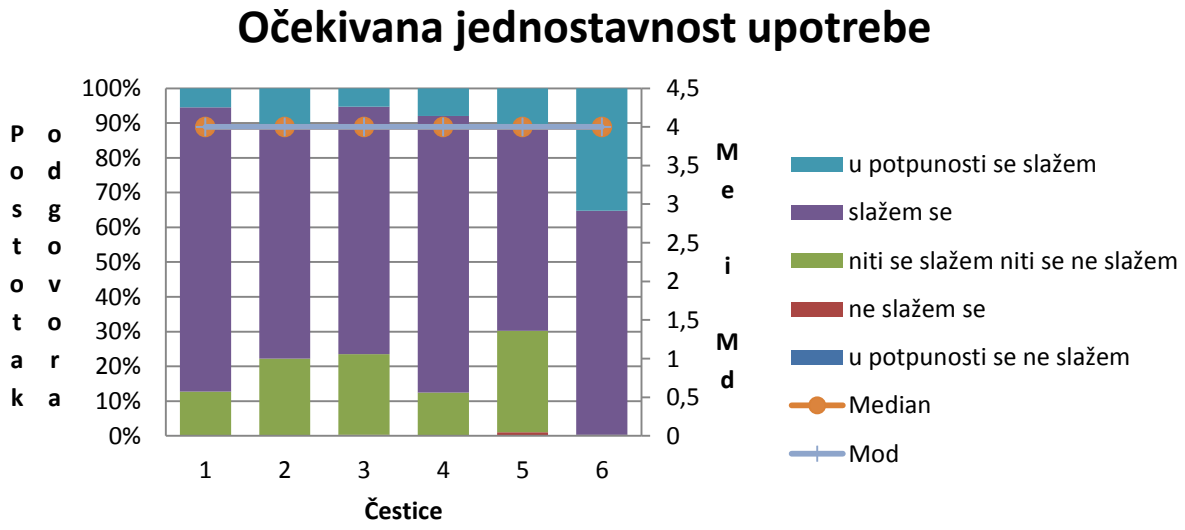


Iz gornje Tablice 15. vidljivo je da je za svaku izjavu latentnog konstrukta „Očekivana korisnost“ kao najčešća, dominantna, Mod vrijednost bila 4, odnosno prema poglavlju „6.1. Razvoj mjernih skala anketnog upitnika“ možemo reći da je najčešći odgovor na svaku izjavu bio „4. slažem se“. Medijan svake izjave također iznosi 4, što nam također govori o središnjoj

tendenciji niza dobivenih podataka (odgovora), odnosno 50% ispitanika (200) za svaku je izjavu odgovorilo ili s „1. u potpunosti se ne slažem“, ili s „2. ne slažem se“, ili s „3. niti se slažem niti se ne slažem“, ili s „4. slažem se“, dok je 50 % ostalih ispitanika (200) za svaku izjavu odgovorilo ili s „4. slažem se“ ili s „5. u potpunosti se slažem“.

Tablica 16. Deskriptivna statistika skale „Očekivana jednostavnost upotrebe“

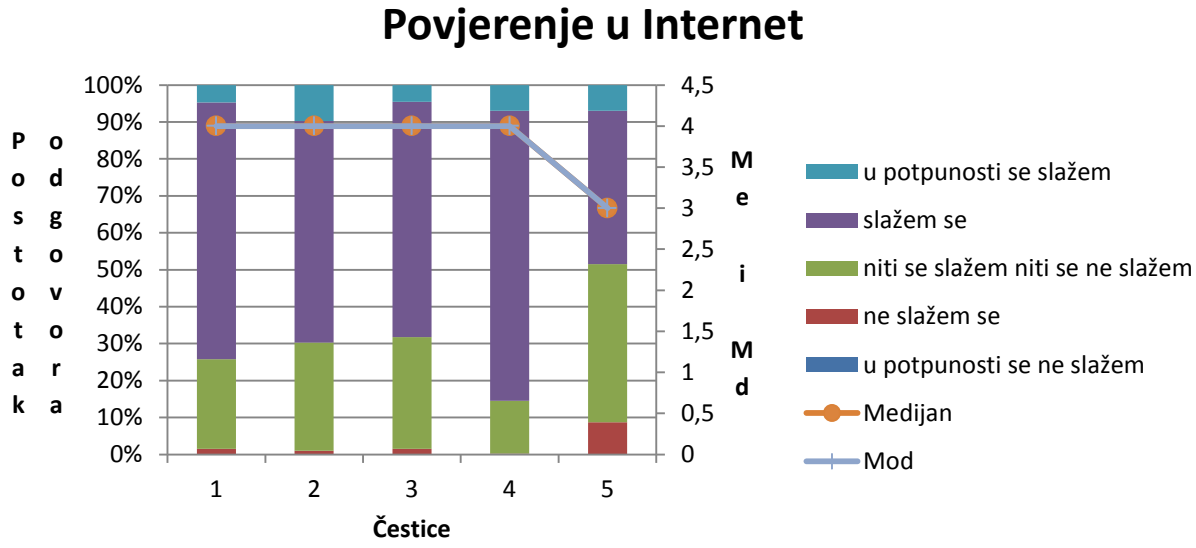
Izjave	„u potpunosti se ne slažem“ (1)	„ne slažem se“ (2)	„niti se slažem niti se ne slažem“ (3)	„slažem se“ (4)	„u potpunosti se slažem“ (5)	Medijan	Mod
Očekivana jednostavnost upotrebe (OJU)							
1. Naučiti upotrebljavati online javne usluge e-participacije za mene je lako.	0 %	0 %	12,8 %	81,8 %	5,5 %	4	4
2. Komuniciranje preko online javnih usluga e-participacije ne zahtijeva mnogo mentalnog napora.	0 %	0 %	22,3 %	67,5 %	10,3 %	4	4
3. Moja interakcija s online javnim uslugama e-participacije jednostavna je i razumljiva.	0 %	0,3 %	23,3 %	71,3 %	5,3 %	4	4
4. Komuniciranje preko online javnih usluga e-participacije jeste prilagodljivo.	0 %	0 %	12,5 %	79,5 %	8,0 %	4	4
5. Mogu lagano postati vješt u korištenju online javnih usluga e-participacije.	0 %	1,0 %	29,3 %	58,0 %	11,8 %	4	4
6. Općenito, online javne usluge e-participacije jednostavne su za upotrebu.	0 %	0 %	0,3 %	64,5 %	35,3 %	4	4



Iz gornje Tablice 16. vidljivo je da je za svaku izjavu latentnog konstrukta „Očekivana jednostavnost upotrebe“ kao najčešća, dominantna, Mod vrijednost bila 4, odnosno prema poglavlju „6.1. Razvoj mjernih skala anketnog upitnika“ možemo reći da je najčešći odgovor na svaku izjavu bio „4. slažem se“. Medijan svake izjave također iznosi 4, što nam također govori o središnjoj tendenciji niza dobivenih podataka (odgovora), odnosno 50% ispitanika (200) za svaku je izjavu odgovorilo ili s „1. u potpunosti se ne slažem“, ili s „2. ne slažem se“, ili s „3. niti se slažem niti se ne slažem“, ili s „4. slažem se“, dok je 50 % ostalih ispitanika (200) za svaku izjavu odgovorilo ili s „4. slažem se“ ili s „5. u potpunosti se slažem“.

Tablica 17: Deskriptivna statistika skale „Povjerenje u Internet“

Izjave	„u potpunosti se ne slažem“ (1)	„ne slažem se“ (2)	„niti se slažem niti se ne slažem“ (3)	„slažem se“ (4)	„u potpunosti se slažem“ (5)	Medijan	Mod
Povjerenje u Internet (PUI)							
1. Osjećam se sigurno jer sam pravno i tehnički dobro zaštićen od problema na Internetu koristeći online javne e-participacijske usluge.	0 %	1,5 %	24,3 %	69,5 %	4,8 %	4	4
2. Internet ima dosta sigurnosnih mehanizama kako bi se osjećao ugodno tijekom aktivnosti na stranicama online javnih e-participacijskih usluga.	0 %	1,0 %	29,3 %	60,0 %	9,8 %	4	4
3. Vjerujem da mi enkripcija i ostala tehnološka dostignuća na Internetu omogućavaju sigurnu komunikaciju na stranicama online javnih e-participacijskih usluga.	0 %	1,5 %	30,3 %	63,8 %	4,5 %	4	4
4. Vjerujem da su tehnologije koje podržavaju online javne e-participacijske usluge pouzdane cijelo vrijeme.	0 %	0,3 %	14,3 %	78,5 %	7,0 %	4	4
5. Općenito gledano, vjerujem da je Internet sigurno okruženje za interakciju s online javnim e-participacijskim uslugama.	0 %	8,8 %	42,8 %	41,5 %	7,0 %	3	3

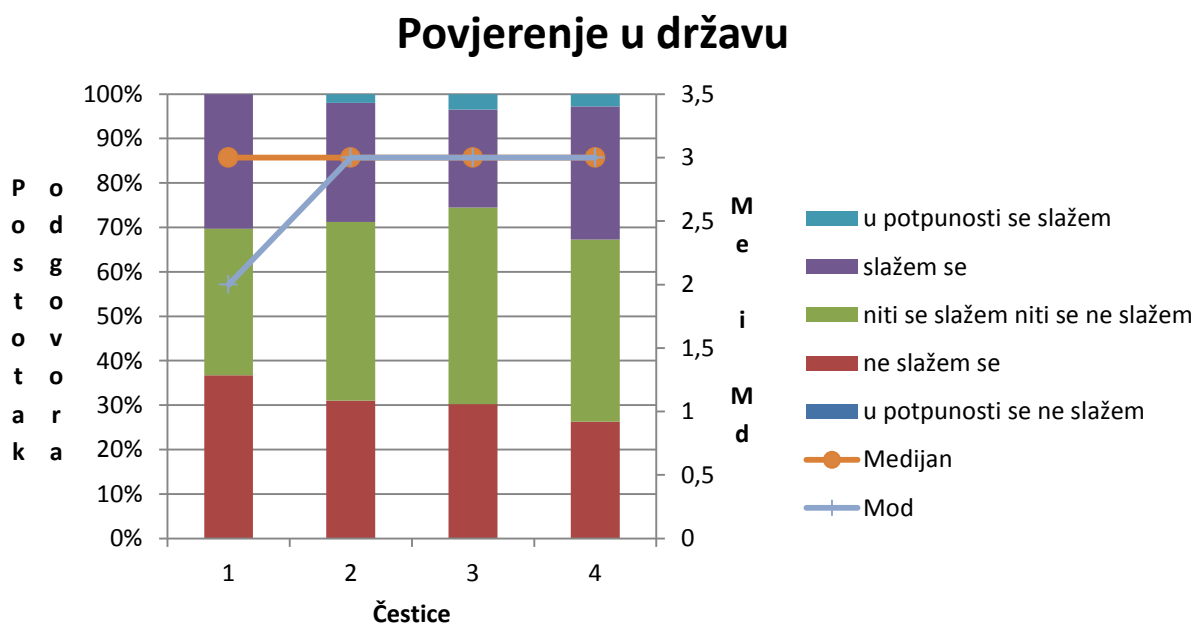


Iz gornje Tablice 17. vidljivo je da je za prve četiri izjave latentnog konstrukta „Povjerenje u Internet“ kao najčešća, dominantna, Mod vrijednost bila 4, odnosno prema poglavlju „6.1.

Razvoj mjernih skala anketnog upitnika“ možemo reći da je najčešći odgovor na svaku izjavu bio „4. slažem se“. Zadnja izjava „5. Općenito gledano, vjerujem da je Internet sigurno okruženje za interakciju s online javnim e-participacijskim uslugama“ ipak ima Mod vrijednost 3, odnosno najčešći odgovor na ovu izjavu bio je „3. niti se slažem niti se ne slažem“. Medijan prve četiri izjave također iznosi 4, što nam također govori o središnjoj tendenciji niza dobivenih podataka (odgovora), odnosno 50% ispitanika (200) za svaku je izjavu odgovorilo ili s „1. u potpunosti se ne slažem“, ili s „2. ne slažem se“, ili s „3. niti se slažem niti se ne slažem“, ili s „4. slažem se“, dok je 50 % ostalih ispitanika (200) za svaku izjavu odgovorilo ili s „4. slažem se“ ili s „5. u potpunosti se slažem“. Zadnja izjava „5. Općenito gledano, vjerujem da je Internet sigurno okruženje za interakciju s online javnim e-participacijskim uslugama“ ipak ima vrijednost medijana 3.

Tablica 18: Deskriptivna statistika skale „Povjerenje u državu“

Izjave	„u potpunosti se ne slažem“ (1)	„ne slažem se“ (2)	„niti se slažem niti se ne slažem“ (3)	„slažem se“ (4)	„u potpunosti se slažem“ (5)	Medijan	Mod
Povjerenje u državu (PUD)							
1. Država je sposobna tijekom korištenja online javnim uslugama e-participacije moje privatne informacije održati tajnima.	0 %	36,5 %	33,0 %	30,0 %	0 %	3	2
2. Država kao davatelj usluga ulijeva mi povjerenje prilikom korištenja online javnim uslugama e-participacije.	0 %	31,0 %	40,3 %	26,8 %	2,0 %	3	3
3. Državne agencije imaju znanja i vještine za provođenje online javnih usluga e-participacije.	0 %	30,3 %	44,3 %	22,0 %	3,5 %	3	3
4. Vjerujem da tijekom korištenja online javnih usluga e-participacije država neće djelovati na način koji bi mi naštetio.	0 %	26,3 %	41,0 %	30,0 %	2,8 %	3	3

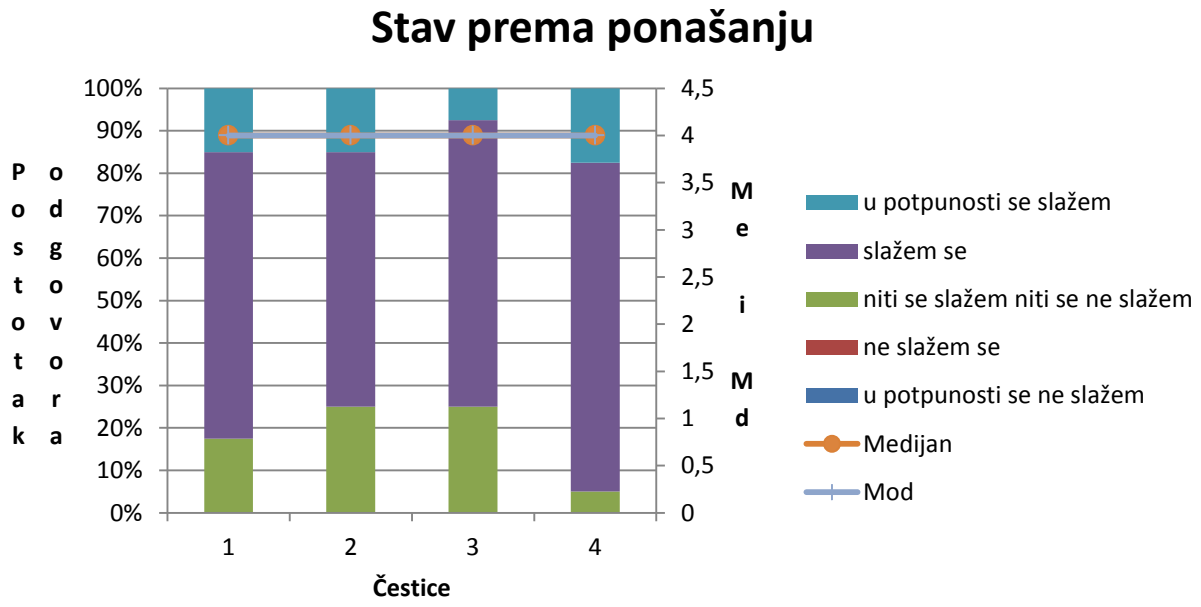


Iz gornje Tablice 18. vidljivo je da je za zadnje tri izjave latentnog konstrukta „Povjerenje u državu“ kao najčešća, dominantna, Mod vrijednost bila 3, odnosno prema poglavlju „6.1. Razvoj mjernih skala anketnog upitnika“ možemo reći da je najčešći odgovor na zadnje tri izjave bio „3. niti se slažem niti se ne slažem“. Prva izjava jedina ima Mod vrijednost 2.

Medijan svake izjave iznosi 3, što nam također govori o središnjoj tendenciji niza dobivenih podataka (odgovora), odnosno 50% ispitanika (200) za svaku je izjavu odgovorilo ili s „1. u potpunosti se ne slažem“, ili s „2. ne slažem se“, ili s „3. niti se slažem niti se ne slažem“, dok je 50 % ostalih ispitanika (200) za svaku izjavu odgovorilo ili s „3. niti se slažem niti se ne slažem“ ili s „4. slažem se“ ili s „5. u potpunosti se slažem“.

Tablica 19: Deskriptivna statistika skale „Stav prema ponašanju“

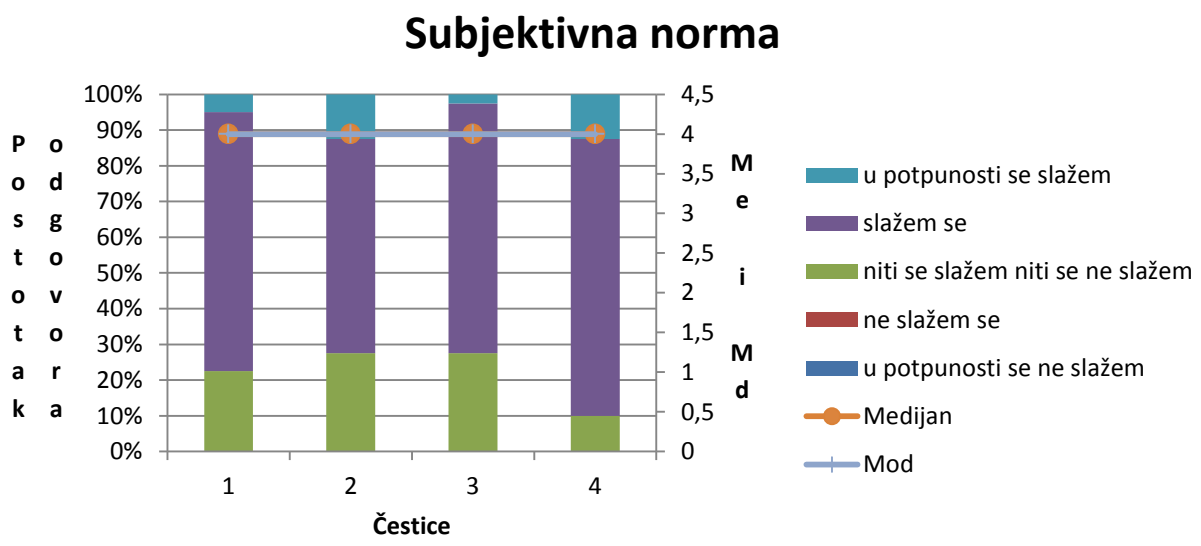
Izjave	„u potpunosti se ne slažem“ (1)	„ne slažem se“ (2)	„niti se slažem niti se ne slažem“ (3)	„slažem se“ (4)	„u potpunosti se slažem“ (5)	Medijan	Mod
Stav prema ponašanju (SPP)							
1. Korištenje online javnih usluga e-participacije za mene je korisno. (SPP_1)	0 %	0 %	17,5 %	67,5 %	15,0 %	4	4
2. Korištenje online javnih usluga e-participacije za mene je pametna ideja. (SPP_2)	0 %	0 %	25,0 %	60,0 %	15,0 %	4	4
3. Sviđa mi se ideja o korištenju online javnih usluga e-participacije. (SPP_3)	0 %	0 %	25,0 %	67,5 %	7,5 %	4	4
4. Imam pozitivno mišljenje o korištenju online javnih usluga e-participacije. (SPP_4)	0 %	0 %	5,0 %	77,5 %	17,5 %	4	4



Iz gornje Tablice 19. vidljivo je da je za svaku izjavu latentnog konstrukta „Stav prema ponašanju“ kao najčešća, dominantna, Mod vrijednost bila 4, odnosno prema poglavlju „6.1. Razvoj mjernih skala anketnog upitnika“ možemo reći da je najčešći odgovor na svaku izjavu bio „4. slažem se“. Medijan svake izjave također iznosi 4, što nam također govori o središnjoj tendenciji niza dobivenih podataka (odgovora), odnosno 50% ispitanika (200) za svaku je izjavu odgovorilo ili s „1. u potpunosti se ne slažem“, ili s „2. ne slažem se“, ili s „3. niti se slažem niti se ne slažem“, ili s „4. slažem se“, dok je 50 % ostalih ispitanika (200) za svaku izjavu odgovorilo ili s „4. slažem se“ ili s „5. u potpunosti se slažem“.

Tablica 20: Deskriptivna statistika skale „Subjektivna norma“

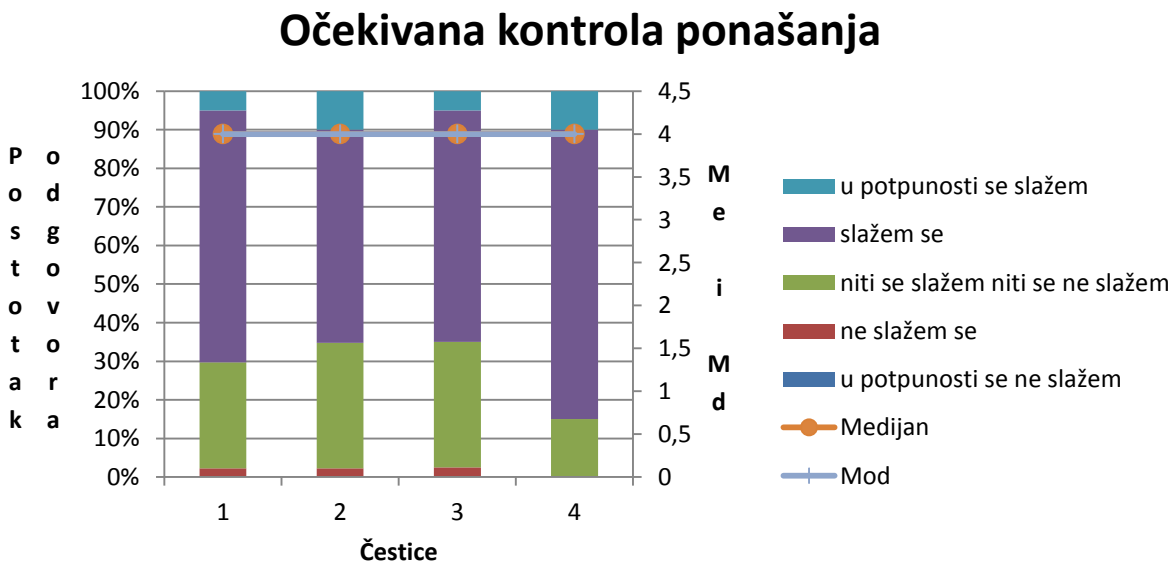
Izjave	„u potpunosti se ne slažem“ (1)	„ne slažem se“ (2)	„niti se slažem niti se ne slažem“ (3)	„slažem se“ (4)	„u potpunosti se slažem“ (5)	Medijan	Mod
Subjektivna norma (SN)							
1. Osobe iz moje obitelji smatraju da bih se trebao koristiti online javnim e-participacijskim uslugama. (SN_1)	0 %	0 %	22,5 %	72,5 %	5,0 %	4	4
2. Osobe koje su meni važne misle da bih se trebao koristiti online javnim e-participacijskim uslugama.	0 %	0 %	27,5 %	60,0 %	12,5 %	4	4
3. Osobe čije mišljenje cijenim željele bi da se koristim online javnim e-participacijskim uslugama.	0 %	0 %	27,5 %	70,0 %	2,5 %	4	4
4. Osobe koje utječu na moje ponašanje smatraju da bih se trebao koristiti online javnim e-participacijskim uslugama.	0 %	0 %	10,0 %	77,5 %	12,5 %	4	4



Iz gornje Tablice 20. vidljivo je da je za svaku izjavu latentnog konstrukta „Subjektivna norma“ kao najčešća, dominantna, Mod vrijednost bila 4, odnosno prema poglavlju „6.1. Razvoj mjernih skala anketnog upitnika“ možemo reći da je najčešći odgovor na svaku izjavu bio „4. slažem se“. Medijan svake izjave također iznosi 4, što nam također govori o središnjoj tendenciji niza dobivenih podataka (odgovora), odnosno 50% ispitanika (200) za svaku je izjavu odgovorilo ili s „1. u potpunosti se ne slažem“, ili s „2. ne slažem se“, ili s „3. niti se slažem niti se ne slažem“, ili s „4. slažem se“, dok je 50 % ostalih ispitanika (200) za svaku izjavu odgovorilo ili s „4. slažem se“ ili s „5. u potpunosti se slažem“.

