Utjecaj digitalne zrelosti, konkurentskih prioriteta i stilova odlučivanja na namjeru prihvaćanja digitalnih tehnologija u mikro i malim organizacijama

Dobrinić, Dunja

Doctoral thesis / Disertacija

2023

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:211:061068

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu

Fakultet organizacije i informatike

Dunja Dobrinić

UTJECAJ DIGITALNE ZRELOSTI, KONKURENTSKIH PRIORITETA I STILOVA ODLUČIVANJA NA NAMJERU PRIHVAĆANJA DIGITALNIH TEHNOLOGIJA U MIKRO I MALIM ORGANIZACIJAMA

DOKTORSKI RAD

Varaždin, 2022.

Sveučilište u Zagrebu

Fakultet organizacije i informatike

Dunja Dobrinić

UTJECAJ DIGITALNE ZRELOSTI, KONKURENTSKIH PRIORITETA I STILOVA ODLUČIVANJA NA NAMJERU PRIHVAĆANJA DIGITALNIH TEHNOLOGIJA U MIKRO I MALIM ORGANIZACIJAMA

DOKTORSKI RAD

Mentor:
Prof.dr.sc. Neven Vrček

Varaždin, 2022.

Sveučilište u Zagrebu

Faculty of Organization and Informatics

Dunja Dobrinić

THE INFLUENCE OF DIGITAL MATURITY, COMPETITIVE PRIORITIES AND DECISION-MAKING STYLES ON THE ACCEPTANCE OF DIGITAL TECHNOLOGIES IN MICRO AND SMALL ORGANISATIONS

DOCTORAL DISSERTATION

Supervisor:
Prof.dr.sc. Neven Vrček

Varaždin, 2022

PODACI O DOKTORSKOM RADU

I. AUTOR

Ime i prezime	Dunja Dobrinić
Datum i mjesto rođenja	17. rujna 1988., Varaždin
Naziv fakulteta i datum diplomiranja	Ekonomski fakultet u Zagrebu, 13. listopada 2011.
Sadašnje zaposlenje	AD AKTIVA d.o.o., Varaždin, ovlašteni revizor

II. DOKTORSKI RAD

Naslov	UTJECAJ DIGITALNE ZRELOSTI, KONKURENTSKIH PRIORITETA I STILOVA ODLUČIVANJA NA NAMJERU PRIHVAĆANJA DIGITALNIH TEHNOLOGIJA U MIKRO I MALIM ORGANIZACIJAMA
Broj stranica, slika, tabela, priloga, bibliografskih podataka	271 stranica, 27 slika, 99 tabela, 1 prilog, 244 bibliografskih podataka
Znanstveno područje i polje iz kojeg je postignut akademski stupanj	Društvene znanosti, znanstveno polje informacijske i komunikacijske znanosti
Mentor i voditelj rada	Prof.dr.sc. Neven Vrček
Fakultet na kojem je rad obranjen	Fakultet organizacije i informatike
Oznaka i redni broj rada	166

III. OCJENA I OBRANA

Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena tema	16. rujna 2021.
Datum predaje rada	05. rujna 2022.
Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena pozitivna ocjena rada	08. prosinca 2022.
Sastav Povjerenstva koje je rad ocijenilo	Izv.prof.dr.sc. Zlatko Stapić Prof.dr.sc. Mirjana Pejić Bach Izv.prof.dr.sc. Martina Tomičić Furjan
Datum obrane	13. siječnja 2023.
Sastav Povjerenstva pred kojim je rad obranjen	Izv.prof.dr.sc. Zlatko Stapić Prof.dr.sc. Mirjana Pejić Bach Izv.prof.dr.sc. Martina Tomičić Furjan
Datum promocije	

INFORMACIJE O MENTORU

Neven Vrček redoviti je profesor u trajnom zvanju na Fakultetu organizacije i informatike Varaždin Sveučilišta u Zagrebu. U razdoblju od 2015. do 2019. godine na istom fakultetu obnaša i dužnost dekana Fakulteta. Područja njegova interesa su e-poslovanje, e-uprava, razvoj informacijskog društva, mjerenje uspješnosti organizacije i softversko inženjerstvo. Autor je većeg broja znanstvenih i stručnih radova te nekoliko knjiga. Dio znanstvene djelatnosti ostvaruje putem znanstvenih projekata te je sudjelovao i vodio više projekata financiranih iz domaćih i EU izvora. Pored akademskih projekata, vodio je i brojne stručne projekte u područjima njegova interesa, kao što su razvoj nacionalnog okvira interoperabilnosti, izrada strategije e-poslovanja, implementacija uravnotežene ljestvice, razvoj nacionalne infrastrukture za e-račune itd. Član je nekoliko stručnih i akademskih udruženja. U razdoblju od 2005. do 2014.godine bio je i glavni urednik časopisa Journal of Organizational and Information Sciences. Bio je voditelj doktorskog programa Informacijske znanosti na FOI-ju, voditelj poslijediplomskog programa Javna uprava, član revizorskog odbora Hrvatske narodne banke i član znanstvenih odbora nekoliko časopisa i konferencija. Također je predstavnik Savjetodavnog odbora Sveučilišta u Zagrebu, Fakulteta organizacije i informatike W3C-a. Za uspješan rad dobio je više društvenih priznanja (srebrnu značku (2008.) Hrvatskog informatičkog zbora, medalju grada Varaždina (2007.), Memorial Eurocoin of Aurel Stodola).

SAŽETAK

Predmet istraživanja ovog rada je utvrditi razinu prihvaćanja digitalnih tehnologija u mikro i malim organizacijama. U postojećoj literaturi uočen je nedostatak istraživanja koja bi se odmaknula od postojećih modela i teorija te objasnila razloge prihvaćanja digitalnih tehnologija u mikro i malim organizacijama. Uočeno je kako se za istraživanje namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama potrebno fokusirati na moderirajuće čimbenike, čiji je utjecaj u postojećim istraživanjima zanemaren.

Istražila se povezanost percipiranog financijskog rizika, percipiranog sigurnosnog rizika, percipiranog gubitaka vremena, percipiranog pritiska države i razine znanja donositelja odluke s namjerom prihvaćanja digitalnih tehnologija. Istražila se i povezanost pritiska sudionika na tržištu i kriznih okolnosti s razinom znanja donositelja odluke u organizacijama. Fokus istraživanja bio je istražiti moderirajući utjecaj digitalne zrelosti organizacije i konkurentskih prioriteta na povezanost čimbenika (percipiranog sigurnosnog rizika, percipiranog gubitaka vremena, percipiranog pritiska države) s namjerom prihvaćanja, te moderirajući utjecaj stila odlučivanja donositelja odluke na povezanost pritiska sudionika na tržištu i kriznih okolnosti s razinom znanja donositelja odluke.

Istraživanje moderirajućeg utjecaj digitalne zrelosti, konkurentskih prioriteta i stila odlučivanja doprinijelo je razvijanju novog modela prihvaćanja digitalnih tehnologija, čime se proširila dosadašnja spoznaja o prihvaćanju digitalnih tehnologija u mikro i malim organizacijama.

Model je testiran na prihvaćanju dvije digitalne tehnologije: uslužno računalstvo i pametni ugovori. U istraživanju je sudjelovalo četiristo trideset i dvije (432) mikro i male organizacije na području Republike Hrvatske.

Ključne riječi: mikro i male organizacije, digitalne tehnologije, namjera prihvaćanja, moderirajući utjecaj, digitalna zrelost, konkurentski prioriteti, stil odlučivanja

ABSTRACT

The subject of this dissertation is to determine the level of acceptance of digital technologies in micro and small organizations. There is a lack of research in the existing literature that would move away from existing models and theories and explain the reasons for the adoption of digital technologies in micro and small organizations. It was noticed that research on the acceptance of digital technologies in micro and small organizations needs to focus on moderating factors, the effect of which has been neglected in existing research.

The relationship between perceived financial risk, perceived security risk, perceived loss of time, perceived government pressure, and the level of knowledge of decision-makers with the acceptance of digital technologies were explored. The influence of the pressure from market participants and crisis circumstances on the level of knowledge of decision makers in organizations was also researched. The focus of the research was to explore the moderating effect of the organization's digital maturity and competitive priorities on the relationship of factors (perceived security risk, perceived loss of time, perceived government pressure) with intent to accept. As well as to explore the moderating effect of the decision-maker's decision-making style on the relationship between the pressure of market participants and crisis circumstances with the level of knowledge of the decision-maker.

Research on the moderating effect of digital maturity, competitive priorities and decision-making style has contributed to the development of a new model of digital technology acceptance, thus expanding current knowledge about digital technology acceptance in micro and small organizations.

The model was tested on the acceptance of two digital technologies: cloud computing and smart contracts. Four hundred and thirty-two (432) micro and small organizations in the Republic of Croatia participated in the research.

Keywords: micro and small organizations, digital technologies, intention to accept, moderating effect, digital maturity, competitive priorities, decision-making style

PROŠIRENI SAŽETAK

Predmet istraživanja ovog rada je utvrditi razinu prihvaćanja digitalnih tehnologija u mikro i malim organizacijama. U okruženju koje je pod izrazitim utjecajem novih tehnologija njihovo prihvaćanje i korištenje postaje *conditio sine qua non* opstanka organizacija te zadržavanja i stjecanje tržišne konkurentnosti. U literaturi je uočen nedostatak istraživanja koja bi se odmaknula od postojećih modela i teorija te objasnila razloge prihvaćanja digitalnih tehnologija u mikro i malim organizacijama. Uočeno je kako se za istraživanje namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama potrebno fokusirati na moderirajuće čimbenike, čiji je utjecaj u postojećim istraživanjima zanemaren.

Istražila se povezanost percipiranog financijskog rizika, percipiranog sigurnosnog rizika, percipiranog gubitaka vremena, percipiranog pritiska države i razine znanja donositelja odluke s namjerom prihvaćanja digitalnih tehnologija. Istražila se i povezanost pritiska sudionika na tržištu i kriznih okolnosti s razinom znanja donositelja odluke u organizacijama. Fokus istraživanja bio je istražiti moderirajući utjecaj digitalne zrelosti organizacije i konkurentskih prioriteta na povezanost čimbenika (percipiranog sigurnosnog rizika, percipiranog gubitaka vremena, percipiranog pritiska države) s namjerom prihvaćanja, te moderirajući utjecaj stila odlučivanja donositelja odluke na povezanost pritiska sudionika na tržištu i kriznih okolnosti s razinom znanja donositelja odluke.

Istraživanje moderirajućeg utjecaj digitalne zrelosti, konkurentskih prioriteta i stila odlučivanja doprinijelo je razvijanju novog modela prihvaćanja digitalnih tehnologija, čime se proširila dosadašnja spoznaja o prihvaćanju digitalnih tehnologija u mikro i malim organizacijama.

Model je testiran na prihvaćanju dvije digitalne tehnologije: uslužno računalstvo i pametni ugovori. U istraživanju je sudjelovalo četiristo trideset i dvije (432) mikro i male organizacije na području Republike Hrvatske. Za potrebe provjere modela kreiran je i mjerni instrument. Valjanost modela ispitana je primjenom metode parcijalnih najmanjih kvadrata modeliranja strukturalnim jednadžbama (engl. *Partial Least Squares Structural Equation Modeling, PLS-SEM*) čime su testirane i hipoteze. Za testiranje moderirajućeg utjecaja korištena je višegrupna analiza. U radu je postavljeno ukupno pet hipoteza s pripadajućim podhipotezama. Od ukupno pet hipoteza u prihvaćanju uslužnog računalstva u potpunosti je potvrđeno četiri, dok su u istraživanju prihvaćanja pametnih ugovora sve postavljene hipoteze tek djelomično potvrđene.

Ključne riječi: mikro i male organizacije, digitalne tehnologije, namjera prihvaćanja, moderirajući utjecaj, digitalna zrelost, konkurentski prioriteti, stil odlučivanja

EXTENDED ABSTRACT

The subject of this dissertation is to determine the level of acceptance of digital technologies in micro and small organizations. In an environment that is strongly influenced by new technologies, their acceptance and use become a *conditio sine qua non* of the survival of organizations and the maintenance and acquisition of market competitiveness. There is a lack of research in the existing literature that would move away from existing models and theories and explain the reasons for the adoption of digital technologies in micro and small organizations. It was noticed that research on the acceptance of digital technologies in micro and small organizations needs to focus on moderating factors, the effect of which has been neglected in existing research.

The relationship between perceived financial risk, perceived security risk, perceived loss of time, perceived government pressure, and the level of knowledge of decision-makers with the acceptance of digital technologies were explored. The influence of the pressure from market participants and crisis circumstances on the level of knowledge of decision makers in organizations was also researched. The focus of the research was to explore the moderating effect of the organization's digital maturity and competitive priorities on the relationship of factors (perceived security risk, perceived loss of time, perceived government pressure) with intent to accept. As well as to explore the moderating effect of the decision-maker's decision-making style on the relationship between the pressure of market participants and crisis circumstances with the level of knowledge of the decision-maker.

Research on the moderating effect of digital maturity, competitive priorities and decision-making style has contributed to the development of a new model of digital technology acceptance, thus expanding current knowledge about digital technology acceptance in micro and small organizations.

The model was tested on the acceptance of two digital technologies: cloud computing and smart contracts. Four hundred and thirty-two (432) micro and small organizations in the Republic of Croatia participated in the research. A measuring instrument was created for the purpose of model verification. The validity of the model was tested using the method of partial least squares modeling with structural equations (Partial Least Squares Structural Equation Modeling, PLS-SEM), which also tested the hypotheses. Multigroup analysis was used to test

the moderating effect. A total of five hypotheses with corresponding subhypotheses were presented in the paper. Out of a total of five hypotheses in the acceptance of cloud computing, four were fully confirmed, while in the research on the acceptance of smart contracts, all hypotheses were only partially accepted.

Keywords: micro and small organizations, digital technologies, intention to accept, moderating effect, digital maturity, competitive priorities, decision-making style

SADRŽAJ

SAŽETAK I
ABSTRACT II
PROŠIRENI SAŽETAK III
EXTENDED ABSTRACT V
1. UVOD 1
1.1.Područje istraživanja 3
1.2. Motivacija istraživanja 6
1.3. Ciljevi i hipoteze istraživanja 9
1.5. Obrazloženje sadržaja i strukture doktorske disertacije 13
2. MIKRO I MALE ORGANIZACIJE 14
3. DIGITALNE TEHNOLOGIJE 22
3.1. Uslužno računalstvo 25
3.1.1. Vrste isporuka uslužnog računalstva 26
3.1.2. Karakteristike uslužnog računalstva 28
3.2. Blockchain 31
3.2.1. Vrste blockchain mreže 33
3.2.2. Karakteristike blockchain tehnologije 34
3.2.3. Pametni ugovori 36
4. PRIHVAĆANJE TEHNOLOGIJA U MIKRO I MALIM ORGANIZACIJAMA 39
4.1. Teorijski modeli prihvaćanja tehnologija u organizacijama 39
4.2. Organizacijski čimbenici namjere prihvaćanja digitalnih tehnologija 47
4.2.1. Razina znanja donositelja odluka 48
4.3. Čimbenici namjere prihvaćanja digitalnih tehnologija iz okruženja organizacije 49
4.3.1. Pritisak sudionika na tržištu 50
4.3.2. Percipirani pritisak države 51
4.3.3. Krizne okolnosti 53
4.4. Barijere prihvaćanja digitalnih tehnologija 55
4.4.1. Percipirani financijski rizik 56
4.4.2. Percipirani gubitak vremena 57
4.4.3. Percipirani sigurnosni rizik 58
5. MODERIRAJUĆI ČIMBENICI PRIHVAĆANJA DIGITALNIH TEHNOLOGIJA U MIKRO I MALIM ORGANIZACIJAMA 61
5.1. Digitalna zrelost organizacije 63

5.1.1. Digitalna transformacija ... 63
5.1.2. Zrelost organizacije u pogledu digitalne transformacije ... 66
5.2. Stil odlučivanja ... 69
5.2.1. Odlučivanje ... 69
5.2.2. Vrste stilova odlučivanja ... 71
5.2.2.1. Intuitivni stil odlučivanja ... 76
5.2.2.2. Racionalni stil odlučivanje ... 79
5.3. Konkurentski prioriteti ... 84
6. KONCEPTUALNI OKVIR ISTRAŽIVANJA ... 89
6.1. Problem prihvaćanja digitalnih tehnologija u mikro i malim organizacijama ... 90
6.2. Konceptualni model ... 92
6.3. Hipoteze istraživanja ... 96
7. METODOLOGIJA EMPIRIJSKOG ISTRAŽIVANJA ... 99
7.1. Instrument istraživanja ... 100
7.2. Populacija i uzorak ... 112
7.2.1. IT industrija ... 113
7.2.2. Uzorak ... 114
7.3. Validacija mjernog instrumenta – anketnog upitnika ... 117
7.3.1. Predistraživanje ... 117
7.3.2. Glavno istraživanje ... 117
7.3.2.1. Pouzdanost ... 118
7.3.2.2. Valjanost ... 118
7.4. Validacija konceptualnog modela istraživanja ... 120
7.4.1. Procjena vanjskog (mjernog) modela ... 123
7.4.2. Procjena unutarnjeg (strukturalnog) modela ... 124
7.5. Moderirajući utjecaj ... 126
7.6. Izračun digitalne zrelosti ... 126
8. REZULTATI EMPIRIJSKOG ISTRAŽIVANJA ... 128
8. 1. Predistraživanje ... 128
8.1.1. Karakteristike ispitanika i organizacija predistraživanja ... 128
8.1.2. Pouzdanost mjernog instrumenta predistraživanja ... 132
8.2. Glavno istraživanje ... 134
8.2.1. Karakteristike i analiza uzorka glavnog istraživanja ... 134
8.2.2.1. Karakteristike ispitanika ... 134
8.2.2.2. Karakteristike organizacija iz uzorka ... 135

8.2.2.3. Digitalna zrelost organizacija iz uzorka 139
8.2.2.4. Stil odlučivanja donositelja odluka organizacija iz uzorka 152
8.2.2.5. Konkurentski prioriteti 158
8.3. Deskriptivna statistika 176
8.4. Procjena mjernog (vanjskog) modela 181
8.4.1. Procjena mjernog (vanjskog) modela – USLUŽNO RAČUNALSTVO 182
8.4.1.1. Pouzdanost i konvergentna valjanost - USLUŽNO RAČUNALSTVO 182
8.4.1.2. Diskriminantna valjanost – USLUŽNO RAČUNALSTVO 184
8.4.2. Procjena mjernog (vanjskog) modela – PAMETNI UGOVORI 187
8.4.2.1. Pouzdanost i konvergentna valjanost – PAMETNI UGOVORI 187
8.4.2.2. Diskriminantna valjanost – PAMETNI UGOVORI 189
8.5. Procjena prikladnosti modela podataka 191
8.5.1. Procjena prikladnosti modela podataka – USLUŽNO RAČUNALSTVO 193
8.5.2. Procjena prikladnosti modela podataka - PAMETNI UGOVORI 195
8.6. Procjena strukturalnog (unutarnjeg) modela i testiranje hipoteza 198
8.6.1. Procjena strukturalnog (unutarnjeg) modela i testiranje hipoteza – USLUŽNO RAČUNALSTVO 198
8.6.1.1. Analiza signifikantnosti i relevantnosti koeficijenta puta (*engl. Path analysis*) - USLUŽNO RAČUNALSTVO 201
8.6.2. Procjena strukturalnog (unutarnjeg) modela i testiranje hipoteza prihvaćanja - PAMETNI UGOVORI 203
8.6.1.2. Analiza signifikantnosti i relevantnosti koeficijenta puta (*engl. Path analysis*) – PAMETNI UGOVORI 205
8.7. Moderirajući utjecaj 207
8.7.1. Moderirajući utjecaj digitalne zrelosti– USLUŽNO RAČUNALSTVO 208
8.7.2. Moderirajući utjecaj konkurentskih prioriteta – USLUŽNO RAČUNALSTVO 211
8.7.3. Moderirajući utjecaj stila odlučivanja – USLUŽNO RAČUNALSTVO 215
8.7.4. Moderirajući utjecaj digitalne zrelosti– PAMETNI UGOVORI 216
8.7.5. Moderirajući utjecaj konkurentskih prioriteta – PAMETNI UGOVORI 218
8.7.6. Moderirajući utjecaj stila odlučivanja – PAMETNI UGOVORI 223
9. DISKUSIJA 225
9.1. Analiza hipoteza istraživanja 227
10. ZAKLJUČAK 232
10.1. Znanstveni doprinos 235
10.2. Ograničenja istraživanja i daljnja istraživanja 238
REFERENCE 239

PRILOG 1 257
ŽIVOTOPIS 270

POPIS TABLICA

Tablica 1 Kriteriji razvrstavanja mikro, malih i srednjih organizacija prema smjernicama Europske komisije 2003/361/EZ i Zakonu o računovodstvu 14
Tablica 2 Struktura organizacija u Europskoj Uniji i Republici Hrvatskoj 15
Tablica 3 Struktura organizacija prema aktivnosti i područjima NKD-a 2007., stanje 30. rujna 2021. godine 17
Tablica 4 Struktura organizacija s obzirom na veličinu od 2015. do 2019. godine 19
Tablica 5 Udio organizacija prema veličini u zaposlenosti, prihodima i izvozu u 2018. i 2019. godini 20
Tablica 6 Udio zaposlenih u obrtima 20
Tablica 7 Modeli i teorije prihvaćanja novih tehnologija 41
Tablica 8 Iskustveni i racionalni sustav procesuiranja 72
Tablica 9 Karakteristike intuicije 78
Tablica 10 Konstrukt digitalna zrelost 102
Tablica 11 Konstrukt percipirani financijski rizik 104
Tablica 12 Konstrukt percipirani sigurnosni rizik 104
Tablica 13 Konstrukt percipirani gubitak vremena 105
Tablica 14 Konstrukt percipirani pritisak države 105
Tablica 15 Konstrukt razina znanja 106
Tablica 16 Konstrukt krizne okolnosti 106
Tablica 17 Konstrukt pritisak sudionika na tržištu 107
Tablica 18 Konstrukt konkurentski prioriteti 107
Tablica 19 Konstrukt stil odlučivanja 108
Tablica 20 Konstrukt namjera prihvaćanja 109
Tablica 21 Karakteristike ispitanika 109
Tablica 22 Karakteristike organizacije 110
Tablica 23 Karakteristike ispitanika iz uzorka predistraživanja 129
Tablica 24 Karakteristike organizacija iz uzorka predistraživanja 129
Tablica 25 Stil odlučivanja donositelja odluka u organizacijama iz uzorka predistraživanja i razina njihove digitalne zrelosti 131
Tablica 26 Konkurentski prioriteti organizacija iz uzorka predistraživanja 131
Tablica 27 Cronbach alfa prije i nakon modifikacija – uslužno računalstvo 132
Tablica 28 Cronbach alfa prije i nakon modifikacija – pametni ugovori 132
Tablica 29 Cronbach alfa koeficijent pouzdanosti skala korištenih u predistraživanju 133
Tablica 30 Cronbach alfa koeficijent pouzdanosti skala korištenih u predistraživanju – digitalna zrelost i stil odlučivanja 133
Tablica 31 Karakteristike ispitanika iz uzorka 134
Tablica 32 Veličina i vrsta organizacije iz uzorka 135
Tablica 33 Županija sjedišta organizacija iz uzorka 136

Tablica 34 Pretežita djelatnost organizacija iz uzorka 137
Tablica 35 Unutarnja pouzdanost dimenzija digitalne zrelosti 139
Tablica 36 Razine digitalne zrelosti 141
Tablica 37 Srednja vrijednost čestica nakon bodovanja 142
Tablica 38 Važnost pojedine dimenzije digitalne zrelosti..... 143
Tablica 39 Digitalna zrelost organizacija iz uzorka 146
Tablica 40 Digitalna zrelost organizacija iz uzorka prema veličini organizacija..... 147
Tablica 41 Digitalna zrelost organizacija iz uzorka prema vrsti organizacija..... 147
Tablica 42 Digitalna zrelost organizacija prema djelatnosti organizacija iz uzorka 149
Tablica 43 Digitalna zrelost organizacija prema županiji sjedišta organizacije 150
Tablica 44 Unutarnja pouzdanost stila odlučivanja 152
Tablica 45 Stil odlučivanja donositelja odluka organizacija iz uzorka 152
Tablica 46 Stil odlučivanja i karakteristike ispitanika iz uzorka..... 153
Tablica 47 Stil odlučivanja i karakteristike organizacija iz uzorka..... 155
Tablica 48 Konkurentski prioriteti 158
Tablica 49 Konkurentski prioriteti prihvaćanja uslužnog računalstva i karakteristike ispitanika iz uzorka 160
Tablica 50 Konkurentski prioriteti prihvaćanja pametnih ugovora i karakteristike ispitanika iz uzorka 162
Tablica 51 Konkurentski prioriteti prihvaćanja uslužnog računalstva i karakteristike organizacija iz uzorka..... 164
Tablica 52 Konkurentski prioriteti prihvaćanja pametnih ugovora i karakteristike organizacija iz uzorka 168
Tablica 53 Konkurentski prioriteti prihvaćanja uslužnog računalstva i digitalna zrelost organizacija iz uzorka..... 173
Tablica 54 Konkurentski prioriteti prihvaćanja pametnih ugovora i digitalna zrelost organizacija iz uzorka..... 174
Tablica 55 Konkurentski prioriteti prihvaćanja uslužnog računalstva i stil odlučivanja donositelja odluka u organizacijama iz uzorka 175
Tablica 56 Konkurentski prioriteti prihvaćanja pametnih ugovora i stil odlučivanja donositelja odluka u organizacijama iz uzorka..... 176
Tablica 57 Deskriptivna statistika čestica u istraživanja prihvaćanju uslužnog računalstva 177
Tablica 58 Deskriptivna statistika čestica u istraživanju prihvaćanja pametnih ugovora.... 178
Tablica 59 Deskriptivna statistika čestica za mjerenje digitalne zrelosti 180
Tablica 60 Deskriptivna statistika čestica za mjerenje stila odlučivanja 181
Tablica 61 Procjena mjernog modela – uslužno računalstvo 183
Tablica 62 Unakrsna standardizirana faktorska opterećenja - uslužno računalstvo..... 184
Tablica 63 Fornell-Larcker kriterij – uslužno računalstvo 186
Tablica 64 Heterotrait-monotrait omjer korelacije (HTMT) – uslužno računalstvo..... 186
Tablica 65 Procjena mjernog modela – pametni ugovori..... 187
Tablica 66 Unakrsna standardizirana faktorska opterećenja – pametni ugovori..... 189
Tablica 67 Fornell-Larcker kriterij – pametni ugovori 190
Tablica 68 Heterotrait-monotrait omjer korelacije (HTMT) – pametni ugovori 191
Tablica 69 Indeks procjene podobnosti modela 192

Tablica 70 Indeksi podobnosti za pojedinačne konstrukte – uslužno računalstvo 194
Tablica 71 Indeksi podobnosti modela – uslužno računalstvo 194
Tablica 72 Indeksi podobnosti za pojedinačne konstrukte – pametni ugovori 196
Tablica 73 Indeksi podobnosti modela - pametni ugovori 197
Tablica 74 Faktor inflacije varijance (VIF) - uslužno računalstvo 198
Tablica 75 Koeficijent determinacije – uslužno računalstvo 199
Tablica 76 f^2 vrijednost – uslužno računalstvo 200
Tablica 77 Q^2 vrijednost - uslužno računalstvo 201
Tablica 78 Sažetak vrijednosti strukturalnog modela – uslužno računalstvo 201
Tablica 79 Faktor inflacije varijance (VIF) - pametni ugovori 204
Tablica 80 Koeficijent determinacije – pametni ugovori 204
Tablica 81 f^2 vrijednost – pametni ugovori 205
Tablica 82 Q^2 vrijednost- pametni ugovori 205
Tablica 83 Sažetak vrijednosti strukturalnog modela – pametni ugovori 206
Tablica 84 ANOVA – razina digitalne zrelosti – uslužno računalstvo 209
Tablica 85 Višegrupna analiza – razina digitalne zrelosti– uslužno računalstvo 210
Tablica 86 Parametrijski test razlika razine digitalne zrelosti– uslužno računalstvo 211
Tablica 87 ANOVA –konkurentski prioriteti– uslužno računalstvo 211
Tablica 88 Višegrupna analiza –konkurentski prioriteti– uslužno računalstvo 214
Tablica 89 T test (stil odlučivanja) – uslužno računalstvo 215
Tablica 90 Višegrupna analiza – stil odlučivanja– uslužno računalstvo 216
Tablica 91 ANOVA – razina digitalne zrelosti – pametni ugovori 216
Tablica 92 Višegrupna analiza – razina digitalne zrelosti pametni ugovori 217
Tablica 93 Parametrijski test razlika digitalne razine zrelosti– pametni ugovori 218
Tablica 94 ANOVA – konkurentski prioriteti – pametni ugovori 219
Tablica 95 Višegrupna analiza –konkurentski prioriteti- pametni ugovori 221
Tablica 96 Parametrijski test razlika konkurentskih prioriteta– pametni ugovori 222
Tablica 97 T test – pametni ugovori 223
Tablica 98 Višegrupna analiza –stil odlučivanja– pametni ugovori 224
Tablica 99 Sumarni prikaz hipoteza istraživanja prihvaćanja uslužnog računalstva i pametnih ugovora 227

POPIS SLIKA

Slika 1 Pregled ciljeva, istraživačkih pitanja i hipoteza u istraživanju 12
Slika 2 Aktivna trgovačka društva i aktivni obrti 16
Slika 3 Kretanje broja organizacija u Republici Hrvatskoj 17
Slika 4 Kronološki prikaz modela i teorija istraživanja namjere prihvaćanja novih tehnologija 43
Slika 5 Teorija difuzije inovacije *(engl. Diffusion of Innovation Theory, DOI)* 44
Slika 6 Okvir „tehnologija-organizacija-okolina“ (*engl. Technology Organization, Environment,* TOE) 46
Slika 7 Model namjere prihvaćanja digitalnih tehnologija mikro i malih organizacija 93

Slika 8 Razvoj i prijevod upitnika 100
Slika 9 SEM dijagram puta 121
Slika 10 Grafički prikaz županije sjedišta organizacija iz uzorka 137
Slika 11 Pretežita djelatnost organizacija iz uzorka 139
Slika 12 Srednja vrijednost pojedine dimenzije 142
Slika 13 Razvijenost dimenzija na 1 razini digitalne zrelosti 144
Slika 14 Razvijenost dimenzija na 2 razini digitalne zrelosti 145
Slika 15 Razvijenost dimenzija na 3 razini digitalne zrelosti 145
Slika 16 Prikaz razvijenosti dimenzija unutar pojedine razine digitalne zrelosti 146
Slika 17 Grafički prikaz digitalne zrelosti organizacija prema djelatnosti organizacija iz uzorka 148
Slika 18 Grafički prikaz digitalne zrelosti organizacija prema županiji sjedišta organizacije 148
Slika 19 Grafički prikaz konkurentskih prioriteta 158
Slika 20 Grafički prikaz odnosa konkurentskih prioriteta prihvaćanja uslužnog računalstva i digitalne zrelost organizacija iz uzorka 174
Slika 21 Grafički prikaz odnosa konkurentskih prioriteta prihvaćanja pametnih ugovora i digitalne zrelost organizacija iz uzorka 175
Slika 22 Prikaz modifikacija po pojedinim konstruktima – uslužno računalstvo 193
Slika 23 Prikaz modifikacija u cijelom modelu – uslužno računalstvo 195
Slika 24 Prikaz modifikacija po pojedinim konstruktima – pametni ugovori 196
Slika 25 Prikaz modifikacija u cjelokupnom modelu – pametni ugovori 197
Slika 26 Strukturalni model (unutarnji model: path analiza i p vrijednost, konstrukti R^2, vanjski model: t vrijednost) - uslužno računalstvo 203
Slika 27 Strukturalni model (unutarnji model: path analiza i p vrijednost, konstrukti R^2, vanjski model: t vrijednost) - pametni ugovori 207

1. UVOD

U današnjem poslovnom okruženju primjena novih tehnologija ključna je za postizanje konkurentnosti i profitabilnosti poslovanja. Nužnost reakcije i „buđenje“ organizacija u smislu prihvaćanja novih tehnologija leži u činjenici kako se društvo nalazi usred četvrte industrijske revolucije, koja se temelji na integraciji informacijsko-komunikacijske tehnologije s operativnim aktivnostima. Četvrtu industrijsku revoluciju karakterizira upotreba novih tehnologija s ciljem postizanja digitalne transformacije poslovanja i to za sve organizacije bez obzira na njihovu veličinu, djelatnost poslovanja ili tržište na kojem djeluju [1].

Primjena i korištenje novih tehnologija omogućava promptno reagiranje na sve zahtjevnije potrebe kupaca, dobavljača, konkurenata i svih ostalih sudionika u poslovnom okruženju [2], [3], [4], [5]. Nove tehnologije označavaju „tehnologiju koja radikalno mijenja način na koji se nešto proizvodi ili izvodi, posebno automatizacijom ili informatizacijom koja štedi ljudski napor“ [6]. Digitalne tehnologije, u kontekstu novih tehnologija, predstavljaju „upotrebu digitalnih resursa (tehnologije, alata, aplikacija i algoritama) kojima se učinkovito pronalaze, analiziraju, stvaraju, prosljeđuju i koriste digitalna dobra u računalnom okruženju“ [7]. One se odnose na najsuvremenije tehnologije današnjice koje omogućuju prijenos digitalnog sadržaja te stvaranje novih vrijednosti u poslovanju, kao i kreiranje novih inovativnih poslovnih modela koji generiraju prihode [7].

Unatoč nužnosti digitalne transformacije primjetno je da ulaganje i prihvaćanje digitalnih tehnologija zaostaje u mikro i malim organizacijama, što je zabrinjavajuće zbog činjenice da se njihov broj svakodnevno povećava čineći ih temeljem današnjeg gospodarstva i globalne ekonomije [8]. U Republici Hrvatskoj mikro i male organizacije čine 98% ukupnih organizacija [9]. Prema definiciji Europske komisije mikro i male organizacije su svaki subjekt uključen u ekonomsku aktivnost, bez obzira na njegovu pravnu formu, koji ispunjava dva od tri kriterija, to su: visina prihoda do 10.000.000 eura, ukupna aktiva do 10.000.000 eura i broj zaposlenih do 50 [9]. Zaostajanje u prihvaćanju digitalnih tehnologija posebice je izraženo u mikro i malim organizacijama izvan IT industrije. IT industrija podrazumijeva industriju koja obuhvaća djelatnosti povezane s informacijskom tehnologijom kao što je djelatnost pružanja IT usluga, proizvodnje IT opreme i trgovine IT proizvodima [10], [11]. Postojeća istraživanja promatraju prihvaćanje tehnologija uglavnom od strane malih i srednjih organizacija, dok se tek nekolicina

njih fokusirala isključivo na mikro i male organizacije. Nedostaje istraživanja koja bi u kontekstu prihvaćanja novih tehnologija u potpunosti obuhvatila sve ključne karakteristike mikro i malih organizacija, prvenstveno je to problem nedostatka resursa (financijskih i ljudskih) te način donošenja odluka koji je u potpunosti u rukama pojedinca koji je u većini slučajeva i vlasnik organizacije. Mikro i male organizacije zaostaju u prihvaćanju novih tehnologija upravo zbog svojih karakteristika koje djeluju kao barijere i dovode do pojave straha od nepoznatog i time percipiranje tehnologije rizičnom i nepotrebnom [12], [13], [8], [14], [15], [16], [17]. Da je prihvaćanje i investiranje u digitalne tehnologije od strane mikro i malih organizacija poželjno i nužno naglašavaju i strategije Europske komisije donesene u ožujku 2020. godine, a koje imaju za cilj ubrzati tehnološki rast mikro i malih organizacija [9].

Prihvaćanje digitalnih tehnologija u kombinaciji s organizacijskim promjenama omogućit će organizacijama da unaprijede svoje poslovne performanse (povećanje učinkovitosti, smanjenje troškova, povećanje prihoda i prikupljanje novih znanja) te da brže i uspješnije implementiraju inovacije u svoje poslovanje. Digitalne tehnologije i digitalna transformacija omogućit će organizacijama preživljavanje možebitnog digitalnog poremećaja u industriji te povećanje poslovne održivosti [18].

Kako bi digitalne tehnologije pomogle mikro i malim organizacijama da unaprijede svoje poslovanje, osiguraju svoj opstanak na tržištu i postignu konkurentnu prednost potrebno je da iste budu prihvaćene i percipirane kao korisne i nužne, kako za nastavak poslovanja tako i za sam rast organizacije [17], [19]. Vezano na to nužno je istražiti što utječe na odluku o prihvaćanje digitalnih tehnologija u mikro i malim organizacijama, te će se u skladu s time istraživanje fokusirati isključivo na mikro i male organizacije. U okviru istraživanja posebna pozornost usmjerit će se na utjecaj moderirajućih čimbenika, što je u dosadašnjim istraživanjima bilo zanemareno.

Svrha istraživanja je utvrditi moderirajući utjecaj čimbenika (digitalna zrelost i konkurentski prioriteti) na povezanost čimbenika (percipirani financijski rizik, percipirani sigurnosni rizik, percipirani gubitak vremena i percipirani pritisak države) i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama. Istražit će se i moderirajući utjecaj stila odlučivanja na vezu vanjskog pritiska (krizne okolnosti i pritisak sudionika na tržištu) i razine znanja donositelja odluke. U skladu s time razvit će se i novi model namjere prihvaćanja (novih)

digitalnih tehnologija. Razvijanjem novog modela napravit će se odmak od postojećih modela čime će se proširit dosadašnje spoznaje o predmetnoj tematici.

1.1.Područje istraživanja

Tijekom proteklog vremena, vezano za prihvaćanje tehnologija, razvijeno je nekoliko modela i teorija koje obrađuju tu tematiku. Neke od njih su (kronološkim slijedom): teorija difuzije inovacije (*engl. Diffusion of Innovation Theory, DOI*), teorija razložne akcije (*engl. Theory od Reasoned Action, TRA*), socijalno kognitivna teorija (*engl. Social Cognitive Theory, SCT*), model prihvaćanja tehnologije (*engl. Technology Acceptance Model, TAM 1*), okvir tehnologija-organizacija-okolina (*engl. Technology, Organization, Environment, TOE*), teorija planiranog ponašanja (*engl. Theory of Planned Bahavior*), motivacijski model (eng. *Motivational model, MM*), model prihvaćanja tehnologija 2 (*TAM 2*), objedinjena teorija prihvaćanja i upotrebe tehnologije (*engl. Unified Theory of Acceptance and Use of Technology, UTAUT*), model prihvaćanja tehnologija 3 (*TAM 3*) i proširena objedinjena teorija prihvaćanja i upotrebe tehnologije *(engl. extending Unified Theory of Acceptance and Use of Technology UTAUT2)* [20], [21], [22], [23]. Promatrajući namjeru prihvaćanja tehnologija isključivo s aspekta organizacije od navedenih modela u literaturi se izdvajaju teorija difuzije inovacije (DOI) i okvir tehnologija-organizacija-okolina (TOE) kao najčešće korišteni, međusobno kombinirani i kroz godine nadograđivani modeli [4]. Neminovno je da je broj modela koji objašnjavaju namjeru prihvaćanja tehnologija u literaturi velik. Međutim, zbog sve bržeg razvoja tehnologija i brojnosti njihovih karakteristika teško je razviti jedinstveni generalni model prikladan za istraživanje prihvaćanja svih inovacija te je stoga potrebno ići u smjeru razvijanja novih modela, a ne u smjeru korištenja istih čimbenika i potvrđivanju njihove značajnosti, tj. korištenje i potvrđivanje postojećih teorija i modela [24], [12], [25], [26].

Pregledom literature uočeno je kako su se postojeća istraživanja namjere prihvaćanja novih tehnologija uglavnom fokusirala na velike organizacije, dok se tek manji broj njih bavio mikro i malim organizacijama. Istraživanja koja obuhvaćaju mikro i male organizacije u pravilu promatraju prihvaćanje na razini tzv. MSP-a (male i srednje organizacije). Analizom definicija mikro, malih i srednjih organizacija vidljivo je da između njih postoje vrlo izražene razlike prvenstveno u kontekstu njihove veličine, što znači da ih je u istraživanju namjere prihvaćanja novih tehnologija potrebno posebno promatrati.

Nadalje, pregledom literature uočen je i nedostatak istraživanja koja bi obuhvatila i utjecaj određenih moderirajućih čimbenika, tj. istraživanja koja bi, prilikom sagledavanja povezanosti čimbenika s prihvaćanjem novih tehnologija, istražila i utjecaj moderirajućih čimbenika na te veze. Kako bi se ta praznina u literaturi upotpunila potrebno je istraživanje usmjeriti na utvrđivanje utjecaja moderirajućih čimbenika [27]. Stoga će se, s ciljem proširenja dosadašnjih spoznaja, istraživanje fokusirati na utvrđivanje utjecaja moderirajućih čimbenika na modelom definirane veze.

Kod dosadašnjih istraživanja utvrđeno je i kako se utjecaj moderirajućih čimbenika više razmatra kod istraživanja namjere prihvaćanja novih tehnologija od strane pojedinaca, dok se kod prihvaćanja novih tehnologija od strane organizacija oni zanemaruju. Također je primijećeno kako istraživanja koja uključuju moderirajuće čimbenike u većini slučajeva pažnju posvećuju jednostavnijim čimbenicima poput: veličine organizacije, razine iskustva i slično. Time je identificirana potreba za istraživanjem onih moderirajućih čimbenika koji će pobliže pojasniti prihvaćanje digitalnih tehnologija u mikro i malim organizacijama.

Analizom prijašnjih istraživanja i pregledom literature identificirana su tri moderirajuća čimbenika: digitalna zrelost organizacije, stil odlučivanja donositelja odluke i konkurentski prioriteti. Istraživanjem će se utvrditi moderirajući utjecaj digitalne zrelosti i konkurentskih prioriteta na vezu između definiranih čimbenika (percipirani financijski rizik, percipirani sigurnosni rizik, percipirani gubitak vremena i percipirani pritisak države) i namjere prihvaćanja digitalnih tehnologija, te moderirajući utjecaj stila odlučivanja na vezu između vanjskih pritisaka (krizne okolnosti i pritisak sudionika na tržištu) i razine znanja donositelja odluke.

Digitalna zrelost organizacija moderirajući je čimbenik koji izaziva i posebnu pozornost istraživača. U tom smislu je i cilj ovog istraživanja istražiti kako mikro i male organizacije, na različitoj razni digitalne zrelosti, percipiraju utjecaj čimbenika na namjeru prihvaćanja digitalnih tehnologija. Drugim riječima, cilj je istražiti da li se porastom razine digitalne zrelosti mijenja svijest mikro i malih organizacija u pogledu prihvaćanja digitalnih tehnologija, te da li negativan utjecaj pojedinih čimbenika na prihvaćanje digitalnih tehnologija opada s porastom digitalne zrelosti organizacije.

Konkurentski prioriteti su sljedeći moderirajući čimbenik čiji se utjecaj želi istražiti. Prilikom odluke o usvajanju digitalnih tehnologija potrebno je identificirati očekivane performanse, tj. konkurentske prioritete organizacije. Bitno je spoznati koji od konkurentskih prioriteta djeluje kao najjači motiv za ulaganje u digitalne tehnologije. Istraživanjem moderirajućeg utjecaja konkurentskih prioriteta (kvaliteta, brzina, pouzdanost, fleksibilnost i trošak), osim što će se dobiti uvid u prioritet kojem mikro i male organizacije teže prihvaćanjem digitalnih tehnologija, omogućit će spoznaju o tome da li različiti konkurentski prioriteti imaju i različiti utjecaj na namjeru prihvaćanja. Isto je ključno i iz razloga što je prilikom kreiranja programa poticanja digitalne transformacije mikro i malih organizacija bitno znati na koji način pristupiti organizacijama i kako ih potaknuti na ulaganje i prihvaćanje digitalnih tehnologija. Nepostojanje razlika između prioriteta ukazat će na to da organizacije imaju isti stav prema prihvaćanju digitalnih tehnologija bez obzira na željeni konkurentski prioritet. To bi omogućilo kreiranje univerzalne strategije za poticanje ulaganja u digitalne tehnologije od strane mikro i malih organizacija.

Uz istraživanje moderirajućeg utjecaja digitalne zrelosti i konkurentskih prioriteta istražit će se i moderirajući utjecaj stila odlučivanja na vezu između vanjskih pritisaka (krizne okolnosti i pritisak sudionika na tržištu) i razine znanja donositelja odluke. Odlučivanje igra ključnu ulogu u upravljaju organizacijom, utječe na uspjeh same organizacije te definira smjer njezinog razvoja [28]. Kod mikro i malih organizacija uobičajeno je da je donositelj odluka, tj. direktor ujedno i vlasnik organizacije. On samostalno donosi većinu ili sve odluke vezane uz poslovanje organizacije. Kako bi donosili što kvalitetnije odluke potrebno je da imaju adekvatnu razinu znanja. Na pozitivnu odluku o prihvaćanju digitalnih tehnologija upravo će razina znanja o tehnologiji koja se prihvaća imati odlučujući utjecaj, s obzirom da će se unaprijed znati kako tu tehnologiju adekvatno upotrijebiti u digitalnoj transformaciji. Na razinu znanja mogu utjecati okolina i informacije iz okruženja (npr. konkurencija), ali i neočekivani poremećaji tzv. krizne okolnosti (npr. pandemija Covid 19). S time u vezi nameće se i potreba za istraživanjem kako stil odlučivanja moderira utjecaj podražaja iz okoline na razinu znanja donositelja odluka. Prethodna su istraživanja pokazala da će intuitivni menadžeri prije prihvatiti nove inovacije, no isto tako većina istraživanja ukazuje da se ljudi (time i menadžeri) više izjašnjavaju i doživljavaju kao racionalni donositelji odluka [29]. Time se može zaključiti kako je većina donositelja odluka racionalna, što nameće potrebu istražiti da li postoji razlika između donositelja odluka intuitivnog i racionalnog stila. Znači li uistinu da oni racionalnog stila imaju drugačiji stav prema prihvaćanju digitalnih tehnologija i da na različiti način percipiraju utjecaj

čimbenika na razinu znanja o digitalnoj tehnologiji koja se prihvaća. U skladu s navedenim cilj istraživanja je istražit postoji li moderirajući utjecaj stila odlučivanja na vezu između vanjskih pritisaka (krizne okolnosti i pritisak sudionika na tržištu) i razine znanja donositelja odluke.

1.2. Motivacija istraživanja

Ubrzani tehnološki razvitak ima veliki utjecaj na cjelokupno društvo, te je samim time i digitalna transformacija neizbježna za sve gospodarske subjekte. U tom smislu organizacije moraju biti spremne odgovoriti na izazove globalizacije te modernizirati i integrirati svoje poslovne aktivnosti s novim digitalnim ekosustavom [18]. Digitalne tehnologije odigrat će ključnu ulogu u prilagodbi i opstanku organizacija, jer osim što će omogućiti lakše savladavanje prepreka one će produbiti postojeće podjele na tržištu između organizacija različitih veličina. Stoga je nužno, s ciljem postizanja poslovne održivosti, da se mikro i male organizacije uhvate u koštac s digitalnom transformacijom poslovanja i integriraju digitalne tehnologije u svoje poslovanje.

Nedvojbeno je da veličina organizacije ima utjecaj na stav o digitalnim tehnologijama i njihovom prihvaćanju, te je u tom smislu potrebno posebno promatrati mikro, male i srednje organizacije. Srednje organizacije raspolažu znatno većim ljudskim i financijskih resursima što je kod prihvaćanja digitalnih tehnologija od ključne važnosti. S druge strane mikro i male organizacije imaju oskudne resurse, što je potrebno uvažiti i istražiti njihov utjecaj na namjeru prihvaćanja digitalnih tehnologija. U postojećoj literaturi većina istraživanja se fokusirala na mala i srednja poduzeća, međutim, prema definicijama razvidno je kako između mikro, malih i srednjih organizacija postoje znatne razlike.

Mikro i male organizacije u ukupnoj strukturi na razini Europske unije čine 98,9% organizacija, dok u Republici Hrvatskoj taj postotak iznosi 98,5% [30]. Činjenica je kako mikro i male organizacije predstavljaju većinu organizacija i time čine temelj gospodarstva i globalne ekonomije. Pregledom literature uočeno je kako te organizacije zaostaju u prihvaćanju digitalnih tehnologija, a kao razlog se navode njihove karakteristika koje djeluju kao barijere u prihvaćanju i dovode do pojave straha od nepoznatog i time percipiranjem tehnologije rizičnom i nepotrebnom [12], [13], [8], [14], [15], [16], [17]. S obzirom na njihov značaj u ekonomiji i ekonomskom razvoju društva nužno je da svoje poslovanje usklade s tehnološkim razvojem, tj. provedu digitalnu transformaciju svojeg poslovanja. Poseban značaj tim procesima ili

promjenama daju i neočekivani i nekontrolirani vanjski utjecaji poput nedavne pandemije Covid 19, gdje su organizacije bile prisiljene izvršiti određene promjene i prilagodbe dosadašnjeg poslovanja kako bi opstale na tržištu. Te su se prilagodbe odnosile na brzo usvajanje i primjenu digitalne tehnologije koja je omogućila bez kontaktni rad ili rad na daljinu. S time u vezi bitno je napomenuti kako će u tzv. postpandemijsko doba važan faktor oporavka i ponovnog rasta gospodarstva biti novi proizvodi i usluge te novi poslovni modeli bazirani na digitalnim tehnologijama [31].

Prihvaćanje i usvajanje digitalnih tehnologija povećava otpornost organizacija tijekom disruptivnih neočekivanih događaja [32]. Corvelo i ostali naglašavaju da su digitalne tehnologije ključne za izgradnju otpornosti i antifragilnosti (anti-krhkosti) organizacija. Definiraju otpornost i antifraglilnost kao dva koncepta koja opisuju način na koji organizacije preživljavaju pa čak i napreduju u nepredvidivim poslovnim okruženjima. Otpornost definiraju kao sposobnost apsorbiranja šokova i oporavak nakon istog, dok antifragilnost definiraju kao sposobnost organizacije da apsorbira udarce i nakon toga postane bolja, tj. da nakon preživljavanja određenog šok postane bolja [33]. Taj je šok u literaturi poznat kao „crni labud“ a predstavlja nepredvidiv, iznenađujući događaj velikog značaja koji dramatično mijenja političko i gospodarsko okruženje, te može prouzročiti poslovne neuspjehe [34]. Upravo nepredvidivi i neočekivani događaji mogu olakšati i ubrzati, ali i spriječiti prihvaćanje tehnologije od strane poduzetnika [35], [36]. Otpornost i antifragilnost nužne su za samu održivost poslovanja a u tome ključnu ulogu imaju digitalne tehnologije i internet.

Održivost poslovanja u svojoj srži ima za cilj preusmjeriti fokus organizacija na ulaganja u mjere koje će omogućiti smanjenje rizika od katastrofa kao što su pandemije, potresi i sl., a ne u napore za pomoć i oporavak nakon katastrofe [1]. Održivost poslovanja u fokusu je Agende za održivi razvoj usvojene od strane država članica Ujedinjenih naroda 2015. godine, a koja je postala imperativ organizacijama koje teže postizanju 17 definiranih ciljeva održivog razvoja *(engl. Sustainable Development Goals-SDGs).* Jedan od ciljeva je i cilj 9 koji glasi: *Izgraditi prilagodljivu infrastrukturu, promovirati uključivu i održivu industrijalizaciju i poticanje inovativnost*. Unutar cilja 9 izdvaja se i podcilj: *Značajno povećati pristup informacijskoj i komunikacijskoj tehnologiji i nastojati osigurati univerzalan i pristupačan pristup internetu u najmanje razvijenim zemljama* [37]. Iz postavljenog cilja vidljivo je da Agenda održivog razvoja ukazuje na potrebu za inovacijama i gospodarskim rastom, koji se može postići prvenstveno primjenom i usvajanjem digitalnih tehnologija [38]. Važnost digitalne

transformacije prepoznata je i od strane Europske komisije, koja u sklopu svog programa „Digitalna Europa“ želi podići digitalnu spremnost malih organizacija i olakšati široku primjenu digitalnih tehnologija [39].

Iz različitih svjetskih i europskih smjernica vidljivo je kako se usvajanju digitalnih tehnologija daje veliki značaj. U tome se posebno naglašavaju male i srednje organizacija koje su motor gospodarskog razvitka i koje se moraju što prije prilagoditi tehnološkim izazovima. Prvenstveno se to odnosi na njihovu digitalnu transformaciju kojom će povećati svoju efikasnost, a time i daljnji razvoj gospodarstva i društva u cjelini.

Prihvaćanje novih tehnologija od strane organizacija bilo je predmetom različitih dosadašnjih istraživanja. Njihovim pregledom uočene su dvije praznine, odnosno dva područja koja nisu dovoljno istražena. Prvo je da se mikro i male organizacije, u kontekstu prihvaćanja novih tehnologija, nisu posebno razmatrale, odnosno rubno su se obuhvaćale u okviru tzv. MSP (mala i srednja poduzeća) organizacija. Drugo se odnosi na istraživanje utjecaja moderirajućih čimbenika na povezanost ili veze osnovnih čimbenika s prihvaćanjem digitalnih tehnologija. U dosadašnjim istraživanjima uglavnom je promatran direktan ili indirektan utjecaj čimbenika na namjeru prihvaćanja, dok se utjecaj moderirajućih čimbenika zapostavljao. Moderirajući čimbenici se ili nisu uključivali u istraživanja ili su se odnosili samo na one bazične poput veličine organizacije, razine iskustva i slično. Na tom tragu se istraživanje namjere prihvaćanja digitalne tehnologije usmjerilo prema mikro i malim organizacijama s posebnim naglaskom na moderirajuće čimbenike.

S obzirom na identificirana područja koja dosadašnjim istraživanjima nisu adekvatno pokrivena istraživanje se usmjerilo na utvrđivanje namjere prihvaćanja digitalnih tehnologija isključivo od strane mikro i malih organizacija. Predloženi su čimbenici utjecaja na namjeru prihvaćanja te se istražio njihov utjecaj. Istraživanje je obuhvatilo i ključne karakteristike mikro i malih organizacija (nedostatak financijskih i ljudskih resursa te način donošenja odluka) što se također prijašnjim istraživanjima nedovoljno obuhvatilo i istražilo. Istraživanje se, nadalje, posebno fokusiralo na utvrđivanje utjecaja moderirajućih čimbenika na veze između čimbenika i namjere prihvaćanja digitalnih tehnologija. Prilikom definiranja moderirajućih čimbenika pažnja se također usmjerila na karakteristike mikro i malih organizacija. Usmjeravanjem istraživanja prema sagledavanju utjecaja moderirajućih čimbenika nadopunit će se prijašnja

istraživanja te omogućiti stjecanje novih znanja vezanih za odlučivanje mikro i malih organizacija o usvajanju digitalnih tehnologija.

Moderirajući čimbenici koji mogu utjecati na donošenje odluke o prihvaćanju novih tehnologija, a čiji se utjecaj u radu istraživao su: digitalna zrelost organizacije, konkurentski prioriteti i stil odlučivanja. Digitalna zrelost organizacija nužna je za opstanak same organizacije stoga je njezin utjecaj kao moderirajućeg čimbenika ključan u istraživanju namjere prihvaćanja digitalnih tehnologija. Istraživanjem će se spoznati razina digitalne zrelosti na kojoj se mikro i male organizacije nalaze, te, ono ključno, da li se s rastom razine zrelosti mijenja percepcija organizacije u vezi s namjerom prihvaćanja digitalnih tehnologija. Konkurentski prioriteti (kvaliteta, brzina, pouzdanost, fleksibilnost i trošak) predstavljaju motiv koji vodi prema usvajanju digitalne tehnologije. Kako bi se dobio uvid u smjer razmišljanja mikro i malih organizacija u pogledu toga što žele ostvariti prihvaćanjem digitalnih tehnologija istražit će se da li odabir pojedinog prioriteta moderira utjecaj definiranih čimbenika na namjeru prihvaćanja digitalnih tehnologija. Pored toga, nužno je obratiti pažnju i na ključnu osobu u mikro i malim organizacijama i njegov/njezin stil odlučivanja. Odlučivanje je temelj poslovanja svake organizacije i ima ključnu ulogu u njezinom funkcioniranju. U radu će se istražiti da li stil odlučivanja moderira utjecaj vanjskih pritiska na razinu znanja o digitalnoj tehnologiji koja se prihvaća. Kako je znanje o digitalnoj tehnologiji ključan čimbenik u prihvaćanju tehnologija u mikro i malim organizacija istražit će se postoji li razlika između pojedinog stila odlučivanja i utjecaja pritiska sudionika na tržištu i kriznih okolnosti na razinu znanja.

1.3. Ciljevi i hipoteze istraživanja

Pregledom literature utvrđeno je kako nedostaje model koji će istraživanjem prihvaćanja digitalnih tehnologija obuhvatiti i utjecaj moderirajućih čimbenika [40]. Pored toga identificirana je i potreba fokusiranja istraživanja isključivo na mikro i male organizacije, kojim će se obuhvatiti njihove ključne karakteristike. Vezano na utjecaj i značaj moderirajućih čimbenika utvrđena je i potreba sagledavanja šireg spektra moderirajućih čimbenika, tj. odmaknuti se od postojećih istraživanja koja su se uglavnom fokusirala samo na utjecaj veličine organizacije i iskustva.

Polazeći od navedenog definirani su ciljevi istraživanja koji glase:

C1 Sintetizirati rezultate prethodnih istraživanja na temu prihvaćanja novih tehnologija na razini organizacija kako bi se identificirali čimbenici koji utječu na namjeru prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.
C2 Na temelju literature izraditi model namjere prihvaćanja digitalnih tehnologija za mikro i male organizacije.
C3 Razviti mjerni instrument (anketni upitnik) za mjerenje namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

U svrhu ispunjenja postavljenih ciljeva definirana su istraživačka pitanja koja su poslužila za usmjeravanje istraživanja. Postavljena istraživačka pitanja su sljedeća:

IP1 Koji su čimbenici prema sintezi prethodnih istraživanja povezani s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama ?
IP2 Koji čimbenici identificirani u IP1 doprinose objašnjenju prihvaćanja digitalnih tehnologija u mikro i malim organizacijama ?
IP3 Koji čimbenici imaju moderirajući utjecaj na identificirane čimbenike IP1 i namjeru prihvaćanja digitalnih tehnologija u mikro i malim organizacijama ?
IP4 Kako kreirati mjerni instrument odgovarajuće pouzdanosti i kriterijske valjanosti ?
IP5 Kakvi su odnosi između čimbenika u modelu prihvaćanja digitalnih tehnologija ?
IP6 Kako razina digitalne zrelosti organizacije moderira odnos između čimbenika i namjere prihvaćanja digitalnih tehnologija ?
IP7 Kako konkurentski prioriteti moderiraju odnos između čimbenika i namjere prihvaćanja digitalnih tehnologija ?
IP8 Kako različiti stil odlučivanja donositelja odluke moderira odnos pritiska sudionika na tržištu i kriznih okolnosti s razinom znanja donositelja odluka ?

U skladu s prethodno definiranim problemom istraživanja, njegovim ciljevima te formuliranim istraživačkim pitanjima, predloženo je pet glavnih hipoteza znanstvenog istraživanja. Hipoteze uključuju i odgovarajuće podhipoteze koje su objašnjene u sklopu disertacije. Glavne hipoteze su sljedeće:

H1 Percipirani rizici (financijski, sigurnosni, gubitak vremena) negativno su povezani s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H2 Percipirani pritisak države i razina znanja donositelja odluka pozitivno su povezani s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H3 Povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja različita je ovisno o razini digitalne zrelosti organizacije.

H4 Povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja različita je ovisno o konkurentskom prioritetu koji se želi postići.

H5 Povezanost vanjskih pritiska (krizne okolnosti i pritisak sudionika na tržištu) s razinom znanja donositelja odluke različita je ovisno o stilu odlučivanja.

Grafički prikaz definiranih ciljeva, istraživačkih pitanja i hipoteza istraživanja prikazan je na slici 1.

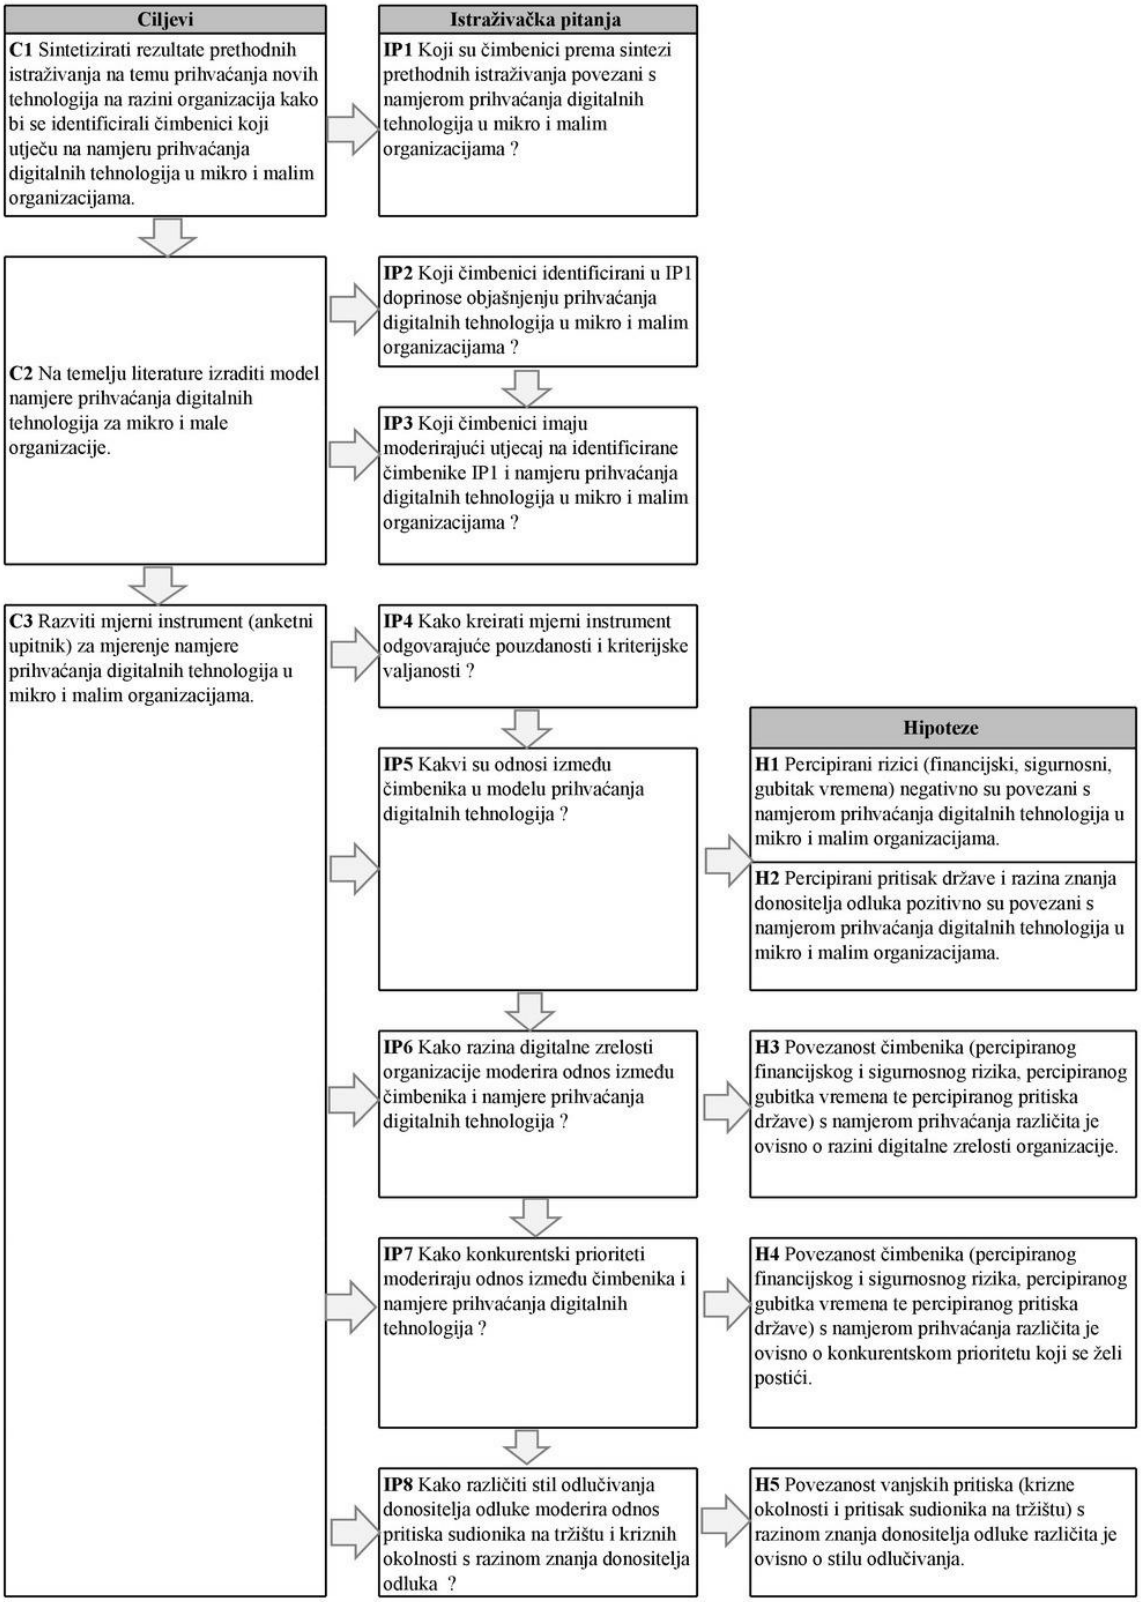

Slika 1 Pregled ciljeva, istraživačkih pitanja i hipoteza u istraživanju

1.5. Obrazloženje sadržaja i strukture doktorske disertacije

Doktorska disertacija sastoji se od deset poglavlja. Prvo poglavlje daje kratak uvod u temu disertacije objašnjavajući područje i motivaciju za istraživanje. Objašnjeni su ciljevi istraživanja, istraživačka pitanja te prikazane hipoteze istraživanja.

U drugom se poglavlju objašnjava pojam mikro i malih organizacija te prikazuje struktura poslovnih organizacija u Europskoj uniji i u Republici Hrvatskoj. Struktura organizacija prikazana je u skladu s Nacionalnom klasifikacijom djelatnosti (NKD-a) te kriterija njihovog razvrstavanja po veličini.

U trećem poglavlju objašnjen je pojam digitalnih tehnologija s osvrtom na digitalne tehnologije čije prihvaćanje će se istraživati: uslužno računalstvo te blockchain tehnologije s naglaskom na pametne ugovore.

Nakon definiranja osnovnih pojmova u četvrtom poglavlja se daje pregled postojećih istraživanja prihvaćanja tehnologija od strane organizacija, s fokusom na čimbenike koji bi mogli utjecati na prihvaćanje digitalnih tehnologija od strane mikro i malih organizacija.

U petom poglavlju se daje osvrt na moderirajuće čimbenike koji su u fokusu ovog istraživanja.

Šesto i sedmo poglavlje prikazuje konceptualni okvir istraživanja i metodologiju empirijskog istraživanja. Prikazan je instrument istraživanja, konceptualni model istraživanja, definirane su pripadajuće hipoteze te objašnjenje metode validacije instrumenta i modela.

U osmom poglavlju prikazani su rezultati istraživanja. Nakon prikaza i interpretiranja rezultata istraživanja slijedi rasprava u okviru devetog poglavlja. Posljednje poglavlje doktorske disertacije čini zaključak u kojem se daju zaključna razmatranja te obrazlaže znanstveni doprinos istraživanja. Nakon zaključka slijedi popis literature i prikaz instrumenta istraživanja.