Tablica 21: Deskriptivna statistika skale „Očekivana kontrola ponašanja“

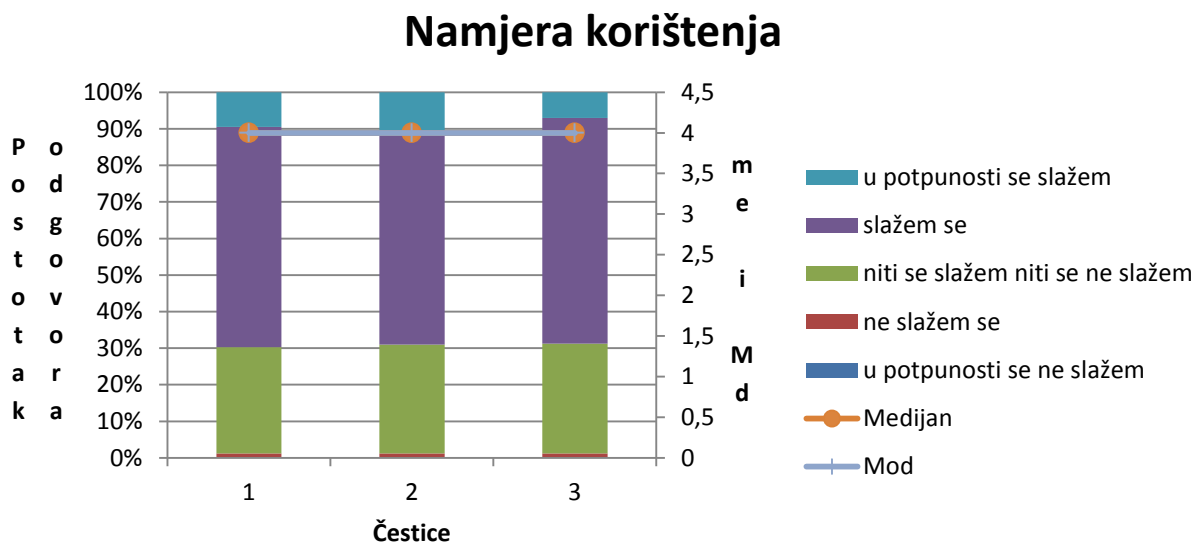
Izjave	„u potpunosti se ne slažem“ (1)	„ne slažem se“ (2)	„niti se slažem niti se ne slažem“ (3)	„slažem se“ (4)	„u potpunosti se slažem“ (5)	Medijan	Mod
Očekivana kontrola ponašanja (OKP)							
1. Vjerujem da imam kontrolu nad korištenjem online javnih e-participacijskih usluga.	0 %	2,3 %	27,5 %	65,3 %	5,0 %	4	4
2. Vjerujem da bi mogao koristit online javne e-participacijske usluge kada bi to htio.	0 %	2,3 %	32,5 %	55,3 %	10,0 %	4	4
3. Korištenje online javnim e-participacijskim uslugama ovisi samo o meni.	0 %	2,5 %	32,5 %	60,0 %	5,0 %	4	4
4. Vjerujem da imam znanja za korištenje online javnim e-participacijskim uslugama.	0 %	0 %	15,0 %	75,0 %	10,0 %	4	4



Iz gornje Tablice 21. vidljivo je da je za svaku izjavu latentnog konstrukta „Očekivana kontrola ponašanja“ kao najčešća, dominantna, Mod vrijednost bila 4, odnosno prema poglavlju „6.1. Razvoj mjernih skala anketnog upitnika“ možemo reći da je najčešći odgovor na svaku izjavu bio „4. slažem se“. Medijan svake izjave također iznosi 4, što nam također govori o središnjoj tendenciji niza dobivenih podataka (odgovora), odnosno 50% ispitanika (200) za svaku je izjavu odgovorilo ili s „1. u potpunosti se ne slažem“, ili s „2. ne slažem se“, ili s „3. niti se slažem niti se ne slažem“, ili s „4. slažem se“, dok je 50 % ostalih ispitanika (200) za svaku izjavu odgovorilo ili s „4. slažem se“ ili s „5. u potpunosti se slažem“.

Tablica 22: Deskriptivna statistika skale „Namjera korištenja“

Izjave	„u potpunosti se ne slažem“ (1)	„ne slažem se“ (2)	„niti se slažem niti se ne slažem“ (3)	„slažem se“ (4)	„u potpunosti se slažem“ (5)	Medijan	Mod
Namjera korištenja (NK)							
1. Namjeravam se koristiti online javnim e-participacijskim uslugama.	0 %	1,3 %	29,0 %	60,3 %	9,5 %	4	4
2. Planiram često se koristiti online javnim e-participacijskim uslugama.	0 %	1,3 %	29,8 %	57,5 %	11,5 %	4	4
3. Preporučio bih drugima korištenje online javnim e-participacijskim uslugama.	0 %	1,3 %	30,0 %	61,8 %	7,0 %	4	4



Iz gornje Tablice 22. vidljivo je da je za svaku izjavu latentnog konstrukta „Namjera korištenja“ kao najčešća, dominantna, Mod vrijednost bila 4, odnosno prema poglavlju „6.1. Razvoj mjernih skala anketnog upitnika“ možemo reći da je najčešći odgovor na svaku izjavu bio „4. slažem se“. Medijan svake izjave također iznosi 4, što nam također govori o središnjoj tendenciji niza dobivenih podataka (odgovora), odnosno 50% ispitanika (200) za svaku je izjavu odgovorilo ili s „1. u potpunosti se ne slažem“, ili s „2. ne slažem se“, ili s „3. niti se slažem niti se ne slažem“, ili s „4. slažem se“, dok je 50 % ostalih ispitanika (200) za svaku izjavu odgovorilo ili s „4. slažem se“ ili s „5. u potpunosti se slažem“.

7.2.1. Procjena mjernog (vanjskog) modela - mode A

Tablica 23: Sumarni rezultati procjene mjernog modela

Čestica	Vanjska opterećenja (eng. *outer loadings*)	Kompozitna pouzdanost (eng. *composite reliability*)[90]	Prosječna ekstrahirana varijanca (eng. *Avarage Variance Extracted*, AVE)	Cronbachov alfa
Namjera korištenja		0,955	0,877	0,929
NK_1	0,907			
NK_2	0,933			
NK_3	0,967			
Očekivana jednostavnost upotrebe		0,877	0,645	0,813
OJU_1	0,646			
OJU_2	0,860			
OJU_3	0,887			
OJU_4	0,711			
~~OJU_5~~	~~0,469~~			
~~OJU_6~~	~~0,507~~			
Očekivana kontrola ponašanja		0,939	0,838	0,902
OKP_1	0,837			
OKP_2	0,928			
OKP_3	0,940			
~~OKP_4~~	~~0,494~~			
Očekivana korisnost		0,943	0,735	0,928
OK_1	0,770			
OK_2	0,838			
OK_3	0,896			
OK_4	0,891			
OK_5	0,901			
OK_6	0,841			
Povjerenje u državu		0,914	0,782	0,866
PUD_1	0,741			
PUD_2	0,899			
PUD_3	0,885			
~~PUD_4~~	~~0,190~~			
Povjerenje u Internet		0,901	0,698	0,852
PUI_1	0,793			

[90] Vrijednosti CR, AVE i Cronbachovog alpha izračunate su bez izbačenih čestica.

PUI_2	0,893			
PUI_3	0,933			
PUI_4	0,682			
~~PUI_5~~	~~0,458~~			
Subjektivna norma		0,899	0,748	0,832
SN_1	0,869			
SN_2	0,778			
SN_3	0,923			
~~SN_4~~	~~0,500~~			
Stav prema ponašanju		0,871	0,695	0,785
SPP_1	0,773			
SPP_2	0,815			
SPP_3	0,903			
~~SPP_4~~	~~0,446~~			

Kao što je već i ranije napomenuto, u prvom koraku PLS-SEM analize Hair i dr. traže da se čestice s vanjskim opterećenjem ispod 0,40 uklone iz daljnje analize, kao i čestice s vanjskim opterećenjem 0,40 - 0,70 ali samo ako njihovo brisanje pozitivno utječe na prosječnu ekstrahiranu varijancu [261]. Identificirane su takve čestice i uklonjene iz daljnje analize što je jasno prikazano u Tablici 23. i u nastavku analize koristio se takav pročišćeni model.

Vezano uz drugi korak, a kao što je prikazano u istoj Tablici 23., konstrukti uključeni u ovo istraživanje pokazuju visok stupanj interne konzistentnosti i to s vrijednostima za Cronbachov alfa u rasponu od 0,785 - 0,929 i kompozitne pouzdanosti u rasponu od 0,871 - 0,955. Naime, više autora smatra da je pouzdanost skale prihvatljiva ako je vrijednost Cronbachovog alfa i kompozitne pouzdanosti za svaki konstrukt u rasponu od 0,60 i više [270] [271].

Vezano uz treći korak analize, u istoj su tablici prikazane i AVE vrijednosti. Sve su AVE vrijednosti veće od tražene referentne vrijednosti (AVE > 0,50), što potvrđuje konvergentnu valjanost konstrukta [270].

Tablica 24: Diskriminantna valjanost - Fornell i Larcker kriterij

	NK	OJU	OK	OKP	PUD	PUI	SN	SPP
NK	**0,936**							
OJU	0,621	**0,803**						
OK	0,426	0,171	**0,857**					
OKP	0,782	0,669	0,236	**0,915**				
PUD	0,107	0,085	0,030	0,161	**0,884**			
PUI	0,788	0,748	0,291	0,813	0,108	**0,835**		
SN	0,631	0,616	0,235	0,644	-0,040	0,663	**0,865**	
SPP	0,410	0,439	0,137	0,431	-0,029	0,410	0,722	**0,833**

U četvrtom koraku analize, prema Fornell i Larcker kriteriju, diskriminantna valjanost[91] nekog konstrukta uspostavljena je kada je vrijednost drugog korijena od AVE ($\sqrt{AVE}$) određenog konstrukta veća od korelacije između tog konstrukta i drugih konstrukta u vanjskom reflektivnom modelu [54] [273]. Na dijagonali Tablice 24. podebljano su prikazane vrijednosti korijena od AVE. Možemo zaključiti da su sve vrijednosti korijena od AVE veće od korelacija latentnih varijabli čime se donosi zaključak da je zadovoljena i diskriminantna valjanost.

Tablica 25. Diskriminantna valjanost – kriterij unakrsnih opterećenja (eng. *cross-loadings*)

	NK	OJU	OK	OKP	PUD	PUI	SN	SPP
NK_1	**0.908**	0.506	0.381	0.700	0.054	0.695	0.552	0.314
NK_2	**0.933**	0.622	0.401	0.748	0.068	0.763	0.618	0.423
NK_3	**0.967**	0.613	0.415	0.750	0.176	0.754	0.602	0.411
OJU_1	0.385	**0.681**	0.134	0.419	-0.094	0.482	0.426	0.237
OJU_2	0.562	**0.877**	0.137	0.624	0.042	0.676	0.591	0.468
OJU_3	0.604	**0.907**	0.156	0.636	0.189	0.664	0.575	0.440
OJU_4	0.403	**0.725**	0.128	0.428	0.086	0.564	0.348	0.200
OKP_1	0.648	0.490	0.194	**0.861**	0.026	0.654	0.539	0.285
OKP_2	0.719	0.672	0.205	**0.936**	0.135	0.777	0.625	0.452
OKP_3	0.776	0.665	0.248	**0.947**	0.261	0.794	0.603	0.437
OK_1	0.292	0.092	**0.770**	0.174	-0.008	0.195	0.156	0.079
OK_2	0.315	0.084	**0.839**	0.160	0.020	0.194	0.164	0.104
OK_3	0.330	0.114	**0.896**	0.205	0.047	0.217	0.208	0.129
OK_4	0.355	0.140	**0.891**	0.156	0.034	0.261	0.161	0.076
OK_5	0.484	0.216	**0.901**	0.309	0.053	0.334	0.307	0.211
OK_6	0.365	0.198	**0.842**	0.172	-0.003	0.257	0.175	0.071
PUD_1	0.053	0.035	0.050	0.073	**0.771**	0.061	-0.063	-0.116
PUD_2	0.092	0.065	0.026	0.136	**0.932**	0.088	-0.017	0.010
PUD_3	0.120	0.105	0.019	0.185	**0.941**	0.121	-0.039	-0.015
PUI_1	0.641	0.510	0.238	0.658	-0.017	**0.801**	0.532	0.258
PUI_2	0.732	0.701	0.262	0.781	0.083	**0.905**	0.645	0.446
PUI_3	0.760	0.697	0.281	0.765	0.199	**0.933**	0.638	0.451
PUI_4	0.452	0.600	0.180	0.460	0.080	**0.881**	0.347	0.143
SN_1	0.427	0.462	0.164	0.422	-0.159	0.490	**0.841**	0.508
SN_2	0.527	0.554	0.191	0.568	-0.009	0.577	**0.819**	0.719
SN_3	0.649	0.572	0.244	0.646	0.025	0.636	**0.932**	0.635
SPP_1	0.242	0.292	0.082	0.269	-0.114	0.266	0.488	**0.758**
SPP_2	0.299	0.376	0.066	0.340	-0.079	0.318	0.529	**0.825**
SPP_3	0.439	0.414	0.170	0.437	0.060	0.412	0.737	**0.910**

Drugi popularni pristup utvrđivanju diskriminantne valjanosti jeste izračun unakrsnih opterećenja (eng. *cross-loadings*) što se još naziva i diskriminantna valjanost na razini čestice [274]. Iz Tablice 25. vidimo da svaka mjerna čestica slabije korelira sa svim ostalim konstruktima osim s onim s kojim je teoretski povezana.

[91] Neki autori koriste izraz divergentna valjanost.

Tablica 26: Heterotrait-monotrait omjer korelacije

	NK	OJU	OK	OKP	PUD	PUI	SN	SPP
NK								
OJU	0.700							
OK	0.448	0.190						
OKP	0.852	0.764	0.249					
PUD	0.110	0.138	0.048	0.164				
PUI	0.871	0.906	0.316	0.909	0.130			
SN	0.701	0.733	0.253	0.728	0.108	0.763		
SPP	0.455	0.519	0.141	0.492	0.138	0.462	0.862	

Treći pristup novijeg je datuma i zahtjeva korištenje Heterotrait-monotrait omjera korelacije (eng. *Heterotrait-Monotrait Ratio of Correlations*, HTMT) kao novog kriterija za provjeru diskriminantne valjanosti i zahtijeva vrijednost manju od 1 [30], [274], [286], [287], [288]. Rezultati prikazani u Tablici 26. prikazuju zadovoljavajuće vrijednosti i može se reći da je i po ovom kriteriju diskriminantna valjanost potvrđena.

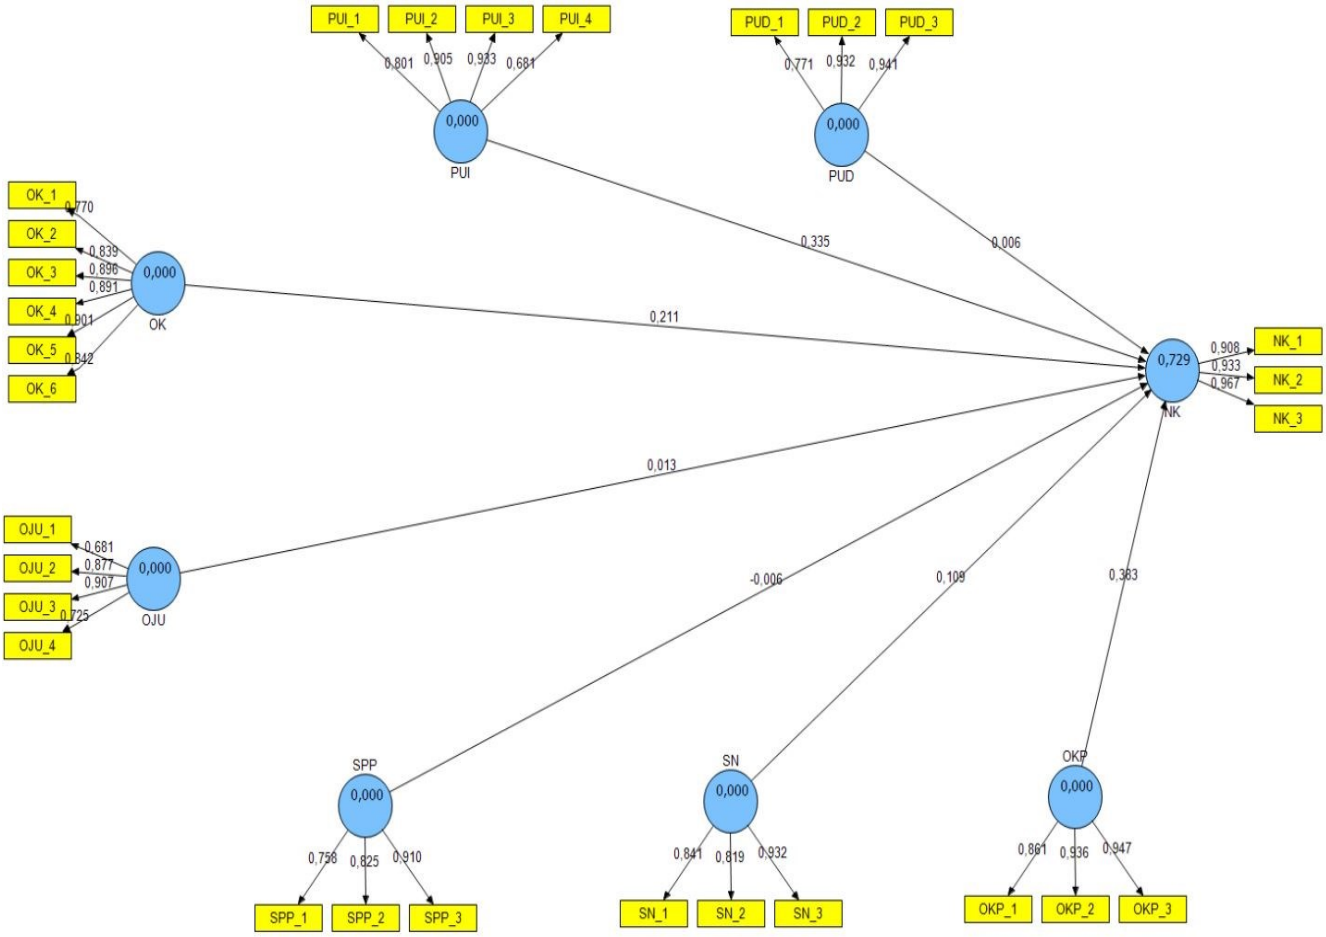
Analiza vrijednosti parametara mjernog modela pokazala je da konceptualni model udovoljava svim kriterijima valjanosti i pouzdanosti. Kada su svi zahtijevani evaluacijski kriteriji mjernog modela zadovoljeni, prelazi se na procjenu strukturalnog modela.

7.2.2. Procjena strukturalnog (unutarnjeg) modela i testiranje hipoteza

Tablica 27: VIF vrijednosti

	NK
NK	
OJU	2.477
OK	1,106
OKP	3,259
PUD	1,067
PUI	4,137
SN	3,399
SPP	2,148

Prije procjene strukturalnih veza, kao prvi korak poželjno provjeriti kolinearnost. Latan i Ramli smatraju kako za reflektivne mjerne modele vrijednosti manje od 5 ne predstavljaju problem u daljnjoj analizi [275]. U ovom radu VIF vrijednosti za sve varijable u rasponu su od 1,067 do 4,137 pa se može zaključiti da ne postoji multikolinearnost između nezavisnih varijabli i zavisne varijable u strukturalnom modelu.



Slika 29: Strukturalni model s koeficijentima puta i determinacije

Drugi korak u analizi strukturalnog modela jeste izračun koeficijenta determinacije R^2. U krugu endogene latentne varijable na Slici 29. nalazi se koeficijent determinacije R^2, odnosno broj koji pokazuje koliko je varijance endogene latentne varijable objašnjeno drugim egzogenim latentnim varijablama. Različite referentnih vrijednosti koeficijenta determinacije prema različitim autorima impliciraju jaku, umjerenu ili slabu prediktorsku snagu skupa egzogenih (nezavisnih) latentnih varijabli. Tako Cohen navodi 0,26, 0,13 i 0,02 kao jak, umjeren i slab intenzitet prediktorske snage egzogenih varijabli, dok je za China to 0,67, 0,33 i 0,19. Prema Hair-ovim najstrožim kriterijima, vrijednosti R^2 oko 0,75 smatraju se jakim, 0.50 umjerenim i 0.25 slabim [9]. U ovom radu R^2 vrijednost endogenog konstrukta „Namjera korištenja“ iznosi $R^2 = 0,729$ pa možemo reći da je rubno jaka, odnosno da sedam egzogenih latentnih varijabli objašnjava visokih 72,9 % varijance u „Namjeri korištenja“.[92]

[92] Prihvatljiva vrijednost R^2 različita je kod različitih istraživanja, pa je tako npr. kod predviđanja povrata dionica prihvatljiva i vrijednost R^2 od 0,10 [289].