2. MIKRO I MALE ORGANIZACIJE

Mikro i male organizacije su prema definiciji Europske komisije svaki subjekt uključen u ekonomsku aktivnost, bez obzira na njegovu pravnu formu, koji ispunjava dva od tri kriterija, a to su: visina prihoda do 10.000.000 eura, ukupna aktiva do 10.000.000 eura i broj zaposlenih do 50 [9]. U Republici Hrvatskoj mikro i male organizacije definirane su Zakonom o poticanju razvoja malog gospodarstva (NN 26/02-121/16), te Zakonom o računovodstvu (NN 78/15-47/20). Zakonom o poticanju razvoja malog gospodarstva propisano je da su mikro organizacije fizičke i pravne osobe koje u prosjeku godišnje imaju zaposleno manje od 10 radnika, ostvaruju godišnji poslovni prihod u protuvrijednosti do 2.000.000 eura, te imaju ukupnu aktivu, tj. ukupnu dugotrajnu imovinu u protuvrijednost do 2.000.000 eura. Male organizacije čine fizičke i pravne osobe koje u prosjeku godišnje imaju zaposleno manje od 50 radnika, ostvaruju godišnji poslovni prihod u protuvrijednosti do 10.000.000 eura, te imaju ukupnu aktivu, tj. ukupnu dugotrajnu imovinu u protuvrijednost do 10.000.000 eura [41]. Prema Zakonu o računovodstvu mikro poduzetnici su oni koji ne prelaze dva od tri kriterija i to: ukupna aktiva do 2.600.000 kuna, ukupni prihodi do 5.200.000 kuna i prosječan broj radnika tokom godine 10. Mali poduzetnicu su oni koji ne prelaze dva od tri kriterija i to: ukupna aktiva 30.000.000 kuna, ukupni prihodi do 60.000.000 kuna i prosječan broj radnika tokom godine 50 [42]. Razvidno je kako Zakon o računovodstvu, za razliku od Zakona o poticanju malog gospodarstva nije usuglašen sa smjernicama Europske komisije od 06. svibnja 2009. godine o razvrstavanju organizacija u mikro, male i srednje (2003/361/EZ), razlika u kriterijima prikazana je u tablici 1 [9].

Tablica 1 Kriteriji razvrstavanja mikro, malih i srednjih organizacija prema smjernicama Europske komisije 2003/361/EZ i Zakonu o računovodstvu

Kategorija organizacije	Smjernica Europske komisije 2003/361/EZ (Iznos u EUR)			Zakon o računovodstvu (Iznos u HRK)		
	Broj zaposlenih	Ukupan prihod	Ukupna aktiva (imovina)	Broj zaposlenih	Ukupan prihod	Ukupna aktiva (imovina)
Mikro	< 10	≤ 2.000.000	≤ 2.000.000	< 10	≤ 5.200.000	≤ 2.600.000
Mala	< 50	≤ 10.000.000	≤ 10.000.000	< 50	≤ 60.000.000	≤ 30.000.000
Srednja	< 250	≤ 50.000.000	≤ 43.000.000	< 250	≤ 300.000.000	≤ 150.000.000

Izvor: [9], [41], [42]

Prema dostupnim podacima Statističkog ureda Europske zajednice – Eurostata vidljivo je kako postotak mikro i malih organizacija u ukupnoj strukturi na razini Europske unije iznosi 98,9%, dok u Republici Hrvatskoj iznosi 98,5% (tablica 2). Kriterij razvrstavanja primijenjen od strane Eurostata uključuje kriterije propisane smjernicama Europske komisije 2003/361/EZ. Vidljivo je i kako mikro i male organizacije kreiraju najveći broj radnih mjesta, čak 49,00% u Europskoj uniji, dok u Republici Hrvatskoj taj broj iznosi 50% [30]. Udio mikro i malih organizacija u bruto dodanoj vrijednosti također je značajan i iznosi 35,80% na razini Europske unije dok u Republici Hrvatskoj taj postotak iznosi 41,70%.

Tablica 2 Struktura organizacija u Europskoj Uniji i Republici Hrvatskoj

Veličina organizacije/EU, HR		**Broj organizacija %**	**Broj zaposlenih %**	**Bruto dodana vrijednost %**[1]
Mikro i male organizacije	EU	98,9%	49,00%	35,80%
	Republika Hrvatska	98,5%	50,00%	41,70%
Srednje organizacije	EU	0,9%	16,00%	17,00%
	Republika Hrvatska	1,2%	18,70%	19,80%
Velike organizacije	EU	0,2%	35,00%	47,20%
	Republika Hrvatska	0,30%	31,40%	38,50%

Napomena: Kriterij razvrstavanja u skladu s smjernicama Europske komisije 2003/361/EZ

Izvor: [30], [43]

Kao što je ranije spomenuto Zakon o računovodstvu nije usuglašen sa smjernicama Europske komisije (2003/361/EZ) od 06. svibnja 2009. godine u pogledu razvrstavanja mikro, malih i srednjih organizacija [9]. Uzimajući u obzir činjenicu da će se istraživanje provesti u Republici Hrvatskoj, kriterij za određivanje veličine organizacije preuzet će se iz prethodno navedenog Zakona o računovodstvu. U skladu s istim u nastavku su primijenjeni sljedeći kriteriji za mikro i male organizacije: mikro i male organizacije su svi subjekti uključeni u ekonomsku aktivnost,

1 Bruto dodana vrijednost (BDV) je mjera produktivnosti koja mjeri doprinos organizacije gospodarstvu. Bruto dodana vrijednost podrazumijeva vrijednost proizvedene količine proizvoda i usluga umanjeno za troškove njihove proizvodnje.

bez obzira na njegovu pravnu formu, koji ispunjava dva od tri kriterija, a to su: visina prihoda do 60.000.000 kuna, ukupna aktiva do 30.000.000 kuna i broj zaposlenih do 50. Vodeći se definicijom Europske komisije u mikro i male organizacije uključuju se i svi oblici samozapošljavanja, obrti, i ostali subjekti uključeni u ekonomsku aktivnost, a koji nisu obuhvaćeni Zakonom o računovodstvu. To se prvenstvo odnosi na obrte koji su prema podacima Hrvatske obrtničke komore u lipnju 2021. godine činili 40,36 % ukupnih organizacija u Republici Hrvatskoj (slika 2) [44].

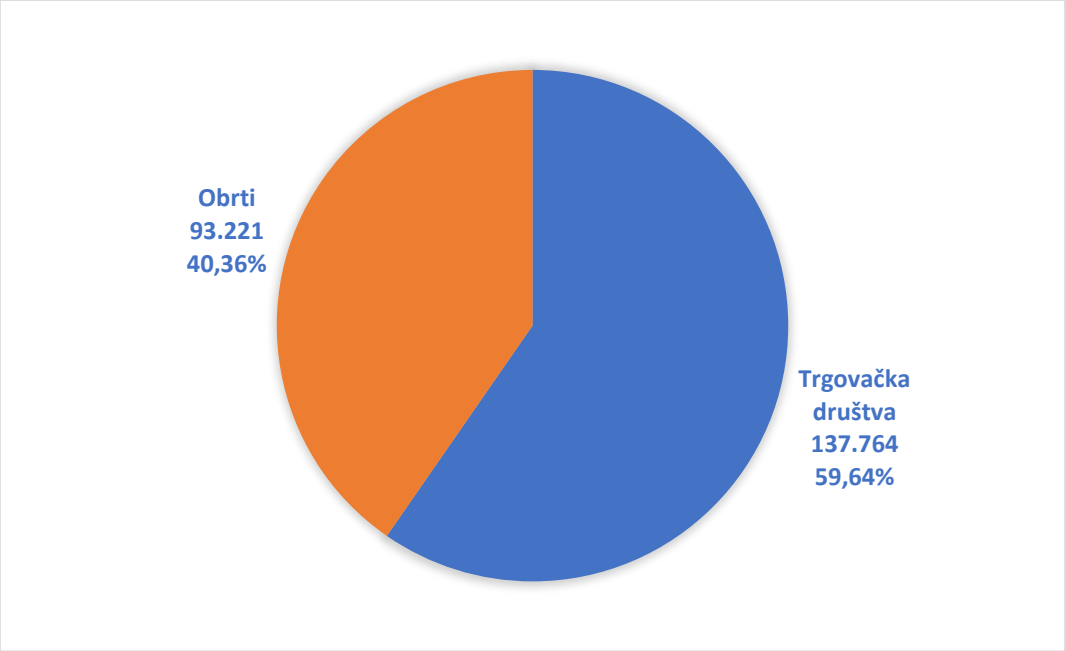

Slika 2 Aktivna trgovačka društva[2] i aktivni obrti

Izvor: Preuzeto Hrvatska obrtnička komora - Statističke informacije lipanj 2021.

Promatrajući kretanje broja organizacija u posljednjih nekoliko godina u Republici Hrvatskoj uočen je trend rasta broja organizacija (slika 3). Prema podacima Državnog zavoda za statistiku i Hrvatske obrtničke komore u rujnu 2021. godine ukupan broj organizacija (mikro, malih i velikih) iznosio je 269.889 aktivnih organizacija [44], [45].

2 Trgovačka društva predstavljaju pravne osobe čije su osnivanje i ustroj određeni Zakonom o trgovačkim društvima – (NN, 111/93-32/22). Trgovačka društva su javno trgovačko društvo, komanditno društvo, dioničko društvo, društvo s ograničenom odgovornošću, jednostavno društvo s ograničenom odgovornošću i gospodarsko interesno udruženje.

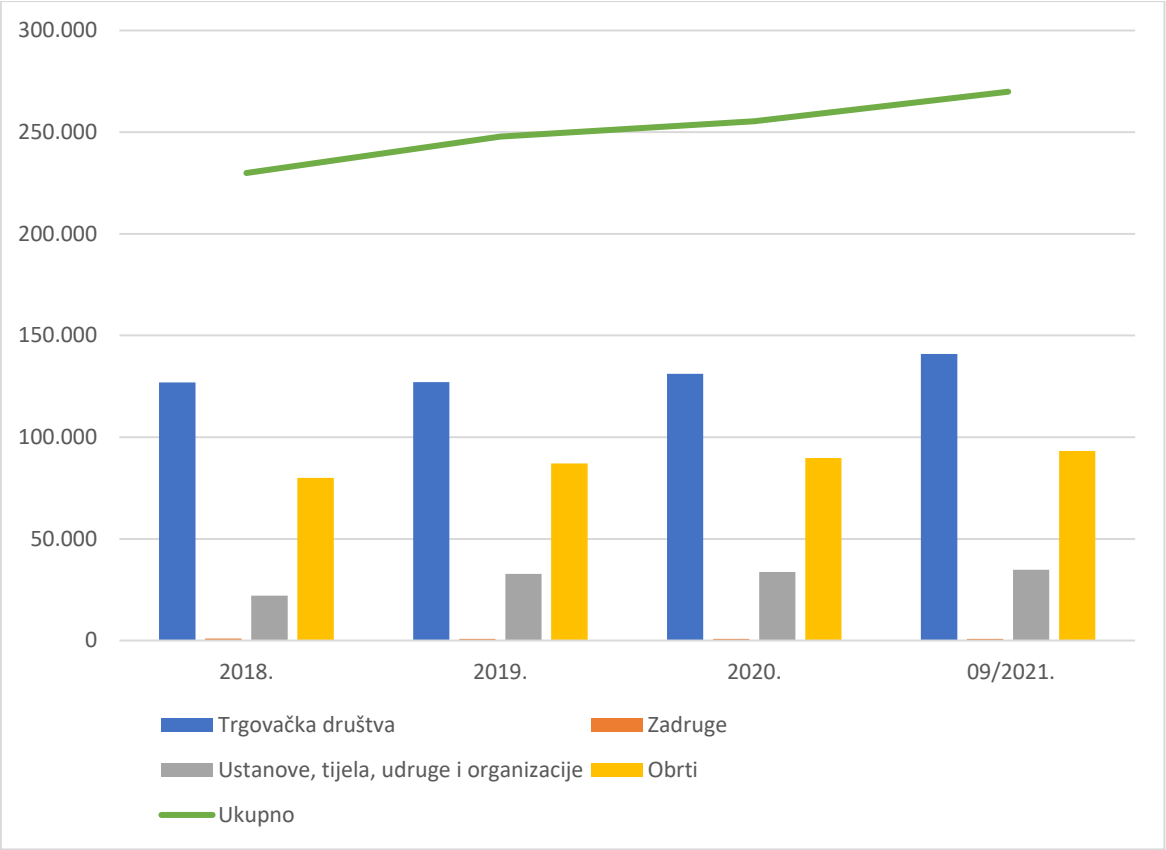

Slika 3 Kretanje broja organizacija u Republici Hrvatskoj

U tablici 3 u nastavku prikazana je struktura organizacija po Nacionalnoj klasifikaciji djelatnosti (NKD-a). Struktura prikazuje ukupan broj organizacija - mikro, male, srednje i velike.

Tablica 3 Struktura organizacija prema aktivnosti i područjima NKD-a 2007., stanje 30. rujna 2021. godine

Djelatnosti prema Nacionalnoj klasifikaciji djelatnosti		**Aktivne pravne osobe**		**Obrti**
		Profitne	**Neprofitne**	
A	Poljoprivreda, šumarstvo i ribarstvo	2.711	2	2.681
B	Rudarstvo i vađenje	187	-	40
C	Prerađivačka industrija	15.481	3	7.998
D	Opskrba električnom energijom, plinom, parom i klimatizacija	789	-	9

Djelatnosti prema Nacionalnoj klasifikaciji djelatnosti		Aktivne pravne osobe		Obrti
		Profitne	Neprofitne	
E	Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša	883	3	92
F	Građevinarstvo	18.482	1	9.629
G	Trgovina na veliko i na malo; popravak motornih vozila i motocikla	28.706	195	9.345
H	Prijevoz i skladištenje	7.328	34	6.178
I	Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	14.117	50	8.049
J	Informacije i komunikacije	7.623	28	3.526
K	Financijske djelatnosti i djelatnosti osiguranja	951	29	535
L	Poslovanje nekretninama	5.628	-	532
M	Stručne, znanstvene i tehničke djelatnosti	21.822	165	12.391
N	Administrativne i pomoćne uslužne djelatnosti	7.417	4	3.598
O	Javna uprava i obrana; obvezno socijalno osiguranje	19	968	6.181
P	Obrazovanje	1.126	2.539	820
Q	Djelatnosti zdravstvene zaštite i socijalne skrbi	1.008	2.457	7.425
R	Umjetnost, zabava i rekreacija	1.879	9.799	2.985
S	Ostale uslužne djelatnosti	4.818	18.566	10.279
T	Djelatnosti kućanstava kao poslodavaca; djelatnosti kućanstava koja proizvode različitu robu i obavljaju različite usluge za vlastite potrebe	1	-	51

Djelatnosti prema Nacionalnoj klasifikaciji djelatnosti		Aktivne pravne osobe		Obrti
		Profitne	Neprofitne	
U	Djelatnosti izvan teritorijalnih organizacija i tijela	-	1	-
Nepoznato		-	-	49
Ukupno		**140.976**	**34.844**	**91.084**

Izvor: [45]

Promatrajući strukturu organizacija u Republici Hrvatskoj mikro i male organizacije čine većinu organizacija, čak 99,20% svih organizacija kao što je prikazano u tablici 4 [46], [44].

Tablica 4 Struktura organizacija s obzirom na veličinu od 2015. do 2019. godine

Veličina organizacije	2015.		2016.		2017.		2018.		2019.	
	br. organizacija	%	br. organizacija	%	br. organizacija	%	br. organizacija	%	br. organizacija	%
Mikro i male organizacije	179.438	99,15	186.771	99,1	194.058	99,1	209.205	99,1	221.501	99,2
Srednje organizacije	1.192	0,66	1.347	0,71	1.400	0,72	1.498	0,71	1.525	0,68
Velike organizacije	348	0,19	327	0,17	329	0,17	360	0,17	370	0,17
Ukupno	**180.978**	**100**	**188.445**	**100**	**195.787**	**100**	**211.063**	**100**	**223.396**	**100**

Izvor: [46], [47]

Snažan utjecaj mikro i malih organizacija na gospodarstvo očituje se u njihovom udjelu u ukupnoj zaposlenosti, prihodima i izvozu. U tablici 5 vidljivo je kako u 2019. godini mikro i mala poduzeća sudjeluju s ukupno 55,3% u ukupnoj zaposlenosti, s 39,59% u ukupnim prihodima te s 28,68% u ukupnom izvozu. Izraženi udijeli ne uključuju obrte koji čine 40,36% ukupnih organizacija u Republici Hrvatskoj, stoga je postotak zaposlenih u obrtima iskazan u tablici 6. Udio zaposlenih u obrtima u odnosu na ukupan broj zaposlenih u Republici Hrvatskoj čini 11,59%. Izraženi postoci ukazuju na činjenicu kako su mikro i male organizacije temelj gospodarskog rasta jer kreiraju veliki broj radnih mjesta, te time osiguravaju društvenu stabilnost [8].

Tablica 5 Udio organizacija prema veličini u zaposlenosti, prihodima i izvozu u 2018. i 2019. godini

Opis	Mikro i mala		Srednja		Velika	
	2018.	**2019.**	**2018.**	**2019.**	**2018.**	**2019.**
Br. Zaposlenih	494.211	536.429	184.278	183.189	261.465	250.158
Zaposlenost (udio) %	52,6	55,3	19,6	18,9	27,8	25,8
Uk. Prihod (mil.kn)	274.860	315.190	161.166	165.172	315.134	315.765
Uk. Prihod (udio) %	36,59	39,59	21,46	20,75	41,95	39,66
Izvoz (mil. kn)	40.103	43.443	37.874	36.739	69.205	71.273
Izvoz (udio) %	27,25	28,68	25,73	24,26	47,02	47,06

Izvor: [46]

Tablica 6 Udio zaposlenih u obrtima

R.br	Zaposleni	2020.	2021.*
1.	Pravne osobe (bez obrtnika zaposlenih u pravnim osobama koji uz radni odnos imaju otvoreni obrt)	1.298.521	1.315.257
2.	**OBRTI (vlasnici/ortaci i radnici)**	**186.000**	**205.359**
3.	VLASNICI - ORTACI (3=4+5)	92.944	96.295
4.	obrtnik - obrt kao jedina djelatnost	66.963	72.121
5.	obrtnik - obrt uz radni odnos kod pravnih osoba (druga djelatnost)	25.981	24.174
6.	RADNICI ZAPOSLENI KOD OBRTNIKA	93.056	109.064
7.	Slobodne profesije	23.962	24.217
8.	Poljoprivrednici	19.214	18.651
9.	UKUPNO ZAPOSLENI (9=1+2+7+8)	1.527.697	1.563.484

R.br	Zaposleni	2020.	2021.*
10.	Ukupno isključivo zaposleni u obrtu (10=1+6)	160.019	181.185
11.	Udio zaposlenih u obrtu u uk. broju zaposlenih (10/9*100)	10,47	11,59

**Obuhvaćeni su podaci zaključno s lipnjem 2021. godine*

Izvor: Hrvatska obrtnička komora, Obrtništvo u brojkama u 2019., 2020. godinu te za lipanja 2021. godinu

Neminovno je kako mikro i male organizacije predstavljaju većinu organizacija što potvrđuje potrebu za fokusiranjem istraživanja isključivo na mikro i male organizacije. U postojećoj literaturi većina istraživanja fokusirala se na tzv. MSP (mala i srednja poduzeća). Prema definiciji mikro, malih i srednjih organizacija razvidno je kako postoji znatna razlika između mikro i malih te srednjih organizacija. Srednje organizacije prema smjernicama Europske komisije uključuju organizacije koje imaju do 250 zaposlenih, ukupan prihod do 50.000.000 eura i ukupnu imovinu do 43.000.000 eura, dok prema Zakonu o računovodstvu uključuju organizacije s do 250 zaposlenih, ukupan prihod do 300.000.000 kuna i ukupnu imovinu do 150.000.000 kuna [42]. Razmatrajući prihvaćanje digitalnih tehnologija, razlike u veličinama između mikro i malih te srednjih organizacija su značajne i time imaju veliki utjecaj na stav organizacija prema digitalnim tehnologijama. Srednje organizacije raspolažu znatno većim ljudskim i financijskih resursima, a upravo je to kod prihvaćanja digitalnih tehnologija od ključne važnosti.

S druge strane mikro i male organizacije imaju oskudne resurse te stoga zaostaju u prihvaćanju digitalnih tehnologija upravo zbog svojih karakteristika koje djeluju kao barijere u prihvaćanju, i dovode do pojave straha od nepoznatog i time percipiranjem tehnologije rizičnom i nepotrebnom [12], [13], [8], [14], [15], [16], [17].

U sljedećem poglavlju objasnit će se pojam digitalne tehnologije s posebnim naglaskom na dvije digitalne tehnologije: uslužno računalstvo i pametni ugovori koje će se koristiti kako bi se istražio utjecaj moderirajućih čimbenika na prihvaćanje digitalnih tehnologija u mikro i malim organizacijama. U izravnoj vezi s digitalnim tehnologijama u nastavku će se dati i kratki osvrt na digitalnu transformaciju.

3. DIGITALNE TEHNOLOGIJE

Težnja svake organizacije je kroz postizanje veće efikasnosti osigurati konkurentnost i profitabilnost poslovanja. Upravo su digitalne tehnologije te koje omogućavaju lakše savladavanje promjena u okolini te promptno reagiranje na sve zahtjevnije potrebe kupaca, dobavljača, konkurenata i ostalih sudionika u poslovnom okruženju [3], [2]. Digitalne tehnologije označavaju upotrebu digitalnih resursa (tehnologije, alata, aplikacija i algoritama) kojima se učinkovito pronalaze, analiziraju, stvaraju, prosljeđuju i koriste digitalna dobra u računalnom okruženju“ [7].

Primjena digitalne tehnologije omogućava stvaranje nove vrijednosti u poslovanju te stvaranje novih poslovnih modela koji generiraju prihode. Pojava, razvoj i primjena digitalne tehnologije osnovna su infrastruktura poslovanja u digitalnoj ekonomiji. Tako se i sam pojam digitalne ekonomije temelji na učestaloj upotrebi digitalnih tehnologija, što rezultira radikalnim promjenama u percepciji resursa koji se koriste u poslovanju. Tako u fokus dolaze neopipljivi resursi – digitalni i elektronički a u drugom su planu oni fizički, opipljivi [47]. Digitalna ekonomija zapravo je ekonomija koja se temelji na informacijskoj i komunikacijskoj tehnologiji kao što su Internet, pametni telefoni, mobilne i bežične mreže, optičke mreže, Internet stvari, uslužno računalstvo, kriptovalute i slično [48].

Temelji na kojima se digitalna ekonomija bazira su [7]:

- integracija i istodobna primjena neovisno razvijenih tehnologija i mogućnosti koje takve tehnologije pružaju,
- integracija progresivnih koncepata poslovanja,
- korištenje digitalnih platformi poslovanja,
- uspješni i „neodoljivi“ poslovni modeli,
- digitalno vođenje – vođenje temeljeno na poduzetničkoj organizacijskoj kulturi, inovativnosti i stvaranju nove vrijednosti.

Okosnicu digitalne ekonomija predstavlja povezanost ljudi, organizacija i strojeva pomoću Interneta i digitalnih tehnologija. Upravo ta povezanost mijenja način na koji su organizacije strukturirane, kako međusobno djeluju te način na koji zadovoljavaju potrebe svojih klijenata [49]. Upravo digitalna ekonomija, kako naglašava Jiang, će pomoći u oporavku gospodarstva

nakon posljedica uzrokovanih pandemijom Covid 19. U tzv. postpandemijskoj eri važan faktor oporavka i ponovnog rasta gospodarstva biti će novi proizvodi, usluge te novi poslovni modeli bazirani na digitalnim tehnologijama proizašli iz ubrzane primjene digitalnih tehnologija u vrijeme pandemije Covid 19 [31].

Digitalne tehnologije omogućuju organizacijama da unaprijede svoje poslovanje, osiguraju svoj opstanak na tržištu i postignu konkurentnu prednost i rast organizacije [19]. Spremić naglašava karakteristiku digitalnih tehnologija koja se očituje u njihovoj sposobnosti da izdvoje informacije i podatke iz uređaja, potom ih analiziraju, obrade i povežu s ostalim uređajima i okolinom, čineći ga tako pametnim i digitalnim [7]. Pritom navodi kako je „Digitalno pridjev koji opisuje intenzitet razmjene informacija i sveobuhvatnu premreženost i interaktivnost raznih fizičkih uređaja i resursa. Fizički resursi kao što su zgrade, postrojenja, automobili, stvari, procesi, ljudi ili timovi postaju digitalni primjenom tehnologija koje očitavaju informacije o njihovome stanju i prosljeđuju te informacije drugim uređajima i svojoj okolini“ [7].

Pousttchi i ostali navode kako digitalne tehnologije mijenjaju način na koji organizacije stvaraju i nude svoje usluge i proizvode kao i način na koji komuniciraju sa svojim klijentima i poslovnim partnerima. Smatraju kako one u kombinaciji s inovativnim metodama obrade i analize podataka poboljšavaju postojeće poslovne procese i omogućuju stvaranje novih poslovnih modela. Na taj način otvaraju i stvaraju nova tržišta, te je stoga nužno da organizacije iskoriste sve prednosti digitalnih tehnologija kako bi osigurale svoje mjesto na tržištu i ostvarile konkurentsku prednost [50]. S istim se slaže i Spremić naglašavajući kako je ključna uloga digitalnih tehnologija mogućnost stvaranja novih poslovnih modela, koji će biti inovativni i omogućiti ostvarivanje konkurentske prednosti. Upravo u svrhu stvaranja inovativnih poslovnih modela kao najvažnija obilježja digitalnih tehnologija Spremić izdvaja [7]:

- istovremena uporaba svih digitalnih tehnologija uz sinergiju usluga koje iz njih proizlaze (pohrana sadržaja, lokacijske usluge, interaktivnost, prediktivna analitika, stvaranje zajednice korisnika koji intenzivno komuniciraju i prenose i stvaraju digitalni sadržaj),
- implementacija u proizvode i uređaje, mogućnost izdvajanja digitalnog sadržaja iz uređaja, njihova analiza i interakcija i sposobnost brze distribucije digitalnog sadržaja (senzori u IoT),

- vrlo intenzivna razmjena digitalnog sadržaja,
- mogućnost digitalizacije poslovanja, digitalne transformacije poslovnih modela i kreiranje digitalnih platformi.

Nužnost prilagođavanja digitalnim trendovima u literaturi se identificira kao „digitalni darvinizam“ koji aludira na činjenicu kako se društvo i tehnologija razvijaju brže od sposobnosti za prilagodbu. Pojam „digitalni darvinizma“ s aspekta organizacija podrazumijeva sposobnost organizacije da se prilagodi novom digitalnom okruženju [51].

Mazzone tu situaciju objašnjava kao „*engl. Digital or Death“,* tj. digitaliziraj ili nestani čime ukazuje na činjenicu kako je za organizacije neophodno da digitaliziraju svoje poslovanje, tj. da prihvate mogućnosti koje digitalne tehnologije pružaju [52].

Neminovno je da su digitalne tehnologije zbog sve bržeg razvoja i smanjenja cijena postale važan čimbenik u pozicioniranju organizacija na tržištu, te je danas teško pronaći organizaciju koja u svom poslovanju ne primjenjuju neku od digitalnih tehnologija.

U svrhu istraživanja na koji način organizacije provode digitalnu transformaciju u Republici Hrvatskoj, konkretno koje digitalne tehnologije su implementirali u svoje poslovanje, Tomičić-Furjan i ostali utvrđuju da su to tri vodeće digitalne tehnologije: veliki podaci, uslužno računalstvo i društvene mreže [51]. Do sličnog rezultata dolazi i istraživanje provedeno na 200 organizacija u Republici Hrvatskoj gdje se pokazalo kako organizacije imaju u planu investirati u automatizaciju procesa, uslužno računalstvo, tj. tehnologije u oblaku, upravljanje podacima i naprednu analitiku [53]. Navedeno je istraživanje pokazalo kako se 57% organizacija ne osjeća spremnim usvojiti digitalne tehnologije, a to je posebice bilo izraženo u organizacijama koje pripadaju uslužnom sektoru.

U kontekstu razvoja digitalnih tehnologija Spremić je izvršio podjelu na primarne (temeljne, bazične, osnovne) i sekundarne digitalne tehnologije. U primarne digitalne tehnologije svrstava mobilne tehnologije *(engl. mobile),* društvene mreže *(engl. social)*, uslužno računalstvo *(engl. cloud),* velike skupove podataka *(engl. big data),* senzore i Internet stvari *(engl. Internet of Things, IoT)*. Kao sekundarne digitalne tehnologije navodi 3D printere, robotiku, dronove, nosivu tehnologiju, virtualnu i proširenu stvarnost, umjetnu inteligencije i slično, koje omogućavaju brojne inovativne usluge i primjene [7].

U nastavku će se detaljnije opisati dvije digitalne tehnologije jedna primarna - uslužno računalstvo i jedna sekundarna - blockchain s naglaskom na pametne ugovore. Navedene tehnologije su izdvojene iz razloga što će iste poslužiti u svrhu ovog istraživanja kako bi se spoznao utjecaj moderirajućih čimbenika na prihvaćanje digitalnih tehnologija u mikro i malim organizacijama.

3.1. Uslužno računalstvo

Uslužno računalstvo *(engl. Cloud)* definirano je od strane Nacionalnog središta za sigurnost nacionalnih računalnih mreža i sustava kao „koncept podjele programskog okruženja koji koristi Internet kao platformu te omogućuje da aplikacije i dokumenti poslani iz bilo kojeg dijela svijeta budu pohranjeni i čuvaju se na za to predviđenim poslužiteljima“ [54]. Marston i drugi definiraju uslužno računalstvo kao model usluge informacijske tehnologije u kojem se računalne usluge (hardverske i softverske) putem mreže isporučuju korisnicima na njihov zahtjev kao oblik samoposluživanja, neovisno o uređaju i lokaciji [55]. S druge strane Wang i drugi ga definiraju kao skup mrežnih usluga koje omogućuju jednostavan pristup računalnim platformama koje su personalizirane prema željama korisnika, te su odgovarajuće razine kvalitete i cjenovno pristupačne [56]. Nadalje, Spremić uslužno računalstvo definira kao upotrebu gotovo neograničenih digitalnih (hardverskih, podatkovnih i softverskih) kapaciteta, koji omogućuju sigurno i efikasno upravljanje podacima, njihovu pohranu i upotrebu. Ne iziskuje dodatna kapitalna ulaganja već djeluje na principu „plati koliko i što koristiš“. Zapravo, korisniku je omogućen pristup ogromnim računalnim resursima do kojih može doći brzo i relativno jednostavno [7].

Teško bi bilo pronaći dva autora koja bi se složila oko definicije uslužnog računalstva. No ono što je sigurno je da bi se svi složili oko tvrdnje Marstona i drugih da se pojavom uslužnog računalstva promijenio način na koji se informacijsko komunikacijske tehnologije razvijaju, koriste, održavaju, i plaćaju [55]. Pejić Bach i ostali navode kako je uslužno računalstvo jedan od bitnih trendova koji se iz računarskog područja pretočio u ključan poslovni trend, te svojom brzinom širenja utjecao na cjelokupno poslovanje [57].

Uslužno računalstvo omogućilo je korisnicima da pristupe aplikacijama bilo kada i bilo gdje bez obzira gdje se nalaze. Uredske aplikacije bazirane na uslužnom računalstvu u velikoj mjeri pronalaze svoje mjesto i u svakodnevnoj poslovnoj praksi. Upotreba udaljenih poslužiteljskih

mreža, umjesto lokalnih poslužitelja i osobnih računala za pohranu, omogućuju upravljanje i obradu podataka izvan radnog okruženja. Također je olakšana komunikacija i dijeljenje datoteka među zaposlenicima. Prednosti koje uslužno računalstvo nudi su i povećanje postojećih kapaciteta i proširenje mogućnosti informacijske tehnologije bez dodatnog i stalnog investiranja u novu računalnu opremu kao i obuku onih koji upravljaju istom te nadograđivanje i kupovina novih licenci [54].

3.1.1. Vrste isporuka uslužnog računalstva

Nacionalno središte za sigurnost nacionalnih računalnih mreža ističe tri arhitekturna modela isporuke uslužnog računalstva tzv. SPI model koji se odnosi na program, platformu ili infrastrukturu (*engl. Software, Platform, Infrastructure*). Modeli su sljedeći [54], [58], [59], [57]:

- **Softver kao usluga - SaaS *(engl. Cloud Software as a Service)*** – Predstavlja „tehnološku platformu koja omogućava dostupnost aplikacija putem Interneta u obliku usluga koje se unajmljuju prema potrebi, umjesto da se kupuju kao zasebni program koje treba instalirati na kućnim (odnosno uredskim) računalima“. Korisnik pristupa usluzi putem različitih uređaja željenim aplikacijama preko prilagođenog korisničkog sučelja. Korisnik ne vodi brigu niti provjerava pozadinsku infrastrukturu, mrežu, servise, pohranu podataka i slično, već je sva briga na pružatelju usluge. Softver kao usluga zapravo predstavlja distribuciju softvera gdje pružatelj usluge razvija i upravlja web aplikacijom čineći je dostupnom korisnicima putem interneta.
- **Platforma kao usluga - PaaS *(engl. Cloud Platform as a Service)* –** Korisnik ima na upotrebu cjelokupnu platformu (hardversku i softversku) na kojoj može sam razvijati aplikacije u oblaku, tj. na infrastrukturi oblaka korisniku je pružena mogućnost implementacije vlastitih ili stečenih aplikacija generiranih pomoću programskih jezika i alata koji su podržani od strane pružatelja usluge. Zapravo je omogućeno korisniku da bez dodatnih troškova kupnje hardvera i softvera programira, testira, implementira i upravlja poslovnim aplikacijama. Usluga je doduše ograničena dizajnom i mogućnostima pružatelja usluge, tako da je na neki način ograničena potpuna sloboda korisnika. Isto tako korisnik nije u mogućnosti provjeravati strukturu oblaka kao ni mrežu, sustave pohrane, operacijske sustave i poslužitelje, ali mu je omogućen nadzor

nad razvijenim aplikacijama a u nekim slučajevima i mogućnost nadzora okolinske konfiguracije.

- **Infrastruktura kao usluga - IaaS *(engl. Cloud Infrastructure as a Service)*** – Predstavlja računalnu infrastrukturu koja se iznajmljuje korisniku koji ju potom koristi kao vlastitu, no on ne kupuje poslužitelje, programe, prostore za pohranu podataka ili mrežnu opremu, nego navedene resurse kupuje kao vanjsku uslugu. Korisnik može upravljati obradom, pohranom, umrežavanjem i drugim osnovnim računalnim resursima, kao i što može pokrenuti različite vrste programske podrške - od operacijskog sustava do aplikacija. Iako korisniku nije omogućena kontrola nad infrastrukturom oblaka, dana mu je kontrola nad operacijskim sustavima, pohranom podataka, razvojem aplikacija kao i ograničeni nadzor nad odabranim komponentama umrežavanja.

Kada se govori o vrsti uslužnog računalstva, neovisno o modelu isporuke, postoji nekoliko osnovnih modela: javni, privatni, zajednički, hibridni i kombinirani [54], [58], [57]:

- **Javni oblak *(engl. Public Cloud)* –** Predstavlja platformu koja je dostupna javnosti a u vlasništvu je pružatelja usluge. Pružatelj usluge ispostavlja račun korisniku usluge na temelju stvarnog korištenja usluge.
- **Privatni (ili interni) oblak *(engl. Private Cloud)* –** Isključivo je namijenjen upotrebi od strane jednog korisnika, tj. jedne organizacije. Organizacija je dužna osigurati i upravljati svim potrebnim resursima (mrežni, strojni, ljudski) kao što je slučaj i u klasičnom računarstvu. Organizacija upravlja infrastrukturom što joj daje i mogućnost nadzora nad raspodjelom aplikacija na toj infrastrukturi. Sama izvedba privatnog oblaka može biti fizička ili virtualna.
- **Zajednički oblak *(engl. Community Cloud)* -** Nekoliko različitih organizacija koje uobičajeno povezuje neki zajednički cilj, dijele strukturu oblaka. Na taj način dijele troškove i osiguravaju veću sigurnost i privatnost nego što bi imale u javnom oblaku, a upravljanje može biti u rukama organizacija ili u rukama pružatelja usluga.
- **Kombinirani ili hibridni oblak *(engl. Hybrid Cloud)* -** Predstavlja kombinaciju javnog i privatnog oblaka. Oni ostaju jedinstveni zasebni entiteti, no međusobno su povezani nekim standardiziranim tehnologijama koje osiguravaju prijenos podataka i/ili aplikacija. Najčešće se upotrebljava na način da se svi procesi odvijaju na privatnom oblaku, dok se funkcije zaštite podataka i obnove osiguravaju javnim oblakom.

Kombinacija dva oblaka može značiti i veća sigurnost i privatnost. Proširivanje privatnih oblaka javnim može se upotrijebiti kod održavanja uslužnih razina kako bi se lakše izdržala neka veća opterećenja.

3.1.2. Karakteristike uslužnog računalstva

Abushofa navodi kako je pojava uslužnog računalstva pridonijela smanjenju troškova računalstva, hostinga aplikacija, pohrane i dostave sadržaja [60]. Omogućila je da korisnici izbjegnu kupnju raznih softvera, hardvera i mrežnih sustava te drugih složenih IT rješenja, koji često iziskuju visoka kapitalna ulaganja. Ono što uslužno računalstvo čini privlačnim mikro i malim organizacijama je upravo mogućnost uštede na operativnim troškovima na način da su troškovi infrastrukture prebačeni na pružatelja usluge [61].

Osim prednosti koje uključuju smanjenje početnih investicijskih ulaganja uslužno računalstvo pruža i niz drugih pogodnosti, u odnosu na tradicionalne pristupe računarstvu, koje su korisnicima posebno zanimljive: [54]:

- **Pružanje usluge na zahtjev korisnika *(engl. On-demand self-service)*.** Jedna od specifičnosti uslužnog računalstva je pružanje mogućnosti korisniku da sam odabere i pokrene željene računalne resurse. Resursi su samoalocirajući i/ili autolocirajući s minimalnom potrebom za konfiguriranjem što bi značilo da korisnik sam bira vrijeme posluživanja kao i mrežni prostor za pohranu podataka, te nije potrebna nikakva interakcija s osobljem pružatelja usluge.
- **Širok mrežni pristup *(engl. Broad network access)*.** Pristup uslugama i aplikacijama u oblaku omogućen je putem osobnih računala, mobilnih uređaja, PDA uređaja i sl. Cilj je da bilo koji uređaj s bilo kojeg mjesta može pristupiti uslugama u oblaku.
- **Udruživanje resursa *(engl. Resource pooling)*.** Pružatelj usluge spaja svoje računalne resurse kako bi bio u mogućnosti poslužiti sve korisnike i to čini koristeći višezakupnički model *(engl. Multi-Tenant model)* koji se sastoji od različitih fizički i virtualnih resursa. Resursi kao što su mrežni prostor, procesori, memorija, mrežna propusnost i virtualni strojevi se dinamički dodjeljuju i uklanjaju po zahtjevu korisnika usluge. O točnoj lokaciji resursa korisnik nema znanje, no pružena je mogućnost da odabere željenu državu lokacije resursa.

- **Brza elastičnost *(engl. Rapid elasticity).*** Potrebama korisnika prilagođeno je dinamičko skaliranje računalnih resursa brzim pribavljanje i otpuštanjem istih. Korisnik može mogućnosti koje koristi kupiti u bilo kojoj količini i u bilo koje vrijeme, potrebno je tek nekoliko minuta, što značajno skraćuje vrijeme primjene alocirane infrastrukture.

- **Odmjerena usluga *(engl. Measured service)***. Karakteristika uslužnog računalstva je mogućnost da korisnik plati onoliko koliko troši. Korisnik plaća samo one resurse koje je stvarno koristio, pri čemu je sama potrošnja transparentna kako pružatelju tako i korisniku usluge.

Uz sve prednosti koje uslužno računalstvo pruža, u literaturi se često uz pojam uslužno računalstvo vežu i rizici povezani sa sigurnošću i privatnošću. Sigurnosni rizik uključuje sigurnost podataka, oporavak podatak, curenje podataka *(engl. data leaking)* i sl. Povezan je i s pohranom osjetljivih podataka na nepoznatim i udaljenim lokacijama [62], [63]. S time u vezi je Lee ustanovio kako upravo sigurnosni rizik negativno utječe na prihvaćanje uslužnog računalstva, a isto su potvrdili i Park i Kim koji su sigurnosni rizik definirali kao razinu povjerenja u sigurnost korištenja uslužnog računalstva [64].

U nastavku su navedeni neki od specifičnih sigurnosnih rizika [54]:

- **Privilegirani korisnički pristup.** Specifičnost uslužnog računalstva je upravljanje podacima izvan organizacije od strane treće strane što sa sobom nosi određenu razinu rizika. Stoga je nužno provjeriti i osigurati integritet pružatelja usluga, kako bi se na taj način rizik sveo na prihvatljivu razinu. To je moguće uraditi i na način da korisnik usluge od pružatelja pribavi informacije o zapošljavanju i nadzoru privilegiranih administratora te provjerama ovlasti njihovih pristupa.

- **Nadzorna usklađenost**. Korisnik uslužnog računalstva treba provjeriti da li organizacija koja mu pruža uslugu uslužnog računalstva posjeduje sigurnosne certifikate i obavlja li vanjske revizije svojih sigurnosnih protokola.

- **Lokacija podataka**. Pružatelj usluge nije u obvezi korisniku usluge otkriti točnu lokaciju pohrane njegovih podataka. Kako bi anulirao rizik korisnik može od pružatelja usluge zatražiti pohranjivanje podataka u određenoj državi, te zahtijevati neku vrstu ugovorne obveze u svezi zaštite privatnost korisnika i njegovih podataka.

- **Odvajanje podataka**. Korisnik usluge mora se osigurati, tj. provjeriti da li su njegovi podaci pohranjeni u oblaku odvojeni od podataka drugih korisnika. To se osigurava na način da pružatelj uslužnog računalstva zaštitno kodira podatke korisnika i na taj način ih odvoji od podataka drugih korisnika. Kako bi se korisnik usluge uvjerio da su sheme zaštitnog kriptiranja zaista i napravljene potrebno je ishoditi dokaze od strane pružatelja usluge. Pogreške u zaštitnom kriptiranju mogu dovesti do problema odnosno do neupotrebljivost podataka korisnika.
- **Oporavljanje**. Pružatelj uslužnog računalstva trebao bi osigurati dupliciranje podataka i aplikacija na više različitih mjesta kako bi osigurao da ne dođe do trajnog gubitka podataka korisnika. Činjenica da korisnik usluge ne zna lokaciju gdje su pohranjeni njegovi podaci ne znači da ga pružatelj usluge ne bi trebao upoznati s planom što se događa s podacima u slučaju nepredvidivih nezgoda.
- **Podrška istraživanja**. Poželjno je kod odabira pružatelja uslužnog računalstva da se odabere onaj koji podržava i omogućuje istraživanje neprikladnih ili ilegalnih aktivnosti. Potvrda pružatelja usluge da podržava istraživanje uvelike anulira sigurnosni rizik.

Pejić Bach i ostali kao nedostatak uslužnog računalstva navode i problem dostupnosti koji se odnosi na činjenicu kako je za korištenje usluge potrebna stalna internetska veza. Uz dostupnost također naglašavaju pitanje sigurnosti, kao i povjerenja u pružatelja usluge da neće zlorabiti podatke. Bitan nedostatak je i ovisnost o pružatelju usluge. Često je poprilično teško promijeniti pružatelja usluge, tj. preseliti podatke na drugog poslužitelja [57], [61]. Svakako bi prilikom odabira pružatelja usluge trebalo napraviti procjenu sigurnosti, te inzistirati na transparentnosti i informacijama o sigurnosnim problemima. Poželjno je prikupiti što više informacije o kompetencijama zaduženih za vođenje politike organizacije, arhitektima, programerima i operaterima. Isto tako trebalo bi prikupiti informacije o samom načinu na koji se nadzire i kontrolira rizik unutar organizacija koje pružaju usluge uslužnog računalstva. Imaju li uspostavljene procese nadzora rizika, te jesu li u mogućnosti procijeniti i identificirati možebitne ranjivosti [54].

Promatrajući uslužno računalstvo s aspekta mikro i malih organizacija, naglašava se kako mikro i male organizacije nemaju vremena pratiti tehnološke trendove kao što to rade velike

organizacije koje u te svrhe imaju zasebne IT odjele. Upravo zbog nedostatka vremena često nisu upoznati sa svim mogućnostima i prednostima koje uslužno računalstvo može pružiti.

3.2. Blockchain

Doslovan prijevod termina blockchain glasio bi lanac blokova pri čemu blokovi predstavljaju distribuirane baze podataka kontrolirane od skupine pojedinaca koji pohranjuju i razmjenjuju informacije. Samo ime blockchain ukazuje kako su podaci pohranjeni u blokove koji su međusobno lančano povezani [65]. Često se definira i kao baza podataka koja ima karakter mreže gdje za razliku od interneta, sudionici podatke pohranjuju na svoja računala. Ideja iza blockchain tehnologije je da se anulira potreba za trećom stranom koja je u tradicionalnom poslovanju odgovorna za pohranjivanje podataka te njihovo odobravanje, tj. validiranje [65].

Kao i kod većine novih tehnologija, u literaturi je teško postići koncensus oko definicije, pa se tako i za blockchain tehnologiju može pronaći mnogo raznih definicija od strane različitih autora. Perkušić i ostali definiraju blockchain tehnologiju kao „distribuiranu bazu podataka koja se dijeli između sudionika putem „*engl. peer-to-peer*“ mreže. Sastoji se od povezanog slijeda blokova koji sadrže transakcije s vremenskim žigom, zaštićene kriptografijom i validirane od strane sudionika na mreži. Nakon što se element doda u blockchain on se ne može mijenjati, pretvarajući blockchain u nepromjenjivi zapis prošle aktivnosti” [66]. Budimir ističe kako blockchain tehnologija predstavlja tehnologiju koja služi za skladištenje, prijenos i enkripciju podataka te na taj način omogućava realiziranje digitalnih transakcija bez posrednika. Izvedena je u formi jednostruke spregnute liste, tj. lanca, gdje čvorovi predstavljaju blokove s podacima o transakcijama koje se odvijaju, a sve je štićeno kriptografskim metodama [67]. Desić i Lenac konstatiraju kako blockchain predstavlja distribuiranu elektroničku knjiga zapisa kod koje nema potrebe za centralnim mjerodavnim tijelom koje bi imalo ulogu jamčenja autentičnosti pohranjenih podataka, pošto je isto prebačeno na programski kod [68]. Prema Čulinović-Herc i ostalima blockchain tehnologija dio je tehnologije distribuiranog knjiženja koja podrazumijeva elemente kriptografije te joj je svojstveno decentralizirano knjiženje podataka [69]. Pinna i Ibba definiraju blockchain tehnologiju kao decentraliziranu računalnu mreža koja omogućuje efikasnije upravljanje transakcijama [70].

Ono što je ključno za blockchain tehnologiju jest da omogućava provođenje digitalnih transakcija bez posrednika. To je zapravo baza podataka koja se temelji na matematičkom algoritmu za distribuiranje kriptografskih informacija koja omogućava nepromjenjivost podataka, tj. nakon što se podaci jednom unesu oni se ne mogu uklanjati ili mijenjati bez suglasnosti većine sudionika u mreži [67]. Dakle, nakon što su podaci zapisani i prihvaćeni u čvor naknadne promijene ili brisanje nije moguće, čak i onda kada je dio čvorova maliciozan i ne prati pravila [68].

Sigurnost unutar blockchain mreže osigurana je na način da su svi podaci kodirani i digitalno potpisani od strane pošiljateljevog privatnog ključa. Potpis i autentičnost podatka provjerava čvor koji primi zahtjev te ukoliko je sve u redu prosljeđuje ga zajedno s drugim zahtjevima u novi blok podataka. Taj se novi blok veže na prethodni blok koristeći kriptografske metode stvarajući na taj način lanac blokova koji naposljetku čine kontinuirano proširivu knjigu zapisa kroz vrijeme [68]. Specifičnost blockchaina je što su kopije transakcija pohranjene na više računala (tzv. decentralizirani sustav upravljanja podacima), te svaki od sudionika provjerava validnost podataka koji se unose čime se osigurava visoka razina sigurnosti istih. Isti podaci čuvaju se na više računala i na više lokacija što znači da ne postoji jedan jedinstveni server, što dodatno podiže razinu sigurnosti [65], [67]. Kako svako računalo u mreži ima istovjetnu kopiju cijele baze podataka nema ni jedinstvene točke kvara [69].

Blockchain mreža funkcionira na način da se prilikom kreiranja transakcije podaci unose u podatkovni blok koji dobiva jedinstveni digitalni potpis kako za sam blok tako i za njegov sadržaj. Blok dobiva i „hash“ (oznaka kojom se označavaju i povezuju blokovi unutar blockchaina) pomoću kojeg se podaci, tj. sadržaj na bloku konvertira u tzv. lanac blokova [67]. Hash funkcija omogućava da se od podataka proizvoljne veličine stvori podatak fiksne veličine, što je izrazito prikladno za kriptografiju podataka. Pomoću hash funkcije povezani su podaci i informacije unutar transakcije [69]. Svaka izmjena podataka se registrira pri čemu se kreira novi blok koji se dodaje na kraj lanca postojećih blokova. Svaki blok sadrži informacije kao što su vremenska oznaka, identitet korisnika koji je dodao taj blok u lanac, informacije o transakcijama koje se nalaze u bloku te hash bloka na kojeg se novi blok nadovezuje [67].

Prilikom provođenja transakcija svaki korisnik koristi dva enkripcijska ključa, jedan javni i jedan privatni. Pri čemu je javni ključ za razliku od privatnog vidljiv svim sudionicama na mreži [69]. Autentičnost transakcije se dokazuje digitalnim potpisom. Nakon što je transakcija

potpisana ona se stavlja, tj. „oglašava“ na mreži kako bi se verificirala temeljem koncensusa sudionika na mreži. Svaki korisnik na mreži se obavještava o transakciji, tj. o njenoj provedbi te pomoću javnog ključa kreatora transakcije dekriptira digitalni potpis i verificira transakciju. Takav oblik verifikacije transakcije temelji se na *„Proof-of-Work“ ili „Proof-of-Stake“* konceptu, a sam proces se naziva rudarenje *(engl. mining)* [69], [68]. Nakon što se transakcija verificira ona se dodaje u ažuriranu verziju baze podataka ili knjige pod nazivom blok. Taj novi blok dodaje se u lanac, tj. u mrežu, čime postaje vidljiv svim sudionicima mreže. Karakterističnost blockchaina koja ga čini poprilično sigurnim je ta da je svaki blok u lancu na jedinstven način povezan sa sljedećim blokom, a knjiži se na svako računalo u mreži. Time je zloupotreba otežana jer da netko želi izmijeniti podatke u bloku trebao bi izmijeniti i sve nadovezane blokove i to na svim čvorovima mreže za što bi trebala velika računalna snaga [69], [68].

3.2.1. Vrste blockchain mreže

Uzimajući u obzir otvorenost blockchain mreže razlikuju se javne i privatne blockchain mreže:

- **Javna blockchain mreža**. Kao što i sam naziv implicira mreži može pristupiti svatko i sudjelovati u procesu konsenzusa, tj. validiranja i provjere autentičnosti transakcije, kao i imati uvid u zapise izvršenih transakcija [68], [67]. Mreža je otvorena i decentralizirana što znači da ne postoji centralni autoritet, a programski kod (i pravila ukodirana) u njemu je otvoren i transparentan [68]. Svaki sudionik u mreži može pogledati programski kod koji upravlja ovim sustavom te predložiti izmjenu ili dopunu koda koja, ukoliko se većina sudionika složi, postaje sustavni dio protokola [67]. Velik broj sudionika u mreži utječe na njezinu efikasnost jer je za svaku izmjenu potrebna suglasnost većine sudionika [67].

- **Privatna blockchain mreža**. Za razliku od javne, privatna mreža otvorena je samo za određene korisnike koji su pozvani od strane administratora. Administrator predstavlja jedinstveno odgovorno tijelo čija uloga je upravljanje mrežom i donošenje odluke o podacima koji će biti zapisani u mreži [68]. Transakcije autorizira administrator ili on definira pravila po kojima mogu autorizirat drugi sudionici [67]. Privatna mreža omogućava suradnju i dijeljenje podataka između pojedinaca ili poduzeća koji ne žele

da su ti podaci vidljivi na javnoj blockchain mreži. U privatnim mrežama ne postoji anonimnost sudionika pošto pristup imaju isključivo pozvani korisnici koji imaju pravo postavljati upite za transakcije. Manji i ograničen broj poznatih korisnika olakšava postizanje koncensusa oko donošenja odluka što mrežu čini bržom i učinkovitijom jer ne sadrži kompleksne protokole za postizanje koncensusa oko transakcija koje se dodaju u blok. Sadrži manji broj čvorova od javne mreže te je fleksibilnija zbog lakše prilagodbe pravila ovjere [68], [67].

- **Konzorcijska ili federirana blockchain mreža** je vrsta privatnog blockchaina gdje grupa vlasnika zajedno administrira jednu privatnu blockchain mrežu [68].

3.2.2. Karakteristike blockchain tehnologije

Kao temeljna obilježja blockchain tehnologije navodi se decentralizacija, neizmjenjivost podataka i transparentnost [69].

Na tom tragu Budimir ističe kako su ključne karakteristike blockchain tehnologije distribuiranost podataka, anonimnost korisnika, nepromjenjivost zapisa te mogućnost autorizacije podataka i informacija od strane svih sudionika [67].

Perkušić i ostali svoju definiciju blockchaina pokazuju kroz njegove bitne karakteristike te navode [66]:

- Distribuirana baza podataka (podaci su spremljeni na više međusobno povezanih računala koja se nalaze u mreži);
- Peer to peer mreža (računala su umrežena bez poslužitelja, tj. nema središnje korespondencije, računala međusobno izravno komuniciraju bez potrebe autorizacije na nekom centralnom poslužitelju);
- Sadrži niz povezanih blokova (informacije se spremaju u blokove koji sadrže podatke, a povezani su putem kriptografije);
- Koristi vremenske oznake;
- Kriptografski osigurana;

- Sudionici u mreži verificiraju podatke;
- Nepromjenjiva (promjena podataka unutar blockchain mreže zahtijeva da se promijene podaci u svim blokovima, a za što je potreban koncensus većine).

Neke od ključnih prednosti blokchaina su [67]:

- **Proces integriranja**. Osigurana je visoka razina sigurnosti na način da se onemogućuje uređivanje transakcija nakon što su one dodane u lanac.
- **Sljedljivost**. Omogućeno je jednostavno utvrđivanje i identificiranje problema koji se mogu na jednostavan način ispraviti.
- **Sigurnost**. Činjenice da svaki korisnik u mreži ima svoj jedinstveni identitet koji je povezan s njegovima nalogom omogućuje visoku razinu sigurnosti.
- **Brza obrada**. Ubrzan je proces obrade transakcija zbog njihovog odvijanja u realnom vremenu i zbog činjenice da nije potrebna dosadašnja papirologija koja je usporavala proces obrade.

Uz sve prednosti blockchain tehnologije jedan od nedostataka je izostanak realnog, zakonodavnog ili regulatornog okvira njene primjene. Upravo to utječe na percepciju sigurnosti i povjerenja u ovu vrstu tehnologije. Uz sigurnost postavlja se i pitanje troškova razvoja, implementacije i samog održavanja što ima i imat će najveći utjecaj na brzinu razvoja te tehnologije [67].

Iz poslovnog aspekta zanimljivost blokchaina proizlazi iz mogućnosti da čvorovi međusobno razmjenjuju vrijednosti bez potrebe postojanja centralnog autoriteta koji bi garantirao sigurnost i ispravnost takvih transakcija. Današnje financijske transakcije npr. slanje novca ili plaćanje računa odvijaju se posredstvom banke ili neke druge financijske institucije, dok kod blokchaina takav posrednik ili autoritet nije potreban.

Iako je blockchain tehnologija svoju veliku primjenu doživjela s Bitcon kriptovalutama, zbog činjenice da je bila anulirana treća strana koja je davala konsenzus na razmjenu novca, danas je uvelike prerasla bitcoin te je njena primjena vidljiva i u drugim područjima kao što su:

bankarstvo, osiguranje intelektualnog vlasništva, elektroničko glasanje, zdravstvo, računovodstvo, e- uprava, zemljišni registri, promet robe i sl. [68], [65].

Neki od primjera primjene blochchaina su sljedeći: [71]

- U državnoj upravi (digitalni potpisi, ovlaštenja, distribuirani sustavi za identifikaciju osoba).
- Kod sustava glasanja gdje je osigurana visoka transparentnost bez otkrivanja osobnih podataka.
- U poslovima državnih službi vezanih za upravljanje podacima koji se odnose na zemljišne knjige, poreze i sl. gdje se isključuje posredovanje (autoriteta) javnih bilježnika i drugih institucija.
- Kod razmjene novca (kriptovaluta), trgovanje dionicama ili izdavanja obveznica.
- Kod zaštite autorskih prava.
- Trgovanja električnom energijom bez posrednika.
- Kod Interneta stvari, postojeće umrežavanje uređaja nadograđuje se pametnim ugovorima koji omogućavaju da, na primjer, uređaji sami naplaćuju određenu uslugu (razni automati za prodaju).

Jedna od primjena blockchain tehnologije su i pametni ugovori čije će se prihvaćanje obuhvatiti ovim istraživanjem, te se oni u nastavku detaljnije objašnjavaju.

3.2.3. Pametni ugovori

Pametni ugovori predstavljaju računalne protokole čija je svrha digitalno izvršenje ugovora kada se ispune određeni uvjeti [68]. Predstavljaju nadogradnju na koncept blockchaina, gdje se kao vrsta podataka u blockchain upisuje programski kod. Perkušić i ostali ističu kako je svrha pametnih ugovora izvršavanje unaprijed definirani kriterija između dvije ili više ugovorenih strana uz pomoć računalnog koda koji se nalazi na blockchain mreži. Navode kako bi bilo ispravnije reći da su pametni ugovori način provedbe ili izvršenje ugovora, a ne sam ugovor ili oblik ugovora [66].

Definiciju pametnog ugovora kao „računalnog transakcijskog protokola koji izvršava uvjete ugovora“ uveo je Nick Szabo još 1994. godine, dok je prva primjena zaživjela s pojavom blockchain tehnologije dvadesetak godina kasnije (2014. g.) na platformi Ethereum [66].

Pametni ugovori predstavljaju računalne programe koji automatski izvršavaju klauzule ugovora, tj. transakcije na blockchainu bez intervencije ljudske ili treće nezavisne strane. U trenutku kada se ispune ugovoreni uvjeti ugovor se izvršava pri čemu nije potreban posrednik u izvršavanju, a što umanjuje transakcijske troškove te anulira mogućnost prijevare [68].

Jednostavnim rječnikom pametni ugovor je računalni protokol čija je svrha da olakša, provjeri i provede izvršenje ugovora na način da obavi vjerodostojnu transakciju bez posrednika koji bi kod tradicionalnih ugovora imao zadaću da osigura transparentnost. Činjenica da su pametni ugovori na blockchain tehnologiji njihova provedba je onakva kako je programirano [66].

Specifičnost pametnih ugovora je automatska izvedba, provedivost, interoperabilnost i otpornost na vanjske greške u sustavu, te činjenica kako su sigurni i nezaustavljivi nakon što su jednom pokrenuti. Pomoću pametnih ugovora osigurana je kontrola nad provođenjem ugovorenih obveza stranaka bez ljudske intervencije. Sam događaj koji aktivira pametni ugovor može bit unutar same blockchain mreže, na primjer pojavljivanje transakcije određenih svojstava ili može ovisiti o vanjskim pružateljima usluga (*engl. oracles*) koji analiziraju podatke vanjskog svijeta i pohranjuju ih u blockchain. Iako nema puno propisa koji bi obuhvatili pametne ugovore, Desić i Lenac navode kako to ne mora značiti da se postojeće ugovoreno pravo i opća načela ne mogu primijeniti i na pametne ugovore, naglašavajući tako da oni nisu u potpunosti neuređeni [68].

Perkušić i ostali navode kako se osnovna konfiguracija pametnih ugovora sastoji od četiri faze koje uključuju sljedeće [66]:

- Sklapanje ugovora - ugovorene odredbe pretvaraju se, tj. prevode u računalni kod;
- Lančani slijed događaja u kojem se ispunjavaju ugovorene obveze;
- Situacija „ako ovo-onda-ovo“ - programski kod aktivira prijenos vrijednosti onda i ako se ispune ugovoreni uvjeti;

- Ugovorene odredbe su ispunjene i sve se pohranjuje na blockchain mrežu.

U literaturi se kao ključne prednosti pametnih ugovora navode ušteda vremena i novca, povećana sigurnost te brzo i efikasno provođenje ugovorenog odnosa. Ono što je specifično za pametne ugovore je njihova sigurnost u pogledu smanjenog rizika zbog činjenice da se spremaju na blockchain koji je nepromijenjen. Ušteda novaca očituje se u anuliranju bespotrebne administracije i drugih popratnih usluga zbog činjenice da je sve automatizirano te nema potrebe za posrednikom. Brzina i efikasnost se isto tako očituje u eliminiranju potrebe za posrednikom što uvelike ubrzava i poboljšava učinkovitost poslovnih procesa [66], [72].
Nepromjenjivost koja se naglašava kao prednost pametnih ugovora ujedno je i nedostatak jer ukoliko dođe do propusta u programskom kodu postoji mogućnost zlouporabe na način da se rupa u kodu iskoristi za hakerski napad. U tom slučaju postoji opasnost da se sadržaj pametnog ugovora pošalje na račun hakera, a zbog nepromjenjivosti to je kasnije teško poništi i/ili izmijeniti što naravno, može prouzročiti velike gubitke [66].

4. PRIHVAĆANJE TEHNOLOGIJA U MIKRO I MALIM ORGANIZACIJAMA

4.1. Teorijski modeli prihvaćanja tehnologija u organizacijama

Važnost identificiranja čimbenika koji utječu na namjeru prihvaćanja tehnologija u mikro i malim organizacijama proizlazi iz stalnog porasta broja istraživanja koja se bave tom problematikom [25], [22]. Prihvaćanje tehnologija definira se kao odluka organizacije da prihvati tehnologiju i prepozna njezinu korisnost [5]. Rogers definira postupak prihvaćanja inovacije kao „postupak kroz koji pojedinac (ili druga jedinica koja donosi odluke) prolazi od prve spoznaje o inovaciji, do formiranja stava i odluke o usvajanju ili odbijanju, provedbi i korištenju nove ideje te potvrdi te odluke“ [26]. Definira inovaciju kao ideju, praksu ili objekt koji je percipiran kao nešto novo od strane onoga koji ga prihvaća, tj. usvaja.

Rogers opisuje proces prihvaćanja kroz 5 faza koje uključuju: znanje, uvjeravanje, odluku, provedbu i potvrdu [26]:

- **Znanje.** Znanje predstavlja prvu fazu procesa prihvaćanja u kojoj se donositelj odluke upoznaje s postojanjem određene inovacije i načinom na koji ona funkcionira. Uključuje aktivno i pasivno prikupljanje informacija o inovaciji. Aktivno prikupljanje informacija uključuje aktivno pretraživanje informacija o inovaciji s ciljem stjecanja znanja o njoj, za razliku od pasivnog gdje se informacije ne traže ali ipak donositelj odluke dolazi u kontakt s njima. Donositelj odluke uobičajeno pretražuje informacije koje su u skladu s njegovim interesima, potrebama i trenutnim ponašanjem. U literaturi ne postoji koncensus o tome da li prvo nastaje potreba za određenom inovacijom ili se potreba stvara nakon što donositelj odluke postane svjestan određene inovacije, te prepozna svoju potrebu za njom. Potreba za inovacijom također se javlja i uslijed pojave određenog problema koji ukaže na njezinu potrebu.

- **Uvjeravanje.** U ovoj fazi donositelj odluke kreira povoljan ili nepovoljan stav prema inovaciji. Za razliku od faze znanja koja uključuje mentalnu aktivnost u obliku kognitivnih sposobnosti faza uvjeravanja je afektivna i temelji se na osjećaju pojedinca. Specifičnost faze uvjeravanja je psihološka uključenost donositelja odluke u inovaciju

koja uključuje aktivno traženje informacija i procjenu njihove vjerodostojnosti. U ovoj fazi se formira opća percepcija o inovacije, te je njezin finalni produkt formiranje povoljnog ili nepovoljnog stava prema inovaciji. Donositelj odluke procjenjuje relativnu prednost, kompatibilnost i složenost, tj. kompleksnost inovacije te traži odgovor na pitanje "Koje su prednosti i nedostaci inovacije za njega?". U potrazi za odgovorom donositelj odluke prikuplja i informacije od postojećih korisnika inovacije, tj. prikuplja iskustva drugih.

- **Odluka.** Faza odluke slijedi nakon što su prikupljene sve dostupne informacije o inovaciji, te podrazumijeva aktivnost koja dovodi do usvajanja ili odbijanja inovacije. Ono što olakšava a ujedno i ubrzava donošenje odluke je mogućnost probe i demonstracija inovacije.

- **Provedba.** Nakon što se donese odluka o usvajanju slijedi faza provedbe, tj. implementacija usvojene tehnologije, odnosno inovacije. Uobičajeno faza provedbe slijedi ubrzo nakon donesene odluke o usvajanju. Prethodne faze uključivale su mentalne vježbe u obliku razmišljanja, promišljanja i odlučivanja, dok faza provedbe uključuje provođenje odluke u djelo, te zahtjeva sasvim novi pristup. U ovoj fazi donositelj odluke razmatra kako i na koji naći provesti ideju u praksi.

- **Potvrda.** Nakon što je inovacija usvojena i implementirana donositelj odluke i dalje pretražuje informacije kako bi potvrdio ispravnost svoje odluke. Ukoliko naknadno spozna negativne ili proturječne informacije o prihvaćenoj inovaciji može odlučiti poništiti odluku o prihvaćanju.

Za razliku od Rogersovih pet prethodno navedenih faza Kamal navodi kako Pierce i Delbecq te Cooper i Zmund definiraju proces prihvaćanja inovacija u organizacijama kroz tri faze i to: inicijacija, prihvaćanje/usvajanje i implementacija [73], [33], [19]. Inicijacija podrazumijeva pritisak na promjenu, te uključuje prikupljanje i analizu dostupnih informacija o inovaciji koja se usvaja. Nakon inicijacije slijedi prihvaćanje, tj. usvajanje inovacije što podrazumijeva donošenje odluke o prihvaćanju nakon čega slijedi provedba, tj. implementacija koja uključuje razvoj i instalacijske aktivnosti kako bi se osiguralo ostvarivanje očekivane koristi od inovacije [19]. Razvidno je kako u fazi inicijacije organizacije postaju svjesne inovacije, te prikupljanjem informacija o njoj stvaraju stav o istoj, tj. stav o prihvaćanju ili odbijanju. Prema Rogersu faza

uvjeravanja je trenutak kada pojedinac stvara povoljan ili nepovoljan stav prema inovaciji na način da postaje više psihološki uključen, te aktivno traži i vrednuje informacije temeljem kojih razvija opću percepciju o njoj [26]. Upravo je faza koja uključuje razvoj percepcije o inovaciji najčešće promatrana i istraživana.