Tablica 28: R^2 vrijednost

	R^2
NK	0,729

Drugim riječima, 72,9 % namjere korištenja javnim uslugama e-participacije može biti objašnjeno konstruktima korištenim u modelu.[93]

Tablica 29: f^2 vrijednosti

	NK
NK	
OJU	0,000
OK	0,100
OKP	0,166
PUD	0,000
PUI	0,150
SN	0,013
SPP	0,000

Cohen-ov f^2 koeficijent govori o jačini utjecaja (eng. *effect size*) pojedinih koeficijenata puta strukturalnog modela. Vrijednost 0,02 predstavlja malu, 0.15 srednju a 0.35 veliku jačinu utjecaja. S obzirom na dobivene vrijednosti, možemo reći da je utjecaj „Očekivane kontrole ponašanja“ (0,166) kao i utjecaj „Povjerenja u Internet (0,150) srednje jačine, dok „Očekivana korisnost“ ima mali utjecaj (0,100). „Očekivana jednostavnost upotrebe“, „Povjerenje u državu“, „Stav prema ponašanju“ i „Subjektivna norma“ imaju slab ili nikakav utjecaj na endogenu varijablu „Namjere korištenja“. Ove vrijednosti u skladu su s vrijednostima i razmišljanjima drugih autora. Tako J. Benitez i dr. smatraju kako neki autori imaju nerealna očekivanja, odnosno bezrazložno očekuju i smatraju dobrim samo velike jačine utjecaja. Isti autori smatraju da je to neprirodno, neoubičajno i malo vjerojatno [290].

[93] Iako mnogi istraživači interpretiraju R2 kao mjeru prediktivne snage njihovog modela, ovakvo tumačenje nije u potpunosti točno. R2 samo indicira eksplanatornu snagu (hrv. objasnidbenu moć) u uzorku, dok ne govori ništa o prediktivnoj vrijednosti modela izvan uzorka [30].

Tablica 30: Q^2 vrijednost

	Q^2
NK	0,599

Hair i dr. spominju i druge načine procjene prediktivne točnosti[94] PLS modela puta kao što je to npr. izračun Stone-Geisser indikatora Q^2. Ova je metrika bazirana na tzv. *blindfolding* proceduri. Već Q^2 vrijednost veća od 0 implicira da model ima prediktivnu relevantnost, dok vrijednosti veće od 0, 0,25 i 0,50 predstavljaju vrijednosti male, srednje i velike prediktivne točnosti (relevantnosti) nekog PLS modela [30]. U ovom radu Q^2 vrijednost endogenog konstrukta „Namjera korištenja“ iznosi $Q^2 = 0,599$ pa i ovdje možemo reći da prediktivna relevantnost korištenog modela znatna.

Treći korak u analizi strukturalnog modela govori o potrebi izračunavanja statističke signifikantnosti i relevantnosti koeficijenata puta (eng. *path coeficioents*). Analizom strukturalnog modela može se zaključiti kako su veze među varijablama različite jačine. Pa tako rezultati mogu biti interpretirani na slijedeći način: egzogena varijabla „Očekivana kontrola ponašanja“ ima najizraženiju povezanost s endogenom varijablom „Namjera korištenja“ (0,383), a slijede ju egzogena varijabla „Povjerenje u Internet“ (0,335) i egzogena varijabla „Očekivana korisnost“ (0,211) s nešto slabije izraženom povezanošću s „Namjerom korištenja“. Dalje slijede egzogena varijabla „Subjektivna norma“ (0,109), egzogena varijabla „Očekivana jednostavnost upotrebe“ (0,013) i egzogena varijabla „Povjerenje u državu“ (0,006). Egzogena varijabla „Stav prema ponašanju“ ima slabo izraženu negativnu povezanost s „Namjerom korištenja“ (-0,006).

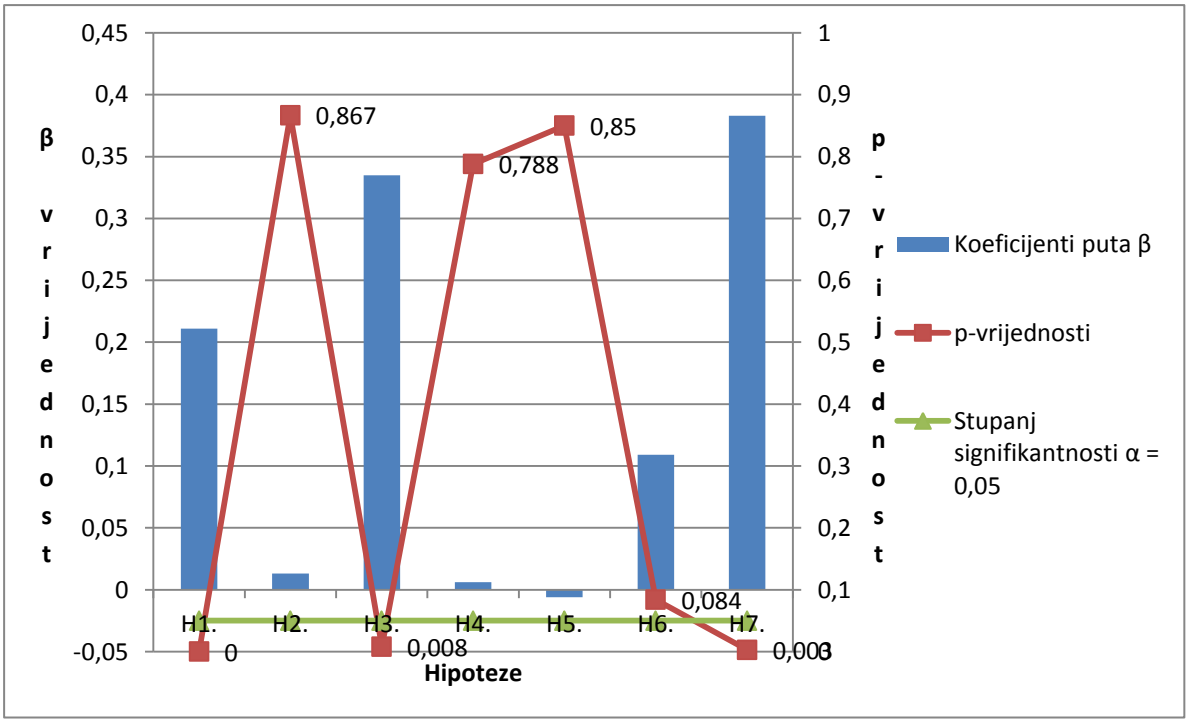
Tablica 31: Dobivene vrijednosti nakon *bootstrapp* procedure

Hipoteza	Povezanost	Koeficijent korelacije β	T-statistika	P- vrijednosti ($p < 0,05$)?	Hipoteza podržana
H1.	OK→NK	0,211	4,456	0,000	Da
H2.	OJU→NK	0,013	0,167	0,867	Ne
H3.	PUI→NK	0,335	2,654	0,008	Da
H4.	PUD→NK	0,006	0,269	0,788	Ne
H5.	SPP→NK	-0,006	0,189	0,850	Ne
H6.	SN→NK	0,109	1,731	0,084	Ne
H7.	OKP→NK	0,383	3,013	0,003	Da

[94] Roldan i Franco govore o prediktivnoj relevantnosti [276].

Tablica 31. prikazuje procijenjene koeficijente korelacije i njihovu signifikantnost u modelu istraživanja. Naime, kao što smo već i naveli u metodologiji, analizom strukturalnog modela može se zaključiti kako su veze među varijablama različite jačine, no potrebno je dodatno izračunati da li su koeficijenti puta signifikantni. Koristeći *bootstraping* algoritam i u SmartPLS-u preporučene *defaultne* vrijednosti (5 000 poduzoraka, *two-tailed t-test*, signifikantni stupanj od 0.05), koeficijent puta biti će signifikantan ako p-vrijednost bude manja od 0,05. Odnosno, ukoliko je empirijski utvrđena p-vrijednost manja od referentne p-vrijednosti, prihvaća se hipoteza o značajnosti koeficijenta puta (uz određeni stupanj signifikantnosti) [227], [291], [270].

U ovom slučaju, tri od sedam koeficijenta puta unutarnjeg modela statistički su signifikantni što je i prikazano u Tablici 31. i grafički na *combo* Grafikonu 11. Odnosno, potvrđene su tri od sedam hipoteza.



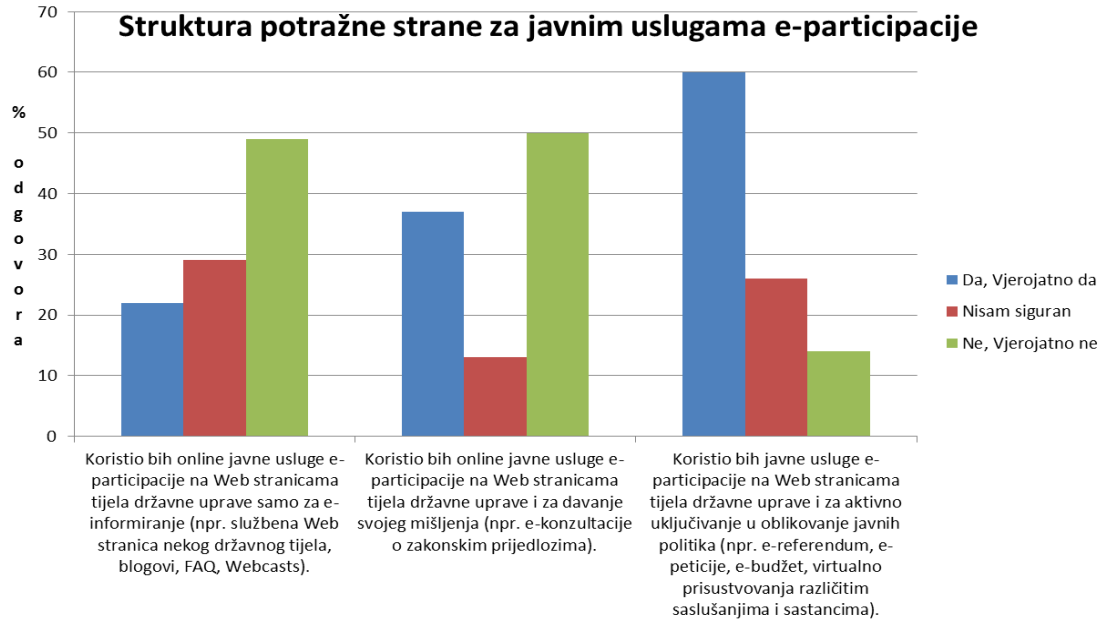
Grafikon 11: Grafički prikaz odnosa koeficijenata puta i p-vrijednosti u odnosu na referentnu p-vrijednost

7.2.3. Struktura potražne strane za javnim uslugama elektroničke participacije

Dodatno, u poglavlju 1.3. Ciljevi istraživanja i istraživačko pitanje, kao zadnji cilj naveden je „Identificirati strukturu potražne strane za javnim uslugama e-participacije vezano uz stupanj uključenosti građana (e-informacijska, e-konzultacijska i e-participacijska razina)“. Tablica 32. daje nam odgovor na pitanje koju razinu javnih usluga e-participacije ispitanici u ovom istraživanju preferiraju.

Tablica 32: Frekvencija odgovora vezano uz strukturu potražne strane za javnim uslugama e-participacije (N=400)

Biste li koristili online javne usluge e-participacije na Web stranicama tijela državne uprave za:	Da, Vjerojatno da	Nisam siguran	Ne, Vjerojatno ne
Koristio bih online javne usluge e-participacije na Web stranicama tijela državne uprave samo za e-informiranje (npr. službena Web stranica nekog državnog tijela, blogovi, FAQ, Webcasts).	22 %	29 %	49 %
Koristio bih online javne usluge e-participacije na Web stranicama tijela državne uprave i za davanje svojeg mišljenja (npr. e-konzultacije o zakonskim prijedlozima).	37 %	13 %	50 %
Koristio bih javne usluge e-participacije na Web stranicama tijela državne uprave i za aktivno uključivanje u oblikovanje javnih politika (npr. e-referendum, e-peticije, e-budžet, virtualno prisustvovanja različitim saslušanjima i sastancima).	60 %	26 %	14 %



Rezultati prikazani u Tablici 32. pokazuju da je najmanji broj ispitanih građana zainteresiran za početnu razinu e-participacije. Naime, na pitanje o namjeri korištenja takvih usluga, s „Da“ i „Vjerojatno da“ odgovorilo je tek 22 % ispitanika. Na pitanje o namjeri korištenja javnih e-participacijskih usluga veće razine, s „Da“ i „Vjerojatno da“ odgovorilo je nešto veći broj odnosno 37 %, dok namjeru korištenja usluga najviše razine ima i najveći broj građana odnosno s „Da“ i Vjerojatno da“ odgovorilo je 60 % ispitanika. Očito je da povećanjem stupnja složenosti javnih usluga e-participacije (stupnja složenosti ne toliko u tehničkom smislu već u smislu uključenosti građana kao sudionika) raste i postotak građana spremnih koristiti iste.

8. RASPRAVA

„Demokratski impuls treba ojačati pronalaženjem novih načina kako građanima omogućiti sudjelovanje u odlučivanju koje na njih utječe. Istina je da će u zrelom društvu predstavnici donijeti bolje odluke ako u potpunosti uzmu u obzir popularno mišljenje i potaknu javnu raspravu o važnim odlukama koje utječu na život ljudi".

Tony Blair, bivši premijer Ujedinjanog Kraljevstva Velike Britanije

Najvažniji zadatak za pružatelje javnih usluga e-participacije jeste privlačenje i zadržavanje korisnika, što razumijevanje čimbenika utjecaja na prihvaćanje javnih usluga e-participacije čini ključnim za istraživače tog područja. Poznavajući čimbenike koji su oblikovali nečiju namjeru, omogućit će se organizacijama da upravljaju tim čimbenicima s ciljem promicanja prihvaćanja i povećanja stvarnog korištenja specifičnih informacijsko-komunikacijskih tehnologija i informacijskih sustava. U skladu s time, u ovom poglavlju doktorskog rada, rezultati istraživanja biti će prezentirani u svijetlu ciljeva istraživanja. Nadalje, biti će raspravljena ograničenja, kao i mogući daljnji smjerovi istraživanja.

U ovom se radu istražuju čimbenici utjecaja na namjeru korištenja javnih e-participacijskih usluga od strane građana Republike Hrvatske. Rad proširuje standardni Model prihvaćanja tehnologije (eng. TAM) i predlaže testiranje dodatnih faktora kao mogućih faktora utjecaja. Prema takvom proširenom modelu, ispitani su faktori „Očekivana korisnost", „Očekivana jednostavnost upotrebe", „Stav prema ponašanju", „Subjektivna norma", „Očekivana kontrola ponašanja", „Povjerenje u Internet" i „Povjerenje u državu" odnosno njihova signifikantnost vezana uz namjeru korištenja javnim uslugama e-participacije.

Prema Vujeviću, kod rasprave i interpretacije, potrebno je podatke dovesti u vezu s hipotezama rada, ali i s podacima sličnih istraživanja (historijskokomparativna metoda) što se u ovom poglavlju i čini [197].

8.1. Analiza ciljeva, hipoteza i istraživačkog pitanja istraživanja

Poglavlje 5. bavi se prvim ciljem koji glasi „razviti višedimenzionalni model prihvaćanja koji će biti korišten u objašnjavanju čimbenika utjecaja na namjeru korištenja građana Hrvatske javnim uslugama elektroničke participacije", dok poglavlje 7. adresira drugi cilj „razumjeti strukturu potražne strane za participacijskim uslugama Uprave 2.0".

Analizom većeg broja znanstvenih i stručnih radova baziranih na raznim modelima prihvaćanja informacijskih tehnologija i informacijskih sustava, definiran je novi konceptualni model pod nazivom „Model korištenja javnih usluga e-participacije“ (eng. *Public E-Participation Services Intention to use Model*, PEPSIM). Model integrira konstrukte različitih modela prihvaćanja tehnologije imajući na umu višedimenzionalnost e-participacije. Pa tako novo razvijeni konceptualni model integrira tehnološku dimenziju, dimenziju utjecaja društva i dimenziju povjerenja kao moguće čimbenike utjecaja na namjeru korištenja javnim uslugama e-participacije. temeljem tako definiranog modela, postavljene su hipoteze rada koje su testirane empirijskim istraživanjem.

Ovaj višedimenzionalni konceptualni model prihvaćanja javnih usluga e-participacije operacionaliziran je u anketni upitnik kao glavni instrument empirijskog istraživanja.

Nakon što su svi podaci analizirani, pouzdanost, konvergentna i diskriminantna valjanost potvrđene i konceptualni model testiran, uz stupanj signifikantnosti od 0,05 mogu se donijeti slijedeći zaključci:

Tablica 33: Potvrđene i nepotvrđene hipoteze istraživanja

Hipoteza	Povezanost	Potvrđena hipoteza
H1.	Pokazuje se da je „Očekivana korisnost“ pozitivno i signifikantno povezana s „Namjerom korištenja“ javnih usluga e-participacije ($\beta = 0,211$, $p = 0,000$) te je H1. potrebno prihvatiti.	Da
H2.	Pokazuje se da je „Očekivana jednostavnost upotrebe“ pozitivno, ali ne i signifikantno povezana s „Namjerom korištenja“ javnih usluga e-participacije ($\beta = 0,013$, $p = 0,867$) te je H2. potrebno odbaciti.	Ne
H3.	Pokazuje se da je „Povjerenje u Internet“ pozitivno i signifikantno povezano s „Namjerom korištenja“ javnih usluga e-participacije ($\beta = 0,335$, $p = 0,008$) te je H3. potrebno prihvatiti.	Da
H4:	Pokazuje se da je „Povjerenje u državu“ pozitivno, ali ne i signifikantno povezano s „Namjerom korištenja“ javnih usluga e-participacije ($\beta = 0,006$, $p = 0,788$) te je H4. potrebno odbaciti.	Ne
H5.	Pokazuje se da je „Stav prema ponašanju“ negativno, ali i nesignifikantno povezan s „Namjerom korištenja“ javnih usluga e-participacije ($\beta = -0,006$, $p = 0,850$) te je H5. potrebno odbaciti.	Ne
H6.	Pokazuje se da je „Subjektivna norma“ pozitivno, ali ne i signifikantno povezana s „Namjerom korištenja“ javnih usluga e-participacije ($\beta = 0,109$, $p = 0,084$) te je H6. potrebno odbaciti.	Ne
H7.	Pokazuje se da je „Očekivana kontrola ponašanja“ pozitivno i signifikantno povezana s „Namjerom korištenja“ javnih usluga e-participacije ($\beta = 0,383$, $p = 0,003$) te je H7. potrebno prihvatiti.	Da

Odnosno, analiza vrijednosti parametara strukturalnog modela pokazala je da su se čimbenici „Očekivana korisnost“, „Povjerenje u Internet“ i „Očekivana kontrola ponašanja“ jedini

pokazali kao signifikantni čimbenici spram namjere korištenja javnim ulugama e-participacije. Hipoteze o utjecaju „Očekivane jednostavnosti upotrebe“, „Stava prema ponašanju“, „Subjektivne norme“ i „Povjerenja u državu“ nisu se pokazale prediktivnima prema namjeri korištenja javnim uslugama e-participacije od strane građana Republike Hrvatske. Sumarno se može reći da se nakon provedene empirijske analize utjecaj očekivane korisnosti, očekivane kontrole ponašanja i povjerenja u Internet pokazao naročito važan u kontekstu razumijevanja namjere korištenja javnih usluga e-participacije kao komunikacijskog medija između države i građana.

Rezultati pokazuju kako je“Očekivana kontrola ponašanja“ najjači prediktor namjere korištenja, slijedi „Povjerenje u Internet“ i na kraju „Očekivana korisnost“.

Vezano uz „Očekivanu korisnost“ kao signifikantno povezanom čimbeniku s namjerom korištenja javnih usluga e-participacije, rezultati sugeriraju da bi država kao pružatelj javnih usluga e-participacije trebala svoje napore (npr. marketinške) usmjeriti na bolje shvaćanje građana o postojanju i korisnosti javnih usluga e-participacije. Država mora staviti naglasak na povećanje svjesnosti o postojanju servisa i ukazati na njihove benefite, što bi posredno dovelo i do povećanja broja korisnika.

Signifikantnost povezanosti čimbenika „Povjerenje u Internet“ s namjerom korištenja, govori da država mora biti usmjerena na implementaciju najnaprednijih sigurnosnih protokola kako bi građane uvjerila da je komunikacija s tijelima države sigurna u smislu očuvanja njihovih podataka (i osobnih i financijskih).

Signifikantnost povezanosti čimbenika „Očekivane kontrole ponašanja“ koja predstavlja percepciju pojedinca koliko se lako ili teško upustiti u određeno ponašanje s namjerom korištenja, govori da građani u pravilu procjenjuju da imaju znanja i mogućosti koristiti se javnim uslugama e-participacije.

Izostanak signifikantne povezanosti „Očekivane jednostavnosti korištenja“ s namjerom korištenja jedini je rezultat koji na prvu iznenađuje. No autor ovoga rada smatra kako to i ne mora biti tako. Naime, teškoća korištenja raznim *online* sustavima (pa tako i raznim *online* e-participacijskim sustavima) postaje sve manja prepreka u njihovu korištenju jer sustavi postaju sve više prilagođeni korisnicima (eng. *user friendly*) ne zahtijevajući više znatno tehničko predznanje što pak utječe na sve veću kompetenciju građana da se služe istim. Čak i

sam Davis nije našao povezanost između „Očekivane jednostavnosti korištenja“ i prihvaćanja informacijskih tehnologija [142].

Ne smije se zaboraviti kako je u poglavlju „6.3.2. Metoda analize dobivenih podataka - modeliranje strukturalnim jednadžbama i testiranje hipoteza“ navedeno kako je PLS-SEM pristup odabran zbog više prediktivne prirode ovog istraživanja s ciljem predviđanja/istraživanja (eng. *prediction*/*explanation*) proširenja postojećih teorija. U konačnici to se mora odraziti i u analizi podataka, pogotovo što se tiče prikazivanja R^2 i Q^2 vrijednosti.

Tablica 34: Objasnidbena snaga korištenog modela

Konstrukt	R^2	Q^2
Namjera korištenja javnim uslugama e-participacije	0,729	0,599

R^2 koeficijent determinacije iznosi 0,729 što je vrijednosti koja se označava kao rubno znatna i može se okarakterizirat kao zadovoljavajuća. Naime, dosadašnji modeli baveći se e-participacijskim faktorima utjecaja na namjeru korištenja dosežu vrijednosti R^2=0,29 ili najviše R^2 = 0,534 [8], [18].

Kao što je ranije i istaknuto, već Q^2 vrijednosti veća od 0 implicira da model ima prediktivnu relevantnost, dok vrijednosti veće od 0, 0,25 i 0,50 predstavljaju vrijednosti male, srednje i znatne prediktivne točnosti (relevantnosti) nekog PLS modela. Dobivena Q^2 vrijednost od 0.599 sugerira znatnu prediktivnost korištenog modela.

Cohen-ov f^2 koeficijent govori o jačini utjecaja (eng. *effect size*) pojedinih koeficijenata puta strukturalnog modela. S obzirom na dobivene vrijednosti, možemo reći da je utjecaj „Očekivane kontrole ponašanja“ (0,166) kao i utjecaj „Povjerenja u Internet (0,150) srednje jačine, dok „Očekivana korisnost“ ima mali utjecaj (0,100). „Očekivana jednostavnost upotrebe“, „Povjerenje u državu“, „Stav prema ponašanju“ i „Subjektivna norma“ imaju slab ili nikakav utjecaj na endogenu varijablu „Namjera korištenja“. Kao što smo i u rezultatima istraživanja naglasili, ovakve vrijednosti su prihvatljive, odnosno nerealno bi bilo očekivati samo velike jačine utjecaja [290].

Što se tiče drugog cilja vezanog za utvrđivanje strukture potražne strane za participacijskim uslugama, rezultati prikazani u Tablici 32. pokazuju da je najmanji broj ispitanih građana

zainteresiran za početnu razinu e-participacije, dok porastom stupnja složenosti javnih usluga e-participacije raste i broj zainteresiranih korisnika.

Rezultati istraživanja mogu pružiti korisne informacije donosiocima raznih strateških planova e-uprave imajući u vidu signifikantne čimbenike utjecaja vezane uz namjeru korištenja javnim e-participacijskim uslugama. Istraživanje je naglasilo ključne čimbenike utjecaja na građane Republike Hrvatske u namjeri korištenja javnih e-participacijskih usluga i u skladu s time osobe zadužene za razvoj e-uprave u Republici Hrvatskoj morale bi više pažnje posvetiti ovim čimbenicima kako bi povećali stupanj korištenja javnih e-participacijskih usluga. U Hrvatskoj, koja zaostaje prema drugim zemljama EU i u pogledu e-uprave općenito, ali i u pogledu e-participacije, malo je istraživanja provedeno vezano uz namjeru korištenja istih.

S obzirom na istraživačko pitanje (Postoji li empirijska potvrda povezanosti namjere korištenja javnih usluga e-participacije s čimbenicima kao što su to konstrukti teorija prihvaćanja tehnologija TAM-a, TPB-a i Modela povjerenja), možemo reći da je empirijski potvrđeno kako je konstrukt TAM-a „Očekivana korisnost“, konstrukt TPB-a „Očekivana kontrola ponašanja“ i konstrukt Modela povjerenja „Povjerenje u Internet“ povezan s namjerom korištenja javnim uslugama e-participacije.

8.2. Pregled i usporedba rezultata dosadašnjih empirijskih istraživanja

E-demokracija kao nadskup e-participacije jest mehanizam baziran na IKT, a IKT imaju potencijal transformiranja loše javne uprave stvarajući tako nove, informacijsko intenzivne društvene servise [81]. No usprkos tome, nove tehnologije još uvijek imaju skroman utjecaj na politiku i političko odlučivanje [292]. Pitanje što pokreće elektroničku participaciju može se postaviti iz više perspektiva: tehnološke, društvene, individualne i psihološke [18]. Svaka od ovih perspektiva može dati odgovore na pitanje zašto je stupanj e-participacije još uvijek mali.

Općenito govoreći, istraživanje prihvaćanja informacijske tehnologije naglašava važnost namjere korištenja u predviđanju stvarnog korištenja. Upravo zbog tog razloga, većina istraživanja prihvaćanja tehnologije svodi se na istraživanje namjere korištenja tehnologije. No vezano uz e-participacijske Web 2.0 tehnologije općenito, teorijska podloga još je u začecima i postoji mali broj istraživanja na tu temu. Ipak, u ovom dijelu rada navode se, prema mišljenju autora, neka od značajnijih istraživanja u ovom području.

Alrashedi, Persaud i Kindra daju uvid vezan uz istraživanje korisnikove namjere participacije u aktivnostima elektroničke uprave u Saudijskoj Arabiji [18]. Naime, autori primjećuju da je zadnjih nekoliko godina Vlada Saudijske Arabije potrošila znatna sredstva na različite Web tehnologije i alate promičući tako e-participaciju, ali je broj korisnika koji se njima služi ostao mali. Autori postavljaju pitanje zašto je tome tako i na osnovu relevantne literature nude svoj konceptualni model kojeg testiraju uz pomoć regresijske analize. Autori identificiraju pet čimbenika utjecaja na namjeru korištenja e-participacije: stav prema elektroničkoj upravi, očekivana korisnost e-uprave, povjerenje, društveni mediji i društveni utjecaj. Svi su se čimbenici pokazali signifikantnima, osim očekivane korisnosti. Nesignifikantnost očekivane korisnosti u suprotnosti je s rezultatima ovog rada gdje je očekivana korisnost pozitivno i signifikantno povezana s namjerom korištenja javnih usluga e-participacije.

Ayo, Mbarika i Aderonke uz pomoć proširenog_modela prihvaćanja tehnologije istražuju namjeru građana prema korištenju različitih tehnoloških platforma e-demokracije kao mehanizama koji omogućuju građanima efikasno sudjelovanje u procesu donošenja odluka u Nigeriji [81]. U ovom istraživanju Model prihvaćanja tehnologije proširen je s Teorijom sprege tehnologija - zadatak (eng. *task - technology fit*, TTF) očekivanim rizikom i povjerenjem kako bi se dobio sveobuhvatniji model. Koristeći PLS-SEM autori na osnovu dobivenih podataka zaključuju kako postoji signifikantna pozitivna veza između očekivane korisnosti i namjere korištenja e-demokracijskih Web stranica. Zanimljivo je da, kao i u ovom radu, autori zaključuju da ne postoji signifikantan efekt očekivane jednostavnosti korištenja na namjeru korištenja. Čimbenik povjerenje u državu u ovom je radu signifikantan vezano uz namjeru korištenja.

Reyo i Yetano istražuju ulogu *crowdsourcing* (hrv. kolektivno prikupljanje) tehnologije kao alata za prikupljanje znanja građana s ciljem rješavanja konkretnih problema u lokalnoj zajednici (npr. emisije ugljičnog dioksida, CO^2) [110]. Zanimljivo je da je manji broj građana ovu inicijativu iskoristio za puko informiranje, dok je veći broj građana izrazio želju da aktivno sudjeluje u rješavanju problema pa možemo još jednom zaključiti kako pod utjecajem moderne IKT građani pokazuju veliku zainteresiranost za sudjelovanje u rješavanju problema od javnog značaja.

Al-Hujran, Al-Debei i Al-Lozi na osnovu Teorije planiranog ponašanja i Modela prihvaćanja tehnologije razvijaju svoj integrativni model nudeći tako sveobuhvatniju sliku prediktora namjere korištenja elektroničke demokracije [54]. S nešto slabijim koeficijentom

determinacije i Stone-Geisser indikatorom nego u ovom radu, autori zaključuju o postojanju signifikantne povezanosti stava prema ponašanju, subjektivne norme i očekivane kontrole ponašanja s namjerom korištenja usluga e-demokracije. Dok je signifikantnost očekivane kontrole ponašanju u skladu s rezultatima ovoga rada, signifikantnost stava i subjektivne norme u suprotnosti je s rezultatima ovoga rada.

Ali i Ali u svom se radu bave čimbenicima utjecaja na prihvaćanje e-participacijskih usluga u Bahrainu [185]. Autori navode da e-participacija povećava transparentnost i poboljšava komunikaciju između države i građana omogućavajući im sudjelovanje u procesu donošenja odluka od javnog značaja. I očekivana korisnost i očekivana jednostavnost upotrebe u ovom su radu signifikantno povezane s stvarnom namjerom korištenja e-participacijskih usluga.

Nam u svom radu postavlja istraživačku pitanje o čimbenicima utjecaja na stavove građana prema Upravi 2.0. Autor identificira slijedeće čimbenike utjecaja: često korištenje usluga elektroničke uprave, očekivana korisnost usluga elektroničke uprave, povjerenje u državu, stav prema novim tehnologijama [48]. Modeliranjem strukturalnim jednadžbama utvrđeno je kako česti korisnici ostalih usluga e-uprave u pravilu imaju pozitivan stav prema Web 2.0 uslugama Uprave 2.0. Očekivana korisnost, povjerenj u državu i stav prema novim tehnologijama također su signifikantni u ovom istraživanju.

Od hrvatskih istraživanja, jedino poznato istraživanje autoru ovog doktorskog rada jeste istraživanje grupe autora Bošnjak, Galešić i Kliček iz 2007. godine (istraživanje je provođeno tijekom 2003. godine) pod naslovom „Determinate online političke participacije u Hrvatskoj“ [12]. Ovo istraživanje bazira se na proširenoj Ajzenovoj teoriji planiranog ponašanja, odnosno Ajzenova teorija proširena je s moralnom obavezom *online* političke participacije u Hrvatskoj. Koristeći dva uzorka i to uzorak eksperata, odnosno osoba s specifičnim interesom o političkoj participaciji (n=1134) i uzorak ne-eksperata dobiven od agencije za istraživanja Puls (n=371) autori se bave konstruktima teorije planiranog ponašanja i identificiranjem konstrukata ove teorije kao faktora utjecaja na namjeru korištenja Interneta za različite oblike političkih aktivnosti. U ovom radu, subjektivna norma i očekivana kontrola ponašanja pokazale su se kao signifikantni čimbenici utjecaja na namjeru participiranja u *online* političkim aktivnostima. Moralna obveza kao konstrukt proširenja također se pokazala kao signifikantni čimbenik objašnjavajući zajedno s originalnim konstruktima teorije planiranog ponašanja 49 % varijance. Nisu pronađeni radovi koji se bave istraživanjem strukture potražne strane za javnim uslugama e-participacije kao što se to u ovom radu čini.

8.3. Ograničenja glavnog istraživanja

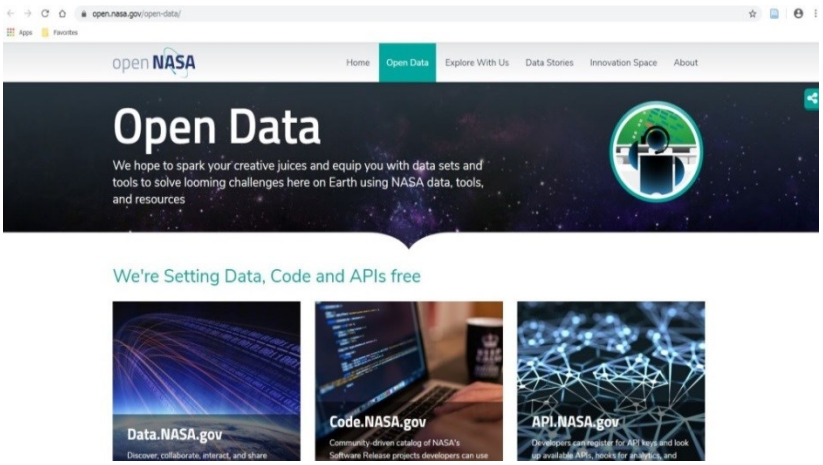
Korišteni model samo je jedan od načina pristupa problemu ispitivanja namjere korištenja javnih usluga elektroničke uprave. Model je neizbježno nepotpun, odnosno ne uzima u obzir mnoge čimbenike koji bi mogli utjecati na namjeru korištenja. U skladu s time, postoji potreba proširenja postojećeg modela.

Zasigurno najveći nedostatak istraživanja jeste odabir uzorka. Naime, kako je to u poglavlju o empirijskom istraživanju i naglašeno, korišteni uzorak bio je ne-slučajan. Nije neuobičajeno koristi ne-slučajne uzorke u PLS-SEM istraživanjima. Tako Ming u svom radu o studentskim percepcijama brendova koristi prigodan uzorak iz populacije studenata [231]. Fernadez i dr. u članku o PLS-SEM pristupu objašnjavanju povezanosti organizacijske kulture i lojalnosti kupca također koristi *snowball* strategiju za odabir uzorka [232]. No, iako su poduzete sve moguće mjere anuliranja negativnih karakteristika ne-slučajnog uzorkovanja metodom snježne grude, svakako se preporuča isti postupak istraživanja primijeniti na nasumično odabrane jedinke populacije.

Također, vezano uz uzorak istraživanja iz Tablice 14. vidljiv je spolni nesrazmjer ispitanika, odnosno činjenica da je na anketu odgovorilo 49,5 % više muškaraca nego žena. U stvarnosti postotak muškaraca i žena Internet korisnika u Republici Hrvatskoj gotovo je identičan, odnosno prema podacima koji predstavljaju procjene dobivene iz godišnjeg istraživanja o primjeni informacijskih i komunikacijskih tehnologija u kućanstvima pojedinaca Državnog zavoda za statistiku 1 197 823 Internet korisnika su muškarci dok su 1 169 991 Internet korisnika žene [22].

8.4. Mogući daljnji smjerovi istraživanja

Participacija građana u rješavanju problema od javnog značaja moguća je i davanjem podataka javnog sektora na uvid zainteresiranim pojedincima (eng. *government public open data*).



Slika 30: Web portal otvorenih podataka američke Nacionalne uprave za aeronautiku i svemir
Izvor: [293]

Poznat je primjer suradnje između američke javne institucije Nacionalne uprave za aeronautiku i svemir (eng. *National Aeronautics and Space Administration,* NASA*)* i građanstva u rješavanju problema solarnih baklji. Solarne baklje utječu na mnoge sfere svakodnevnog života od kojih je civilni zračni promet samo jedna od njih. Više od dva desetljeća znanstvenici NASA-e neuspješno su pokušavali su riješiti problem predikcije pojave solarnih baklji trošeći desetke milijuna dolara. Tek kad su prikupljeni podaci o pojavnosti solarnih baklji dani na uvid građanstvu, problem je riješen s točnošću od blizu 90 %.

Crowdsourcing (pojam još uvijek zahtijeva dobar hrvatski prijevod, ali najčešće se prevodi kao kolektivno prikupljanje) i njegovo korištenje od strane državnih tijela zanimljiv je fenomen kojim bi se trebalo detaljnije pozabaviti. Više je načina na koje država može iskoristi *crowdsourcing* kao alat u rješavanju problema od javnog značaja. Već u ranijim poglavljima spomenut c*rowdsourcing* zakonodavstva, primjer je demokratske inovacije koja građanima daje riječ u zakonodavnom procesu.

Ilustrativan je, i nama u Hrvatskoj blizak, aktualan problem reforme znanosti kao uspješan primjer snage mnoštva. Nakon dugotrajnih *online* konzultacija sa svim zainteresiranim stranama, 2014. godine njemačko je Ministarstvo znanosti Sjeverne Rajne-Vestfalije donijelo novi Zakon o visokom školstvu njemačke pokrajine Sjeverne Rajne-Vestfalije. Ponudivši mogućnost svim zainteresiranim pojedincima da glasuju, raspravljaju, komentiraju o različitim aspektima zakona, Ministarstvo znanosti Sjeverne Rajne-Vestfalije dalo je mogućnost različitim dionicima da učestvuju u procesu donošenja zakona. Cilj *online*

konzultacije bio je „*doseći do građana koji su generalno isključeni iz participacijskih procedura legislativnog procesa*“.



Slika 31: Faze donošenja Zakona o visokom školstvu njemačke pokrajine Sjeverne Rajne-Vestfalije

Izvor: [294]

U svom završnom izvješću Ministarstvo je zaključilo kako je postignuta visoka razina transparentnosti vezano uz donošenje novog zakona od javnog značaja te kako je prikupljena velika količina praktičnog znanja koje je uvelike poboljšala konačnu verziju zakona [295]. Već ranije spominjana NASA rano je prepoznala vrijednost javnosti kao strategijskog partnera i raznim nagradama potiče kreativne pojedince u rješavanju važnih problema s kojima se država susreće [296].

Big Data (hrv. Veliki podatci) područje je usko povezano s društvenim mrežama, pa tako i posredno s Web 2.0 e-participacijskim tehnologijama. Radi se o tehnologiji koja omogućava prikupljanje i obradu velikih količina strukturiranih i nestrukturiranih podataka u realnom vremenu. Dok se *Big Data* tehnologije u fizici koriste za obradu velikih količina podataka (što je i dovelo do otkrića Higgsovog bozona), na sličan način moguća je analiza i društvenih mreža. Zainteresirani pojedinci mogu na osnovu javno dostupnih mišljenja birača koristeći *Big Data* tehnologije vršiti analizu podataka o ponašanju birača s ciljem kreiranja efikasnih izbornih kampanja. Slučaj *Cambridge Analytica* jasno je pokazao da se korištenjem tehnologije obrade velikih količina podataka o korisnicima društvenih mreža može utjecati na razvoj događaja kao što su izbor američkog predsjednika i referendum o Brexitu. Cambridge Analitica američka je konzalting kompanija koja je 2014. godine preko Facebook aplikacije

„*This Is Your Digital Life*“ sakupljala informacije o stotinama tisuća profila na Facebook-u uključujući i informaciju o stvarima koje ti korisnici označuju da im se sviđa (eng. *like*). Dobivene informacije Cambridge Analitica koristila je za ciljane tzv. hiper specifične pozive neodlučnim biračima, koristeći tako tehniku koja je kasnije dobila ime psihografsko modeliranje [297].[95]

Tijekom istraživanja literature primijećeno je da mnogi autori uvrštavaju kulturnu varijablu u konceptualne modele namjere korištenja usluga elektroničke uprave [298], [299], [300]. Naime, prihvaćanje novih tehnologija uključuje rizik i neizvjesnost. Sve veći broj istraživanja pokazuju da nacionalna kultura ispitanika utječe na to kako ljudi reagiraju na rizik i povjerenje. Hofstedov model dimenzija kulture glavni je okvir u međukulturalnim istraživanjima i sastoji se od više dimenzija. Osobito je zanimljiva dimenzija izbjegavanja neizvjesnosti i njezin indeks (eng. *Uncertainy Avoidance Indeks*, UAI). Prema Hofstedu, UAI predstavlja indikator sklonosti riziku neke nacije i to na način da mjeri stupanj do kojeg se neko društvo osjeća nelagodno (nekonformno) u vezi neizvjesnosti. Kulture s niskim UAI toleriraju (prihvaćaju) rizik, a kulture s visokim UAI više su zabrinute neodređenostima, traže stabilnost i predvidljivost. Kao rezultat toga, zemlje s visokim UAI teže izbjegavanju promjena i manje je vjerojatno da će takve kulture prihvaćati *online* tehnologije [301]. Međukulturalno istraživanje bazirano na Hofstedovim kulturnim varijablama dalo bi odgovore na pitanja zašto se neki narod više uključuje u političke procese i ovisi li to od političke kulture i povijesne pozadine. Odnosno, postavlja se pitanje da li je visok e-participacijski indeks. npr. Danske u nekakvoj korelaciji s njihovim niskim indeksom izbjegavanja neizvjesnosti koji iznosi 23, dok je kod Hrvatske stanje obrnuto, odnosno Hrvatski je e-participacijski indeks nizak, dok je indeks izbjegavanja neizvjesnosti prilično visok i iznosi 80 [302].

Dodatno, kroz rad se provlači misao kako e-participacija građana utječe na sam čin glasovanja, odnosno da ako građani više participiraju u donošenju odluka da će i više izlaziti na izbore. Ovakvu misao bilo bi interesantno i empirijski istražiti na način da se ispituje povezanost prethodne aktivnosti građana u procesima e-participacije i samog čina glasovanja. Odnosno, u ovom slučaju prethodno korištenje e-participacijskih tehnologija bila bi nezavisna varijabla, a ispitivala bi se povezanost s zavisnom varijablom namjere glasovanja.

[95] Radi se o izgradnji modela o korisnicima na temelju o njima prikupljenih podataka. Takvi modeli koriste se kasnije za predviđanje i utjecanje npr. na odabir predsjedničkih kandidata prilikom izlaska na izbore.

Također, poznato je da kad korisnici steknu iskustvo, percepcije se mijenjaju pa bi longitudinalno istraživanje sigurno dalo zanimljive rezultate.

9. ZAKLJUČAK

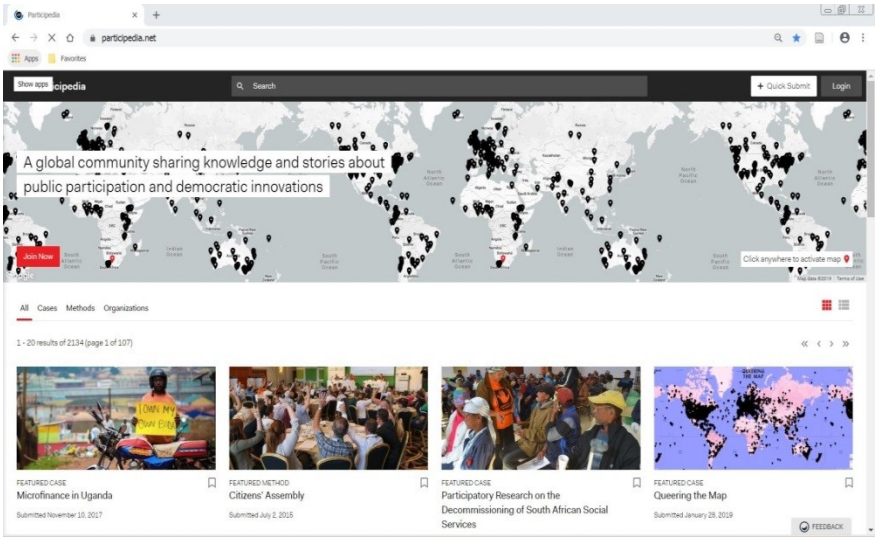
„Građani su u jednoj stvari sigurno stručni, a to je pitanje njihovih potreba“.
Stephen Boucher, direktor Dreamocracy-e

Dvije su različite škole mišljenja o učincima informacijsko-komunikacijskih tehnologija na upravljanje državom. Tzv. cyberoptimisti ističu mnoge prednosti korištenja informacijsko-komunikacijskih tehnologija u upravljanju državom i tvrde da će tehnologija donijeti veće sudjelovanje građana i kvalitetnije rasprave. Ova skupina u elektroničkoj demokraciji vidi priliku za povratak u neposrednu atensku demokraciju. Zagovornici ovakve nove neposredne e-demokracije favoriziraju upotrebu e-savjetovanja, e-peticija i e-referenduma. Cyberoptimisti ističu da Internet može obnoviti veze između birača i političkih elita i da je sudjelovanje u građanskim aktivnostima veće ako se građanima pruži Web platforma koju mogu lako koristiti.

Nasuprot njima, cyberpesimisti dovode u pitanje bilo kakav učinak informacijsko-komunikacijskih tehnologija na upravljanje državom tvrdeći da se država nikad neće u toj mjeri prilagodit mogućnostima informacijsko-komunikacijskih tehnologija jer joj to niti nije u interesu [40]. Kontraargument koji često koriste protivnici upotrebe informacijsko-komunikacijskih tehnologija u javnom životu jest da je prosječni građanin kada se radi o odlukama od javnog značaja neuk, neinformiran i općenito nesposoban odlučivati o sudbonosnim pitanjima.