Kroz godine razvijeno je nekoliko modela i teorija koje mjere prihvaćanje tehnologija (tablica 7). Neki od njih su (kronološkim slijedom): teorija difuzije inovacije (*engl. Diffusion of Innovation Theory, DOI*), teorija razložne akcije (*engl. Theory od Reasoned Action, TRA*), socijalno kognitivna teorija (*engl. Social Cognitive Theory, SCT*), model prihvaćanja tehnologije (*engl. Technology Acceptance Model, TAM 1*), okvir tehnologija-organizacija-okolina (*engl. Technology, Organization, Environment, TOE*), teorija planiranog ponašanja (*engl. Theory of Planned Bahavior*), motivacijski model (*engl. Motivational model, MM*), model prihvaćanja tehnologija 2 (*TAM 2*), objedinjena teorija prihvaćanja i upotrebe tehnologije (*engl. Unified Theory of Acceptance and Use of Technology, UTAUT*), model prihvaćanja tehnologija 3 (*TAM 3*), i proširena objedinjena teorija prihvaćanja i upotrebe tehnologije *(engl. extending Unified Theory of Acceptance and Use of Technology UTAUT 2)* [20], [21], [22], [23].

Tablica 7 Modeli i teorije prihvaćanja novih tehnologija

Godina	Autor	Model
1962.	E.M. Rogers	Teorija difuzije inovacije (*engl. Diffusion of Innovation Theory, DOI*)
1975.	M. Fishbein i I. Ajzen	Teorija razložne akcije (*engl. Theory od Reasoned Action, TRA*)
1986.	A. Bandura	Socijalno kognitivna teorija *(engl. Social Cognitive Theory, SCT)*
1986., 1989.	F.D. Davis	Model prihvaćanja tehnologije (*engl. Technology Acceptance Model, TAM 1*)
1990.	L. G. Tornatzky i M. Fleischer	Okvir tehnologija-organizacija-okolina (*engl. Technology Organization, Environment, TOE*)
1991.	I. Ajzen.	Teorija planiranog ponašanja *(engl. Theory of Planned Bahavior, TPB)*

Godina	Autor	Model
1992.	Davis, F., Bagozzi, R., i Warshaw, P.	Motivacijski model *(engl. Motivational model, MM)*
2000.	V.Venkatesh i F.D.Davis, V.Venkatesh	Model prihvaćanja tehnologija 2 (TAM 2)
2003.	V. Venkatesh i M. Morris	Objedinjena teorija prihvaćanja i upotrebe tehnologije (*engl. Unified Theory of Acceptance and Use of Technology, UTAUT)*
2008.	V.Venkatesh i H.Bala	Model prihvaćanja tehnologija 3 (TAM 3)
2012.	Venkatesh, V., Thong, J., i Xu, X.	Proširena objedinjena teorija prihvaćanja i upotrebe tehnologije *(engl. extending Unified Theory of Acceptance and Use of Technology UTAUT 2)*

Izvor: [23], [20], [21], [22]

Navedeni modeli i teorije korišteni su za istraživanje prihvaćanja novih tehnologija s aspekta pojedinca i/ili organizacija. Na slici 4 prikazan je kronološki razvoj modela i teorija kao i svrha u koju su upotrebljavani, tj. da li se promatralo prihvaćanje s aspekta pojedinca i/ili organizacije.

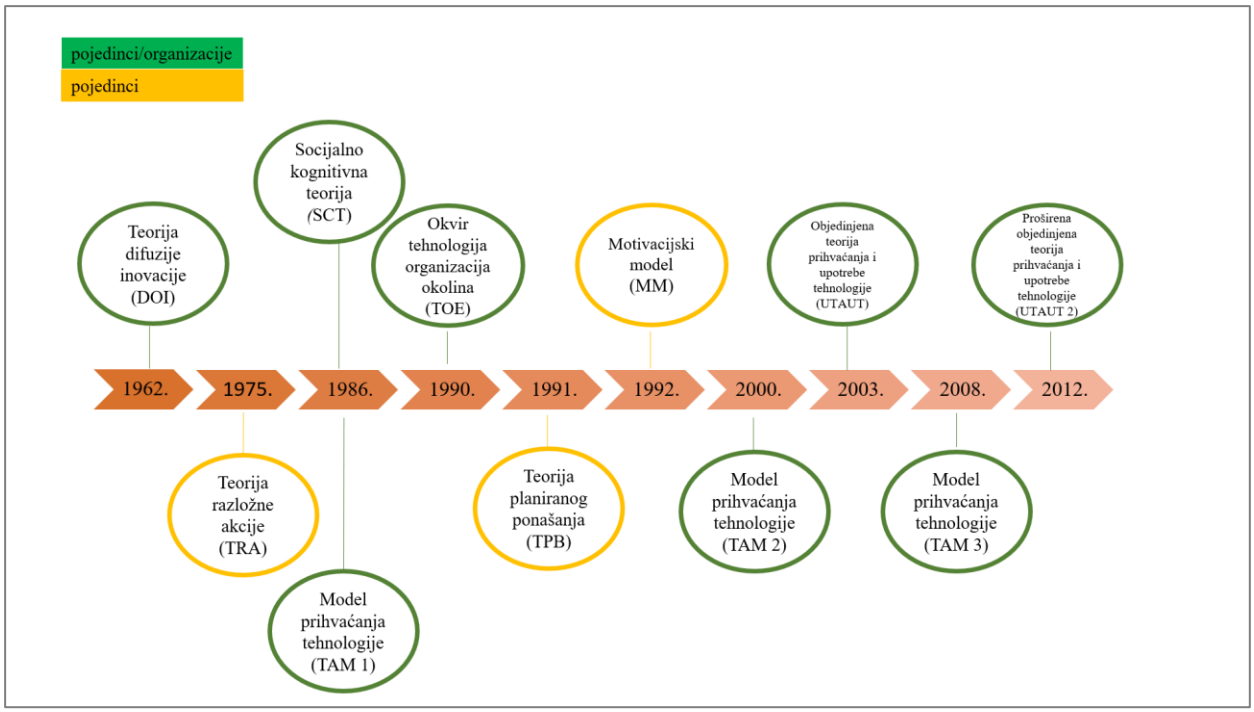

Slika 4 Kronološki prikaz modela i teorija istraživanja namjere prihvaćanja novih tehnologija
Izvor: [23], [20], [21], [22]

Promatrajući namjeru prihvaćanja tehnologija s aspekta organizacije od navedenih modela u literaturi se izdvajaju DOI i TOE okvir kao najčešće korišteni međusobno kombinirani i kroz godine nadograđivani modeli [4].

Rogersova teorija difuzije inovacije (DOI) (slika 5), kao teorija koja zauzima najvišu poziciju u istraživanju prihvaćanja tehnologija, polazi od pretpostavke da na prihvaćanje tehnologija s aspekta organizacije utječu karakteristike organizacije i same inovacije [25], [74]. Sam pojam difuzija podrazumijeva „proces u kojem se inovacija komunicira određenim kanalima tijekom određenog vremenskog razdoblja između članova društvenog sustava“ [26], [24]. Karakteristike inovacije koje su identificirane kao ključne u prihvaćanju čine: relativna prednost, kompatibilnost, kompleksnost, mogućnost probe, tj. probnost i uočljivost [26], [24], [75].

- **Relativna prednost.** Relativna prednost podrazumijeva stupanj do kojeg se inovacija, tj. tehnologija percipira boljom od tehnologije koju zamjenjuje. Kako ne postoji jasna definicija što relativna prednost podrazumijeva ona se promatra kao prednost mjerena iz perspektive onoga tko tehnologiju usvaja. To može biti ekonomska korist, određeni

društveni status, udobnost ili zadovoljstvo. Što je veća percepcija relativne prednosti prije će se tehnologija usvojiti.

- **Kompatibilnost.** Kompatibilnost podrazumijeva stupanj do kojeg je tehnologija usklađena s postojećim vrijednostima, prošlim iskustvima i potrebama onoga tko usvaja, tj. potencijalnim korisnicima. Tehnologija koja nije usklađena s postojećim vrijednostima sporije će se usvojiti nego tehnologija koja je kompatibilna.

- **Složenost.** Složenost je stupanj do kojeg se tehnologija percipira kao relativno teška za razumijevanje i korištenje. Nove tehnologije koje je lakše razumjeti usvajaju se brže od tehnologija koje zahtijevaju da usvojitelji razviju nove vještine i razumijevanje. Složenost tehnologije negativno utječe na usvajanje.

- **Mogućnost probe.** Mogućnost probe podrazumijeva stupanj do kojeg se tehnologijom može eksperimentirati, tj. testirati prije donošenja odluke o usvajanju. Mogućnost probe anulira neizvjesnost oko korištenja tehnologije.

- **Uočljivost.** Uočljivost podrazumijeva stupanj do kojeg su rezultati primjene nove tehnologije uočljivi drugima. Ukoliko su rezultati usvajanja tehnologije uočljiviji prije će se ta tehnologija usvojiti.

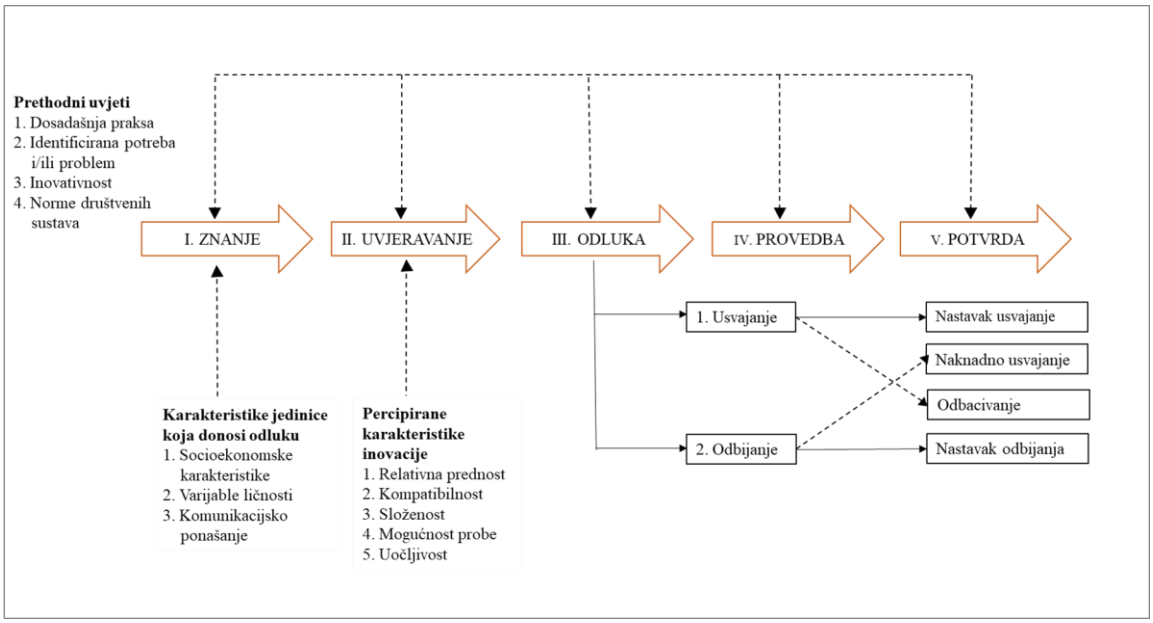

Slika 5 Teorija difuzije inovacije *(engl. Diffusion of Innovation Theory, DOI)***,** Izvor: [26]

Promatrajući DOI model razvidno je kako model ne obuhvaća utjecaj okoline, tj. okruženja. Promatrajući prihvaćanje s aspekta organizacije, okruženje podrazumijeva okolinu u kojoj organizacija posluje i koje može ograničavati ali i olakšati prihvaćanje tehnoloških inovacija [4]. Konkurencija primjerice može djelovati motivirajuće na prihvaćanje novih tehnologija, ali ujedno može predstavljati i barijeru u njezinom prihvaćanju [75].

Uočavajući nedostatak Rogersove teorije Tornatzky i Fleisher razvijaju TOE okvir *(engl. technological, organizational, and environmental framework*) u koji uključuju utjecaj okruženja. Pod okruženjem podrazumijevaju „arenu koja okružuje organizacije a sastoji se od njene industrije, infrastrukture, tehnološke potpore i državne regulative [74]. Kao problem DOI modela naveli su i preopširno definiranje karakteristika inovacije, odnosno njezine relativne prednosti i kompatibilnosti. Smatraju kako je upitna pouzdanost relativne prednosti kao čimbenika u istraživanju prihvaćanja inovacija jer je previše generaliziran, odnosno razmatra se u kontekstu različitih aspekata (ekonomske prednosti, prednosti u društvenom statusu, udobnosti i zadovoljstvu kao prednosti).

Nadalje, ističu i problem kompatibilnosti kao karakteristike inovacije smatrajući kako je također previše opširno opisana. Navode kako se zapravo ne promatra stvarna kompatibilnost tehnologije već se promatra percepcija onog tko usvaja, tj. da li on ili ona smatraju da je tehnologija koja se usvaja kompatibilna s postojećim sustavom i postojećom tehnologijom. Iako se i kompatibilnost pokazala kao značajna u većini prethodnih istraživanja, Tornetzky i Klein osporavaju način njezinog tumačenja. Neka istraživanja su promatrala kompatibilnost u smislu praktične kompatibilnosti, neka u smislu vrijednosti, a neka kao kombinaciju praktičnosti i vrijednosti. Sukladno tome Tornetzky i Klein ističu problematičnost mjerenja kompatibilnosti, tj. ističu pitanje kako se kompatibilnost uopće mjeri i/ili istražuje [76].

Naslanjajući se na Rogersov model prihvaćanja i uzimajući u obzir identificirane nedostatke modela predlažu „tehnologija-organizacija-okruženje“ okvir (TOE) s ciljem objašnjenja utjecaja tehnološke, organizacijske i dimenzije okruženja na prihvaćanje nove tehnologije. TOE okvir uključuje tri komponente koje utječu na proces prihvaćanja tehnologija: tehnološku, organizacijsku i komponentu okruženja (slika 6) [77], [4], [78], [79].

- **Tehnološka komponenata.** Tehnološka komponenta uključuje interne i eksterne tehnologije relevantne za organizaciju. Podrazumijeva trenutnu praksu i tehnologiju

koja se koristi unutar organizacije, kao i skup dostupnih tehnologija izvan organizacije [4].

- **Organizacijska komponenta.** Organizacijska komponenta opisuje organizacijske karakteristike kao što je: veličina poduzeća, stupanj centralizacije, formalnost, složenost upravljačke strukture i kvalitetu ljudskih resursa [78].

- **Komponenta okruženja.** Komponenta okruženja uključuje okruženje u kojem organizacija posluje. Podrazumijeva veličinu industrije u kojoj organizacija posluje, razinu konkurencije te zakonsku regulativu, tj. utjecaj vlade na poslovanje organizacije [79], [78].

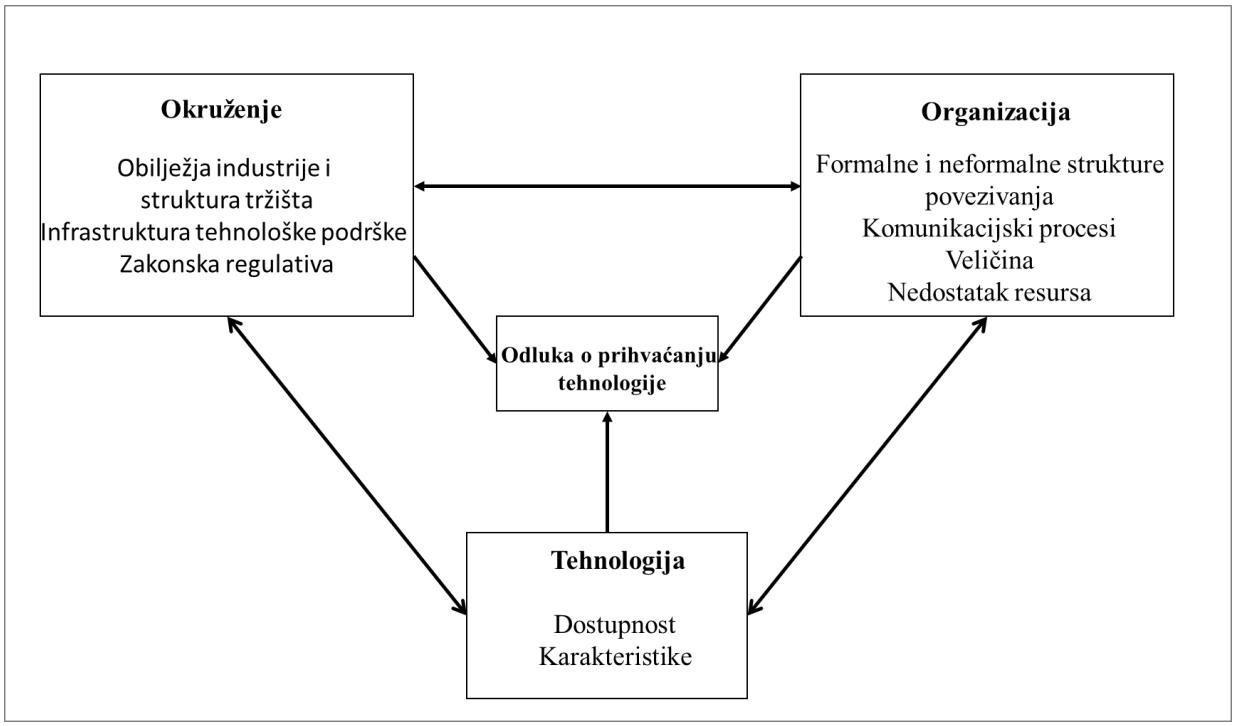

Slika 6 Okvir „tehnologija-organizacija-okolina“ (*engl. Technology Organization, Environment*, TOE), Izvor: [77]

Kao što je ranije navedeno, pregledom postojeće literature razvidno je kako su upravo difuzija inovacije i TOE okvir najzastupljeniji u istraživanju prihvaćanja novih tehnologija u kontekstu organizacija, te su najčešća polazišna točka istraživačima u razvoju novih modela prihvaćanja.

Koristeći navedene teorije istraživalo se prihvaćanje na razini pojedinih odjela ili funkcija unutar organizacije, kao i na razini cijele organizacije. U pravilu se istražuje odluka o prihvaćanju, namjera za prihvaćanjem, namjera za korištenjem te prihvaćanje i difuzija [20].

Hmeed i ostali istražujući postojeće modele prihvaćanja tehnologija dolaze do zaključka kako se čimbenici upotrijebljeni u tim modelima, razvijenim od strane različitih autora, mogu svrstati u četiri kategorije: tehnološku, organizacijsku, okruženje i individualnu. Zaključuju kako se ta formulacija koristi od strane većine autora [3]. S druge strane Jeyaraj i ostali smatraju kako se ključni čimbenici korišteni u modelima prihvaćanja mogu podijeliti na: karakteristike inovacije, karakteristike organizacije i karakteristike okruženja [20]. Ono što je nedvojbeno je zaključak, koji i sam Rogers navodi skrećući pozornost budućim istraživačima, da nova istraživanja trebaju ići u smjeru razvijanja novih modela a ne u smjeru korištenja istih čimbenika i potvrđivanju njihove značajnosti, tj. korištenje i potvrđivanje postojećih teorija i modela [25], [26].

U skladu s prethodno navedenim, a u svrhu daljnjeg pregleda čimbenika relevantnih u prihvaćanju digitalnih tehnologija s aspekta organizacija (s posebnim naglaskom na mikro i male organizacije) u nastavku se daje pregled čimbenika grupiranih na sljedeći način: organizacijski čimbenici, čimbenici iz okruženja organizacije te barijere u prihvaćanju tehnologija.

4.2. Organizacijski čimbenici namjere prihvaćanja digitalnih tehnologija

Nedvojbeno je kako je za mikro i male organizacije potrebna prilagodba postojećih modela i teorija njihovim specifičnostima, kao što su nedostatak ljudskih, financijskih i tehnoloških resursa koji djeluju kao barijere u prihvaćanju digitalnih tehnologija [80], [12], [75], [8], [2].

Jedna od ključnih karakteristika mikro i malih organizacija je visoki stupanj centralizacije s donositeljem odluke, koji je u većini slučajeva i vlasnik organizacije, u centralnoj ulozi [12], [80], [75]. Negativan utjecaj centralizacije potvrdili su Hameed i ostali utvrdivši kako ona ima negativan utjecaj na intenciju i prihvaćanje tehnologija [3]. Suprotno, Jeyaraj i ostali utvrđuju kako se centralizacija kao oblik organizacijske strukture pokazala kao jedan od najmanje važnih čimbenika prihvaćanja tehnologija [20]. Potpora ključnog menadžmenta potvrđena je u brojnim

istraživanjima kao ključna u prihvaćanju tehnologija. To posebice dolazi do izražaja u mikro i malim organizacijama gdje donositelj odluke koji je ujedno i vlasnik ima glavnu riječ u većini odluka, pa tako i po pitanju ulaganja i prihvaćanja digitalnih tehnologija. Potpora top menadžmenta ključna je za prihvaćanje digitalnih tehnologija unutar organizacija. To naglašavaju Jeyaraja i ostali koji utvrđuju da je potpora top menadžmenta ne samo najčešće korišteni čimbenik u istraživanjima prihvaćanja tehnologija, već i najbolji čimbenik te čimbenik koji najviše obećava za buduća istraživanja [81], [20], [3]. Isto je potvrdilo istraživanje Hameeda i ostalih gdje je najveći utjecaj u prihvaćanju tehnologija u mikro i malim organizacijama imala upravo potpora top menadžmenta [3], [80], [2], [12]. Razvidno je da veliki utjecaj u percipiranju i prihvaćanju digitalnih tehnologija u mikro i malim organizacijama imaju donositelji odluke, bez čijeg odobrenja i znanja se ništa unutar organizacija ne odvija, sve znaju sa svime su upoznati i svaku odluku odobravaju [82].

4.2.1. Razina znanja donositelja odluka

Postojeća istraživanja pokazuju da na prihvaćanje tehnologija utječu karakteristike donositelja odluke te njegova inovativnost i razina znanja o tehnologiji [12]. Karakteristike donositelja odluke ključne su u prihvaćanju digitalnih tehnologija pa tako Thong i Yap naglašavaju kako donositelji odluka koji su skloni inovacijama lakše prihvaćaju tehnologije. Autori u svom istraživanju potvrđuju da su donositelji odluke koji su imali pozitivan stav prema tehnologijama, bili inovativni te imali spoznaju o tehnologiji koja se prihvaća bili skloniji njenom prihvaćanju [82]. Prihvaćanje digitalnih tehnologija bit će uspješnije ukoliko donositelj odluke procijeni da će investicija donijeti prednosti i da je rizik prihvaćanja minimalan. Percepcija donositelja odluke o inovaciji je ključna, a ona će biti pozitivnija ukoliko je razina znanja o digitalnoj tehnologiji veća [12]. Donositelji odluka u mikro i malim organizacijama donose odluke pod utjecajem neformalnih informacija iz njihove okoline i pod utjecajem su prijašnjih iskustva [80]. U potrazi za informacijama često se oslanjaju i na same pružatelje usluge te tehnologije [8], [83], [81].

Bitna prepreka u prihvaćanju digitalnih tehnologija od strane mikro i malih organizacija je nedostatna razina znanja o digitalnim tehnologijama, koja je rezultat spore tehnološke promjene i transformacije u mikro i malim organizacijama [14], [84], [16], [85], [8], [81], [12]. Razina znanja o digitalnoj tehnologiji jedan je od najutjecajnijih čimbenika utjecaja na prihvaćanje inovacija posebice kod mikro i malih organizacija. Nedostatak znanja o digitalnoj tehnologiji

implicira nedostatak znanja o prednostima koje ista može donijeti. Činjenica kako su u mikro i malim organizacijama donositelji odluka ujedno i vlasnici ukazuje kako njihova razina znanja o digitalnim tehnologijama utječe na njihovo prihvaćanje [19]. Thong i Yap navode kako donositeljima odluke u mikro i malim organizacijama nedostaje adekvatno znanje o tehnologijama, a time i spoznaja o dostupnim tehnologijama [82]. Na istu stvar ukazuje i istraživanje Gable i Ramana koje je utvrdilo kako u mikro i malim organizacijama nedostaje znanja i svjesnosti o dostupnim tehnologijama [86]. Chang i ostali u svom istraživanju također utvrđuju značajnost znanja donositelja odluke o tehnologiji koja se prihvaća, te smatraju da ima najveći utjecaj u odnosu na ostale karakteristike donositelja odluke (razina njegove inovativnosti i stav prema prihvaćanju tehnologija) [87].

Da je u mikro i malim organizacijama razina znanja o digitalnim tehnologija na niskoj razini ukazuje i istraživanje provedeno od strane Gregurec i ostalih. U istraživanju suočavanja organizacija iz uslužnog sektora s poremećajima uzrokovanim pandemijom COVID 19 utvrđuju kako su se u pandemiji organizacije većinom okrenule manje naprednim tehnološkim rješenjima kao što su platforme društvenih medija i mobilne tehnologije, prvenstveno iz razloga nedostatka resursa i stručnosti potrebnih za implementaciju i korištenje naprednijih tehnoloških rješenja [34].

Nedvojbeno je da ukoliko donositelj odluke ne posjeduje adekvatno znanje o digitalnoj tehnologiji koju prihvaća nije u mogućnosti prepoznati prednosti koje bi mu prihvaćanje te digitalne tehnologije donijelo. Ključno je da donositelj odluke ima neko prethodno znanje o digitalnoj tehnologiji koju prihvaća kako bi razumio sve prednosti, a i možebitne rizike prilikom prihvaćanja. Upoznatost s možebitnim rizicima omogućit će da se isti svedu na prihvatljivu razinu. S porastom razine znanja stvara se i pozitivan stav donositelja odluke prema digitalnoj tehnologiji što pospješuje njezino prihvaćanje.

4.3. Čimbenici namjere prihvaćanja digitalnih tehnologija iz okruženja organizacije

Element okruženja u istraživanju prihvaćanja novih tehnologija, kako je i ranije navedeno, uvode Tornetzkyu i Fleischeru razvojem TOE okvira. Oni ističu veliki značaj okruženja u kojem organizacija posluje a čini ga: industrija, infrastruktura, tehnološka potpora i državna

regulativa [4], [77]. Okruženje može predstavljati svojevrsna ograničenja ali i prilike za uvođenje digitalne tehnologije.

4.3.1. Pritisak sudionika na tržištu

U literaturi se naglašava kako je upotreba tehnologija ključna za opstanak na tržištu i postizanje konkurentske prednosti [4], [5]. Chiu i Chen smatraju kako okolina, tj. okruženje uključuje konkurenciju i poslovne partnere s čim se slažu Iacovou i ostali definirajući taj utjecaj kao vanjski pritisak [88], [24]. Vanjski pritisak prema Gibbsu i Kreameru također uključuje pritisak konkurencije i pritisak kupaca koji zahtijevaju „više“ [89]. S istim se slažu Kuan, Chau, Hsu i ostali koji smatraju da mikro i male organizacije mogu biti potaknute da investiraju u tehnologije zbog pritiska dobavljača ili kupaca koji uvjetuju korištenje određene tehnologije [13], [74]. U svom istraživanju Jeyaraj i ostali utvrđuju kako je vanjski pritisak jedan od najboljih čimbenika namjere prihvaćanja tehnologija u organizacijama [20]. Utjecaj konkurencije potvrdio je i Thong u svom istraživanju [12]. Suprotno tome, El Haddadeh u svom istraživanju pokazuje da konkurencija nije imala utjecaj na odluku o prihvaćanju tehnologija, dok su Thong i Yap utvrdili kako je pritisak konkurencije imao utjecaj na stav donositelja odluke o prihvaćanju, a ne direktno na samo prihvaćanje [17], [2]. Svoj nalaz protumačili su na način da razlog zašto konkurencija nije imala utjecaj može ležati u tome da male organizacije u principu djeluju u jednakim uvjetima i obično je donositelj odluke upoznat s konkurentskom slikom, te svaka njegova odluka već je pod utjecajem konkurencije i stanja na tržištu. Da pritisak sudionika na tržištu utječe na prihvaćanje tehnologija potvrdili su Garg i Chooeu te Chang i ostali utvrdivši kako su ubrzana digitalizacija i razvoj tehnologije promijenili način izvođenja mnogih poslovnih operacije, što je rezultiralo većim konkurentskim izazovima i pritiscima za mikro i male organizacije [87], [90]. Iacovou i ostali opisuju vanjski pritisak kao utjecaj iz okoline u kojoj organizacije posluju, a koji uključuje pritisak konkurencije i pritisak poslovnih partnera [88]. Ukoliko konkurencija i poslovni partneri (kupci i dobavljači) prihvate ili već posjeduju i primjenjuju određenu tehnologiju i mikro i male organizacije će ju brže prihvatiti. Autori posebice naglašavaju utjecaj pritiska poslovnih partnera na namjeru prihvaćanja a taj pritisak se očituje u zahtijevanju, preporuci ili ucjeni da se određena tehnologija koristi [88].

Nadalje, donositelj odluke ključan je faktor u prihvaćanju digitalnih tehnologija. Ono što utječe na njega je njegova razina znanja o digitalnoj tehnologiji koja se prihvaća. Upravo na tu razinu znanja može utjecati pritisak sudionika na tržištu. Spoznaja da poslovni partneri u svom poslovanju upotrebljavaju određenu digitalnu tehnologiju može potaknuti donositelja odluke na prikupljanje više informacija o toj tehnologiji. Na taj se način može upoznati s prednostima koje bi prihvaćanje digitalne tehnologije donijelo organizaciji. Isto tako uvjetovanje korištenja određene digitalne tehnologije od strane poslovnog partnera može pozitivno utjecati na znanje donositelja odluke u mikro i malim organizacijama o digitalnim tehnologijama.

4.3.2. Percipirani pritisak države

Kao utjecaj okruženja organizacije u literaturi se navodi i utjecaj države u obliku pritiska ili potpore. Državne inicijative i subvencije identificirane su kao pokretači prihvaćanja novih tehnologija i kao neka vrsta ohrabrenja za organizacije da investiraju, posebice u zemljama koje su slabije razvijene [89]. Utjecaj državne potpore prepoznali su i Liu i ostali navodeći kako bi se uloga države u prihvaćanju novih tehnologija trebala očitovati u obliku poticanja i povećanja svijesti o novim tehnologijama, kao i u organiziranju raznih tehnoloških centra u svrhu informiranja i obrazovanja donositelja odluke i vlasnika organizacija o prednostima novih tehnologija [75]. Utjecaj države u svom istraživanju potvrdio je i Kamal definirajući kako postojanje određene vladine politike i pravnog okvira može pozitivno utjecati na usvajanje novih tehnologija [19]. Za razliku od utjecaja države u obliku potpore Hsu i ostali kao i Kuan i Chau u svom istraživanju navode utjecaj države i u vidu pritiska koji utječe na prihvaćanje novih tehnologija. Pod pritiskom države navode zahtjeve države da organizacije koje posluju s državom i državnim institucijama koriste određenu tehnologiju i na taj način potiču digitalizaciju i digitalnu transformaciju mikro i malih organizacija. Za razliku od Hsu i ostalih Kuan i Chen u svom istraživanju potvrđuju utjecaj pritiska države na namjeru prihvaćanja. Razlika u rezultatima može se objasniti strukturom ispitanika, Hsu i ostali provodili su istraživanje između organizacija svih veličina od kojih je većina bila srednje i velike veličine, dok su Kuan i Chen svoje istraživanje proveli isključivo među malim organizacija [74], [13].

Kao primjer pritiska države na organizacije koje posluju s državom i državnim institucijama u Hrvatskoj je primjerice Zakonom o elektroničkom izdavanju računa u javnoj nabavi propisana obveza izdavanju e- računa u javnoj nabavi i to za sve sudionike u sustavu javne nabave [91].

Isto tako, sve organizacije koje imaju više od tri osiguranika dužne su prijave/odjave na mirovinsko osiguranje podnositi isključivo elektroničkim putem [92].

Upravo je na e-računima vidljiv utjecaj pritiska države na primjenu određene tehnologije. Obveza uvođenja e-računu odnosila se na B2G[3] sektor, tj. na poslovanje organizacija s državom. Vodeći servis u Republici Hrvatskoj za e-račun, primarno fokusiran na sektor malog i srednjeg poduzetništva, „Moj-eRačun“ navodi kako je broj razmijenjenih e-računa od srpnja 2019. godine do kraja 2021. godine u Republici Hrvatskoj iznosio devet milijuna eRačuna, što je, naglašavaju, daleko manje od Europskog prosjeka [93]. Prema podacima Financijske agencije (Fina) preko njihove centralne platforme od srpnja 2019. godine do kraja 2020. godine razmijenjeno je osam milijuna e-računa isključivo prema javnim naručiteljima. Navode kako je broj e-računa razmijenjen između organizacija koje nisu javni naručitelj bio znatno manji. Prema njihovim podacima u 2020. godini ukupno je 55.000 poslovnih subjekata barem jednom putem njihove centralne platforme poslao e-račun. Procjenjuju kako je ukupan broj poslovnih subjekata koji koriste neki oblik razmjene strukturiranih elektroničkih računa oko 60.000, ako se uključe i subjekti koji nisu nikada slali e-račun prema javnim naručiteljima već isključivo unutar poslovnih subjekata. Uzimajući u obzir broj registriranih subjekata u lipnju 2020. godine (288.991) zaključuju kako 20% registriranih poslovnih subjekata koristi e-račun, promatrajući samo aktivne subjekte (169.637) postotak se penje na 28%. Navedeni postotak i dalje je ispod prosjeka Europske unije gdje primjena e-računa godišnje raste po stopi od 10-20 posto [94].

Neminovno je da će mikro i male organizacije brže prihvatiti digitalne tehnologije uslijed pritiska države. Ukoliko države donesu neke zakonske regulative koje će uvjetovati korištenje digitalnih tehnologija isto će zasigurno rezultirati prihvaćanjem od strane mikro i malih organizacija. U dosadašnjoj literaturi pritisak države podrazumijevao je pritisak u vidu uvjetovanja prihvaćanja određene tehnologije ukoliko organizacija želi poslovati s javnim ustanova [74], [13].