No nalazimo se u dobu četvrte industrijske revolucije koju između ostalog karakterizira internetizacija i međusobno snažno povezano društvo. Internet, što se tiče informiranosti, izjednačava sve građane. Autor ovog rada ipak više vjeruje u optimističnu verziju imajući na umu da postoje jasni dokazi da se građane u doba apatičnosti lako mobilizira IKT tehnologijama. Već je u poglavlju „3. ELEKTRONIČKA PARTICIPACIJA“ spomenuto da je to prvi 2008. godine prepoznao Barack Obama tijekom svoje prve kampanje. Brojni primjeri uspješne suradnje građanstva i države od kojih su neki navedeni u poglavlju „8.4. Mogući daljnji smjerovi istraživanja“ dodatno govore tome u prilog.

Gotovo je nemoguće popisati sve pozitivne primjere suradnje države i građana s ciljem rješavanja problema od javnog interesa. Web stranica https://participedia.net/ obuhvaća stotine primjera unapređenja života građana koristeći *online* i *offline* participaciju na svim razinama vlasti.



Slika 32: Particiopedia

Izvor: [303]

Od sedam početnih hipoteza, rezultati glavnog empirijskog istraživanja pokazali su potrebu prihvaćanja njih tri i to hipoteze o utjecaju očekivane korisnosti, povjerenja u Internet i očekivane kontrole ponašanja na namjeru korištenja javnim uslugama e-participacije. Očekivana jednostavnost korištenja, stav prema ponašanju, subjektivna norma i povjerenje u državu prema ovom istraživanju nemaju signifikantan utjecaj na namjeru korištenja javnih usluga e-participacije. Jasno je naznačeno i koji čimbenici imaju relativno najjači učinak na namjeru korištenja javnih usluga e-participacije. Naime, dobivene vrijednosti koeficijenata puta omogućavaju rangiranje njihove relativne statističke važnosti, odnosno, ako je jedan koeficijent puta veći od drugog, veći je i njegov utjecaj na endogenu varijablu.

Sumarno možemo reći da egzogena varijabla „Očekivana kontrola ponašanja“ ima najizraženiji učinak na endogenu varijablu „Namjeru korištenja“, a slijede ju egzogena varijabla „Povjerenje u Internet“ i egzogena varijabla „Očekivana korisnost“ s nešto slabije izraženim učinkom na „Namjeru korištenja“. Nadalje slijedi egzogena varijabla „Subjektivna norma“, egzogena varijabla „Očekivana jednostavnost upotrebe“ i egzogena varijabla „Povjerenje u državu“ dok egzogena varijabla „Stav prema ponašanju“ ima slabo izražen negativni učinak na „Namjeru korištenja“.

Što se tiče ispitivanja strukture potražne strane za javnim uslugama elektroničke uprave, rezultati pokazuju da većina ispitanika preferira javne usluge e-participacije više razine složenosti.

Elektronička uprava mora dati svoj doprinos ekonomskom i socijalnom razvoju Hrvatske i zbog toga je postala važno područje istraživanja. Postoji evidentan rast u broju inicijativa koje spadaju u domenu elektroničke uprave. No ne može se sa sigurnošću reći da će građani prihvatiti sve usluge elektroničke uprave usprkos njihovim potencijalno velikim benefitima. Uspjeh tih inicijativa ovisit će o namjeri građana za prihvaćanjem tih usluga (u ovom radu namjera = stvarno korištenje). Iako postoji veći broj istraživanja koja se bave analizom prihvaćanja usluga elektroničkog trgovanja (eng. *e-commerce*), područje e-participacije novijeg je datuma i još uvijek slabo istraženo. Osobito je to izraženo kod istraživanja nad građanima Republike Hrvatske. U skladu s time, čini se kako sistematska studija čimbenika koji su povezani s prihvaćanjem javnih usluga e-participacije predstavlja znanstveno relevantno istraživanje i doprinos.

Sumarno, što se tiče znanstvenog doprinosa:

- Provedena je analiza većeg broja dostupnih relevantnih istraživanja iz područja prihvaćanja Web 2.0 usluga općenito, s ciljem pronalaženja svih bitnih komponenti koji će novi konceptualni model činiti potpunijim i odražavati sve bitne čimbenike korisničkog prihvaćanja javnih usluga e-participacije,
- Definiran je strukturalni model utjecaja različitih čimbenika na namjeru korištenja javnim uslugama e-participacije,
- Provedenom statističkom analizom na skupu prikupljenih podataka identificirani su čimbenici koji su značajno povezani s prihvaćanjem javnih usluga e-participacije Uprave 2.0 od strane građana Republike Hrvatske,
- Tijekom istraživanja primijećena je i praznina u razumijevanju strukture potreba građana za određenim razinama e-participacijskih usluga vezano uz stupanj uključenosti građana, pa je tako u ovom radu istražena struktura potreba građana, odnosno teži li društvo promjenama u smislu prihvaćanja novih e-participacijskih tehnologija višeg stupnja uključenosti ili teži korištenju usluga nižeg stupnja uključenosti. Istraživanje je dalo odgovor na pitanje ne bi li se možda razvoj javnih e-participacijskih usluga u Republici Hrvatskoj trebao kretati prema razvoju visoko kvalitetnih usluga nižeg stupnja uključenosti (eng. *high quality low level services*) ili

korisnici preferiraju napredne usluge višeg stupnja uključenosti. U radu se došlo do zaključka da građani preferiraju usluge višeg stupnja složenosti.

- Rezultati istraživanja provedenog u ovom radu imaju potencijalni utjecaj na strategiju razvoja elektroničke uprave u Hrvatskoj. Naime, rezultati bi mogli imati i neke upravljačke implikacije. Državna tijela zadužena za provedbu e-participacijske strategije (ili strategije e-uprave uopće) mogle bi, u skladu s rezultatima istraživanja, usredotočiti se na barijere prema prihvaćanju javnih usluga e-participacije. Odnosno, predloženi model istraživanja mogao bi poslužiti donositeljima političkih odluka za bolje shvaćanje potreba korisnika i u skladu s time kao putokaz za razvoj e-participacijskih usluga. Rezultati rada mogu koristiti znanstvenicima i osobama u državnim tijelima zaduženim za planiranje i implementaciju javnih usluga elektroničke uprave.
- Doktorski rad pružio je metodološku osnovu za buduća istraživanja, odnosno vezano uz statističku analizu, istraživanje doprinosi daljnjem predstavljanju korištenja PLS-SEM pristupa prilikom predviđanja/istraživanja proširenja postojećih teorija.
- Ovo istraživanje doprinosi i ukupnom istraživanju područja informacijskih sustava, pogotovo u području mjerenja korisničke namjere korištenja tehnologije što je važno polje istraživanja zadnjih 40-tak godina.

Iako se svaka teorija može oboriti (prema nekim autorima, teorija koja se ne može oboriti nema znanstvenu vrijednost) u konačnici rezultati istraživanja predstavljaju originalni znanstveni doprinos i povećanje ukupne količine znanja o elektroničkoj participaciji općenito.

LITERATURA

[1] P. Šuhel, "Kako Web 2.0 spremenja procese v politiki", Magistarsko delo, Univerza v Mariboru, Fakulteta za organizacijske vede, avgust 2013.

[2] F. Trček, "Internet kot medij politične participacije: primer priprave novega prostorskega plana Mestne občine Ljubljana," *Časopis Za Krit. Znan.*, vol. 31, no. 211, p. 12, 2003.

[3] N. Komunikacije, "Sve više građana izabire apstinenciju: Hrvatska od 2000. 'izgubila' više od 900 tisuća birača / Novi list." http://www.novilist.hr/content/view/full/1259742 (accessed Aug. 16, 2018).

[4] L. Bryant, "Web 2.0, Participation and E-democracy :: Blog :: Headshift, [Online]. Available: https://www.headshift.com/our-blog/2006/02/07/web-20-participation-and-edemo/." https://www.headshift.com/our-blog/2006/02/07/web-20-participation-and-edemo/ (accessed Jul. 28, 2018).

[5] "EUR-Lex - l24226j - EN - EUR-Lex." http://eur-lex.europa.eu/legal-content/EN/TXT/?uri=URISERV:l24226j (accessed May 20, 2017).

[6] M. Aladalah, Y. Cheung, and V. Lee, "Enabling Citizen Participation in Gov 2.0: An Empowerment Perspective," *Electron. J. E-Gov.*, vol. 13, no. 2, 2015, Accessed: 20-May-2017. [Online]. Available: http://www.ejeg.com/issue/download.html?idArticle=409.

[7] C. G. Reddick, "Citizen interaction and e-government: Evidence for the managerial, consultative, and participatory models," *Transform. Gov. People Process Policy*, vol. 5, no. 2, pp. 167–184, May 2011, doi: 10.1108/17506161111131195.

[8] A. Alharbi, K. Kang, and I. Hawryszkiewycz, "The Influence of Trust and subjective Norms on Citizens Intentions to Engage in E-participation on E-government Websites," *ArXiv160600746 Cs*, May 2016, Accessed: 23-Aug-2017. [Online]. Available: http://arxiv.org/abs/1606.00746.

[9] T. Orehovački, "Metodologija vrjednovanja kvalitete u korištenju aplikacijama Web 2.0, Doktorski rad, Sveučilište u Zagrebu, Fakultet organizacije i informatike Varaždin, Varaždin, 2013.," p. 560.

[10] J. R. Edwards, R. P. Bagozzi, "On the Nature and Direction of Relationships Between Constructs and Measures", Psyhological Methods, 2000, Vol. 5, No. 2, 155-174.

[11] G. L. Polites, N. Roberts, and J. Thatcher, "Conceptualizing models using multidimensional constructs: a review and guidelines for their use," *Eur. J. Inf. Syst.*, vol. 21, no. 1, pp. 22–48, Jan. 2012, doi: 10.1057/ejis.2011.10.

[12] M. Bošnjak, M. Galešić, and B. Kliček, "Determinants of online political participation in Croatia," *Druš. Istraživanja Zagreb*, no. 17, p. 23, 2008.

[13] "European Commission Directorate General for Information Society and Media Smarter, Faster, Better eGovernment 8th eGovernment Benchmark Measurement | November 2009." Accessed: 24-Jun-2017. [Online]. Available: https://www.es.capgemini.com/resource-file-access/resource/pdf/Estudio_sobre_los_servicios_p__blicos_online_de_la_UE.pdf.

[14] "INFOGRAFIKA: Tko su hrvatski Facebook korisnici? [2016. vs. 2018.]," *arbona.hr*. https://www.arbona.hr/blog/online-digitalni-marketing/infografika-tko-su-hrvatski-facebook-korisnici-2016-vs-2018/695 (accessed Sep. 22, 2018).

[15] P. A. Macintosh, "Characterizing E-Participation in Policy-Making," *Th Hawaii Int. Conf. Syst. Sci.*, p. 10, 2004.

[16] C. Akkaya, P. Wolf, and H. Krcmar, "Factors Influencing Citizen Adoption of E-Government Services: A Cross-Cultural Comparison (Research in Progress)," in *2012*

45th Hawaii International Conference on System Science (HICSS), 2012, pp. 2531–2540, doi: 10.1109/HICSS.2012.278.
[17] S. Stieglitz and T. Brockmann, "The Impact of Smartphones on E-Participation," 2013, pp. 1734–1742, doi: 10.1109/HICSS.2013.623.
[18] R. Alrashedi, A. Persaud, and G. Kindra, "Drivers of eParticipation: Case of Saudi Arabia," *J. Bus.*, vol. 14, no. 1, pp. 1–22, 2015.
[19] D. L. Blanc, "E-participation: a quick overview of recent qualitative trends," p. 33.
[20] "Eurostat - Tables, Graphs and Maps Interface (TGM) graph - Individuals using the internet for participating in social networks." https://ec.europa.eu/eurostat/tgm/graph.do?tab=graph&plugin=1&language=en&pcode=tin00127&toolbox=type (accessed Jul. 07, 2019).
[21] "Struktura aktivnih Facebook korisnika u Hrvatskoj," *arbona.hr*. https://www.arbona.hr/blog/online-digitalni-marketing/infografika-tko-su-hrvatski-facebook-korisnici/453 (accessed Feb. 15, 2020).
[22] M. Klačmer, "Struktura Internet korisnika po spolu?," 28-Feb-2010.
[23] "Eurostat - Tables, Graphs and Maps Interface (TGM) graph - Individuals using the internet for interaction with public authorities, by type of interaction." https://ec.europa.eu/eurostat/tgm/graph.do?tab=graph&plugin=1&language=en&pcode=tin00013&toolbox=type (accessed Jul. 07, 2019).
[24] "Eurostat - Tables, Graphs and Maps Interface (TGM) graph - Individuals using the internet for taking part in online consultations or voting." https://ec.europa.eu/eurostat/tgm/graph.do?tab=graph&plugin=1&language=en&pcode=tin00129&toolbox=type (accessed Jul. 07, 2019).
[25] M. Lukačić, "DIGITALIZACIJA HRVATSKE Ukidaju se biljezi i uplatnice, dolaze nove beskontaktne osobne iskaznice," *www.icv.hr*, 09-Nov-2018. https://www.icv.hr/2018/11/digitalizacija-hrvatske-ukidaju-se-biljezi-i-uplatnice-dolaze-nove-beskontaktne-osobne-iskaznice/ (accessed Mar. 02, 2020).
[26] "INOVACIJA … i sustav e-Građani," *ICT Business*. https://www.ictbusiness.info/kolumne/inovacija-i-sustav-e-gradani (accessed Feb. 16, 2020).
[27] "Statistički prikaz," *uprava.gov.hr*. https://uprava.gov.hr/statisticki-prikaz/14431 (accessed Apr. 01, 2019).
[28] D. Osimo, "Web 2.0 in government: Why and how," *Inst. Prospect. Technol. Stud. IPTS JRC Eur. Comm. EUR*, vol. 23358, 2008.
[29] M. J. Wills, O. F. El-Gayar, and D. Bennett, "Examining healthcare professionals' acceptance of electronic medical records using UTAUT," no. 2, p. 6, 2008.
[30] J. F. Hair, J. J. Risher, M. Sarstedt, and C. M. Ringle, "When to use and how to report the results of PLS-SEM," *Eur. Bus. Rev.*, vol. 31, no. 1, pp. 2–24, Jan. 2019, doi: 10.1108/EBR-11-2018-0203.
[31] F. D. Davis, "Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology," *MIS Q.*, vol. 13, no. 3, p. 319, Sep. 1989, doi: 10.2307/249008.
[32] E. Lironi and E. C. A. Service, "Potential and challenges of e-participation in the European Union, Directorate general for internal policies, [Online]. Available: http://www.europarl.europa.eu/supporting-analyses. [Accessed: 11-Nov-2018]," p. 76, 2016.
[33] S. I. Mofleh and M. Wanous, "Understanding Factors Influencing Citizens' Adoption of e-Government Services in the Developing World: Jordan as a Case Study," p. 11.
[34] B. Solis, "The Definition of Digital Transformation, [Online]. Available: https://www.briansolis.com/2017/01/definition-of-digital-transformation/," *Brian Solis*,

23-Jan-2017. https://www.briansolis.com/2017/01/definition-of-digital-transformation/ (accessed Sep. 10, 2019).
[35] M. Spremić, *Digitalna transformacija poslovanja*. Ekonomski fakultet Zagreb, 2017.
[36] M. Edmead, "Digital transformation: Why it's important to your organization," *CIO*, 02-May-2016. https://www.cio.com/article/3063620/digital-transformation-why-its-important-to-your-organization.html (accessed Sep. 10, 2019).
[37] "INOVACIJA … inovacijske kontroverze u javnom sektoru," *ICT Business*. https://www.ictbusiness.info/kolumne/inovacija-inovacijske-kontroverze-u-javnom-sektoru (accessed Nov. 25, 2018).
[38] "Exam Preparation Your exam is NOT just remembering FACTS. It is a DESIGN EXAM The Final exam is worth 40% of the final GCSE It will be 2 hours and is. - ppt video online download." https://slideplayer.com/slide/5304978/ (accessed Jul. 07, 2019).
[39] S. Baller, S. Dutta, and B. Lanvin, *The Global Information Technology Report 2016: Innovating in the Digital Economy*. 2016.
[40] N. Vrček and A. Musa, "E-uprava u Hrvatskoj: izazovi transformacije uprave u digitalnom društvu", u Musa, A. (ur.) Uprava u digitalno doba Transformacijski potencijal e-uprave za veću učinkovitost i odgovornost. Forum za javnu upravu. Zagreb: Institut za javnu upravu i Zaklada Friedrich Ebert, 2017.
[41] "OECD (2019), Measuring the Digital Transformation: A Roadmap for the Future, OECD Publishing, Paris, [Online]. Available: https://doi.org/10.1787/9789264311992-en." [Online]. Available: https://doi.org/10.1787/9789264311992-en.
[42] "Hollerith 1890 Census Tabulator." http://www.columbia.edu/cu/computinghistory/census-tabulator.html (accessed Feb. 16, 2019).
[43] "Keep employment by developing e-skills, [Online]. Available: http://docplayer.cz/3041807-Kemp-134681-llp-1-2007-1-pt-grundtvig-gmp-modul-4-elektronicke-bankovnictvi.html." .
[44] "The Institute for Prospective Technological Studies," 14-Mar-2015. http://ipts.jrc.ec.europa.eu/publications/pub.cfm?id=1565 (accessed Mar. 14, 2015).
[45] "European Commission Directorate General for Information Society and Media Smarter, Faster, Better eGovernment 8th eGovernment Benchmark Measurement, November 2009." .
[46] "The Difference Between Web 1.0 and Web 2.0," *Digital Inspiration*, 26-Jun-2007. https://www.labnol.org/internet/favorites/the-difference-between-web-10-and-web-20/665/ (accessed Oct. 07, 2019).
[47] P. Anderson, "What is Web 2.0? Ideas, technologies and implications for education," *JISC Technol. Stand. Watch*, p. 64, 2007.
[48] T. Nam and others, "Toward the new phase of e-government: An empirical study on citizens'attitude about open government and government 2.0," in *11th Public Management Research Conference*, 2011, pp. 2–4, Accessed: 01-Jul-2017. [Online]. Available: https://www.maxwell.syr.edu/uploadedFiles/conferences/pmrc/Files/Nam_Toward%20the%20New%20Phase%20of%20E-government.pdf.
[49] "Governments Around the Globe Have Become Early Adopters of Web 2.0 Strategies." http://www.govtech.com/e-government/Governments-Around-the-Globe-Have-Become.html (accessed Aug. 12, 2017).
[50] "The E-Government Hype Cycle Meets Web 2.0, Gartner, Publication Date: 2 October 2007, ID Number: G00151565." Accessed: 10-Mar-2015. [Online]. Available: http://wiki.douglasbastien.com/images/b/b3/The_E-Government_Hype_Cycle_Meets_Web_2-0.pdf.

[51] “E-Government Meets Web 2.0: Goodbye Portals, Hello Web Services,” *ReadWrite*, 10-Mar-2015. http://readwrite.com/2007/11/05/e-government_meets_web_20 (accessed Mar. 10, 2015).
[52] “A Transformational Agenda For The Digital Age, [Online]. Available: https://www.digitaleurope.org/wp/wp-content/uploads/2019/02/DIGITALEUROPE-%E2%80%93-Our-Call-to-Action-for-A-STRONGER-DIGITAL-EUROPE.pdf. [Accessed: 12-Aug-2017].,” in *DIGITALEUROPE*, 2010, Accessed: 20-May-2017. [Online]. Available: https://www.digitaleurope.org/wp/wp-content/uploads/2019/02/DIGITALEUROPE-%E2%80%93-Our-Call-to-Action-for-A-STRONGER-DIGITAL-EUROPE.pdf.
[53] S. AbdelSalam ElKheshin, "Determinants of E-government Services Adoption in Developing Countries (Egypt)", Ph.D. dissertation, Middlesex University, 2016. Accessed: 29-Jul-2017. [Online]. Available: http://eprints.mdx.ac.uk/21306/1/SElkheshin%20Thesis.pdf.
[54] O. Al-Hujran, M. M. Al-Debei, and E. Al-Lozi, “Examining eDemocracy Adoption Intention for Digital Society: An Integrative Model,” in *The Eighth International Conference on Digital Society*, 2014, pp. 39–47, Accessed: 18-May-2017. [Online]. Available: http://www.zuj.edu.jo/wp-content/staff-research/economic/dr.enas-al-lozi/5.pdf.
[55] “Facebook users worldwide 2019,” *Statista*. https://www.statista.com/statistics/264810/number-of-monthly-active-facebook-users-worldwide/ (accessed Feb. 16, 2020).
[56] M. G. Zago, “Why the Web 3.0 Matters and you should know about it,” *Medium*, 30-Jan-2018. https://medium.com/@matteozago/why-the-web-3-0-matters-and-you-should-know-about-it-a5851d63c949 (accessed Nov. 21, 2018).
[57] “35+ Web 3.0 Examples Of How Blockchain Is Changing The Web,” *101 Blockchains*, 29-Jul-2018. https://101blockchains.com/web-3-0-examples/ (accessed Nov. 17, 2018).
[58] “Why the Blockchain Could Transform the Face of Digital Democracy,” *CitizenLab*, 08-May-2017. https://www.citizenlab.co/blog/civic-tech/blockchain-could-transform-democracy/ (accessed Apr. 30, 2018).
[59] D. Arunović, “Kako rade blockchain i pametni ugovori,” *Bug*, no. 33, pp. 120–126.
[60] “e-Justice,” *e-Estonia*. https://e-estonia.com/solutions/security-and-safety/e-justice/ (accessed Feb. 26, 2019).
[61] “An Australian Political Party with Blockchain Ideals,” *CCN*, 28-Jun-2016. https://www.ccn.com/australian-political-party-blockchain-ideals/ (accessed Nov. 21, 2018).
[62] “Ukraine Government Plans to Trial Ethereum Blockchain-Based Election Platform,” *NASDAQ.com*, 25-Feb-2016. https://www.nasdaq.com/article/ukraine-government-plans-to-trial-ethereum-blockchain-based-election-platform-cm585001 (accessed Nov. 21, 2018).
[63] “Top Trends from Gartner Hype Cycle for Digital Government Technology, 2018.” https://www.gartner.com/smarterwithgartner/top-trends-from-gartner-hype-cycle-for-digital-government-technology-2018/ (accessed Dec. 28, 2018).
[64] M. R. Vicente and A. Novo, “An empirical analysis of e-participation. The role of social networks and e-government over citizens’ online engagement,” *Gov. Inf. Q.*, vol. 31, no. 3, pp. 379–387, Jul. 2014, doi: 10.1016/j.giq.2013.12.006.
[65] P. Mancini, “Transcript of ‘How to upgrade democracy for the Internet era.’” https://www.ted.com/talks/pia_mancini_how_to_upgrade_democracy_for_the_internet_era/transcript (accessed Nov. 11, 2019).