[3] B2G *(engl. business-to-government)* predstavlja model poslovanja između države i organizacija iz javnog sektora i privatnih organizacija.

4.3.3. Krizne okolnosti

Vanjski pritisak uključuje i novonastale krizne promjene na tržištu. Situacija u kojoj se svijet trenutno nalazi, uzrokovana COVID 19 pandemijom, utjecala je na promptno reagiranje organizacija u prilagodbi svog poslovanja. Tako su zabrane rada u određenim djelatnostima te održavanje fizičke distance prisilile organizacije na određene brze promjene i prilagodbe. COVID 19 pandemija predstavlja neočekivanu i time kriznu vanjsku okolnost koja je ukazala na potrebu digitalizacije i digitalne transformacije poslovanja koja će organizacijama omogućiti efikasno reagiranje na neočekivane poremećaje i izazove u poslovanju. Pojedini autori izjednačavaju pandemiju COVID 19 s događajem poznatim u literaturi kao „crni labud“ a koji predstavlja nepredvidiv, iznenađujući događaj velikog značaja koji dramatično mijenja političko i gospodarsko okruženje, te može prouzročiti poslovne neuspjehe [34].

Utjecaj nepredvidivog i neočekivanog događaja opisuju Moghavvemi i ostali smatrajući kako takvi događaji mogu olakšati i ubrzati ali i spriječiti prihvaćanje tehnologije od strane poduzetnika [35],[36]. Autori su istraživali kako određeni vanjski događaji, (promjene u vladinoj politici, dostupnost resursa, ponuda velikog ugovora, pristup novom tržištu, dostupnost resursa, itd.) utječu na promjenu prihvaćanja novih tehnologija. Kao rezultat istraživanja utvrđuju da neočekivani vanjski događaj može utjecati na povoljnije prihvaćanje novih tehnologija [35], [36]. Svoje istraživanje temelje na modelu poduzetničkog potencijala *(engl. Entrepreneurial Potential Model),* razvijenog od strane Krueger i Brazeal 1994. godine, koji pretpostavlja da unatoč tome što pojedinac određenu akciju percipira poželjnom i izvedivom u suštini je nema namjeru konačno i realizirati, osim ako ga određeni događaj na to ne potakne. Krueger i Brazeal smatraju kako je ljudsko ponašanje u svojoj suštini inertno sve do trenutka kada određeni događaj ne prekine i istisne tu inertnost. Događaj može biti nešto negativno kao npr. gubitak posla ili nezadovoljstvo poslom ili pozitivan kao npr. dobivanje nasljedstva, dobitak na lutriji, podrška kupca ili partnera. Bez obzira da li se radi o pozitivnom ili negativnom događaji on će pokrenutu određenu akciju kod pojedinca, te pokrenuti naglu promjenu u njegovim životnim i radnim uvjetima. Sama reakcija pojedinca na neočekivani događaj povezana je s njegovom percepcijom događaja, te se razlikuje od pojedinca do pojedinca i može dovesti do naglih promjena u njegovom ponašanju [35]. Moghavvemi i ostali potvrđuju kako promjene u svakodnevnom životu donositelja odluke u organizaciji kao što je primjerice povećanje troškova, nova ulaganja, dostupnost resursa, promjene u zahtjevima

kupaca i/ili dobavljača utječu na njihovu realizaciju namjere korištenja nove tehnologije u poslovanju [35], [36].

Pandemija COVID 19 se nedvojbeno može smatrati neočekivanim događajem i samim time kriznom okolnosti koja je djelovala i djeluje na ponašanje donositelja odluke u organizaciji na način da ga je potaknula da podigne razinu znanja o digitalnim tehnologijama. Long i Feng istražujući utjecaj COVID 19 pandemije na poslovanje organizacija naglašavaju kako je 30% anketiranih vlasnika poduzeća (od 761) izjavilo kako će svoje poslovanje zbog smanjenog priljeva novca moći održati najviše tri mjeseca, dok je gotovo polovica ispitanika izjavila da će izgubiti od 10 do 30% prihoda u ovoj godini (2020.godini) [95], [96]. Pandemija je prouzročila situaciju u kojoj su se organizacije morale brzo prilagoditi te pronaći načine kako da osiguraju daljnje poslovanje poštujući sve propisane mjere. Organizacije su morale pronaći modele poslovanja koji će omogućiti zaposlenicima rad od kuće, mogućnost daljnjeg održavanja odnose s dobavljačima kao i daljnje pružanje usluga svojim klijentima uz minimalan fizički kontakt [97]. Krizne situacije kao što je pandemija posebice imaju utjecaj na poslovanje mikro i malih organizacija upravo zbog njihovih ograničenih resursa [95]. Kako bi se izbjeglo gašenje gospodarskih aktivnosti organizacije su pribjegle prihvaćanju novih tehnologija, koje prije pandemije nisu smatrale nužnim za svoje poslovanje. Upravo su tehnologije postale strategija za preživljavanje tijekom propisanih mjera zatvaranja s ciljem suzbijanja širenja pandemije COVID 19 [98].

Neminovno je da je COVID 19 već uzrokovao posljedice koje će donijeti gubitke u poslovanju organizacija, te negativno djelovati na cjelokupnu ekonomiju i financije [99]. Tehnološki stručnjaci ističu kako se trenutna situacija može promatrati kao prilika ili kao izazov za digitalnu transformaciju poslovnih modela i implementaciju nove tehnologije koja će podupirati poslovne procese [34]. Strusani i Houngbonon ističu kako je COVID 19 uzrokovao naglo usvajanje digitalnih tehnologija, te kako će pandemija ubrzati inovacije i usvajanje tehnologije, kao i potaknuti integraciju inovacija u poslovne modele organizacija [97]. S navedenim se slažu i Ishaq i ostali navodeći kako je COVID 19 utjecao na prihvaćanje novih tehnologija na način da je učinio prihvaćanje određenih tehnologija nužnim a ne više opcionalnim, kao što je to bio slučaj prije COVID-a 19. Smatraju kako je upotreba određene tehnologije postala neizbježna te kako su i oni koji su ranije imali averziju prema novim tehnologijama morali usvojiti istu kako bi bili u mogućnosti obavljati svoje svakodnevne zadatke. Pandemija je utjecala na stav prema prihvaćanju novih tehnologija na način da je ukazala na prednosti koje tehnologije pružaju, kao

što su praktičnost, jednostavnost komunikacije, isplativost i što je najvažnije preživljavanje u izazovnim situacijama [100].

Razvidno je kako iznenadni poremećaji na tržištu mogu utjecati na prihvaćanje digitalnih tehnologija u mikro i malim organizacijama [101]. Mikro i male organizacije zaostajale su u prihvaćanju digitalnih tehnologija, no s dolaskom COVID 19 pandemije i poremećajima koje je pandemija uzrokovala to se mijenja. Dolazi do bržeg prihvaćanja digitalnih tehnologija kako bi se ublažile posljedice negativnog djelovanja na poslovanje [34]. Pandemija je pokazala kako organizacije (posebice mikro i male) neće uvijek imati luksuz tradicionalnog načina rada već se moraju razvijati kako bi preživjele, a to znači preispitati poslovne modele i pronaći inovativne digitalne načine za postizanje profitabilnosti i rasta organizacije.

Pandemija je nedvojbeno prisilila organizacije da ubrzaju proces digitalizacije svog poslovanja s ciljem promptnog odgovora na promjene koje se dešavaju. Kako u potražnji i zahtjevima kupaca, ponudi od strane konkurencije tako i u organizaciji kvalitetnog i konkurentno održivog poslovanja, koje se sve više temelji na neosobnoj komunikaciji i radu od kuće [102]. COVID 19 pandemija utjecala je na povećanje interesa donositelja odluke u pogledu mogućnosti i dostupnosti digitalnih tehnologija. Kao i ranije spomenuti pritisak sudionika na tržištu, krizne okolnosti u kontekstu COVID 19 pandemije utječe na razinu znanja donositelja odluke o digitalnim tehnologijama. Pandemija je preuzela ulogu neočekivanog događaja koji je potaknuo donositelje odluke da prošire svoje znanje o digitalnim tehnologijama. Donositelji odluke su doslovno prisiljeni potražiti informacije i time podići razinu svojeg znanja o digitalnim tehnologijama, kako bi bili u mogućnosti nastaviti svoje poslovanje. Pandemija je ukazala na nužnost prilagodbe i istovremeno na nedostatak digitalizacije mikro i malih organizacija, što je posljedično utjecalo na povećanje interesa donositelja odluke za unaprjeđenje poslovanja organizacije prihvaćanjem digitalnih tehnologija. Organizacije koje su prije pandemije aktivno razvijale digitalne kompetencije lakše su se prilagodile novonastaloj situaciji, a time i brže oporavile od posljedica.

4.4. Barijere prihvaćanja digitalnih tehnologija

Uvođenje tehnologija u mikro i male organizacije može dovesti do određenih rizika i kompleksnosti što posljedično utječe i na njihovo prihvaćanje [2]. Mikro i male organizacije

percipiraju prihvaćanje tehnologija radikalnom promjenom koja sa sobom nosi određenu razinu rizika [82]. U prethodnim istraživanjima potvrđen je negativni utjecaj percipiranog rizika na prihvaćanje tehnologija [25]. Jacoby i Kaplan opisuju percipirani rizik kao multidimenzijalni koncept koji se sastoji od pet različitih međusobno neovisnih komponenata rizika: rizik izvođenja, financijski rizik, socijalni rizik, fizički rizik i psihološki rizik, dok Rijsdijk i Hultink citirajući Roseliusa tome dodaju i rizik gubitka vremena [103], [25], [104], [105].

4.4.1. Percipirani financijski rizik

Većina autora se slaže kako je nedostatak financijskih resursa jedna od glavnih značajki mikro i malih organizacija [2], [85], [81], [82]. U dosadašnjim istraživanjima financijska komponenta promatrala se kao tzv. primarni atribut. Downs i Mohr definiraju primarne atribut kao atribute svojstvene inovacijama ili tehnologijama nepromjenjivim u svim okruženjima i organizacijama, dok sekundarne atribute definiraju kao percepcijski utemeljena (ili subjektivna) obilježja [106]. Pretpostavlja se da na percepciju sekundarnih atributa ne utječu karakteristike određenog okruženja kao niti akteri uključeni u provedbu određene inovacije. Financijski utjecaj u većini istraživanja promatrao se kao primarni atribut koji se mogao objektivno izmjeriti. No autori naglašavaju činjenicu kako se usprkos mogućnosti objektivnog mjerenja nekih činitelja na kraju sve procjenjuje u okviru percepcije onoga tko prihvaća tehnologiju, te stoga smatraju da i financijska komponenta postaje sekundarni atribut. Onaj tko prihvaća tehnologiju i odlučuje se na investiciju procjenjuje taj iznos u odnosu na svoje financijske resurse i upravo zato financijsku komponentu treba promatrati kao percepciju, tj. kao sekundarni atribut. Percepcije se uvijek vrednuju u odnosu na neki internalizirani sustav vrijednosti ili kognitivni okvir (npr. veličina, trošak itd.) [76], [106].

U svoje istraživanje Kuana i Chao uključuju čimbenik percipirani trošak te utvrđuju njegov utjecaj na prihvaćanje tehnologije u malim organizacijama [13]. Percepcija troška ključna je u prihvaćanju tehnologija upravo zbog činjenice da se nedostatak financijskih resursa pokazao kao jedna od glavnih barijera u prihvaćanju tehnologija u mikro i malim organizacijama. Percipirani financijski rizik pod utjecajem je percipiranog troška koji predstavlja kombinaciju cijene koštanja proizvoda, cijene njegovog pribavljanja i cijene korištenja. Percipirani trošak pozitivno utječe na percipirani financijski rizik koji negativno utječe na percipiranu vrijednost, a time i na prihvaćanje tehnologija [107].

Percipirani financijski rizik u prethodnim istraživanjima potvrđen je kao jedan od značajnijih čimbenika pri prihvaćanju novih tehnologija. Sama činjenica da mikro i male organizacije posluju s ograničenim resursima govori da trošak prihvaćanja digitalnih tehnologija ima značajan utjecaj na samo prihvaćanje. Možebitni financijski gubici nakon ulaganja u digitalne tehnologije i same upotrebe iste mogu utjecati na odluku o prihvaćanju. Mikro i male organizacije zbog svojih ograničenih financijskih, ljudskih i infrastrukturnih resursa odluci o prihvaćanju digitalnih tehnologija pristupaju s velikim oprezom analizirajući sve moguće rizike. S obzirom na njihovu veličini a pritom i snagu, svaki rizik može biti potencijalno opasan za njihovo daljnje poslovanje.

No, kao što je ranije navedeno, poremećaji na tržištu uzrokovani pandemijom COVID 19 utjecali su na promjenu percepcije mikro i malih organizacija vezano za ulaganja u digitalne tehnologije, prvenstveno u percipiranju financijskog rizika. Pandemija je dodatno ukazala na nespremnost mikro i malih organizacija na digitalizaciju i digitalnu transformaciji poslovanja. Ukazala je i na nužnost ulaganja u digitalne tehnologije s obzirom da je pandemija uzrokovala zabrane rada u određenim djelatnostima te održavanje fizičke distance. Organizacije su time na neki način prisiljene investirati u digitalne tehnologije kako bi donekle osigurale uvijete za svoj rad. Upravo zbog nužnosti investiranja u digitalne tehnologije postoji mogućnost da financijski rizik više nije najznačajniji faktor prilikom donošenja odluke o prihvaćanju i investiranju u digitalne tehnologije.

4.4.2. Percipirani gubitak vremena

Rijsdijk i Hultink kao jedan od rizika navode i rizik gubitka vremena. U mikro i malim organizacijama jedan od velikih problema je nedostatak ljudskih resursa. Zaposlenici su obično dovoljno opterećeni svojim poslom te im je teško odvojiti vrijeme za implementaciju i edukaciju korištenja tehnologije. Percipirani rizik gubitka vremena obuhvaća vrijeme za odabir adekvatne tehnologije, vrijeme za uvođenje te vrijeme za edukaciju zaposlenika [25], [104], [105]. Mikro i male organizacije često nemaju dovoljno znanja kako bi bile u mogućnosti odabrati adekvatnu digitalnu tehnologiju. Zbog navedenog često i sam odabira adekvatne tehnologije iziskuje dulje vrijeme. Nakon odabira željene digitalne tehnologije slijedi implementacija i edukacija zaposlenika što opet iziskuje dodatno vrijeme i angažman.

Prijelaz sa stare na novu tehnologiju dugotrajan je i iscrpljujući proces koji iziskuje jedno duže vrijeme. Često je potrebno u određenom vremenu simultano raditi na staroj i novoj tehnologiji kako bi prijelaz bio što bezbolniji. Istovremeni unos podataka u stari i novi sustav posebice je problematičan u mikro i malim organizacijama, pošto iziskuje dodatni angažman zaposlenika. Uzimajući u obzir kako su u mikro i malim organizacijama ograničeni ljudski resursi dodatan angažman utjecat će na vrijeme potrebno za uspješno prihvaćanje digitalnih tehnologija [8]. Duže vrijeme i nužnost edukacije i treninga za rad s prihvaćenom digitalnom tehnologijom rezultat je „politike zapošljavanja“ i razine znanja zaposlenika u mikro i malim organizacijama. U većini slučaja zapošljavaju se ljudi s generalnim i/ili općenitim znanjem zbog mogućnosti da rade više poslova, te se rijetko zapošljavaju IT stručnjaci koji bi bili upoznati s prihvaćenom digitalnom tehnologijom i olakšali samu implementaciju i prihvaćanje od svih zaposlenika [8], [82].

U skladu s navedenim je i istraživanje Masood i Sonntag koji su identificirali vrijeme kao možebitnu barijeru prihvaćanja inovacije. Ispitanici uključeni u istraživanje naveli su kako se vrijeme koje je potrebno izdvojiti za tehnologije te za trening i edukaciju negativno percipira u odnosu na prihvaćanje iste [85]. Ukoliko je percipirano vrijeme za trening i edukaciju dugo vrlo vjerojatno je da se inovacija neće prihvatiti [8]. Većina direktora, tj. donositelja odluka nema vremena ni strpljenja učiti nove stvari te su prema vlastitoj percepciji prezaposleni za učenje korištenja tehnologija [81]. Nedostatak vremena i nedostatak financijskih sredstva identificirani su kao najveće prepreke pri pokušaju digitalne transformacije poslovanja među organizacijama u Republici Hrvatskoj [108].

4.4.3. Percipirani sigurnosni rizik

Element rizika koji u posljednje vrijeme dobiva na važnosti je sigurnosni rizik. Sigurnosni rizik označava mogućnost realizacije neželjenog događaja koji može negativno utjecati na povjerljivost, integritet i raspoloživost informacijskih resursa. Informacijski resursi označavaju sva sredstva koje jedna organizacija koristi kako bi ispunila svoje poslovne ciljeve (hardver, softver, ljudski resursi i slično) [109]. Sigurnosni rizik podrazumijeva razinu povjerenja u sigurnost korištenja tehnologija i zauzima jednu od glavnih uloga u njenom prihvaćanju [64]. Sigurnosni rizik odnosi se na strah od nepoznatog i njegov negativni utjecaj potvrđen je u nekoliko istraživanja prihvaćanja tehnologija [25], [110], [111].

Thong i Yap su konstatirali da male organizacije imaju averziju prema tehnologijama zbog percepcije rizika i straha [17]. S istim se slaže i El Haddedeh koji u svom istraživanju prihvaćanja uslužnog računalstva potvrđuje negativnu vezu percipiranog rizika i prihvaćanja tehnologija, navodeći kako donositelji odluke u malim organizacijama prilikom razmatranja prihvaćanja tehnologija uzimaju u obzir negativne učinke promatrane tehnologije [2].

Može se zaključiti kako je pandemija Covid 19 utjecala na percepciju sigurnosnog rizika od strane organizacija. Razlog tome leži u činjenici kako je zbog žurne prilagodbe načina rada novim okolnostima uzrokovanim pandemijom sigurnost stavljena u drugi plan. Mnoge organizacije su bile prisiljene prijeći na rad na daljinu te omogućiti svojim zaposlenicima rad od kuće što je sa sobom donijelo i određene rizike. Uvođenje raznih online alata kako bi se olakšao rad na daljinu povećali su razinu kibernetičkih rizika i time potencijalnu mogućnost kibernetičkih napada *(engl. cyber attack).*

Spremić i ostali naglašavaju kako je u današnjim uvjetima digitalne ekonomije i sve intenzivnije primjene digitalnih tehnologija svaki informatički rizik ujedno i kibernetički rizik. Kibernetički rizik „predstavlja rizike primjene digitalne tehnologije u osmišljavanju, provedbi i nadzoru te upravljanju digitalnim poslovnim modelima“ [112]. Autori navode kako se kibernetički rizici javljaju uslijed intenzivne primjene digitalnih tehnologija u poslovanju organizacija, a rezultat su aktivnosti vanjskih subjekata koji napadaju organizaciju. Ono što se posebno naglašava je činjenica da živimo u vremenu kad više nije pitanje da li će se neželjeni događaj u vidu napada dogoditi, već je pitanja kada.

Jedan od najčešćih percipiranih rizika vezanih uz digitalnu tehnologiju je potencijalni gubitak uzrokovan prijevarom ili napadom hakera koji ugrožava sigurnost korisnika, uzrokuje novčane gubitke i ugrožava privatnost [113]. U Izvješću o obrani od kibernetičkih prijetnji u 2021. godini navodi se kako su glavne prijetnje od kojih strahuju organizacije prilikom primjene nove tehnologije zlonamjerni softveri, napadi s otkupninama *(engl. ransomware*) te zlonamjerni mailovi sa svrhom krađe identiteta *(engl. spear phishing*) [114]. Ransomeare predstavlja vrstu zloćudnog otkupnog programa koji ima za cilj onemogućiti ili uskratiti pristup računalnom sustava i programima, te traži plaćanje otkupnine za njihovo ponovno korištenje. Spear phising je varijacija tzv. trojanskih mailova (*engl. phisinga)* koji predstavljaju ciljani napad u kojem se pomoću elektroničke pošte pokušava uvjeriti korisnika da otvori određenu datoteku ili da posjeti određenu web stranica koja ima skriveni zlonamjerni program *(engl. malware).* Uobičajeno se ciljaju zaposlenici koji pripadaju najranjivijoj skupini unutar organizacije a koji

imaju pristup zatvorenom i osiguranom računalnom sustavu. Nakon otvaranja takve pošte na njihovo se računalo instalira zlonamjerni program. Ono što razlikuje spear phishing od klasičnog phisinga gdje oštećeni ostaje bez novca je da hakeri preuzimaju potpunu kontrolu nad računalom te su svi poslovni podaci pod njihovim nadzorom [115].

Nedvojbeno je da je rad od kuće itekako povećao mogućnost kibernetičkih napada pošto zaposlenici nisu imali zaštitu na razini kakva je bila osigurana i/ili omogućena u organizacijama [116]. Prema Izvješću o obrani od kibernetičkih prijetnji u 2021. godini *(engl. Cyberthreat Defense Report)* 86% ispitanih organizacija pretrpjelo je neki vid kibernetičkog napada tijekom 2020. godine. Prema navedenom izvješću 69% organizacija pretrpjelo je kibernetički napad u kojem se zahtijevala otkupnina u zamjenu za podatke organizacije *(engl. ransomware*), te je njih 57% pristalo platiti traženu otkupninu [114].

Percipirani sigurnosni rizik često je razlog sporog prihvaćanja digitalnih tehnologija od strane mikro i malih organizacija prvenstveno zbog toga što uključuje opasnosti i prijetnje prilikom njihovog usvajanja, a što potencijalno može prouzročiti neželjene i neočekivane posljedice koje će utjecati na samu odluku o prihvaćanju digitalnih tehnologija. Sigurnosni rizik se odnosi na razinu povjerenja u sigurnost korištenja digitalnih tehnologija te percipiranu razinu straha i rizika prihvaćanja, što ga čini ključnim i utjecajnim čimbenikom kod razmatranja odluke o prihvaćanju digitalnih tehnologija od strane mikro i malih organizacija.

5. MODERIRAJUĆI ČIMBENICI PRIHVAĆANJA DIGITALNIH TEHNOLOGIJA U MIKRO I MALIM ORGANIZACIJAMA

Agarwal i Prasad kritizirajući postojeće modele prihvaćanja novih tehnologija naglašavaju potrebu usmjeravanja istraživanja u smjeru moderirajućih čimbenike [40]. Tako TAM 3 model *(engl. Technology Acceptance Model 3*) kao moderirajuće čimbenike istražuje iskustvo, volju za korištenjem i kvalitetu outputa, dok UTAUT model *(engl. The unified theory of acceptance and use of technology)* uz iskustvo i volju za korištenjem dodaje dob i spol. Sun i Zhang istražujući moderirajuće čimbenike u modelima namjere prihvaćanja novih tehnologija od strane pojedinaca grupiraju iste u organizacijske čimbenike (volja za korištenjem te rutinski i ne rutinski zadaci), tehnološke čimbenike (individualna/grupna tehnologija, svrha, kompleksnost) i individualne (osobne) čimbenike (intelektualna sposobnost, kulturna pozadina, spol, dob i iskustvo) [27]. Promatrajući istraživanja namjere prihvaćanja novih tehnologija od strane organizacija broj istraživanja koja uključuju moderirajuće čimbenike je daleko manji. U postojećim istraživanjima usmjerenim prema organizacijama istražuje se moderirajući utjecaj organizacijske kulture [117], sposobnosti korištenja računala od strane vlasnika organizacije [118], i u velikoj većini istraživanja fokus je usmjeren na moderirajući utjecaj veličine organizacije i iskustva.

Pregledom literature razvidno je kako u prihvaćanju digitalnih tehnologija od strane organizacija u većini je uglavnom promatran direktan ili indirektan utjecaj čimbenika na namjeru prihvaćanja. Kako bi se upotpunila praznina u literaturi potrebno je istraživanje fokusirati na utvrđivanje utjecaja moderirajućih čimbenika [27].

Fokusirajući istraživanje na mikro i male organizacije nužno je ne zanemariti ključnu specifičnost tih organizacija, a to je centralizirano donošenje odluka koje je u rukama pojedinca koji je često i sam vlasnik organizacije. Stoga se nameće pitanje postoje li razlike u utjecaju identificiranih čimbenika na namjeru korištenja digitalnih tehnologija s obzirom na razlike samih donositelja odluka. S obzirom da je glavna funkcija donositelja odluka upravo donošenje odluka, nameće se pitanje postoji li razlika s osnova različitih stilova odlučivanja. S tim u vezi, kao jedan od moderirajućih čimbenika koji će se promatrati u ovom istraživanju je stil odlučivanja donositelja odluke. Istražit će se kako različiti stil odlučivanja donositelja odluke, kao ključne osobe u mikro i malim organizacijama, utječe na njegovo znanje o digitalnoj tehnologiji koju prihvaća.

Isto tako, promatrajući prethodna istraživanja uočeno je kako ne postoji istraživanje koje bi uključilo motiv za prihvaćanje i promatrao njegov utjecaj na povezanost čimbenika s namjerom prihvaćanja. Svako prihvaćanje nove tehnologije pa tako i digitalnih tehnologija motivirano je postizanjem određenog cilja. Promatrajući poslovanje organizacija ključni ciljevi su konkurentski prioriteti, stoga je sljedeći moderirajući čimbenik koji će se promatrati konkurentski prioriteti. Prihvaćanje tehnologija motivirano je ostvarivanjem konkurentskih prioriteta, te nedostaje istraživanje koje će ukazati kako prioriteti utječu na odluku o prihvaćanju novih tehnologija te postoji li razlika u prihvaćanju ovisno o konkurentskom prioritetu koji se digitalnom tehnologijom želi postići.

Svrha i krajnji cilj prihvaćanja digitalnih tehnologija je postizanje digitalizacije poslovanja i naposljetku digitalne transformacije poslovanja. Digitalna transformacija učestala je istraživačka tema, no nedostaje istraživanje koje bi ujedinilo digitalnu transformaciju i samo prihvaćanje digitalnih tehnologija. Napredak u postizanju digitalne transformacije mjeri se zrelošću organizacije. Stoga se nameće potreba za istraživanjem zavisnošću digitalne zrelosti organizacije i njenog prihvaćanja digitalnih tehnologija. Koje su to i postoje li razlike u utjecaju određenih čimbenika na namjeru prihvaćanja u odnosu na razinu digitalne zrelosti organizacije. Uključivanje digitalne zrelosti organizacije u model namjere prihvaćanja digitalnih tehnologija pomoći će u dobivanju šire slike stanja organizacije i njenog cjelokupnog promišljanja o digitalizaciji poslovanja, odnosno digitalnoj transformaciji. Pritom će se istražiti postoje li razlike u prihvaćanju digitalnih tehnologija između organizacija na različitoj razini digitalne zrelosti.

U nastavku su objašnjeni moderirajući čimbenici identificirani kao ključni u istraživanju utjecaja čimbenika na prihvaćanje digitalnih tehnologija u mikro i malim organizacijama: digitalna zrelost organizacije, stil odlučivanja donositelja odluke i konkurentski prioriteti. Objašnjen je pojam digitalne transformacije organizacije kao i sama digitalna zrelost organizacije. Nakon toga definiran je pojam odlučivanja i različitih stilova odlučivanja, te naposljetku je dani pregled konkurentskih prioriteta.

5.1. Digitalna zrelost organizacije

5.1.1. Digitalna transformacija

Digitalna transformacija u današnjem poslovnom okruženju svakako više nije pitanje izbora već je neizbježna, neophodna i nezaobilazna. Razvidno je kako organizacije, posebice mikro i male, nisu u potpunosti upoznate s pojmom digitalne transformacije i samim time načinom na koji da postignu digitalnu transformaciju svog poslovanja. Nedvojbeno je kako još uvijek postoji nerazumijevanje pojmova „digitalizacija“ i „digitalna transformacija“, koji se često poistovjećuju. Digitalizacija podrazumijeva proces pretvaranja analognih procesa u digitalne i to uz pomoć digitalne tehnologije. Digitalna transformacija je dublji pojam i označava „temeljite promjene unutar organizacija i načinu tradicionalnog poslovanja korištenjem digitalnih tehnologija i primjenom novih poslovnih modela“. Ono što je ključno za digitalnu transformaciju su „korijenite promijene u načinu razmišljanja i poimanja organizacije“ [119]. Burilović naglašava kako digitalna transformaciju za razliku od digitalizacije omogućava razvoj novog inovativnog poslovnog modela, upotrebu inovacijskog sustava organizacije pri kreiranju novih usluga i/ili proizvoda te cjelokupnu reorganizaciju sustava [108].

Unapređenje poslovanja upotrebom digitalnih tehnologija danas je postalo nužno kako bi se održala i stekla tržišna konkurentnosti. Digitalna transformacija podrazumijeva fundamentalnu transformaciju cjelokupnog poslovanja upotrebom novih tehnologija baziranih na Internetu s ciljem utjecaja na društvo u cjelini [120]. To je dugotrajan put koji započinje onog trenutka kada poduzeće krene promišljati o uvođenju digitalnih tehnologija u svoje poslovanja i traje sve do trenutka njihove potpune integracije [121]. Digitalna transformacija podrazumijeva razvoj novih digitalnih poslovnih modela, nove digitalne ponude, integraciju i optimizaciju sustava te podizanje znanja zaposlenika u području digitalnih tehnologija putem raznih edukacija i treninga. Burilović definira digitalnu transformaciju kao razvoj novih poslovnih modela koji će omogućiti i stvoriti nove poslovne prilike za organizacije a pritom i novu vrijednost [108]. Spremić definira digitalnu transformaciju kao proces promjene u kojem se upotrebom digitalne tehnologije i digitalnih resursa kreiraju novi poslovni modeli i novi način poslovanja u svrhu generiranja novih prihoda i rasta organizacije [7]. Na sličan način i Aguiar definira digitalnu transformaciju kao upotreba digitalne tehnologije sa svrhom unaprjeđenja poslovnih procesa kreiranjem novih poslovnih modela [122]. Kozina ističe da digitalna

transformacija uključuje kontinuirano uvođenje i primjenu digitalnih tehnologija sa svrhom kreiranja inovativnih poslovnih modela i strategija kako bi se unaprijedio položaj organizacije na tržištu [123]. U suštini digitalna transformacija obuhvaća različite transformacije unutar poslovnih sustava koje uključuju promjene dosadašnjih načina razmišljanja i poslovanja te tehničke promjene u obliku digitalizacije i/ili automatizacije. Podrazumijeva promjene u strategiji organizacije, poslovnim procesima, poslovnim modelima i organizacijskoj kulturi u svrhu osvajanja novih tržišnih udjela i postizanje konkurentske prednosti [7].

Nedvojbeno je da digitalna transformacija uključuje implementaciju digitalnih tehnologija, no učinkovita i kvalitetna digitalna strategija se ne odnosi isključivo na primjenu digitalne tehnologije već i na rekonstrukciju cjelokupnog poslovanja kako bi se iskoristile informacije prikupljene digitalnim tehnologijama. Iz tog razloga potrebna je koordinirana reorganizacija unutar poduzeća koja bi omogućila da se digitalnom transformacijom stvori dodana vrijednost [124]. Mnogi autori se slažu kako nisu digitalne tehnologije te koje igraju glavnu ulogu u digitalnoj transformaciji, već se naglašava način na koji organizacija reorganizira svoje poslovanje kako bi iskoristila implementiranu tehnologiju za razvoja novih proizvoda i/ili usluga, kreiranjem novih poslovnih modela te osvajanje novih tržišnih udjela [125]. Evidentno je da digitalna transformacija zahtjeva promišljenu digitalnu strategiju s jasno postavljenim ciljevima, koja zahtijeva uključivanje svih zaposlenih u organizaciji. Kruljac smatra kako se digitalna transformacija odvija u dvije faze, pri čemu prava faza uključuje poboljšavanje postojećih resursa primjenom digitalnih tehnologija a druga uključuje istraživanje digitalnih inovacija [126]. Berghaus i Back naglašavaju kako strategija digitalne transformacije sadrži viziju, planiranje i implementaciju organizacijskih promjena [127]. S istim se slaže i Kruljac i Knežević navodeći kako se digitalna transformacija može sagledati kao proces strateškog transformiranja koji podrazumijeva kreiranje vizije, strateško planiranje i implementaciju. Onaj teži dio transformacije uključuje samu provedbu koja uključuje kreiranje funkcionalne i održive strategije digitalne transformacije poslovanja, koja zahtjeva određena znanja i kompetencije [126].

Današnje poslovno okruženje karakteriziraju brze i iznenadne promjene, te upravo digitalna transformacija poslovanja može pomoći da organizacije spremno dočekaju i odgovore na sve promjene. Ono što bi digitalna transformacija poslovanja trebala postići je podizanje performansi organizacije na viši nivo i to kroz optimizaciju poslovnih procesa, smanjenje

troškova poslovanja i broja radne snage na mjestima gdje može doći do ljudske greške, te otvaranje novih radnih mjesta tamo gdje je ljudski faktor neophodan [119].

Digitalna transformacija dolazi velikom brzinom stoga je od strane poduzetnika percipirana i kao prilika i kao prijetnja [108]. Organizacije moraju napraviti radikalne promjene u svom poslovanju kako bi se prilagodile brzorastućem digitalnom svijetu. Uz sve prednosti koje digitalna transformacija sa sobom nosi, postavlja se i pitanje sigurnosti i rizika. Digitalne tehnologije kao što su društvene mreže, mobilne tehnologije, uslužno računalstvo podižu zabrinutost oko sigurnosti podataka i privatnosti korisnika [128]. Upravo to je nužno sagledati prilikom provođenja digitalne strategije kako bi se osiguralo da razina rizika bude na prihvatljivoj razini, te da se anuliraju možebitni sigurnosni propusti.