[66] “Voter Turnout Database | International IDEA.” https://www.idea.int/data-tools/data/voter-turnout (accessed Aug. 16, 2018).
[67] R. Coleman, P. Lieber, A. L. Mendelson, and D. D. Kurpius, “Public life and the internet: if you build a better website, will citizens become engaged?,” *New Media Soc.*, vol. 10, no. 2, pp. 179–201, Apr. 2008, doi: 10.1177/1461444807086474.
[68] G. Aichholzer and D. Allhutter, “Online forms of political participation and their impact on democracy,” *Jt. Sess. Eur. Consort. Polit. Res. ECPR Workshop “Professionalisation Individ. Collect. Action Anal. New ‘Participatory’ Dimens. Civ. Soc. Lisbon Port. 14-19 April 2009*, p. 26.
[69] A. Musa and D. Dobrić Jambrović, “Participacija na lokalnoj razini kao standard Vijeća Europe: uloga Europske povelje o lokalnoj samoupravi i Protokola o pravu na sudjelovanje u poslovima lokalnih vlasti,” u I. Koprić (ed.) Europeizacija hrvatske lokalne samouprave. Zagreb: Institut za javnu upravu, pp. 272–342, 2018.
[70] I. Šiber, “Interest in Elections and Electoral Participation,” *Polit. Misao*, vol. Vol. XLI, no. 5, p. 25, 2004.
[71] “Whistle stop train tour,” *Wikipedia*. 01-Jul-2019, Accessed: 17-Jul-2019. [Online]. Available: https://en.wikipedia.org/w/index.php?title=Whistle_stop_train_tour&oldid=904360818.
[72] M. L. Grace, “President Truman’s ‘whistle-stop’ campaign and the end of a tradition in american politics.,” *CRUISING THE PAST*. https://www.cruiselinehistory.com/president-trumans-whistle-stop-campaign-and-the-end-of-a-tradition-in-american-politics/ (accessed Nov. 16, 2018).
[73] “Obama’s Social Media Advantage,” *ReadWrite*, 05-Nov-2008. https://readwrite.com/2008/11/05/social_media_obama_mccain_comparison/ (accessed Dec. 18, 2018).
[74] “Internet and Campaign 2010, Pew Research Center, [Online]. Available: http://pewinternet.org/Reports/2011/The-Internet-and-Campaign-2010.aspx. [Accessed: 24-Nov-2016].” .
[75] L. Rainie, “22% of registered voters have announced their vote for president on social media like Facebook or Twitter,” p. 6.
[76] “Information Communications Technology for Development, Evalution Office (EO) United Nations Development Programme (UNDP) One United Nations Plaza New York, NY 10017.” .
[77] N. M. Lisjak, “Koliko je ‘dobre vladavine’ u hrvatskoj e-vladavini?,” *Anali Hrvat. Politol. Druš.*, p. 33, 2006.
[78] A. Macintosh, "Characterizing e-participation in policy making," Proceedings of the 37th Hawaii International Conference on System Sciences, 2004. Accessed: 19-Aug-2017. [Online]. Available: http://unpan1.un.org/intradoc/groups/public/documents/un-dpadm/unpan038449.pdf.
[79] D. Zissis, D. Lekkas, and A.-E. Papadopoulou, “Competent electronic participation channels in electronic democracy,” *Electron. J. E-Gov.*, vol. 7, no. 2, pp. 195–208, 2009.
[80] “E-participation: what it means and what might it look like,” *communityboostr.org*. http://communityboostr.org/resource/e-participation-what-it-means-and-what-might-it-look (accessed Nov. 24, 2016).
[81] C. K. Ayo, V. W. Mbarika, and A. A. Oni, “The Influence of Trust and Risk on Intention to Use E-Democracy in Nigeria,” *Mediterr. J. Soc. Sci.*, Nov. 2015, doi: 10.5901/mjss.2015.v6n6s1p477.
[82] C. Vrabie and A.-M. Tîrziu, “E-Participation – A Key Factor In Developing Smart Cities,” *EIRP Proc.*, vol. 11, no. 1, Jul. 2016, Accessed: 20-May-2017. [Online]. Available: http://www.proceedings.univ-danubius.ro/index.php/eirp/article/view/1746.

[83] A. Kes-Erkul and R. E. Erkul, “Web 2.0 in the Process of e-participation: The Case of Organizing for America and the Obama Administration,” 2009, Accessed: 20-May-2017. [Online]. Available: http://scholarworks.umass.edu/ncdg/32/.
[84] A. Macintosh, “Characterizing e-participation in policy-making,” in *System Sciences, 2004. Proceedings of the 37th Annual Hawaii International Conference on*, 2004, pp. 10–pp, Accessed: 19-Aug-2017. [Online]. Available: http://ieeexplore.ieee.org/abstract/document/1265300/.
[85] S. Delakorda, “Elektronska participacija,” *Zavod Inštitut za elektronsko participacijo - INePA*. http://www.inepa.si/e-participacija-e-demokracija/elektronska-participacija.html (accessed Sep. 18, 2019).
[86] P. Waller, “In the service of democracy a consultation paper on a policy for electronic democracy, [Online]. Available: https://www.researchgate.net/publication/265348503_E-government_in_the_service_of_democracy. [Accessed: 27-Feb-2019].,” *HM Gov.*, p. 62.
[87] S. Coleman and J. Gotze, "Bowling Together: Online Public Engagement in Policy Deliberation," Hansard Society, St Philips Building North LSE, Sheffield Street London WC2A 2EX. Accessed: 14-Aug-2017. [Online]. Available: https://assets.contentful.com/u1rlvvbs33ri/5VaEnHaaR288yO4cuQUCiK/dd0d2714d4ba52344986f1e63da77e9c/Publication__Bowling-Together-Online-Public-Engagement-in-Policy-Deliberation-2001.pdf.
[88] “Public Consultation on summertime arrangements (This consultation is closed),” *European Commission - European Commission*. https://ec.europa.eu/info/consultations/2018-summertime-arrangements_en (accessed Feb. 27, 2019).
[89] “e-Democracy – ‘What Works’, Local e-Democracy National Project, Key lessons from recent e-Democracy literature, Bristol City Councile, 2005.” Accessed: 14-Aug-2017. [Online]. Available: https://askbristol.files.wordpress.com/2011/10/co-e-demo-what-works.pdf.
[90] “Petition: Revoke Article 50 and remain in the EU.,” *Petitions - UK Government and Parliament*. https://petition.parliament.uk/petitions/241584 (accessed Mar. 23, 2019).
[91] D. B. A. Khosrow-Pour, *Encyclopedia of Information Science and Technology, Third Edition (10 Volumes)*. IGI Global, 1AD.
[92] C. Shirky, *How the Internet will (one day) transform government, [Online]. Available: https://www.ted.com/talks/clay_shirky_how_the_internet_will_one_day_transform_government/transcript?language=en. [Accessed: 23-Mar-2019]*. .
[93] S. P. Weber, *This project is about writing the people’s ideal copyright law.: singpolyma/Copyright-Act-Citizens--Draft*. 2015.
[94] A. Kohut, S. Keeter, C. Doherty, and M. Dimock, “Social Networking and Online Videos Take Off, Internet’s broader role in campaign 2008,” *Pew Res. Cent. People Press*, p. 32, 2008.
[95] Rahvakogu, “juhised rahvakogu kui ühisloomemeetodi kasutamiseks,” *Rahvakogu*. https://rahvakogu.ee/ (accessed Oct. 07, 2019).
[96] “Bills Recently Introduced in Congress.” https://www.popvox.com/us/federal/bills/new (accessed Nov. 11, 2018).
[97] “Neighborland,” *Neighborland*. https://neighborland.com/ (accessed Oct. 07, 2019).
[98] R. Pohoryles and R. Decheva, *eDemocracy and eParticipation: the precious first steps and the way forward*. 2017.
[99] “DemocracyOS - Change the Tool.” http://democracyos.org/ (accessed Oct. 07, 2019).
[100] “Pazi(n), proračun!” http://proracun.pazin.hr/ (accessed Nov. 12, 2018).

[101] S. G.-C. C. Ltd, “Sisak.hr - Moj gradski proračun 2019.” http://proracun.sisak.hr (accessed Feb. 19, 2019).
[102] “Gradsko oko - Grad Bjelovar.” http://bjelovar.oko.hr/# (accessed Oct. 07, 2019).
[103] B. W. and M. Touchton, “Brazil let its citizens make decisions about city budgets. Here’s what happened.,” *Washington Post*, 22-Jan-2014.
[104] C. I. Vrabie and A.-M. Tîrziu, “The European Citizen and Public Administration,” *Eur. Integr.*, p. 7, 2016.
[105] “Innovation Cities™ Index 2018 - Global City Ranking by 2thinknow,” *Innovation Cities Program & Index*, 09-Aug-2018. https://www.innovation-cities.com/innovation-cities-index-2018-global/13935/ (accessed Nov. 25, 2018).
[106] “MojZagreb.” https://moj.zagreb.hr/#/main (accessed Oct. 07, 2019).
[107] “Pilot projekt ‘Zagreb – inovativni grad.’” https://www.zg-inovacija.eu/ (accessed Oct. 07, 2019).
[108] “Grad Varaždin - Službene internet stranice Grada Varaždina,” *varazdin.hr*. https://varazdin.hr/ (accessed Oct. 07, 2019).
[109] I. Graafland-Essers and E. Ettedgui, *Benchmarking E-Government in Europe and the US*, vol. Issue 1733. RAND Europe.
[110] S. Royo and A. Yetano, “‘Crowdsourcing’ as a tool for e-participation: two experiences regarding CO2 emissions at municipal level,” *Electron. Commer. Res.*, vol. 15, no. 3, pp. 323–348, Sep. 2015, doi: 10.1007/s10660-015-9183-6.
[111] “EUR-Lex - 52006DC0173 - EN - EUR-Lex.” http://eur-lex.europa.eu/legal-content/EN/ALL/?uri=CELEX:52006DC0173 (accessed Mar. 14, 2015).
[112] “i2010 – A European Information Society for growth and employment”, Commission of the European communities, Brussels, 1.6.2005.” Accessed: 14-Mar-2015. [Online]. Available: http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2005:0229:FIN:EN:PDF.
[113] “European eGovernment Action Plan 2011-2015,” *Digital Single Market*. https://ec.europa.eu/digital-single-market/en/european-egovernment-action-plan-2011-2015 (accessed May 20, 2017).
[114] “Generation Web 2.0: using new technologies in the public sector in Europe.” https://www.cesi.org (accessed Oct. 07, 2019).
[115] “e-SENS: digitising government services across Europe,” *Digital Agenda for Europe*. ec.europa.eu//digital-agenda/en/news/e-sens-digitising-government-services-across-europe (accessed Mar. 16, 2015).
[116] “Home | European citizens’ initiative - portal.” https://europa.eu/citizens-initiative/home_en (accessed Mar. 18, 2020).
[117] “Consultations,” *European Commission - European Commission*. https://ec.europa.eu/info/consultations_en (accessed Mar. 18, 2020).
[118] “Home | PETI | Committees | European Parliament.” https://petiport.secure.europarl.europa.eu/petitions/en/home (accessed Mar. 18, 2020).
[119] “Guidelines for civil participation in political decision making.” https://search.coe.int/cm/Pages/result_details.aspx?ObjectId=09000016807509dd (accessed Aug. 16, 2018).
[120] “Kodeks savjetovanja sa zainteresiranom javnošću u postupcima donošenja zakona, drugih propisa i akata.” https://narodne-novine.nn.hr/clanci/sluzbeni/2009_11_140_3402.html (accessed Feb. 29, 2020).
[121] “Zakon o pravu na pristup informacijama.” https://narodne-novine.nn.hr/clanci/sluzbeni/2013_02_25_403.html (accessed Mar. 16, 2020).
[122] A. Musa and M. Fulir, “Savjetovanja s javnošću u hrvatskim regulatornim agencijama,” Zbornik radova Veleučilišta u Šibeniku, vol. 13, pp. 7–26, 2019.

[123] "Zakon o izmjenama i dopunama Zakona o pravu na pristup informacijama." https://narodne-novine.nn.hr/clanci/sluzbeni/2015_08_85_1649.html (accessed Mar. 25, 2020).
[124] "Strategija suzbijanja korupcije za razdoblje od 2015. do 2020. godine." https://narodne-novine.nn.hr/clanci/sluzbeni/full/2015_03_26_545.html (accessed Mar. 20, 2020).
[125] "Zakon o procjeni učinaka propisa." https://narodne-novine.nn.hr/clanci/sluzbeni/2017_05_44_998.html (accessed Mar. 16, 2020).
[126] "Partnerstvo za otvorenu vlast," *udruge.gov.hr*. https://udruge.gov.hr/partnerstvo-za-otvorenu-vlast-271/271 (accessed Mar. 19, 2020).
[127] "Provedba Akcijskog plana za provedbu inicijative Partnerstvo za otvorenu vlast u Republici Hrvatskoj za razdoblje do 2020. godine," *udruge.gov.hr*. https://udruge.gov.hr/istaknute-teme/partnerstvo-za-otvorenu-vlast-271/provedba-akcijskog-plana-za-provedbu-inicijative-partnerstvo-za-otvorenu-vlast-u-republici-hrvatskoj-za-razdoblje-do-2020-godine/4898 (accessed Mar. 16, 2020).
[128] "Strategija e-Hrvatska 2020, Ministarstvo uprave - svibanj 2017, [Online]. Available: https://uprava.gov.hr/UserDocsImages/Istaknute%20teme/e-Hrvatska/Strategija_e-Hrvatska_2020.pdf. [Accessed: 20-May-2017]." .
[129] "EGOVKB | United Nations > Data > Country Information." https://publicadministration.un.org/egovkb/en-us/Data/Country-Information/id/42-Croatia/dataYear/2018 (accessed Oct. 07, 2019).
[130] S. Taylor and P. A. Todd, "Understanding Information Technology Usage: A Test of Competing Models," *Inf. Syst. Res.*, vol. 6, no. 2, pp. 144–176, Jun. 1995, doi: 10.1287/isre.6.2.144.
[131] M. S. Featherman and P. A. Pavlou, "Predicting E-Services Adoption: A Perceived Risk Facets Perspective," Social Science Research Network, Rochester, NY, SSRN Scholarly Paper ID 2380274, Nov. 2002. Accessed: 24-Jun-2017. [Online]. Available: https://papers.ssrn.com/abstract=2380274.
[132] E. M. Rogers, *Diffusion of innovations*, 3rd ed. New York : London: Free Press ; Collier Macmillan, 1983.
[133] L. Christian Schaupp and L. Carter, "E-voting: from apathy to adoption," *J. Enterp. Inf. Manag.*, vol. 18, no. 5, pp. 586–601, Oct. 2005, doi: 10.1108/17410390510624025.
[134] K. I. Al-Qeisi and G. M. Al-Abdallah, "Internet Banking Adoption in Jordan: A Behavioral Approach," *Int. J. Mark. Stud.*, vol. 5, no. 6, p. p84, Nov. 2013, doi: 10.5539/ijms.v5n6p84.
[135] "Predicting and changing behavior A reasoned action approach.pdf." .
[136] "Belief, attitude, intention and behaviour An introduction to theory and research.pdf." .
[137] "Theory of reasoned action," *Wikipedia*. 22-Oct-2018, Accessed: 01-Nov-2018. [Online]. Available: https://en.wikipedia.org/w/index.php?title=Theory_of_reasoned_action&oldid=865148782.
[138] I. Ajzen, "The theory of planned behaviour: Reactions and reflections," *Psychol. Health*, vol. 26, no. 9, pp. 1113–1127, Sep. 2011, doi: 10.1080/08870446.2011.613995.
[139] "Theory of planned behavior," *Wikipedia*. 16-Oct-2018, Accessed: 31-Oct-2018. [Online]. Available: https://en.wikipedia.org/w/index.php?title=Theory_of_planned_behavior&oldid=864237208.

[140] I. Ajzen, “The Theory of Planned Behavior,” in *Handbook of Theories of Social Psychology: Volume 1*, 1 Oliver’s Yard, 55 City Road, London EC1Y 1SP United Kingdom: SAGE Publications Ltd, 2012, pp. 438–459.
[141] “The psychology of attitudes. A.H. Eagly & S. Chaiken. Fort Worth, TX: Harcourt, Brace, & Janovich, 1993, 794 pp. Reviewed by Christopher Leone, University of North Florida,” *Psychol. Mark.*, vol. 12, no. 5, pp. 459–466, Aug. 1995, doi: 10.1002/mar.4220120509.
[142] Drexel University, D. Gefen, D. Straub, and Georgia State University, “The Relative Importance of Perceived Ease of Use in IS Adoption: A Study of E-Commerce Adoption,” *J. Assoc. Inf. Syst.*, vol. 1, no. 1, pp. 1–30, Oct. 2000, doi: 10.17705/1jais.00008.
[143] F. D. Davis, “A Technology Acceptance Model for Empirically Testing New End-User Information Systems,” Massachusetts Institute of Technology, Sloan School of Management.
[144] M. Chuttur, ‘Overview of the Technology Acceptance Model: Origins, Developments and Future Directions’ (2009). All Sprouts Content. 290.” Accessed: 25-Jun-2017. [Online]. Available: http://aisel.aisnet.org/cgi/viewcontent.cgi?article=1289&context=sprouts_all.
[145] O. Al Hujran, A. Aloudat, and I. Altarawneh, “Factors Influencing Citizen Adoption of E-Government in Developing Countries: The Case of Jordan,” *Int. J. Technol. Hum. Interact.*, vol. 9, no. 2, pp. 1–19, Apr. 2013, doi: 10.4018/jthi.2013040101.
[146] Y. Malhotra and D. F. Galletta, “Extending the technology acceptance model to account for social influence: theoretical bases and empirical validation,” in *Proceedings of the 32nd Annual Hawaii International Conference on Systems Sciences. 1999. HICSS-32. Abstracts and CD-ROM of Full Papers*, Maui, HI, USA, 1999, p. 14, doi: 10.1109/HICSS.1999.772658.
[147] A. Bandura, “Human Agency in Social Cognitive Theory,” *Am. Psychol.*, p. 10, 1989.
[148] R. L. Thompson, C. A. Higgins, and J. M. Howell, “Personal Computing: Toward a Conceptual Model of Utilization,” *MIS Q.*, vol. 15, no. 1, p. 125, Mar. 1991, doi: 10.2307/249443.
[149] N. Nistor, T. Lerche, A. Weinberger, C. Ceobanu, and J. O. Heymann, “Towards the integration of culture into the Unified Theory of Acceptance and Use of Technology,” *Br. J. Educ. Technol.*, 2012, Accessed: 25-Jun-2017. [Online]. Available: http://onlinelibrary.wiley.com/doi/10.1111/j.1467-8535.2012.01383.x/abstract.
[150] A. Alomary and J. Woollard, “HOW IS TECHNOLOGY ACCEPTED BY USERS? A REVIEW OF TECHNOLOGY ACCEPTANCE MODELS AND THEORIES,” p. 4, 2015.
[151] K. Mathieson, “Predicting User Intentions: Comparing the Technology Acceptance Model with the Theory of Planned Behavior,” *Inf. Syst. Res.*, vol. 2, no. 3, pp. 173–191, Sep. 1991, doi: 10.1287/isre.2.3.173.
[152] G. C. Moore and I. Benbasat, “Development of an Instrument to Measure the Perceptions of Adopting an Information Technology Innovation,” *Inf. Syst. Res.*, vol. 2, no. 3, pp. 192–222, Sep. 1991, doi: 10.1287/isre.2.3.192.
[153] University of Arkansas, V. Venkatesh, J. Thong, Hong Kong University of Science and Technology, X. Xu, and The Hong Kong Polytechnic University, “Unified Theory of Acceptance and Use of Technology: A Synthesis and the Road Ahead,” *J. Assoc. Inf. Syst.*, vol. 17, no. 5, pp. 328–376, May 2016, doi: 10.17705/1jais.00428.
[154] “Unified theory of acceptance and use of technology,” *Wikipedia*. 14-Nov-2018, Accessed: 25-Nov-2018. [Online]. Available:

https://en.wikipedia.org/w/index.php?title=Unified_theory_of_acceptance_and_use_of_technology&oldid=868815137.
[155] M. D. Williams, N. P. Rana, and Y. K. Dwivedi, "The unified theory of acceptance and use of technology (UTAUT): a literature review," *J. Enterp. Inf. Manag.*, vol. 28, no. 3, pp. 443–488, Apr. 2015, doi: 10.1108/JEIM-09-2014-0088.
[156] K. Alshare and A. Mousa, "The moderating effect of espoused cultural dimensions on consumer's intention to use mobile payment devices," 2014, Accessed: 26-Jun-2017. [Online]. Available: http://aisel.aisnet.org/icis2014/proceedings/GlobalandCulturalIssues/3/.
[157] M. Alshehri, S. Drew, and R. AlGhamdi, "Analysis of Citizens Acceptance for E-government Services: Applying the UTAUT Model," *ArXiv13043157 Cs*, Apr. 2013, Accessed: 14-Jan-2015. [Online]. Available: http://arxiv.org/abs/1304.3157.
[158] "What is the Difference Between the Theoretical and the Conceptual Framework?," *Knoji*. https://college.knoji.com/what-is-the-difference-between-the-theoretical-framework-and-the-conceptual-framework/ (accessed Sep. 19, 2019).
[159] D. Adom, E. K. Hussein, A. A. Joe, 'Theoretical and conceptual framework: mandatory ingredients of a quality research', International journal of scientific research, Volume-7 | Issue-1 | January-2018 | ISSN No 2277 - 8179 | IF : 4.176 | IC Value : 93.98..
[160] K. I. Al-Qeisi, "Analyzing the use of UTAUT model in explaining an online behaviour: Internet banking adoption," Thesis, Brunel University Brunel Business School PhD Theses, 2009.
[161] A. Tkalac Verčič, D. Sinčić, and N. Pološki Vokić, *Priručnik za metodologiju istraživačkog rada: kako osmisliti, provesti i opisati znanstveno i stručno istraživanje*. Zagreb: M.E.P., 2010.
[162] J. W. Creswell, *Research design: qualitative, quantitative, and mixed method approaches*, 2nd ed. Thousand Oaks, Calif: Sage Publications, 2003.
[163] S. Vogt and A. Haas, "The future of public participation in Germany: Empirical analyses of administration experts' assessments," *Technol. Forecast. Soc. Change*, vol. 98, no. Supplement C, pp. 157–173, Sep. 2015, doi: 10.1016/j.techfore.2015.04.013.
[164] "Falling Through the Net: Table of Contents." https://www.ntia.doc.gov/legacy/ntiahome/fttn99/contents.html (accessed Feb. 23, 2020).
[165] ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT, "UNDERSTANDING THE DIGITAL DIVIDE," 2001. [Online]. Available: http://www.oecd.org/dataoecd/38/57/1888451.pdf.
[166] B. Campaine, "Re-Examining the Digital Divide," *Digit. Divide Facing Crisis Creat. Myth MIT Press*, 2001.
[167] J. A. G. M. Van Dijk, "Digital Divide: Impact of Access," in *The International Encyclopedia of Media Effects*, P. Rössler, C. A. Hoffner, and L. van Zoonen, Eds. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2017, pp. 1–11.
[168] J. Murphy and M. Roser, "Internet," *Our World Data*, Jul. 2015, Accessed: 12-Sep-2019. [Online]. Available: https://ourworldindata.org/internet.
[169] "Digital Divide is Shrinking for America's Hispanic Population, NTIA Data Show | National Telecommunications and Information Administration." https://www.ntia.doc.gov/blog/2019/digital-divide-shrinking-america-s-hispanic-population-ntia-data-show (accessed Feb. 23, 2020).
[170] "Digital Nation Data Explorer | National Telecommunications and Information Administration." https://www.ntia.doc.gov/data/digital-nation-data-explorer#sel=internetUser&demo=&pc=prop&disp=chart (accessed Feb. 23, 2020).

[171] "Going Digital: Shaping Policies, Improving Lives | READ online," *OECD iLibrary*. https://read.oecd-ilibrary.org/science-and-technology/going-digital-shaping-policies-improving-lives_9789264312012-en (accessed Sep. 12, 2019).
[172] "Analyse one indicator and compare countries — Digital Scoreboard - Data & Indicators." https://digital-agenda-data.eu/charts/analyse-one-indicator-and-compare-countries#chart={%22indicator-group%22:%22internet-usage%22,%22indicator%22:%22i_iu3%22,%22breakdown%22:%22empl_une%22,%22unit-measure%22:%22pc_ind%22,%22ref-area%22:[%22BE%22,%22BG%22,%22CZ%22,%22DK%22,%22DE%22,%22EE%22,%22IE%22,%22EL%22,%22ES%22,%22FR%22,%22IT%22,%22CY%22,%22LI%22,%22LV%22,%22LT%22,%22LU%22,%22HU%22,%22MT%22,%22NL%22,%22AT%22,%22PL%22,%22PT%22,%22RO%22,%22SI%22,%22SK%22,%22FI%22,%22SE%22,%22UK%22,%22EU%22,%22HR%22,%22IS%22,%22NO%22]} (accessed Mar. 19, 2020).
[173] "PRIMJENA INFORMACIJSKIH I KOMUNIKACIJSKIH TEHNOLOGIJA (IKT) U KUĆANSTVIMA I KOD POJEDINACA U 2018., PRVI REZULTATI/USAGE OF INFORMATION AND COMMUNICATION TECHNOLOGIES (ICT) IN HOUSEHOLDS AND BY INDIVIDUALS, 2018, FIRST RESULTS." https://www.dzs.hr/Hrv_Eng/publication/2018/02-03-02_01_2018.htm (accessed Feb. 19, 2020).
[174] "Kakvo je zapravo stanje interneta u Hrvatskoj?," *ICT Business*. http://www.ictbusiness.info/internet/kakvo-je-zapravo-stanje-interneta-u-hrvatskoj (accessed Aug. 14, 2017).
[175] Zee, "First Finland, Now Spain Makes Broadband Access a Legal Right.," *The Next Web*, 19-Nov-2009. https://thenextweb.com/eu/2009/11/19/finland-spain-broadband-legal/ (accessed Mar. 18, 2020).
[176] "Pravilnik o izmjenama i dopunama Pravilnika o načinu i uvjetima obavljanja djelatnosti elektroničkih komunikacijskih mreža i usluga." http://narodne-novine.nn.hr/clanci/sluzbeni/2016_05_42_1101.html (accessed Aug. 14, 2017).
[177] K. Rogers, "Why Romania's Internet Is So Much Faster Than America's," *Motherboard*, 02-Feb-2015. https://motherboard.vice.com/en_us/article/jp5aa3/why-romanias-internet-is-so-much-faster-than-americas (accessed Apr. 08, 2018).
[178] "Digital divide," *Wikipedia*. 31-Oct-2017, Accessed: 02-Nov-2017. [Online]. Available: https://en.wikipedia.org/w/index.php?title=Digital_divide&oldid=808008115.
[179] "A new digital divide: Young people who can't use keyboards：The Asahi Shimbun," *The Asahi Shimbun*. http://www.asahi.com/ajw/articles/AJ201803290068.html (accessed Jul. 23, 2018).
[180] "Eurostat - Tables, Graphs and Maps Interface (TGM) graph - Level of internet access." https://ec.europa.eu/eurostat/tgm/graph.do?tab=graph&plugin=1&language=en&pcode=tin00134&toolbox=type (accessed Oct. 07, 2019).
[181] "INOVACIJA … postanite e-Građani uz pomoć knjižnice!," *ICT Business*. https://www.ictbusiness.info/kolumne/inovacija-postanite-e-gradani-uz-pomoc-knjiznice (accessed Aug. 17, 2018).
[182] S. Funilkul and W. Chutimaskul, "The framework for sustainable eDemocracy development," *Transform. Gov. People Process Policy*, vol. 3, no. 1, pp. 16–31, Mar. 2009, doi: 10.1108/17506160910940713.
[183] A. Macintosh and A. Whyte, "Towards an evaluation framework for eParticipation," *Transform. Gov. People Process Policy*, vol. 2, no. 1, pp. 16–30, Mar. 2008, doi: 10.1108/17506160810862928.

[184] M. J. Magro, “A Review of Social Media Use in E-Government,” *Adm. Sci.*, vol. 2, no. 2, pp. 148–161, Apr. 2012, doi: 10.3390/admsci2020148.
[185] H. Ali and T. Ali, “E-participation: Factors affect Citizens’ acceptance and readiness in Kingdom of Bahrain,” in *International Conference on Information Society (i-Society 2014)*, London, United Kingdom, 2014, pp. 146–150, doi: 10.1109/i-Society.2014.7009029.
[186] N. Fathema, "Structural Equation Modeling (SEM) of an Extended Technology Acceptance Model (TAM) to Report Web Technology Adoption Behavior in Higher Education Institutions," Ph.D. dissertation, Graduate Faculty of Auburn University, Auburn, Alabama December 14, 2013.
[187] C.-L. Hsu and J. C.-C. Lin, “Acceptance of blog usage: The roles of technology acceptance, social influence and knowledge sharing motivation,” *Inf. Manage.*, vol. 45, no. 1, pp. 65–74, Jan. 2008, doi: 10.1016/j.im.2007.11.001.
[188] M. Warkentin, D. Gefen, P. Pavlou and G. Rose, Encouraging Citizen Adoption of e-Government by Building Trust, 2002 Electronic Markets.
[189] A. Chadwick, “Web 2.0: New challenges for the study of e-democracy in an era of informational exuberance,” *Isjlp*, vol. 5, p. 9, 2008.
[190] A Avdic, K. Hedström, J. Rose, A. Grönlund, Understanding eParticipation Contemporary PhD eParticipation research in Europe, Örebro University Library, 2007.
[191] E. W. Welch and C. C. Hinnant, “Internet use, transparency, and interactivity effects on trust in government,” in *36th Annual Hawaii International Conference on System Sciences, 2003. Proceedings of the*, Big Island, HI, USA, 2003, p. 7 pp., doi: 10.1109/HICSS.2003.1174323.
[192] B. S. Krueger, “Assessing the Potential of Internet Political Participation in the United States: A Resource Approach,” *Am. Polit. Res.*, vol. 30, no. 5, pp. 476–498, Sep. 2002, doi: 10.1177/1532673X02030005002.
[193] K. I. Al-Qeisi, “Analyzing the use of UTAUT model in explaining an online behaviour: Internet banking adoption,” Thesis, Brunel University Brunel Business School PhD Theses, 2009.
[194] “Constructs in quantitative research | Lærd Dissertation.” http://dissertation.laerd.com/constructs-in-quantitative-research.php (accessed Feb. 23, 2020).
[195] “Data Center.” https://publicadministration.un.org/egovkb/en-us/Data-Center (accessed Jul. 08, 2019).
[196] G. Milas, *Istraživačke metode u psihologiji i drugim društvenim znanostima*. Naklada Slap, 2005.
[197] M. Vujevic, *Uvodjenje U Znanstveni Rad*. Školska knjiga Zagreb, 2006.
[198] O. Alhujran, “Determinants of e-government services adoption in developing countries: a field survey and a case study,” *Univ. Wollongong Thesis Collect.*, Jan. 2009, [Online]. Available: http://ro.uow.edu.au/theses/1998.
[199] A. Z. Abbasi, D. H. Ting, and H. Hlavacs, “Engagement in Games: Developing an Instrument to Measure Consumer Videogame Engagement and Its Validation,” *Int. J. Comput. Games Technol.*, vol. 2017, pp. 1–10, 2017, doi: 10.1155/2017/7363925.
[200] G. A. Churchill, “A Paradigm for Developing Better Measures of Marketing Constructs,” *J. Mark. Res.*, vol. 16, no. 1, p. 64, Feb. 1979, doi: 10.2307/3150876.
[201] “Adopting or Adapting Instruments.” http://korbedpsych.com/R09aAdopt.html (accessed Sep. 17, 2018).
[202] M. Mejovšek, *Metode znanstvenog istraživanja u društvenim i humanističkim znanostima*. Zagreb: Naklada Slap, Udžbenici Sveučilišta u Zagrebu.

[203] S. Wangpipatwong, W. Chutimaskul, and B. Papasratorn, "Understanding Citizen's Continuance Intention to Use e-Government Website: a Composite View of Technology Acceptance Model and Computer Self-Efficacy," vol. 6, no. 1, p. 10, 2008.
[204] "N. Vrček, M. Klačmer, Intention to Use and Variables Influencing Intention to Use Electronic Government Services Among Citizens. Journal of Information and Organizational Sciences. 38. 2014, 55-69." .
[205] S. Renko and D. Popović, "Exploring the consumers' acceptance of electronic retailing using technology acceptance model," *Posl. Izvrsnost Zagreb*, vol. IX, no. 1, p. 13, 2015.
[206] M. Hakkak, H. A. Vahdati, and V. Pirdadeh Biranvand, "An extended technology acceptance model for detecting influencing factors: An empirical investigation," *Manag. Sci. Lett.*, pp. 2795–2804, 2013, doi: 10.5267/j.msl.2013.09.030.
[207] A. S. Ahadzadeh, S. P. Sharif, F. S. Ong, and K. W. Khong, "Integrating Health Belief Model and Technology Acceptance Model: An Investigation of Health-Related Internet Use," *J. Med. Internet Res.*, vol. 17, no. 2, p. e45, 2015, doi: 10.2196/jmir.3564.
[208] Y. Sun, N. Wang, X. Guo, and Z. Peng, "Understanding the acceptance of mobile health services: a comparison and integration of alternative models," vol. 14, no. 2, p. 18, 2013.
[209] L. Carter and F. Bélanger, "The utilization of e-government services: citizen trust, innovation and acceptance factors," *Inf. Syst. J.*, vol. 15, no. 1, pp. 5–25, Jan. 2005, doi: 10.1111/j.1365-2575.2005.00183.x.
[210] F. Bélanger and L. Carter, "Trust and risk in e-government adoption," *J. Strateg. Inf. Syst.*, vol. 17, no. 2, pp. 165–176, Jun. 2008, doi: 10.1016/j.jsis.2007.12.002.
[211] S. E. Colesca, "Increasing e-trust: a solution to minimize risk in e-government adoption," p. 14.
[212] M. M. Al-Debei, E. Al-Lozi, and A. Papazafeiropoulou, "Why people keep coming back to Facebook: Explaining and predicting continuance participation from an extended theory of planned behaviour perspective," *Decis. Support Syst.*, vol. 55, no. 1, pp. 43–54, Apr. 2013, doi: 10.1016/j.dss.2012.12.032.
[213] L. M. Kuran, "Applying the theory of planned behavior in the purchase of organic food," *Mark.-Trž.*, vol. 26, no. 2, p. 19, 2014.
[214] H.-F. Lin, "Predicting consumer intentions to shop online: An empirical test of competing theories," *Electron. Commer. Res. Appl.*, vol. 6, no. 4, pp. 433–442, Dec. 2007, doi: 10.1016/j.elerap.2007.02.002.
[215] I. Faletar, "Usporedba teorije planiranog ponašanja i teorije aktiviranja normi na primjeru ponašanja potrošača ekoloških prehrambenih proizvoda, Doktorski rad, Sveučilište u Zagrebu, Agronomski fakultet, Zagreb 2018," 2018.
[216] J. F. George, "The theory of planned behavior and Internet purchasing," *Internet Res.*, vol. 14, no. 3, pp. 198–212, Jul. 2004, doi: 10.1108/10662240410542634.
[217] S. S. Kim, "The Integrative Framework of Technology Use: An Extension and Test," *MIS Q.*, vol. 33, no. 3, pp. 513–537, 2009, doi: 10.2307/20650307.
[218] C.-H. Ku, "Extending the technology acceptance model using perceived user resources in higher education web-based online learning courses, PhD. dissertation," College of Education at the University of Central Florida Orlando, Florida Spring Term, 2009.
[219] F. D. Davis and V. Venkatesh, "A critical assessment of potential measurement biases in the technology acceptance model: three experiments," *Int. J. Hum.-Comput. Stud.*, vol. 45, no. 1, pp. 19–45, Jul. 1996, doi: 10.1006/ijhc.1996.0040.
[220] L. Preglej, "ISTRAŽIVANJA U NASTAVI," p. 18, 2014.

[221] "Non-Probability Sampling: Definition, Methods and Examples," *QuestionPro*, 30-Apr-2018. https://www.questionpro.com/blog/non-probability-sampling/ (accessed Oct. 15, 2019).
[222] "P.Mean: Debating the validity of snowball sampling (created 2012-10-01)." http://www.pmean.com/12/snowball.html (accessed Oct. 15, 2019).
[223] L. Thabane *et al.*, "A tutorial on pilot studies: the what, why and how," *BMC Med. Res. Methodol.*, vol. 10, no. 1, Dec. 2010, doi: 10.1186/1471-2288-10-1.
[224] D. R. Hill, "What sample size is 'enough' in Internet," *Interpers. Comput. Technol. Electron. J. 21st Century*, vol. 6, no. 3, p. 10, Jul. 1998.
[225] M. A. Hertzog, "Considerations in determining sample size for pilot studies," *Res. Nurs. Health*, vol. 31, no. 2, pp. 180–191, Apr. 2008, doi: 10.1002/nur.20247.
[226] I. Pandža Bajs, "Čimbenici očekivane i doživljene vrijednosti za potrošača: primjer turističke destinacije Dubrovnik", Ekonomski pregled, 65 (4) 271-293 (2014).
[227] K. K.-K. Wong, "Partial least squares structural equation modeling (PLS-SEM) techniques using SmartPLS," *Mark. Bull.*, vol. 24, no. 1, pp. 1–32, 2013.
[228] S. A. Samani, "Steps in Research Process (Partial Least Square of Structural Equation Modeling (PLS-SEM))," *Int. J. Soc. Sci. Bus.*, vol. 1, no. 2, p. 13, 2016.
[229] K.-L. Wong, S.-F. Ong, and T.-Y. Kuek, "Constructing a Survey Questionnaire to Collect Data on Service Quality of Business Academics," p. 13, 2012.
[230] P. T. Jaeger and K. M. Thompson, "Social information behavior and the democratic process: Information poverty, normative behavior, and electronic government in the United States," *Libr. Inf. Sci. Res.*, vol. 26, no. 1, pp. 94–107, Dec. 2004, doi: 10.1016/j.lisr.2003.11.006.
[231] W. Wong Poh Ming and T. T. Ling, "Students perceptions of brand equity: the moderating role of student satisfaction," *J. Appl. Struct. Equ. Model.*, vol. 3, 2019.
[232] J. Garcia-Fernadez, S. Martelo-Landroguez, L. Velez-Colon, and G. Cepeda-Carrion, "An explanatory and predictive PLS-SEM approach to the relationship between organizational culture, organizational performance and customer loyalty," *J. Hosp. Tour. Technol.*, vol. 9, no. 3, 2018, doi: 101108.
[233] G. Lappas, A. Triantafillidou, P. Yannas, and A. Kleftodimos, "Local E-Government and E-Democracy: An Evaluation of Greek Municipalities," in *E-Democracy – Citizen Rights in the World of the New Computing Paradigms*, vol. 570, S. K. Katsikas and A. B. Sideridis, Eds. Cham: Springer International Publishing, 2015, pp. 134–150.
[234] "The Sage Encyclopedia of Qualitative Research Methods - Sage Encyclopedia of Qualitative Research Methods- 2008.pdf." http://www.yanchukvladimir.com/docs/Library/Sage%20Encyclopedia%20of%20Qualitative%20Research%20Methods-%202008.pdf (accessed Aug. 14, 2017).
[235] J. Kirchherr and K. Charles, "Enhancing the sample diversity of snowball samples: Recommendations from a research project on anti-dam movements in Southeast Asia," *PLOS ONE*, vol. 13, no. 8, p. e0201710, Aug. 2018, doi: 10.1371/journal.pone.0201710.
[236] "Practical Sampling," *SAGE Publications Ltd*, 24-Nov-2018. https://uk.sagepub.com/en-gb/eur/practical-sampling/book3152 (accessed Dec. 25, 2018).
[237] G. D. Israel, "Determining Sample Size," 14-Jun-2013. https://edis.ifas.ufl.edu/pd006 (accessed Sep. 07, 2015).
[238] P. Boyd, "Sampling Concepts," p. 21.
[239] H. Taherdoost, "Determining Sample Size; How to Calculate Survey Sample Size," vol. 2, p. 4, 2017.
[240] J. E. Bartlett, J. W. Kotrlik, and C. C. Higgins, "Organizational Research: Determining Appropriate Sample Size in Survey Research," p. 8.

[241] K. Puszczak, A. Fronczyk, and M. Urbański, “Analysis of sample size in consumer surveys,” *Task Force Qual. BCS Data*, Aug. 2013.
[242] N. Bosilj, “MODEL I EMPIRIJSKI ČINITELJI KORISNIČKOG PRIHVAĆANJA MOBILNOG OGLAŠAVANJA,” Falultet organizacije i informatike Varaždin, Varaždin, 2011.
[243] A. A. Ayele and W. K. Birhanie, “Acceptance and use of e-learning systems: the case of teachers in technology institutes of Ethiopian Universities,” *Appl. Inform.*, vol. 5, no. 1, p. 1, Dec. 2018, doi: 10.1186/s40535-018-0048-7.
[244] M. Charmchian Langerodi, “Structural equation modeling of rice farmers’ participation in environmental protection,” *Appl. Ecol. Environ. Res.*, vol. 15, no. 3, pp. 1765–1780, 2017, doi: 10.15666/aeer/1503_17651780.
[245] Student of Education management ,Islamic Azad University, Saveh Branch, Saveh,Iran and A. Rezaei, “Impact of management style of managers on amount of parent participation in schools issues in the saveh city,Iran,” *IOSR J. Bus. Manag.*, vol. 13, no. 6, pp. 21–25, 2013, doi: 10.9790/487X-1362125.
[246] “Determining sample size, Business Advocacy Network, [Online]. Available: http://www.businessadvocacy.net/dloads/fsSampleSize.pdf. [Accessed: 14-Aug-2017].” .
[247] J.-H. Lee, S. W. Kim, and C. H. Song, “The Effects of Trust and Perceived Risk on Users’ Acceptance of ICT Services,” Social Science Research Network, Rochester, NY, SSRN Scholarly Paper ID 1703213, Oct. 2010. Accessed: 13-Oct-2015. [Online]. Available: http://papers.ssrn.com/abstract=1703213.
[248] “Determinants of young consumers online shopping intentions.” .
[249] M. Mora, O. Gelman, A. Steenkamp, and M. S. Raisinghani, “Research Methodologies, Innovations and Philosophies in Software Systems Engineering and Information Systems,” *Inf. Sci. Ref. Impr. IGI Glob.*, p. 17.
[250] J. Carlos Roca, J. José García, and J. José de la Vega, “The importance of perceived trust, security and privacy in online trading systems,” *Inf. Manag. Comput. Secur.*, vol. 17, no. 2, pp. 96–113, Jun. 2009, doi: 10.1108/09685220910963983.
[251] W. W. Chin, "The Partial Least Squares Approach to SEM," Advances in Hospitality and Leisure 8(2), January 1998.
[252] Marcoulides and Saunders, “Editor’s Comments: PLS: A Silver Bullet?,” *MIS Q.*, vol. 30, no. 2, p. iii, 2006, doi: 10.2307/25148727.
[253] D. Gefen, D. W. Straub, and M.-C. Boudreau, *Structural Equation Modeling And Regression: Guidelines For Research Practice*. 2000.
[254] B. E. Whitley, M. E. Kite, "Principles of Research in Behavioral Science, Factor Analysis, Path Analysis, and Structural Equation Modeling," Principles of Research in Behavioral Science Fourth Edition, 2018.
[255] J. B. Ullman, “Structural Equation Modeling: Reviewing the Basics and Moving Forward,” *J. Pers. Assess.*, vol. 87, no. 1, pp. 35–50, Jul. 2006, doi: 10.1207/s15327752jpa8701_03.
[256] N. Kock, “Factor-based structural equation modeling with WarpPLS,” *Australas. Mark. J. AMJ*, vol. 27, no. 1, pp. 57–63, Feb. 2019, doi: 10.1016/j.ausmj.2019.02.002.
[257] C. M. Ringle and M. Sarstedt, “Gain more insight from your PLS-SEM results: The importance-performance map analysis,” *Ind. Manag. Data Syst.*, vol. 116, no. 9, pp. 1865–1886, Oct. 2016, doi: 10.1108/IMDS-10-2015-0449.
[258] J. F. Hair, C. M. Ringle, and M. Sarstedt, “PLS-SEM: Indeed a Silver Bullet,” *J. Mark. Theory Pract.*, vol. 19, no. 2, pp. 139–152, Apr. 2011, doi: 10.2753/MTP1069-6679190202.
[259] W. W. Chin, “The Partial Least Squares Approach to Structural Equation Modeling,” *Mod. Methods Bus. Res.*, vol. 295, 1998.