Stanje na tržištu danas prisiljava organizacije da prilagode svoje poslovanje te prilagode i uvedu strategije za provođenje digitalne transformacije poslovanja. Dok neke organizacije uspješno provode digitalnu transformaciju veliki broj organizacija se još uvijek „bori“ s njihovim uvođenjem [125]. To je posebno izraženo kod mikro i malih organizacija koje često ne znaju kako i od kuda krenuti. Svjesne su potrebe za njom ali nedostaje im adekvatno znanje, tj. nedostaje im ljudskih i financijskih resursa za pokretanje adekvatne digitalne strategije.

Na važnost digitalne transformacije organizacija ukazuje i program Europske komisije „Digitalna Europa“ koji je usmjeren na izgradnju strateških digitalnih kapaciteta Europske unije i olakšavanje široke primjene digitalnih tehnologija. Plan je u razdoblju od 2021. do 2027. godine uložiti 7,5 milijardi eura u odlikovanje i potporu digitalnoj transformaciji europskih društva i gospodarstva. Program obuhvaća ulaganja u digitalnu infrastrukturu i digitalnu transformaciju malih organizacija, ulaganje u istraživanja na području digitalnih tehnologija te davanje potpora socijalnoj ekonomiji kako bi i ona ostvarila koristi od digitalne transformacije. Primarno je financiranje usmjereno na pet ključnih područja: super računalstvo, umjetna inteligencija, kibernetska sigurnost, napredne digitalne vještine i osiguravanje široke uporabe digitalnih tehnologija u cijelom gospodarstvu i društvu [39]. Poseban naglasak stavlja se na male organizacije i podizanje njihove digitalne spremnosti [39].
Kao glavni pokretači digitalne transformacije u Hrvatskoj su potreba za većom učinkovitosti, bolje i kvalitetnije korisničko iskustvo te stvaranje novih digitalnih poslovnih modela [53]. Uz navedeno jedan od pokretača digitalne transformacije je i pritisak poslovnih partnera i razvoj novih proizvoda i usluga [53].

Za uspješnu digitalnu transformaciju potrebno je da menadžeri razumiju trenutno „*as is*“ stanje unutar poduzeća, kako bi bili u mogućnosti razviti strategiju o postizanju tzv. „*to be*“ stanja, tj. kako bi uz pomoć digitalne tehnologije transformirali i unaprijedili poslovanje. Za identificiranje trenutnog stanja koriste se modeli digitalne zrelosti koji prema unaprijed definiranim dimenzijama procjenjuju fazu digitalne zrelosti poduzeća [126], [127].

5.1.2. Zrelost organizacije u pogledu digitalne transformacije

Tijekom cjelokupnog procesa digitalne transformacije poslovanja donositelji odluke moraju razumjeti trenutno stanje organizacije i njenu spremnost na transformaciju poslovanja [126]. Usvajanje novih tehnologija prema određenim autorima nije dovoljno i ne igra značajnu ulogu u procesu digitalne transformacije. Ključan je način na koji organizacija mijenja način upotrebe te tehnologije kako bi stvorila nove proizvode i usluge s ciljem ostvarivanja prednosti na tržištu [125]. Bitna je sposobnost organizacije da usvojenu tehnologiju primjeni i upotrebi u cilju digitalne transformacije svog poslovanja. Sposobnost organizacije očituje se u njenoj digitalnoj zrelosti. Ifenthaler i Egloffstein definiraju digitalnu zrelost kao „stanje digitalne transformacije organizacije, odnosno ono što je organizacija već postigla u smislu izvođenja napora na transformaciji“ [129]. Kruljac navodi da je digitalno zrela organizacija „ona koja je istražila utjecaj novih tehnologija na društvo i potrošače, projicirala njene mogućnosti na vlastito poslovanje, isplanirala put razvoja u procesu transformacije, motivirala zaposlenike i koja ostvaruje vrijednost na tržištu na način da nove tehnologije utječu na sve aspekte poslovanja i u srži su svake poslovne odluke“ [130]. Digitalna zrelost opisuje razinu digitalne transformacije organizacije i samim time opisuje koliko je i što je organizacija do sada učinila u pogledu upravljanja digitalnom transformacijom [127]. Zapravo, opisuje napredak organizacije u transformaciji poslovanja korištenjem nove tehnologije u digitalnom okruženju s ciljem postizanja i zadržavanja konkurentnosti na tržištu [131], [132]. Chanias i Hess naglašavaju kako digitalna zrelost nadilazi samo unaprjeđenje poslovnih procesa upotrebom raznih tehnoloških rješenja i informacijske tehnologije, već ono uključuje i praćenje napretka u digitalnoj transformacije organizacije od strane menadžmenta [132]. Pri tome razina digitalne zrelost nije konstanta već je pod utjecajem tehnoloških promjena, te se stoga treba iznova procjenjivati i mjeriti [133].

U mjerenju digitalne zrelosti koriste se modeli zrelosti koji osim što procjenjuju stanje same organizacije promatraju i njen odnos prema konkurenciji, te omogućuju upravljanje napretkom prema višim fazama zrelosti. Osnovna zadaća modela zrelosti je opisati stadij sazrijevanja te izmjeriti trenutni položaj na putu sazrijevanja. Svoj početak modeli zrelosti doživjeli su sa CMM modelom *(engl. Capability Maturity model)* koji je razvijen na Institutu za softversko istraživanje Carnagie Mellon University čija je svrha bila „pomoći razvojnim inženjerima da postignu kontrolu nad razvojem i upravljanjem procesom te da je vodič kako da evoluiraju u postizanju kulture izvrsnosti u softverskom inženjerstvu i menadžmentu“ [130], [134]. Od tada se razvilo mnogo modela od kojih su najviše pažnje dobili modeli kao što su: BPMMM Rosemann et.al.2005; BPMM Weber et.al.2008; PEMM Hammer 2007; CMMI Carnagie Mellon University; DPMM Visconti i Cook 1993; čija se svrha definirala kao „informirani pristup za kontinuirano poboljšanje “ ili „sredstvo procjene treće strane ili samoprocjene“ [130].

Modeli zrelosti sastoje se od nekoliko razina zrelosti (obično tri do šest razina), generičkog opisa svake razine, elemenata povezanih s odgovarajućim dimenzijama i opisa svakog elementa za svaku razinu zrelosti [135]. U literaturi se razlikuju deskriptivni, tj. opisni, preskriptivni i usporedni modeli zrelosti. Opisni model zrelosti pogodan je za procjenu trenutne situacije. Model preskriptivne zrelosti podržava definiranje i provedbu razvojnog plana. Usporedni model zrelosti omogućuje usporedbu među industrijama ili regijama, kao i olakšavanje uspoređivanja [135].

S dolaskom digitalne transformacije razvijaju se modeli digitalne zrelosti koji imaju za funkciju objektivnu procjenu organizacije u uspješnosti provedbe digitalne transformacije. Primjenjuju se za ukupno poslovanje organizacije ili za pojedinu funkciju, a sastoje se od više dimenzija i kriterija čija je zadaća opisati područje djelovanja i faze zrelosti koje ukazuju na put evolucije prema zrelosti organizacije [127], [126].

Model digitalne zrelosti opisni je tip modela kojem je primarni cilj utvrditi postojeće stanje organizacije, tj. postojeću razinu digitalne transformacije opisujući što je organizacija do sada napravila po pitanju transformacijskih napora. Pomoću modela digitalne zrelosti organizacija ima mogućnost procijeniti svoj trenutni položaj na putu digitalne transformacije prema unaprijed definiranim dimenzijama. Jasno definirane dimenzije i kriteriji opisuju područje djelovanja i mjere na putu prema zrelosti, pri čemu je svaka dimenzija specifična, mjerljiva i

neovisna komponenta koja odražava glavni, temeljni i različit aspekt digitalne zrelosti i opisuje područje djelovanja [135], [131], [127].

Prema Teichertu najčešće korištene dimenzije u mjerenju digitalne zrelosti uključuju dimenziju koja se odnosi na raspoloživu tehnologiju unutar organizacije, dimenziju digitalne vještine koja uključuje raspoložive vještine unutar same organizacije te dimenziju koja uključuje procese unutar organizacije, tj. obujam njihove digitalizacije [131].

U svom istraživanju Kruljac je utvrdio kako čimbenici koji utječu na razinu digitalne zrelosti organizacije uključuju sljedeće dimenzije [130]:

- **Organizacijska spremnost.** Temelj procesa digitalne transformacije je kreiranje strategije unutar organizacije, tj. kreiranje plana kako i na koji način će se provesti digitalna transformacija. To uobičajeno uključuje angažman donositelja odluke u organizaciji čija uloga je ključna za uspješnu provedbu transformacije, zapravo je za postizanje digitalne zrelosti potreban jak upravljački mehanizam. Stoga organizacijska spremnost uključuje poddimenziju - resursi za provedbu digitalne transformacije.
- **Tehnološka spremnost.** Uključuje dvije poddimenzije: korištenje naprednih tehnologija i efikasnost upravljanja tehnologijama. Neminovno je kako organizacija ne može postići digitalnu zrelost ukoliko tehnologija koju primjenjuje nije na određenoj razini, tj. nije digitalno zrela, a zrelost tehnologije ovisi o njenoj fleksibilnosti. Fleksibilnost tehnologije očituje se u njenoj mogućnosti nadogradnje, tj. mogućnosti da se na postojeću tehnologiju nadogradi nova koja će omogućiti organizaciji postizanje digitalne transformacije. Prilikom pokretanja digitalne transformacije u organizaciji i pri kreiranju strategije kako postići istu nužno je napraviti reviziju postojeće tehnologije unutar organizacije s aspekta budućih poslovnih procesa, te razmotriti koje nove tehnologije odabrati i implementirat u organizaciju kako bi se postigla željena razina digitalne zrelosti. Organizacija s adekvatnom i razvijenom tehnologijom ima dobre predispozicije za postizanje poslovnih rezultata.
- **Inovativna organizacijska kultura.** Organizacijska kultura ima ključnu ulogu u digitalnoj transformaciji. Definira se kao obrazac ponašanja karakterističan za ljude unutar pojedine organizacije koji je nastao njihovim radom na vanjskim i unutarnjim poslovnim procesima. Karakterističan način ponašanja, razmišljanja i percipiranja

problema nameće se i svim novim zaposlenicima unutar organizacije [136]. Može se sažeti kako organizacijska kultura predstavlja neku vrstu nepisanog pravila na koji način se zaposlenici unutar jedne organizacije moraju ponašati. Kruljac navodi kako je povezanost organizacijske kulture i poslovnih rezultata potvrđena u mnogim istraživanjima, isto kao i njena povezanost sa zrelosti poduzeća. Dimenzija inovativna organizacijska kultura uključuje dvije poddminezije i to otvorenost i komunikaciju i prihvaćanje rizika.

5.2. Stil odlučivanja

5.2.1. Odlučivanje

Primarna funkcija poduzetnika je odlučivanje i upravo su odluke ono što stvara ili uništava poduzetnika, a kvaliteta istih čini ga uspješnim [137], [138]. Poduzetnici su u suštini informacijski radnici koji barataju velikom količinom kompleksnih informacija o dvojbama, prilikama i problemima i koji većinu svojeg vremena provode apsorbirajući, procesuirajući i evaluirajući ih [139]. Može se zaključiti kako odlučivanje igra ključnu ulogu u upravljaju organizacijom, utječe na uspjeh same organizacije te definira smjer njezinog razvoja [28].

Bulog definira proces odlučivanja kao proces koji se sastoji od aktivnosti koje uključuju prikupljanje, procesuiranje i procjenu informacija, tj. kao proces transformacije znanja i informacija u poduzetničke akcije i odluke [140]. Sikavica i ostali analizirajući definiciju odlučivanja uočavaju kako se u postojećoj literaturi izdvajaju dva pravca objašnjavanja iste. Na jednoj strani je grupa autora koja smatra i tumači kako je odlučivanje sama bit upravljanja, te izjednačavaju odlučivanje s funkcijom upravljanja. Na suprotnoj strani nalaze se autori koji smatraju kako odlučivanje nije dostatno da bi obuhvatilo cjelokupno upravljanje, te kako je samo upravljanje organizacijom daleko šire od odlučivanja, tj. procesa odlučivanja. Smatraju kako odlučivanje dominira cjelokupnim procesom upravljanja, te da je upravljanje prvenstveno, ali ne i isključivo, odlučivanje [138].

Na temelju analize Sikavica i ostali zaključuju kako je proces odlučivanja suštinski dio funkcije upravljanja na način da je isprepleten i nužan u svim fazama upravljanja od postavljanja ciljeva, planiranja, organiziranja i vođenja do kontrole [138]. Proces odlučivanja temelj je funkcije

upravljanja i samim time bit istog. Današnje poslovno okruženje karakteriziraju brze promjene koje svojom nepredvidivošću čine okruženje neizvjesnim i nesigurnim. Takvo okruženju utječe na proces donošenja odluka iz razloga jer se donositelji odluka suočavaju s nedostatkom vremena za prikupljanje i analizu velikog broja informacija [141].

Promatrajući proces odlučivanje u mikro i malim organizacijama može se zaključiti kako je poprilično različit od odlučivanja u većim organizacijama. Ono što je karakteristično za mikro i male organizacije je centralizirano donošenje odluka koje je u većini slučaja u rukama pojedinca koji je istovremeno i vlasnik organizacije. Jong i ostali ističu tri specifičnosti procesa odlučivanja u mikro i malim organizacijama [142]. Navode kako nedostatak ljudskih resursa otežava i onemogućuje prikupljanje velikog broja informacija iz unutarnjeg i vanjskog okruženja organizacije a koje su nužne kod donošenja odluke. Upravo taj nedostatak informacija čini okruženje, u okviru kojeg mikro i male organizacije donose odluke, neizvjesnim. Kao drugu specifičnost navode okruženje u kojem mikro i male organizacije posluju a koje je izrazito dinamično i složeno. U velikim organizacijskim sustavima uobičajeno je razvijanje rutinskog odlučivanja koje u velikoj mjeri pojednostavljuje proces donošenja odluka. Male organizacije upravo zbog nedostataka resursa nisu u mogućnosti razvijati rutinsko odlučivanje te se u procesu odlučivanja u mikro i malim organizacijama većina odluka temelji na metodi pristranosti i heuristike [142]. „Metoda pristranosti i heuristike ukazuje da ako traganje za nekom informacijom iziskuje neku vrstu troška, kao što je recimo vrijeme, ljudi će biti prisiljeni pronaći načine, „trikove“, kratice, tj. metode kako da skrate postupak odlučivanja i uštede na vremenu pronalaska informacija“. Metodu su predstavili Kahneman i Tverski koji su zaključili kako se ljudi, ograničeni svojim kognitivnim sposobnostima i znanjem, u procesu odlučivanja i razmišljanja služe „prečicama“ ili heuristikama, ali ih upravo te prečice često navode na pogrešne odluke i zaključke [143], [144]. Kao treću specifičnost donošenje odluka u mikro i malim organizacijama De Jong i ostali navode karakteristike samog donositelja odluka. Donositelji odluka u mikro i malim organizacijama (tzv. poduzetnici) obično posjeduju određene karakteristike koje ih razlikuje od ostataka populacije. Oni su “odlučni, nestrpljivi, akcijski orijentirani pojedinci tzv. grubi individualisti”. Istraživanja ukazuju kako su donositelji odluka u mikro i malim organizacijama skloniji donositi rizičnije odluke od onih u velikim organizacijama, tj. skloniji su preuzimanju rizika [142].

Robbinson i Jugde smatraju kako je odlučivanje zapravo neka vrsta reakcije na problem. Opisuju ga kao raskorak između trenutnog postojećeg stanja stvari i ciljanog željenog stanja do

kojeg se dolazi razmatranjem alternativnih načina djelovanja. Smatraju kako problem nije generalan te kako problem jednom pojedincu ne znači ujedno problem i drugome, te kako svjesnost postojanja problema i potrebe za njegovim rješavanjem ovisi o percepciji pojedinca [145]. Hamilton i ostali ističu kako upravo način na koji se donose odluke utječe na poslovnu učinkovitost i poslovno zadovoljstvo [28] navodeći kako identificiranje stila donošenja odluke pomaže u shvaćanju zašto menadžeri suočeni s naizgled istim situacija donose različite odluke [146].

5.2.2. Vrste stilova odlučivanja

Berisha i ostali analizirajući stavove istraživača u pogledu stila odlučivanja zaključuju kako je evidentno da u literaturi nedostaje konsenzus po pitanju stilu odlučivanja. Neki autori smatraju kako stil donošenja odluka ovisi o kognitivnom sustavu, dok drugi smatraju kako ovisi o karakteristikama pojedinca te da ljudi uobičajeno imaju jedan dominantni stil koji je podložan promjenama ovisno o situaciji u kojoj se nađu [146]. Da je stil odlučivanja podložan promjenama smatra i Baron koji se suprotstavlja tradicionalnom shvaćanju stilova prema kojem je stil odlučivanja stabilan i nepromjenjiv neovisno o situaciji [147]. Sličnog je razmišljanja i Furnham koji smatra kako pojedinac može svojom odlukom promijeniti svoj stil odlučivanja i naučiti koristiti druge stilove. Time postavlja tezu da je relativno lako promijeniti stil odlučivanja, no naglašava da, unatoč određenoj varijabilnosti, pojedinci imaju tendenciju pokazivati dosljedne obrasce ponašanja kroz situacije i s vremenom [148].

Suprotno razmišljanju kako je stil odlučivanja podložan promjenama, što ga razlikuje od kognitivnih stilova koji su nepromijenjeni neovisno o situaciji, nalazi se druga grupa autora koja smatra kako stil odlučivanja ovisi i pod utjecajem je osobina ličnosti, te se ne mijenja promjenom situacije. Kao potvrdu ovakvom razmišljanju Berisha i ostali navode istraživanje Streufert i Nogamija u kojem oni ukazuju kako pojedinim zaposlenicima promjenom posla i zadataka efikasnost ostaje nepromijenjena, dok drugima s istom razinom inteligencije, iskustva i treninga, promjenom posla i zadataka opada njihova efikasnost. Ukazali su kako je promjena okruženja kod jedne skupine pojedinaca utjecala na rezultate izvršavanja njihovih zadataka, dok kod druge nije, tj. nije bilo promjena [146].
Povezanost stila donošenja odluke s kognitivnim stilom pojedinca ističe većina autora, pritom smatrajući kako je stil donošenja odluka itekako pod utjecajem osobina ličnosti pojedinaca.

Kognitivni stil podrazumijeva preferirani stil pojedinca prilikom prikupljanja, procesuiranja i vrednovanje informacije, to je jedinstveni način na koji pojedinci opažaju, pristupaju i reagiraju na situacije donošenja odluka, tj. individualni način kognitivne obrade informacija [149], [150]. U suštini se ljudski kognitivni sustav procesuiranja informacija dijeli na onaj brzi - holistički koji ne treba svjesni kognitivni napor i na onaj spori - analitički i kognitivno naporni [139]. Dualni način procesuiranja informacija prihvaćaju i Allinson i ostali koji prepoznaju jedan kao analitički, deduktivni, rigorozni, ograničen i kritičan a drugi kao sintetički, induktivni, ekspanzivan, neograničen, divergentan, neformalan, difuzni i kreativan [151].

Dualna teorija procesuiranja proizašla je iz potrebe i nužnosti objašnjenja ljudske spoznaje, tj. ljudskog kognitivnog stila. Prema dualnoj teoriji procesuiranja ljudski kognitivni aparat sastoji se od dva sustava. Prvi sustav je brz, paralelan i automatski, dok je drugi spor, naporan i serijski [143]. Dualna teorija procesuiranja informacija uvedena je od strane Freuda koji je na taj način objasnio kako razumjeti sveprisutnu iracionalnost ljudskih bića, unatoč njihovoj sposobnosti racionalnog mišljenja kao prirodnog ishoda svojstva nesvjesnog uma [152]. Ova spoznaja omogućila je shvaćanje devijantnog ponašanja koje se do tada pripisivalo isključivo bolestima organizma. Oslanjajući se upravo na Freudovu teoriju Epstein razvija kognitivno-iskustvenu teoriju pojma o sebi *(engl. cognitive-experiential self theory - CEST)* koja pretpostavlja postojanje dva sustava obrade informacija. Prvi sustav obrade informacije je iskustveni, dok je drugi racionalni. Iskustveni sustav procesuiranja ima dugu evolucijsku povijest te na sličan način funkcionira u ljudi i životinja, dok racionalni ima kratku evolucijsku povijest i karakterističan je isključivo za ljudsku vrstu [152]. Dok je jedan automatski, brzi, i ne zahtjeva napor u procesuiranju informacija (iskustveni), drugi je namjeran, naporan i apstraktan (racionalni) [153].

Tablica 8 Iskustveni i racionalni sustav procesuiranja

Iskustveni sustav procesuiranja	**Racionalni sustav procesuiranja**
Holistički	Analitički
Afektivan, vođen principom ugode	Logički, vođen razumom
Djeluje na principu asocijacija	Djeluje na principu logičke povezanosti
Medijator ponašanja: prošla afektivna iskustva	Medijator ponašanja: svjesne procjene događaja

Iskustveni sustav procesuiranja	Racionalni sustav procesuiranja
Kodira realnost u vidu konkretnih slika, metafora i narativa	Kodira realnost u vidu apstraktnih simbola, jezika i brojeva
Brzo i efikasno procesiranje, trenutačna reakcija	Sporo i neefikasno procesiranje, odgođena reakcija
Otporniji na promjene, mijenja se uslijed opetovanih iskustava ili intenzivnih emocionalnih doživljaja	Receptivniji na promjene, mijenja se uslijed logičkih dokaza
Grubo diferenciran, široke generalizacije, stereotipno mišljenje	Visoko diferenciran
Grubo integriran, mogućnost disocijacije određenih uvjerenja od ostatka sustava, postojanost emocionalnih kompleksa, procesiranje određeno kontekstom	Visoko integriran, procesiranje određeno upotrebom generalnih principa
Pasivno doživljavanje, mala mogućnost kontrole	Aktivno doživljavanje, vjerujemo da možemo kontrolirati svoje svjesne misli
Postojanost doživljaja implicira postojanost vjerovanja, neupitna valjanost doživljaja	Zahtijeva logičko opravdanje

Izvor: [152]

Kako bi testirao svoju teoriju i potvrdio dualnost procesuiranja informacija Epsteine je koristio testove koji su uključivali eksperimente temeljene na izmišljenim scenarijima. Od ispitanika se tražilo da odgovore na tri pitanja kojima se željelo saznati: (1) kako bi većina ljudi reagirala na situacije u stvarnom svijetu, (2) kako bi oni sami reagirali i (3) kako bi razumna osoba reagirala. Kao primjer takvog eksperimenta navodi se zamišljeni scenarij u kojem dvije žene dolaze u zračnu luku na predviđeni let, svaka s pola sata zakašnjenja. Jedna žena saznaje da je njezin let krenuo na vrijeme dok druga saznaje da je njezin let kasnio, ali je upravo krenuo. U postavljenom scenariju željelo se utvrditi koja se žena više uzrujala? Sukladno pitanju „Kako bi osobe reagirale u stvarnom svijetu?“ dobiveni odgovori sugeriraju da bi se više uzrujala druga žena. Dok na pitanje „Kako bi razumna osoba reagirala?“, odgovori bi bili da nema razlike u reakciji pošto su obje propustile svoj let. Ovim testom Epsteine potvrđuje kako su ljudi svjesni dualnog razmišljanja koje može rezultirati različitim odgovorima [153].

U kasnijim eksperimentima promatrala se različita reakcija ispitanika na situacije koje su vezane za kockanje, odnosno naglašavanja razlika između vjerojatnosti i frekvencija. Eksperiment se bazirao na osvajanju nagrade ukoliko se iz staklenke koja sadrži 10% crvenih i 90% bijelih bombona izvuče crveni. Ispitanici su mogli odlučiti žele li da se bombon izvlači iz staklenke koja sadrži 10 ili iz staklenke koja sadrži 100 bombona. Ovim eksperimentom Epseine je ukazao na činjenicu da kada se ljudi suoče sa stvarnom situacijom (za razliku od hipotetičke gdje su ravnodušni na izbor staklenke) biraju staklenku sa 100 bombona. Izbor staklenke Epsteine tumači odražavanjem dva načina razmišljanja. U hipotetičkim situacijama ljudi više koriste analitičko rasuđivanje, te su ravnodušni u odbiru staklenke pošto je vjerojatnost odabira crvenog bombona u obje staklenke ista. Dok u stvarnoj situaciji ljudi zaključuju primitivnije te reagiraju na veću vjerojatnost odabira crvenog bombona i biraju staklenku sa više bombona [153].

Salas i ostali ističu kako postoje mnoge varijacije na tu temu i razne klasifikacije ali se u suštini ljudski kognitivni sustav procesuiranja informacija dijeli na onaj brzi holistički koji ne treba svjesni kognitivni napor i na onaj spori analitički kognitivno naporni [139], [154], [155], [156] [157], [28], [158].

Scott i Bruce smatraju kako je stil donošenja odluka priučena navika, tj. uobičajeni obrazac odgovora koji pokazuje pojedinac kad se suoči sa situacijom odluke. Stil donošenja odluke prema njima nije osobina ličnosti već sklonost utemeljena na navikama da se na određeni način reagira u određenom kontekstu odluke [159]. U svom istraživanju identificirali su pet stilova odlučivanja: racionalni, intuitivni, ovisni, izbjegavajući i spontani. Istraživanjem su utvrdili kako pojedinci koriste kombinaciju stilova prilikom donošenja važnih odluka, te kako stil odlučivanja nije pod utjecajem konteksta i problema te da stil donošenja odluka odražava individualni kognitivni stil [159].

S druge strane, Sikavica i Bahtijarević naglašavaju kako je donošenje odluka vještina koja se usavršava s vremenom i iskustvom te kako je odluka spoj triju faktora: intuicije, prosudbe i racionalnosti. U skladu s time predlažu podjelu na intuitivno odlučivanje, odlučivanje na temelju iskustva i racionalno odlučivanje [160]. Navode kako u teoriji navedeni redoslijed odlučivanja je ujedno i hijerarhijski jer je za operativne odluke uobičajeno intuitivno odlučivanje (taktičko odlučivanje na temelju prosuđivanja), dok bi se strateške odluke kao najzahtijevanije trebale donositi racionalnim odlučivanjem. Odlučivanje na temelju iskustva

nalazi se između racionalnog i intuitivnog s tim da je bliže intuitivnom nego racionalnom. Ono podrazumijeva donošenje odluka temeljeno na prethodnom iskustvu pojedinca i stečenom znanju u prethodnim sličnim situacijama. Ono što ga razlikuje od intuitivnog je činjenica da je za primjenu odlučivanja temeljenog na iskustvu potrebno da se pojedinac nađe u istoj ili približno istoj situaciji, kako bi bio u mogućnosti donijeti odluku temeljenu na prethodnom iskustvu. Ukoliko situacija nije ista ili približno ista primijenit će se intuitivno odlučivanje što odlučivanje na temelju iskustva čini poprilično ograničenim [160].

U skladu s prethodnim istraživanjima prihvaća se teza kako se način odlučivanja temelji na osnovama kognitivne perspektive odlučivanja i dualnosti načina procesuiranja informacija prema kojem pojedinci obrađuju informacije na dva načina: intuitivni i racionalni.
Dva načina odlučivanja smatraju se dvjema odvojenim dimenzijama odlučivanja a ne dva kraja jednog kontinuuma [150], [155].

Ovakvom razmišljanju suprotstavljaju se tvrdnje Hammonda i ostalih koji definiraju intuiciju kao „analizu zamrznutu u navikama i sposobnost brze reakcije prepoznavanjem“ aludirajući kako je zabluda suprotstavljati intuitivni i racionalni način razmišljanja. Smatraju kako poduzetnik ne može birati između intuitivnog i racionalnog, te da on mora biti u stanju analizirati svaki problem i ujedno biti sposoban brzo reagirati u određenoj situaciji što zahtjeva intuiciju i sposobnost prosuđivanja temeljeno na iskustvu [155]. No ovakav način razmišljanja ne objašnjava zašto donositelji odluka u organizacijama suočeni s naizgled istim situacijama donose različite odluke [146].

U svom radu Scott i Bruce citirajući Keena navode da je većina pojedinaca klasificirana kao analitička ili intuitivna kada se radi o prikupljanju informacija i njihovoj procjeni. To potkrepljuju tvrdnjom da pojedinci koji na sustavni način prikupljaju informacije procjenjuju iste na misaoni način dok oni koji na intuitivni način prikupljaju informacije obrađuju iste na osjećajni način [159].

Hamilton i ostali su u potrebi za sustavnijim načinom istraživanja načina odlučivanja kritički analizirali postojeće modele i stilove odlučivanja. Navode kako se u literaturi ističe nekoliko tipologija stila odlučivanja kao i da se koristi različita terminologija, broj i vrste predloženih stilova odlučivanja i njihovog mjerenja. Nakon analize fokusiraju se na dva stila: racionalni i intuitivni, obrazlažući svoj odabir nabrajajući nedostatke postojećih načina i mjerenja. Te tako

ističu nedovoljno dokaza u valjanosti konstrukta postojećih ljestvica. Smatraju kako su upravo racionalni i intuitivni najzastupljeniji stilovi te da su u prethodnim istraživanjima srednje vrijednosti bile najviše upravo kod ta dva stila [150].

5.2.2.1. Intuitivni stil odlučivanja

Intuicija se u kognitivnom smislu smatra kao nešto u potpunosti suprotno od svjesnog i analitičkog prosuđivanja. Salas i ostali citirajući Carl Junga navode kako intuicija nije samo nešto suprotno razumu već ono nešto iznad područja razuma, ono što omogućava sofisticirano procesuiranje informacija koje se temelji na prethodnom znanju i iskustvu [139],[140].

Epstein je u nastojanjima da ukaže kako ljudi ne razmišljaju isključivo racionalno već da je sveprisutno i iracionalno, tj. intuitivan način razmišljanja i procesuiranja informacija, kao primjer naveo religiju. Ukazao je kako gotovo da ni ne postoji civilizacija koja nije razvila ili imala neku vrstu religije. Upravo u religiji, racionalni i analitički način razmišljanja nije dostatan za objašnjenje vjerovanja. Kao primjer iracionalnog razmišljanja navodi i vjerovanje u nadnaravno. Navedenim primjerima tumači da ljudski mozak ne razmišlja isključivo na racionalan način. To potkrjepljuje istraživanjem u kojima je potvrđeno da velik broj ispitanika vjeruje u neki vid nadnaravnog. Navodi kako je u određenim situacijama intuitivan način razmišljanja privlačniji od onog racionalnog [152]. S istim se slaže i Bulog navodeći kako je većina ljudi prilikom rješavanja problema sklonija koristiti jednostavnije odlučivanje a ne analitičko. Samo odlučivanje je emocionalno i kognitivno zahtjevan proces, te je kao takav zahtjevan za održavanje. Upravo iz tog razloga često se prilikom rješavanja problema koristi subjektivni pristup čak i u situacijama kada su dostupne sve potrebne informacije te je primjenjivije koristiti analitičke procese [140].

Iz postojeće literature razvidno je kako je u početku bilo prisutno neslaganje istraživača oko definiranja intuicije, te se kroz godine isticala potreba za jasnom i konzistentnom definicijom [140],[139]. Salas u svom istraživanju navodi kako je usuglašavanje definicije krenulo s definiranjem tri ključna elementa intuitivnog stila odlučivanja: inputi, proces donošenja odluke te rezultat odlučivanja, tj. odluka. Usuglašeno je da intuitivni stil odlučivanja predstavlja proces razmišljanja da su inputi znanje pohranjeno u dugotrajnoj memoriji stečeno asocijativnim

učenjem, a da je rezultat osjećaj koji može poslužiti kao osnova za prosuđivanje i donošenje odluka [139].

Pregledom novije literature uočeno je kako i dalje postoji nekoliko pravaca u definiranju intuicije. Bulog dijeli autore u dvije skupine, u prvoj skupini nalaze se autori koji intuiciju definiraju kao „iskustveni fenomen koji proizlazi iz tacitnog[4] znanja akumuliranog iskustvom koji se iskazuje obrascem“, dok drugu skupinu čine autori koji pri opisivanju intuicije i intuitivnog stila donošenja odluke naglašavaju „senzorne i afektivne elemente“ [140]. Analizirajući različite definicije intuicije Sinclair i Ashkanasy ističu kako sve definicije imaju tri zajednička obilježja: intuitivni događaji potječu iza svjesnog, informacije se procesuiraju holistički te je intuitivna percepcija praćena emocijama [161].

Sikavica i ostali objašnjavaju intuitivni stil odlučivanja kao odlučivanje na temelju osjećaja pojedinca koje se ne može na racionalan način objasniti, tj. pojedinac ne može objasniti zašto je donio određenu odluku. Intuicija je zapravo produkt prethodnog iskustva pojedinca koje zajedno s akumuliranim znanjem čini racionalnu podlogu odluci, no toga pojedinac u trenutku donošenja odluke naprosto nije svjestan [160]. Abubakar i ostali citiraju Zandera i ostale navodeći kako je intuitivni stil donošenja odluka proces u kojem se neorganizirane informacije postepeno pretvaraju u organizirane sve do trenutka kada se temeljem njih mogu donijeti određeni zaključi [162]. Patoon u definiranja intuitivnog stila odlučivanja navodi da intuicija izvire iz tri izvora: iz općeg iskustva koje podrazumijeva iskustvo stečeno učenjem i starenjem, iz urođene reakcije koja podrazumijeva adekvatnu podsvjesnu reakciju na određenu situaciju te iz fokusiranog učenja koje predstavlja učenje određenih navika, tj. „treniranje“ intuitivnog razmišljanja prilikom donošenja odluka [163].