[260] J. C. Anderson and D. W. Gerbing, “Structural Equation Modeling in Practice: A Review and Recommended Two-Step Approach,” *Psychol. Bull.*, vol. 103, no. 3, p. 13, 1998.
[261] J. F Hair, G. T. M. Hult, C. M. Ringle, and M. Sarstedt, *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)*, Second Edition. SAGE Publications, 2017.
[262] C. B. Jarvis, S. B. MacKenzie, and P. M. Podsakoff, “A Critical Review of Construct Indicators and Measurement Model Misspecification in Marketing and Consumer Research,” *J. Consum. Res.*, vol. 30, no. 2, pp. 199–218, Sep. 2003, doi: 10.1086/376806.
[263] Petter, Straub, and Rai, “Specifying Formative Constructs in Information Systems Research,” *MIS Q.*, vol. 31, no. 4, p. 623, 2007, doi: 10.2307/25148814.
[264] R. C. MacCallum and M. W. Browne, “The use of causal indicators in covariance structure models: some practical issues,” *Psychol. Bull.*, vol. 114, no. 3, pp. 533–541, Nov. 1993.
[265] K. Pousttchi and L. Goeke, “Determinants of customer acceptance for mobile data services: an empirical analysis with formative constructs,” *Int. J. Electron. Bus.*, vol. 9, no. 1/2, p. 26, 2011, doi: 10.1504/IJEB.2011.040354.
[266] I. Ajzen, P. Schmidt, "The Theory of Planned Behavior (TPB) Meets Structural Equation Modeling (SEM)," Workshop, Department of Psychosocial Science / DICE-Lab, Faculty of Psychology, University of Bergen, Christiesgate 13, 5020 Bergen.
[267] M. Haenlein and A. M. Kaplan, “A Beginner’s Guide to Partial Least Squares Analysis,” *Underst. Stat.*, vol. 3, no. 4, pp. 283–297, Nov. 2004, doi: 10.1207/s15328031us0304_4.
[268] “An Assessment of Formative and Reflective Constructs in IS Research, Ronald D. Freeze, Robyn L. Raschke, Proceedings of the Fifteenth European Conference on Information Systems, ECIS 2007, St. Gallen, Switzerland, 2007.” .
[269] D. Šimić, "Pisanje i objavljivanje znanstvenih i stručnih radova," FOI Varaždin, 2014.
[270] M. C. Lo, T. Ramayah, and A. A. Mohamad, “Does Intention Really Lead to Actual Use of Technology? A Study of an E-learning System among University Students in Malaysia / Vodi li namjera korištenja tehnologijom njezinoj stvarnoj upotrebi? Istraživanje sustava e-učenja među studentima u Maleziji,” *Croat. J. Educ. - Hrvat. Časopis Za Odgoj Obraz.*, vol. 17, no. 3, Oct. 2015, doi: 10.15516/cje.v17i3.1085.
[271] J. F. Hair, Ed., *Multivariate data analysis*, 7. ed., Pearson new internat. ed. Harlow: Pearson, 2014.
[272] “Structural Equation Models with Unobservable Variables and Measurement Error: Algebra and Statistics Claes Fornell, David F. LarckerFirst Published August 1, 1981 Announcement https://doi.org/10.1177/002224378101800313 Article information No Access Article Information Volume: 18 issue: 3, page(s): 382-388 Issue published: August 1, 1981.” .
[273] C. Fornell and D. F. Larcker, “Evaluating Structural Equation Models with Unobservable Variables and Measurement Error,” *J. Mark. Res.*, p. 12, 1981.
[274] J. Henseler, C. M. Ringle, and M. Sarstedt, “A new criterion for assessing discriminant validity in variance-based structural equation modeling,” *J. Acad. Mark. Sci.*, vol. 43, no. 1, pp. 115–135, Jan. 2015, doi: 10.1007/s11747-014-0403-8.
[275] H. Latan and N. A. Ramli, “The Results of Partial Least Squares-Structural Equation Modelling Analyses (PLS-SEM),” *SSRN Electron. J.*, 2013, doi: 10.2139/ssrn.2364191.
[276] J. L. Roldán and M. J. Sánchez-Franco, “Variance-based Structural Equation Modeling: Guidelines for Using Partial Least Squares in Information Systems Research,” p. 64, 2012.

[277] R. Silva, C. Ringle, D. Silva, and D. Bido, “Structural equation modeling with the smartpls,” *Rev. Bras. Mark.*, vol. 13, pp. 56–73, Sep. 2014.
[278] N. Urbach and F. Ahlemann, “Structural Equation Modeling in Information Systems Research Using Partial Least Squares,” vol. 11, no. 2, p. 37.
[279] M. Afandi nin Md Amin, “A User Acceptance Model of Web Personalization Systems,” Computer science discipline, Queensland University of Technology, 2012.
[280] Econterms, “What Is the Significance Level in Hypothesis Testing?,” *ThoughtCo*. https://www.thoughtco.com/significance-level-in-hypothesis-testing-1147177 (accessed Feb. 27, 2020).
[281] “P-Values and Statistical Significance | Simply Psychology.” https://www.simplypsychology.org/p-value.html (accessed Feb. 27, 2020).
[282] “How to Interpret Likert Surveys,” *Sciencing*. https://sciencing.com/interpret-likert-surveys-8573143.html (accessed Jun. 17, 2019).
[283] D. Barry, “Do not use averages with Likert scale data,” *Enterp. Anal.*, p. 24, 2017.
[284] D. Bertram, “Likert Scale,” *CPSC 681 – Top. Rep.*, p. 11.
[285] J. Sauro, “MeasuringU: Can You Take the Mean of Ordinal Data?” https://measuringu.com/mean-ordinal/ (accessed Jun. 18, 2019).
[286] U. Sivarajah, "Exploring the Application of Web 2.0 Technologies in the context of e-Government," Brunel Business School Brunel University February 2014.” .
[287] M. R. Ab Hamid, W. Sami, and M. H. Mohmad Sidek, “Discriminant Validity Assessment: Use of Fornell & Larcker criterion versus HTMT Criterion,” *J. Phys. Conf. Ser.*, vol. 890, p. 012163, Sep. 2017, doi: 10.1088/1742-6596/890/1/012163.
[288] J. Henseler, “All rights reserved Composite Modeling GmbH & Co. KG, Kleve, Germany.,” p. 61.
[289] S. Raithel, M. Sarstedt, S. Scharf, and M. Schwaiger, “On the value relevance of customer satisfaction. Multiple drivers and multiple markets,” *J. Acad. Mark. Sci.*, vol. 40, no. 4, pp. 509–525, Jul. 2012, doi: 10.1007/s11747-011-0247-4.
[290] J. Benitez, J. Henseler, A. Castillo, and F. Schuberth, “How to perform and report an impactful analysis using partial least squares: Guidelines for confirmatory and explanatory IS research,” *Inf. Manage.*, p. 103168, May 2019, doi: 10.1016/j.im.2019.05.003.
[291] D. Fitriani, “The usage of Internet in Indonesian government agencies: The cultural validity of the unified theory of acceptance and use of technology,” Master thesis, University of Twente.
[292] L. Komito, “e-Participation and Governance: Widening the net,” *Electron. J. E-Gov.*, vol. 3, no. 1, pp. 39–48, 2005.
[293] “Open Data,” *openNASA*. https://open.nasa.gov/open-data/ (accessed Nov. 11, 2019).
[294] “Erstellt im Auftrag des Ministeriums für Innovation, Wissenschaft und Forschung des Landes Nordrhein-Westfalen, Marz 2013, [Online]. Available: http://fsvkbo.de/wp-content/uploads/2011/10/Statistikbericht_Hochschule-Gestalten.NRW_.de_.pdf. [Accessed: 25-Sep-2019].” .
[295] “Online Consultation on Higher Education in North Rhine-Westphalia, Germany – Participedia.” https://participedia.net/case/4161 (accessed Sep. 25, 2019).
[296] C. Canales, “NASA Uses Crowdsourcing for Open Innovation Contracts,” *NASA*, 04-Jun-2015. http://www.nasa.gov/press-release/nasa-uses-crowdsourcing-for-open-innovation-contracts (accessed Sep. 25, 2019).
[297] M. von Aue, “What Is the ‘Psychographic Modeling Technique’ and How Did It Help Trump?,” *Inverse*. https://www.inverse.com/article/42459-psychographic-modeling-technique-facebook-data (accessed Oct. 17, 2019).

[298] A. Arslan, “Cross-Cultural Analysis of European E-Government Adoption,” Social Science Research Network, Rochester, NY, SSRN Scholarly Paper ID 1525863, Dec. 2009. Accessed: 14-Jan-2015. [Online]. Available: http://papers.ssrn.com/abstract=1525863.
[299] M. Ali, V. Weerakkody, and R. El-Haddadeh, “The Impact of National Culture on eGovernment Implementation: A Comparison Case Study,” p. 14, 2009.
[300] O. Al-Hujran, M. Al-dalahmeh, and A. Aloudat, “The Role of National Culture on Citizen Adoption of eGovernment Services: An Empirical Study,” vol. 9, no. 2, p. 131, 2011.
[301] M. R. Jekni, “Kulture i organizacije: organizacijske kulture Geerta Hofstedea,” *Zb. Rad. Pravnog Fak. U Splitu*, vol. 48, no. 1, p. 21, 2011.
[302] “Compare countries,” *Hofstede Insights*. https://www.hofstede-insights.com/product/compare-countries/ (accessed Mar. 21, 2020).
[303] “Participedia.” https://participedia.net/ (accessed Sep. 21, 2019).

PRILOZI

Prilog A: Anketni upitnik glavnog istraživanja

Istraživanje čimbenika povezanih s namjerom korištenja javnih usluga e-participacije u Republici Hrvatskoj u 2019. godini

Uputa

Poštovani, ljubazno Vas molim za petnaestak minuta Vašeg vremena za ispunjavanje anketnog upitnika kako biste mi pomogli u provođenju istraživanja. Istraživanje se provodi za potrebe izrade doktorske disertacije pod nazivom „Činitelji prihvaćanja javnih usluga e-participacije u Republici Hrvatskoj“. Upitnik služi za utvrđivanje čimbenika koji mogu utjecati na namjeru korištenja javnih usluga e-participacije (korištenje informacijsko-komunikacijskih tehnologija za osnaživanje sudjelovanja građana vezano uz sve procese donošenja odluka koje su od javnog značaja). Dodatno, ovim upitnikom želi se istražiti koliko su građani Republike Hrvatske spremni koristiti različite razine javnih usluga e-participacije.

Kako bi se klasificirali za popunjavanje ovog upitnika morate biti građanin Republike Hrvatske koji koristi Internet barem jedanput tjedno i ima više od 16 a manje od 74 godina. Popunjavanje ovog upitnika je anonimno, dobrovoljno i smijete ga popuniti samo jednom. Ukoliko ste popunili upitnik, smatra se da ste suglasni s korištenjem vaših odgovora za statistička istraživanja isključivo u znanstvene svrhe.

Za sva pitanja možete me kontaktirati na mario.klacmer@gmail.com ili na 091/588-12-44.

MOLIM VAS DA NA SLIJEDEĆA PITANJA ODGOVORITE ZAOKRUŽIVANJEM JEDNOG PONUĐENOG ODGOVORA (1-5):

1. Korištenje online javnih usluga e-participacije omogućava mi da određene aktivnosti obavim brže.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

2. Korištenje online javnih usluga e-participacije podiže moju efikasnost.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

3. Korištenje online javnih usluga e-participacije za mene je praktično.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

4. Korištenje online javnih usluga e-participacije učinit će moj život udobnijim.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

5. Naučiti upotrebljavati online javne usluge e-participacije za mene je lako.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

6. Komuniciranje preko online javnih usluga e-participacije ne zahtijeva mnogo mentalnog napora.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

7. Korištenje online javnih usluga e-participacije za mene ima puno prednosti.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

8. Moja interakcija s online javnim uslugama e-participacije jednostavna je i razumljiva.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

9. Komuniciranje preko online javnih usluga e-participacije je prilagodljivo.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

10. Općenito gledano, korištenje online e-participacijskih javnih usluga za mene je korisno.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

11. Mogu lagano postati vješt u korištenju online javnih usluga e-participacije.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

12. Općenito, online javne usluge e-participacije jednostavne su za upotrebu.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

13. Korištenje online javnih usluga e-participacije za mene je korisno.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

14. Korištenje online javnih usluga e-participacije za mene je pametna ideja.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

15. Imam pozitivno mišljenje o korištenju online javnih usluga e-participacije.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

16. Osobe iz moje obitelji smatraju da bih se trebao koristiti online javnim e-participacijskim uslugama.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

17. Osobe koje su meni važne misle da bih se trebao koristiti online javnim e-participacijskim uslugama.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

18. Sviđa mi se ideja o korištenju online javnih usluga e-participacije.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

19. Osobe koje utječu na moje ponašanje smatraju da bih se trebao koristiti online javnim e-participacijskim uslugama.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

20. Vjerujem da imam kontrolu nad korištenjem online javnih e-participacijskih usluga.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

21. Vjerujem da bi mogao koristit online javne e-participacijske usluge kada bi to htio.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

22. Osobe čije mišljenje cijenim željele bi da se koristim online javnim e-participacijskim uslugama.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

23. Korištenje online javnim e-participacijskim uslugama ovisi samo o meni.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

24. Vjerujem da imam znanja za korištenje online javnim e-participacijskim uslugama.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

25. Osjećam se sigurno jer sam pravno i tehnički dobro zaštićen od problema na Internetu koristeći online javne e-participacijske usluge.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

26. Internet ima dosta sigurnosnih mehanizama kako bi se osjećao ugodno tijekom aktivnosti na stranicama online javnih e-participacijskih usluga.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

27. Vjerujem da su tehnologije koje podržavaju online javne e-participacijske usluge pouzdane cijelo vrijeme.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

28. Općenito gledano, vjerujem da je Internet sigurno okruženje za interakciju s online javnim e-participacijskim uslugama.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

29. Država je sposobna tijekom korištenja online javnim uslugama e-participacije moje privatne informacije održati tajnima.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

30. Država kao davatelj usluga ulijeva mi povjerenje prilikom korištenja online javnim uslugama e-participacije.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

31. Državne agencije imaju znanja i vještine za provođenje online javnih usluga e-participacije.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

32. Vjerujem da mi enkripcija i ostala tehhnološka dostignuća na Internetu omogućavaju sigurnu komunikaciju na stranicama online javnih e-participacijskih usluga.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

33. Vjerujem da tijekom korištenja online javnih usluga e-participacije država neće djelovati na način koji bi mi naštetio.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

34. Namjeravam se koristiti online javnim e-participacijskim uslugama.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

35. Planiram često se koristiti online javnim e-participacijskim uslugama.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

36. Preporučio bih drugima korištenje online javnim e-participacijskim uslugama.

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

MOLIM VAS DA ZAOKRUŽIVANJEM ODGOVORITE NA SLIJEDEĆE TVRDNJE:

37. Koristio bih online javne usluge e-participacije na Web stranicama tijela državne uprave samo za informiranje (npr. službena Web stranica nekog državnog tijela, blogovi, FAQ, Webcasts).

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

38. Koristio bih online javne usluge e-participacije na Web stranicama tijela državne uprave za davanje svojeg mišljenja (npr. online konzultacije o zakonskim prijedlozima).

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

39. Koristio bih javne usluge e-participacije na Web stranicama tijela državne uprave za aktivno uključivanje u oblikovanje javnih politika (npr. e-referendum, e-peticije, e-budžet, virtualno prisustvovanja različitim saslušanjima i sastancima).

(u potpunosti se ne slažem) 1 2 3 4 5 (u potpunosti se slažem)

MOLIM VAS DA ZAOKRUŽITE JEDAN PONUĐENI ODGOVOR NA SVAKO PITANJE:

40. Dob: 16-26 27-35 35-42 43-50 50-74

41. Spol: M Ž

42. Stručna sprema: NSS SSS VŠS (bacc) VSS (mag) Mr.sc./Dr.sc.

43. Da li dnevno pristupate Internet stranicama: Da Ne

44. Internet priključak imate: samo kod kuće samo na poslu oboje

Zahvaljujem Vam na sudjelovanju u ovom istraživanju!

ŽIVOTOPIS



Europass
Životopis

Osobni podaci

Ime / Prezime	**Mario Klačmer**
Adresa	R. Boškovića 8 A, 42 000 Varaždin
Telefonski broj	Posao: 042/401-833 Broj mobilnog telefona: 091/588-12-44
Broj faksa	Posao: 042/312-563
E-mail	mario.klacmer@gmail.com
Državljanstvo	Hrvat
Datum rođenja	13.3.1978.
Spol	Muški

Radno iskustvo

Datumi	7/2005 – danas
Zanimanje ili radno mjesto	Viši informatički savjetnik, voditelj Odjela za informatičku podršku
Glavni poslovi i odgovornosti	Informatička podrška radu suda, stručni poslovi I. stupnja složenosti
Ime i adresa poslodavca	Općinski sud u Varaždinu, B. Radić 2, 42 000 Varaždin
Vrsta djelatnosti ili sektor	Državni službenik
----------	----------
Datumi	6/2004 – 7/2005
Zanimanje ili radno mjesto	Informatički savjetnik
Glavni poslovi i odgovornosti	Informatička podrška radu suda, stručni poslovi I. stupnja složenosti
Ime i adresa poslodavca	Visoki trgovački sud Republike Hrvatske u Zagrebu, Berislavićeva 11, 10 000 Zagreb
Vrsta djelatnosti ili sektor	Državni službenik

Obrazovanje i osposobljavanje

Datumi	2/2004 - 2/2011
Naziv dodijeljene kvalifikacije	Mr.sc.
Glavni predmeti / stečene profesionalne vještine	Poslovna informatika
Ime i vrsta organizacije pružatelja obrazovanja i osposobljavanja	Sveučilište u Zagrebu, Fakultet organizacije i informatike Varaždin
Razina prema nacionalnoj ili međunarodnoj klasifikaciji	Magistar znanosti
---	---
Datumi	10/1997 – 2/2004
Naziv dodijeljene kvalifikacije	Dipl.inf.
Glavni predmeti / stečene profesionalne vještine	Poslovna informatika
Ime i vrsta organizacije pružatelja obrazovanja i osposobljavanja	Sveučilište u Zagrebu, Fakultet organizacije i informatike Varaždin
Razina prema nacionalnoj ili međunarodnoj klasifikaciji	Visoka stručna sprema

Osobne vještine i kompetencije

Materinski jezik	Hrvatski

Drugi jezik

Samoprocjena	Razumijevanje		Govor		Pisanje
Europska razina (*)	Slušanje	Čitanje	Govorna interakcija	Govorna produkcija	
Engeski	C2	C2	C1	C1	C1
Njemački	B1	B1	B1	B1	B1

(*) Zajednički europski referentni okvir za jezike

Društvene vještine i kompetencije	- Položen državni stručni ispit za radno mjesto I. vrste složenosti poslova pri Ministarstvu pravosuđa Republike Hrvatske - Dobitnik zahvalnice predsjednika Visokog trgovačkog suda Republike Hrvatske prigodom obilježavanja pedesete obljetnice trgovačkih sudova u Republici Hrvatskoj - Tijekom svog rada na Visokom trgovačkom sudu Republike Hrvatske u Zagrebu ocijenjen ocjenom "naročito uspješan" s maksimalnim brojem bodova - Tijekom svog dosadašnjeg rada na Općinskom sudu u Varaždinu ocijenjen ocjenom "naročito uspješan" s maksimalnim brojem bodova - Povjerenik za etiku Općinskog suda u Varaždinu - Ključni korisnik E-spis Općinskog suda u Varaždinu - Ključni korisnik SuPra Nova Općinskog suda u Varaždinu

Organizacijske vještine i kompetencije	- Hrvatski predstavnik 14-tog plenarnog sastanka CEPEJ pilot sudova Europskog vijeća (Barcelona, 2019.) - Član radne skupine za e-Pravosuđe pri Vijeću EU (Brisel, 2015. – danas) - Projekt IPA 2010, "Nabava opreme za snimanje glavnih rasprava“, korisnik Ministarstvo pravosuđa RH, član Evaluacijskog odbora (Zagreb, 2012.) - Projekt IPA 2009, "Profesionalni razvoj sudskih savjetnika i budućih sudaca", korisnik Pravosudna akademija, član Evaluacijskog odbora (Zagreb, 2011.) - Projekt IPA 2008, "Probacija, usluge", korisnik Ministarstvo pravosuđa RH, član Evaluacijskog odbora (Zagreb, 2011.) - Sudjelovao u studijskom posjetu Sudu za ljudska prava u Strasbourgu i Europskom sudu pravde u Luxembourgu u organizaciji VSRH (Strasbourg, Luxembourg, 2010.) - Projekt JSSP, IBRD Loan, "Nabava IT opreme i softvera", korisnik Ministarstvo pravosuđa RH, član Evaluacijskog odbora (Zagreb, 2010.) - Projekt IPA 2010 "Jačanje učinkovitosti pravosuđa u RH", korisnik Ministarstvo pravosuđa RH, analiza tržišta (Zagreb, 2010.) - Projekt PHARE 2006 "Usklađivanje i objavljivanje sudske prakse", korisnik Vrhovni sud RH, član Jedinice za implementaciju projekta (Zagreb, 2010.) - Projekt PHARE 2006 "Usklađivanje i objavljivanje sudske prakse", korisnik Vrhovni sud RH, član Evaluacijskog odbora (Zagreb, 2008.) - Voditelj seminara informatičkog obrazovanja sudaca i državnih odvjetnika grada Varaždina na Fakultetu organizacije i informatike Varaždin (Varaždin, 2008.) - Odslušao niz predavanja pod zajedničkim nazivom "Upravljanje odnosima s klijentima u bankarstvu" u organizaciji Dubrovačke škole bankarstva i financija (Dubrovnik, 2008.) - Odslušao niz predavanja pod zajedničkim nazivom "Međunarodni obrazovni program za jačanje institucionalnih mehanizama u javnoj upravi Republike Hrvatske" u organizaciji Fakulteta organizacije i informatike Varaždin (Zagreb, 2007.) - Projekt "Tehničke pomoći sudovima u vezi sa stečajevima" Ministarstva pravosuđa Republike Hrvatske financiran od strane Svjetske banke, projekt "Odluke VTSRH", suradnja s predstavnicima projekta (Zagreb, 2004.) - Odslušao niz predavanja pod zajedničkim nazivom "Abeceda EU" u organizaciji Ministarstva europskih integracija Republike Hrvatske (Zagreb, 2004.)
Tehničke vještine i kompetencije	-
Računalne vještine i kompetencije	Napredno služenje računalom

Umjetničke vještine i kompetencije	Završena tri razreda osnovne muzičke škole
Druge vještine i kompetencije	Šest godina aktivnog bavljenja atletikom
Vozačka dozvola	Da

Dodatne informacije	Znanstveni radovi: - Klačmer, Mario: Digitalizacija starih glavnih knjiga zemljišnoknjižnih odjela općinskih sudova: Općinski sud u Varaždinu kao studija slučaja // Zbornik mednarodne konference Tehnični in vsebinski problemi klasičnega in elektronskega arhiviranja 16 / Gostenčnik, Nina (ur.), Maribor: Pokrajinski arhiv Maribor, 2017. (pozvano predavanje, domaća recenzija, pp prezentacija, stručni) - Klačmer, Mario; Klačmer Čalopa, Marina; Horvat, Jelena: Strategic Management of E-government development // Book of Proceedings: 10th International Scientific Conference on Economic and Social Development – Miami / Primorac, Dinko, Primorac, Igor, Detelj, Kristina (ur.), Varaždin: Varazdin Development and Entrepreneurship Agency, Varazdin, Croatia University North, Koprivnica, Croatia, 2015. str. 218-225 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni) - Klačmer, Mario; Vrček, Neven: Intention to Use and Variables Influencing Intention to Use Electronic Government Services Among Citizens // Journal of Information and Organizational Sciences, 1 (2014), 38; 55-69 (međunarodna recenzija, članak, znanstveni)