Iz navedenih definicija razvidan je utjecaj iskustva na intuitivno odlučivanja stoga se može zaključiti kako s rastom iskustva raste i sposobnost intuitivnog odlučivanja. Na korelaciju intuicije i iskustva ukazuje i Salas navodeći kako intuicija i iskustvo prate tzv. „U“ krivulju, te pritom identificira nezrelu i iskustvenu intuiciju [139]. Nezrela intuicija javlja se kad je iskustvo na najnižoj razini, porastom iskustva i specifičnog znanja upotreba intuicije pada da bi se

[4] Tacitno znanje podrazumijeva znanje nastalo integracijom višegodišnjeg iskustva i teorijskog znanja u određenom području. Pojam je uveo sociologa filozof Michael Polanyi koji smatra kako se dobar dio znanja stječe nesvjesno. Tacitno znanje temelji se na dojmu, osjećaju, intuiciji, unutarnjem stavu, predosjećaju, idealu, što je izrazito važno za inovativne procese te osnovno sredstvo kreativaca [244], [243].

daljnjim rastom iskustva pretvorila u tzv. iskustvenu intuiciju temeljenu na velikom znanju i iskustvu [139]. Na povezanost intuicije i iskustva ukazuju i Allinson i ostali ističući kako intuicija raste sa radnim stažom menadžera. Hamilton i ostali dijele intuiciju na heuretičku i stručnu, pri čemu stručna intuicija podrazumijeva intuiciju koja se oslanja na prethodno znanje i iskustvo dok se heuretička oslanja na upotrebu heuretike [151], [150].

Analizirajući definicije intuicije Malewska identificira njezine karakteristike temeljem specifičnih kriterija kao što su: tok procesa, vrijeme i trud utrošen u proces, odnos intuicije i iskustva, utjecaj na odluku i učinak procesa (tablica 9) [164].

Tablica 9 Karakteristike intuicije

Kriterij	**Ključni elementi u definiranju koncepta intuicije (karakteristike intuicije)**
Svijest / podsvijest (tok procesa)	Intuicija je proces mišljenja koji se događa, barem djelomično, bez sudjelovanja svijesti.
Vrijeme i trud utrošen na proces	Intuitivni proces se pokreće automatski (bez ikakvog napora od strane donositelja odluke).
Odnos intuicije i iskustva	Intuicija se temelji na iskustvu i sposobnosti prevođenja u akciju (ovaj se proces temelji na strukturama znanja formuliranih kroz različite vrste učenja).
Utjecaj na odluke	Podržava učinkovitu provedbu procesa donošenja odluka (bitan je element učinkovitog donošenja odluka).
Učinak procesa	Korištenje intuicije dovodi do stjecanja znanja (može biti u obliku osjećaja, signala ili tumačenja).

Izvor: [164]

Intuitivan stil odlučivanja posebice dolazi do izražaja u situacijama koje su okarakterizirane kao neizvjesne, gdje su informacije ograničene te je donositelj odluke vremenski ograničen [151]. Nadalje, intuitivne odluke su odluke donesene relativno brzo koristeći mali broj informacija, odnosno s ograničenim brojem informacija što omogućava donositelju odluke

fleksibilnost i spontanost u odlučivanju [165]. Intuitivni stil odlučivanja omogućava donositelju odluke da ponudi odgovore na predstavljeni problem temeljem brzog i sveobuhvatnog pogleda na situaciju, te da istovremeno rješava nekoliko aspekata problema [160].

Iako intuitivno odlučivanje nije najpoželjniji način odlučivanja u poslovnom okruženju Sikavica i ostali ukazuju na istraživanje koje je pokazalo kako se najveći broj strateških, tj. ključnih odluka u organizaciji donosi upravo intuitivnim stilom odlučivanja. Smatraju kako je poduzetnik gotovo uvijek u mogućnosti da racionalno odlučuje te kako je upravo racionalno odlučivanje pogodnije prilikom donošenja poslovnih odluka. Unatoč tome naglašavaju i kako su česte situacije kada ne preostaje ništa drugo osim intuicije [138]. S druge strane Drucker smatra kako je upravo upotreba intuicije ključna za donošenje dobrih poslovnih odluka. Naglašava kako je prilikom donošenja strateških odluka bitan netradicionalan pristup problemu, postavljanje nekonvencionalnih pitanja i prihvaćanje rješenja koja često nisu logična [166]. S istim se slažu i Allinson i ostali koji smatraju da je današnji način odlučivanja kod poduzetnika prisilno intuitivan. Poduzetnici moraju donijeti brze odluke o situacijama koje su im nepoznate gdje su informacije dvosmislene, nepotpune ili ih nema [151]. Dean i Shrfman zaključuju kako su upravo neizvjesne odluke povezane s metodama koje su u manjoj mjeri racionalne [167], [151].

U skladu s prethodnim istraživanjima i definicijama, prihvaća se sljedeća definicija intuitivnog odlučivanja:
Intuitivno odlučivanje podrazumijeva donošenje odluke temeljeno na spoznaji bez očite racionalne misli, potkrijepljeno iskustvom, stručnosti, znanju i vještinama donositelja odluke kao i na etičkim vrijednostima i kulturi prisutnoj u samoj organizaciji. Ono zapravo podrazumijeva podsvjesne mentalne obrade zasnovane na vrijednostima i etici [160]. Karakterizira ga brzo donošenje odluka, oslanjanje na predosjećaje i osjećaje, ono je automatsko, podsvjesno, relativno brzo, nabijeno, heurističko i temelji se na iskustvu [150].

5.2.2.2. Racionalni stil odlučivanje

Za razliku od intuitivnog stila odlučivanja racionalni stil podrazumijeva odlučivanje koje se oslanja na objektive procjene [28]. Temelji se na analitičkom pristupu, temeljitoj i sistemskoj potrazi za informacijama te na logičkom i sustavnom vrednovanju mogućih alternativa [150]

[138]. Russ i ostali definiraju racionalni stil odlučivanja kao odlučivanje koje je namjerno, analitičko, logičko i vođeno razmišljanjem o dugoročnim posljedicama svake odluke [165]. Odluke donesene racionalnim stilom odlučivanja rezultat su logičke analize svih dostupnih informacija što ovaj stil odlučivanja čini poprilično sporim i skupim [160]. Dean i Sharfman definiraju racionalnost kao proces prikupljanja i analize informacija te u skladu s tim definiraju racionalni stil odlučivanja kao proces donošenja odluka temeljen na analizi prikupljenih informacija važnih za donošenje odluka [167].

Racionalni stil odlučivanja implicira proces u kojem pojedinac analizira moguća rješenja i odabire ono koja će mu pružiti dovoljnu razinu uvjerenje i sigurnosti. [168] Isto potvrđuju Verma i ostali definirajući racionalni stil odlučivanja kao proces traženja i logične procijene alternativa s ciljem odabira najbolje. Navode kako racionalno odlučivanje podrazumijeva pomno planiranje i logičko donošenje odluka kroz sustavno pretraživanje različitih solucija u svrhu postizanja željenog cilja, kao i kroz dvostruku provjeru informacija. Podrazumijeva pristupanje rješavanju problema objektivno, bez emocija, analitički i temeljito [29].

Začetnik ideje primjene racionalnog odlučivanja u poslovnom odlučivanju smatra se H.A. Simon koji je ukazao na dva oblika racionalnosti: objektivnu i subjektivnu racionalnost. Objektivna racionalnost nešto je što je teško postići iz razloga jer bi zahtijevalo da donositelj odluke bude upoznat i da zna sva moguća rješenja problema te između njih odabere ono najbolje. Realnija je subjektivna ili ograničena racionalnosti koja do odluke, tj. do rješenja problema dolazi na temelju postojećeg znanja pojedinca [169]. Ono što karakterizira ograničenu racionalnost je ograničeno vrijeme i resursi, organizacijska ograničenja te osobna ograničenja. Organizacijsko ograničenje podrazumijeva neslaganje organizacijske kulture i strukture kao i neslaganje etičkih vrijednosti unutar organizacije, dok se pod osobnim ograničenjima podrazumijevaju osobni stil donositelja odluke, želja za uspjehom donositelja odluke kao i njegova potvrda da zadovolji svoje emocionalne potrebe [160]. Verma i ostali navode kako je Simonov model ograničene racionalnosti uveo revoluciju u dotadašnje shvaćanje organizacijskog odlučivanja. Simov je ukazao kako odluke nisu u potpunosti racionalne zbog činjenice da donositelj odluke ne može imati potpunu kontrolu nad okruženjem i svojim mentalnim sposobnostima, a to je bilo u suprotnosti s tadašnjim učenjima neoklasične i klasične škole upravljanja organizacijom [29].

Daft ukazuje kako do razvoja racionalnog stila odlučivanja dolazi zbog nesustavnog i proizvoljnog donošenja odluka unutar organizacija. Navode kako bi donositelji odluka u organizacijama trebali što je moguće češće koristiti sustavne postupke u donošenju odluka. Smatraju da iz dubokog razumijevanje racionalnog procesa donošenja odluka može proizaći kvalitetna odluka čak i onda kada nisu dostupne sve informacije. Kao primjer racionalnog stila odlučivanja navode vojne organizacije koje teže racionalnom stilu odlučivanja zbog brzog, efikasnog i odlučnog rješavanja složenih pitanja. Unatoč težnji k racionalnom stilu odlučivanja napominju kako se često one najvažnije odluke, kao što su odluke o ratovanju, donose iracionalnim putem te sa sobom donose katastrofalne posljedice [170].

Kao primjer prisutnosti racionalnog sila odlučivanja unutar organizacija Verma i ostali navode današnje selekcijske pristupe odabira zaposlenika koji se temelje na strukturiranim, bihevioralnim i situacijskim metodama intervjua. Unutar organizacija smatraju kako takav pristup selekcije omogućava odabir najkvalitetnijih pojedinaca [171]. Nadalje, u svom istraživanju Russ i ostali utvrđuju kako upotreba racionalnog stila odlučivanja dovodi do kvalitetnijih odluka za razliku od intuitivnog stila koji dovodi do odluka niže kvalitete [165].

Razvidno je kako racionalno odlučivanje označava misaoni proces u kojem donositelj odluke donosi određene zaključke i odluke na temelju logičkog prosuđivanja. Sikavica i ostali, analizirajući faze racionalnog odlučivanja, prenose nekoliko njegovih podjela [138]:

- Prema Mesconu faze racionalnog odlučivanja uključuju: dijagnosticiranje problema, prepoznavanje ograničenja u odlučivanju, prepoznavanje mogućnosti odnosno određivanje alternativa, procjena mogućnosti odnosno ocjena alternativa i izbor alternative, odnosno donošenje odluka [172].
- Prema Viewegi proces racionalnog odlučivanja započinje fazom pobude i poticaja, nastavlja se na fazu traženja – istraživanja i završava fazom optimiranja. Unutar tri osnovne faze nalaze se i faze koje uključuju: postavljanje problema, prikupljanje informacija, zbirka alternativa, ocjenjivanje alternativa, izbor alternativa te realizacija učenje i revidiranje [173].
- Promatrajući odlučivanje iz poslovne perspektive prema Druckeru faze racionalnog odlučivanja uključuju: definiranje problema, analizu problema, razrada različitih rješenja, odluka o najboljem rješenju te praktično provođenje odluke u djelo [138].

- Daft i ostali proces racionalnog odlučivanje dijele u osam faza gdje prve četiri faze podrazumijevaju identifikaciju problema, dok preostale četiri faze podrazumijevaju rješavanje problema. Faze uključuju: [170]

  - **Skeniranje okruženja.** U ovoj prvoj fazi, donositelj odluke promatra i prikuplja informacije unutar i izvan okruženja ne bi li uočio odstupanje od planiranog ili prihvatljivog ponašanja. To uključuje razgovor s kolegama, pregledavanje financijskih izvješća, evaluacija performansi, promatranje indeksa industrije, praćenje aktivnosti konkurenata i sl.

  - **Definiranje problema.** U drugoj fazi donositelj odluke definira pojedinosti identificiranog problema. Prikuplja informacije o tome gdje je nastao problem, kada, tko ga je stvorio, tko je bio uključen, na koga je utjecao, te kako i na koji način utječe na tekuće aktivnosti unutar organizacije.

  - **Specificiranje željenih ciljeva.** U trećoj fazi striktno se specificira koji su željeni ciljevi, tj. što se želi postići.

  - **Dijagnosticiranje problema**. U četvrtoj fazi donositelj odluka analizira kako je nastao problem i što ga je prouzročilo. Prikupljaju se dodatne informacije u svrhu razumijevanja uzroka problema te kako bi se pronašlo adekvatno rješenje.

  - **Razvijanje alternativnih rješenja**. S petom fazom započinje rješavanje problema, na način da se donositelj odluke upoznaje sa svim alternativnim solucijama koje postoje. U ovom koraku donositelj odluke prihvaća i traži ideje i prijedloge od strane drugih unutar organizacije.

  - **Procjena alternativnih rješenja**. U šestoj fazi koriste se statističke tehnike ili profesionalna prosudba temeljena na iskustvu kako bi se procijenila vjerojatnost uspjeha svakog pojedinog rješenja, tj. svake pojedine solucije.

  - **Odabiri najbolje alternative.** Pretposljednja faza smatra se samom srži procesa racionalnog odlučivanja. U ovoj fazi donositelj odluke na temelju analize problema, željenog cilja i evaluacije alternativa odabire jednu alternativu koja prema njegovoj analizi ima najveće šanse za uspjeh.

  - **Provedba odabrane alternative.** U zadnjoj fazi procesa temeljem svojih upravljačkih i administrativnih sposobnostima te na temelju sposobnosti uvjeravanja donositelj odluke daje upute kako da se određena odluka provede.

Nakon provedbe odluke ponovno kreće proces odlučivanja na način da počinje faza kontrole provedbe odluke, tj. vraća se na prvi korak procesa.

Bulog navodi kako pri racionalnom odlučivanju donositelj odluke sam odlučuje koliko duboko će ići u obradu i analizu prikupljenih informacija. Navodi kako racionalno odlučivanje nije samo zamjena za inovativno i kreativno razmišljanje. On smatra da racionalni način odlučivanja uključuje niz aktivnosti od detaljne i pažljive analize znakova, generiranja velikog broja opcija, istovremeno rangiranje i uspoređivanje dokaza do odabira jedne od mogućih opcija [140].

Po svemu sudeći racionalan način odlučivanja najpouzdaniji je način odlučivanja, no istovremeno i teško primjenjiv u današnjem okruženju koje je često nestabilno, turbulentno, nemirno te podložno brzim promjenama [160]. Racionalno odlučivanje zahtijeva nepromjenjivost parametra obuhvaćenih analizom što je u današnjem okruženju skoro pa nemogući scenarij. Nadalje, racionalno odlučivanje iziskuje obradu velikog broj informacija što traži određeno vrijeme. Upravo nedostatak relevantnih informacija potrebnih za definiranje bitnih kriterija evaluacije alternativa, kao i relativno kratko vrijeme za kvalitetnu usporedbu razmatranih scenarija, karakteristika je današnjeg okruženja u kojem organizacije posluju.
Provedenim istraživanjem u Indiji utvrdilo se da najveći broj menadžera u organizacijama koristi racionalni stil odlučivanja. Pokazalo se kako većina menadžera u ekonomiji u razvoju, koristi racionalni stil odlučivanja navodeći kako je pažljivo planiranje odluka, dvostruka provjera svih informacija te logično i sustavno odlučivanje ključno za razvoj ekonomije [29].

U skladu s prethodnim istraživanjima i prezentiranim definicijama, prihvaća se sljedeća definicija racionalnog odlučivanja:
Racionalni način odlučivanja podrazumijeva način odlučivanja temeljen na sustavnom prikupljanju i pretraživanju informacija, sustavnom vrednovanje svih mogućnosti i potencijalnih alternativa te razmatranju raspoloživih opcija djelovanja i upotrebljavanju analitičkih metoda i tehnika u procesu odlučivanja [140], [150].

5.3. Konkurentski prioriteti

Konkurentska prednost je ono što određuje uspjeh ili neuspjeh organizacije, a očituje se u udjelu tržišta koji organizacija posjeduje kao i u visini ukupne prodaje na tržištu [174], [175]. Konkurentska prednost zapravo predstavlja jedinstveni način poslovanja organizacije koji joj omogućuje ostvarivanje vodeće pozicije na tržištu i daje prednost nad drugim sudionicima na tržištu. Buble naglašava kako je upravo postizanje konkurentske prednosti dugoročni cilj organizacija [174]. Sposobnost organizacije da konkurira s drugim organizacijama podrazumijeva stjecanje prednosti kako u postojećim djelatnostima i na postojećem tržištu tako i u budećim djelatnostima i na budućim tržištima. Nadalje, konkurentska prednost implicira sposobnost organizacije da predvidi buduće tržišne uvjete i stvori pretpostavke za uspješno prilagođavanje reagiranja na potencijalne konkurentske prijetnje [176]. Ono što organizaciji omogućava postizanje konkurentske prednosti je upotreba jedinstvene strategije stvaranja vrijednosti koju ne primjenjuje ni jedna druga organizacija na tržištu i koja nije podložna lakom kopiranju od strane drugih organizacija [177]. To podrazumijeva strategiju koja će koristi unutarnju snagu organizacije da odgovori na sve izazove u okruženju, eliminirajući vanjske prijetnje i unutarnje slabosti [177]. U svojoj konačnici konkurentska prednost zapravo predstavlja set vrijednosti koji organizaciji omogućava prednost na tržištu a ujedno čini i temelj njene poslovne strategije.

Porter kao izvore konkurentske prednosti navodi troškovno vodstvo i diferencijaciju [175].

- **Troškovno vodstvo** podrazumijeva ostvarivanje konkurentske prednosti na način da se efikasnijim obavljanjem aktivnosti smanje troškovi poslovanja. Troškovno vodstvo kao strategija postizanja konkurentske prednosti uključuje smanjivanje troškova u svim segmentima poslovanja, s ciljem pronalaženja efikasnijeg načina obavljanja aktivnosti te eliminiranje troškovno neefikasnih aktivnosti [176], [175].

- **Diferencijacija** podrazumijeva ostvarivanje konkurentske prednosti na način da organizacija ponudi nešto jedinstveno što druge organizacije nisu u mogućnosti ponuditi. Odnosi se na kreiranje poslovnih aktivnosti koje će razlikovati organizaciju od drugih [176], [175].

Uz troškovno vodstvo i diferencijaciju kao izvor konkurentske prednosti u literaturi se navodi i vrijeme. Ukoliko organizacija napravi određeni potez ranije od svojih konkurenata velika je mogućnost da će si na taj način osigurati i određenu konkurentsku prednost na tržištu [178].

Nedvojbeno je da je fokus većine organizacija posebice mikro i malih organizacija osigurati opstanak na tržištu čime postizanje konkurentske prednosti predstavlja osnovni cilj. Pojavom novih tehnologija izmijenila su se pravila konkuriranja kao i izbrisale granice nacionalnih i globalnih tržišta. Za razliku od vremena kada je zbog velike potražnje konkurentska prednost bila ostvariva stvaranjem nove vrijednosti a kasnije smanjenjem troškova, danas je za postizanje i održavanje konkurentske prednosti potrebno ponuditi neku dodanu vrijednost koja će zadovoljiti sve zahtijevanije potrebe klijenata [179].

Na promjenu pravila konkuriranja ukazuje i Daraboš navodeći kako današnje tržište karakteriziraju sve zahtjevniji klijenti koji zahtijevaju više i bolje, te kako se iz dana u dan pojavljuju novi potencijalni konkurenti koji žele osigurati svoje mjesto na tržištu koristeći se agresivnim strategijama [180].

Današnje tržište karakteriziraju jake konkurentske prijetnje upravo zahvaljujući globalnoj umreženosti i digitalnim tehnologijama, što je doprinijelo djelomičnim ili potpunim uklanjanjem barijera ulaska na nova tržišta. Organizacije su primorane kontinuirano inovirati svoje poslovanje i iskorištavati prednosti digitalnih tehnologija kako bi ostvarile konkurentsku prednost i osigurale svoj opstanak na tržištu. Nadalje, digitalne tehnologije pridonose konkurentskoj prednosti na način da umanjuju postojeće troškove i omogućuju organizaciji diferencijaciju u vidi kreiranja inovativnih proizvoda i/ili usluga [175]. Upravo činjenica da organizacije posluju u nesigurnoj okolni koju karakterizira sučeljavanje s naglim, neočekivanim i nepredvidivim promjenama implicira da organizacije moraju primijeniti inovativna rješenja kako bi osigurale i održale konkurentsku prednost [180].

Kako bi se prilagodile tehnološkom napretku i osigurale svoj opstanak na tržištu za organizacije je nužno da prihvate digitalne tehnologije i uključe ih u svoje poslovanje. Zaostajanje u tehnološkom napretku može biti pogubno za opstanak organizacije, stoga je neophodno pratiti i predviđati trendove kako bi se omogućilo ostvarivanje konkurentske prednosti. Upravo je postizanje konkurentske prednosti jedan od vodećih motiva u mikro i malim organizacijama za donošenje odluke o ulaganju u digitalne organizacije. Neminovno je da je odluka o prihvaćanju

i ulaganju u digitalne tehnologije pod utjecajem konkurentskih prioriteta, tj. očekivanih performansi ili željenih ciljeva koje organizacija takvom odlukom želi postići.

Utjecaj postizanja željenih ciljeva prilikom prihvaćanja novih tehnologija potvrđen je od strane nekoliko autora. Vankatesh i ostali u UTAUT model uvode varijablu „očekivane performanse„ s ciljem istraživanja utjecaja na prihvaćanje novih tehnologija od strane pojedinaca. Očekivane performanse podrazumijevaju stupanj vjerovanja pojedinca da će upotreba tehnologije omogućiti poboljšanje njegovih poslovnih performansi [181]. Varijabla se temelji na varijablama iz prethodnih modela između ostalih i na varijabli očekivani ishodi iz socijalno kognitivne teorije (SCT). Compeau i Higgins u svom modelu socijalno kognitivne teorije (SCT) varijablu željeni/očekivani ishod definiraju kao posljedicu koja proizlazi iz određenog ponašanja te ju promatraju kroz dva koncepta: koncepta očekivane poslovne i koncepta očekivane osobne performanse pojedinca [182]. Obje varijable (očekivane performanse u UTAUT modelu i željeni ishod u socijalno kognitivnoj teoriji) pokazale su se kao značajne u namjeri prihvaćanja novih tehnologija od strane pojedinaca, čime ukazuju na činjenicu da ispunjenje očekivanih performansi, tj. željenih ciljeva djeluje poticajno na samo prihvaćanje tehnologije.

Promatrajući prihvaćanje tehnologija s aspekta organizacije očekivane performanse podrazumijevaju očekivano ispunjenje zadanih ciljeva. Ciljevi impliciraju neko željeno stanje ili rezultat koji se želi postići u određenom vremenom. U literaturi je razvidno kako pojedini autori imaju svoj određeni set ciljeva koji smatraju relevantnim za postizanje konkurentske prednosti organizacije.

Slack i ostali kao ciljeve navode konkurentske prioritete koji su fokusirani na tržište i stjecanje konkurentske prednosti kroz kvalitetu, brzinu, pouzdanost, fleksibilnost i smanjenje troškova [183].

- **Kvaliteta.** Kvaliteta kao konkurentski prioritet označava svojstvo proizvoda i/ili usluge da služi svojoj svrsi, tj. da udovoljava željenim i traženim kriterijima od strane kupaca. Kvaliteta je sama po sebi usporediva, te je u većem dijelu stvar percepcije kupca što znači da ne percipira svatko kvalitetu na jednak način [184]. Kvaliteta se može promatrati s dva aspekta, jedan podrazumijeva objektivna svojstva proizvoda i/ili usluga organizacije, dok se drugi aspekt odnosi na interakciju kupca s proizvodom i/ili uslugom

organizacije. Kada organizacija odabere kvalitetu kao svoj konkurentski prioritet to znači da ju mora implementirati u svaki aspekt svog poslovanja. Usvajanje digitalnih tehnologija od strane mikro i malih organizacija može utjecati na kvalitetu proizvoda i/ili usluge organizacije, na način da podigne njihovu kvalitetu ili da podigne kvalitetu aktivnost unutar organizacija. Kvaliteta kao konkurentski prioritet omogućuje diferencijaciju od ostalih organizacija na način da pruža konkurentsku prednost organizaciji, izdvajajući je od ostalih po razini kvalitete proizvoda i/ili pružene usluge.

- **Brzina.** Brzina kao konkurentski prioritet označava brzinu procesa od njegovog početka do kraja. U današnjem okruženju brzina dobiva na značaju kada je ključno za postizanje konkurentske prednosti biti ispred ostalih. Uključuje ubrzanje poslovnih procesa u vidu ubrzanja isporuke proizvoda i/ili usluge ili ubrzanja procesa unutar organizacije. U današnjem okruženju brzina ima ključnu ulogu u postizanju konkurentske prednosti, cilj je skratiti vrijeme isporuke i osigurati isporuku što je moguće prije te ubrzati proces razvoja ideja, tj. skratiti vrijeme od ideje do tržišta. Jedna od karakteristika digitalnih tehnologija je upravo ubrzanje poslovnih procesa zbog eliminiranja nepotrebne administracije. Može se zaključiti kako je brzina danas jedan od važnijih konkurentskih prioriteta.

- **Pouzdanost.** Pouzdanost kao konkurentski prioritet odnosi se na oslanjanje kupca na ono što im je obećano. Pouzdanost omogućava organizaciji izgradnju povjerenja kupca u samu organizaciju i uslugu i/ili proizvod koji nudi. Pouzdanost štedi vrijeme i novac a ujedno pruža dozu sigurnosti. Digitalne tehnologije mogu pomoći organizacijama u podizanju razine pouzdanosti koju kupci percipiraju. Pouzdanost gradi konkurentnost organizaciji na način da stvara odnos povjerenje između organizacije i njenih kupaca. Percepcija pouzdanosti omogućuje pozicioniranje i razlikovanje od ostalih organizacija.

- **Fleksibilnost.** Fleksibilnost kao konkurentski prioritet podrazumijeva sposobnost organizacije na prilagođavanje različitim situacijama i promjenama na tržištu, kao i mogućnost reorganizacije cijele organizacije. Današnje okruženje karakterizira nesigurnost i brze promjene stoga je mogućnost brze prilagodbe promjenama ključna za postizanje ali i održavanje konkurentske prednosti. Činjenica da se okruženje u kojem organizacije posluju brzo mijenja, kao i potrebe i očekivanja kupaca, mogućnost lake prilagodbe tim promjenama može biti ključna za postizanje konkurentske prednosti.

Organizacije koje odaberu fleksibilnost kao konkurentski prioritet u većini slučajeva u drugi plan stavljaju brzinu i trošak. Fleksibilnost kao prioritet zahtijeva vrijeme za prilagođavanje poslovnih procesa zahtjevima kupaca te često zahtijeva više resursa [184], [183].

- **Smanjenje troška.** Smanjenje troška kao konkurentski prioritet možda je jedan od najčešće istaknutih prioriteta. U samim počecima razmatranja konkurentnosti upravo se trošak izdvojio kao jedan od ključnih elemenata za postizanje konkurentske prednosti. Nedvojbeno je kako je upravo smanjenje troška primarna stvar svakog donositelja odluke u organizaciji. Čak i organizacije koje svoje konkurentske prioritete vide u drugim elementima žele i teže smanjenju troška upravo zbog činjenice da umanjenje troškova povećava profit organizacije. Digitalne tehnologije pojednostavljuju strukturu troškova i omogućuju stvaranje uštede omogućavajući na taj način organizacijama da u potpunosti iskoriste najnovije digitalne inovacije i potaknu promjene na tržištu [179].

Prilikom odluke o usvajanju digitalnih tehnologija potrebno je identificirati očekivane performanse, tj. konkurentske prioritete organizacije. Bitno je identificirati koji od konkurentskih prioriteta djeluje kao najjači motiv za ulaganje u digitalne tehnologije. Očekuju li organizacije da će prihvaćanje digitalnih tehnologija rezultirati povećanjem kvalitete usluge i/ili proizvoda organizacije ili je mogućnost bržeg ispunjavanja i prepoznavanja zahtjeva tržišta i/ili ubrzavanje poslovnih procesa ono što organizaciju motivira da prihvati digitalne tehnologije. Možda je nadalje, ono što organizacija očekuje od digitalnih tehnologija povećanje pouzdanosti u vidu izvršavanja radnih zadataka i usluga na vrijeme ili postizanje fleksibilnosti u vidu mogućnosti prilagođavanja brzim promjenama na tržištu. S druge strane, smanjenje troškova poslovanja uvijek je bio cilj donositelja odluka, no je li smanjenje troškova glavni motiv prilikom odlučivanja o prihvaćanju digitalnih tehnologija [183], [185]. U literaturi je razvidno kako mikro i male organizacije zaostaju u prihvaćanju digitalnih tehnologija stoga je nužno istražiti koji konkurentski prioritet je ključan kako bi mikro i male organizacije promijenile svoj stav prema prihvaćanju istih.

6. KONCEPTUALNI OKVIR ISTRAŽIVANJA

Istraživanje u ovom radu obuhvaća teorijsko i empirijsko istraživanje pri čemu je empirijski dio podijeljen na predistraživanje i istraživanje. Teorijski dio obuhvatio je pregled postojeće relevantne literature na temu prihvaćanja tehnologija s ciljem rezimiranja rezultata prethodnih istraživanja, te definiranja ključnih čimbenika povezanih s prihvaćanjem digitalnih tehnologija u mikro i malim organizacijama.

Uloga teorijskog okvira je pružiti širu sliku područja istraživanja kao i prikazati postojeća znanja u području istraživanja [186]. Teorijski okvir temelji se na postojećoj prethodno testiranoj, potvrđenoj i validiranoj teoriji na kojoj istraživač/ica temelji svoje istraživanje i s kojom povezuje hipoteze u svom istraživanju. Sastoji se od teorijskih principa, konstrukta i koncepta te pomaže istraživaču/ici u pronalaženju odgovarajućeg istraživačkog pristupa, odgovarajućih analitičkih alata i postupaka za provođenje istraživanja, što naposljetku osigurava općenitost rezultata samog istraživanja [187].

Za razliku od teorijskog okvira konceptualni okvir istraživanja predstavlja ključni dio samog dizajna istraživanja i kao takav uključuje: sustav pojmova, pretpostavke, očekivanja, uvjerenja i teorije koje podržavaju i informiraju istraživanje koje se provodi [186]. Konceptualni okvir naglašava razloge zašto je istraživačka tema vrijedna proučavanja, ukazuje na same pretpostavke istraživača te navodi teorije s kojima se istraživač slaže ili ne slaže. U suštini čini temelje na kojem istraživač/ica bazira svoje istraživanje [187].

Konceptualni okvir zapravo je vizualni ili pisani produkt koji objašnjava u grafičkom ili pisanom obliku glavne komponente koje će se istraživati (ključne čimbenike ili varijable) i pretpostavlja veze između njih [188], [186]. Upravo konceptualni okvir opisuje ključne varijable ili konstrukte koji će se istraživati kao i veze između njih, te ujedno objašnjava logiku kreiranja konceptualnog modela i opravdanost varijabli [187].

Cilj oba okvira (teorijskog i konceptualnog) je učiniti rezultate istraživanja značajnim i prihvatljivim za teorijske konstrukte kao i osigurati njihovu općenitost, tj. generalizaciju kako bi se u konačnici postigao cilj proširenja postojećeg znanja [187].

6.1. Problem prihvaćanja digitalnih tehnologija u mikro i malim organizacijama

Pregledom dosadašnjih istraživanja uočen je nedostatak istraživanja koja bi se odmaknula od postojećih modela i teorija te objasnila razloge prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

Broj mikro i malih organizacija rapidno raste te one postaju temelj gospodarstva i globalne ekonomije kreirajući velik broj radnih mjesta i doprinoseći daljnjem razvoju istog [8]. Samo u Republici Hrvatskoj mikro i male organizacije čine 98% ukupnih organizacija [12]. Kako bi digitalne tehnologije pomogle mikro i malim organizacijama da unaprijede svoje poslovanje, osiguraju svoj opstanak na tržištu i postignu konkurentnu prednost potrebno je da iste budu prihvaćene i percipirane kao korisne i nužne kako za nastavak poslovanja tako i za sam rast organizacije [19].

Broj modela koji objašnjavaju namjeru prihvaćanja tehnologija u literaturi je velik, no zbog sve bržeg razvoja tehnologija i brojnosti njihovih karakteristika teško je razviti jedinstveni generalni model koji je prikladan za istraživanje prihvaćanja svih inovacija. Stoga je potrebno ići u smjeru razvijanja novih modela a ne u smjeru korištenja istih čimbenika i potvrđivanju njihove značajnosti, tj. korištenje i potvrđivanje postojećih teorija i modela [25], [26], [22].

Dosadašnja istraživanja prihvaćanja novih tehnologija djelomično su obuhvaćala i mikro i male organizacije najčešće u kontekstu MSP-a, te ih se vrlo malo fokusiralo isključivo na mikro i male organizacije. Da je prihvaćanje i investiranje u digitalne tehnologije u mikro i malim organizacijama poželjno i nužno naglašavaju i strategije Europske komisije donesene u ožujku 2020. godine, a koje imaju za cilj ubrzati tehnološki rast mikro i malih organizacija [189].

Pregledom literature uočeno je kako se za istraživanje namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama potrebno fokusirati na moderirajuće čimbenike, čiji je utjecaj u postojećim istraživanjima zanemaren. Uočen je nedostatak istraživanja koja bi prilikom sagledavanja povezanosti čimbenika s prihvaćanjem novih tehnologija istražila i utjecaj moderirajućih čimbenika. U prihvaćanju novih tehnologija od strane organizacija uglavnom je promatran direktan ili indirektan utjecaj čimbenika na namjeru prihvaćanja. Kako

bi se upotpunila uočena praznina u literaturi potrebno je istraživanje fokusirati na utvrđivanje utjecaja moderirajućih čimbenika [27]. Usmjeravanjem istraživanja u smjeru utvrđivanja utjecaja moderirajućih čimbenika omogućit će se stjecanje novog znanja o odlučivanju mikro i malih organizacija o usvajanju digitalnih tehnologija.

Pregledom literature identificirani su moderirajući čimbenici koji bi mogli utjecati na odluku o prihvaćanju digitalnih tehnologija u mikro i malim organizacijama, to su: digitalna zrelost organizacije, konkurentski prioriteti i stil odlučivanja donositelja odluke. Digitalna zrelost opsežna je istraživačka tema, no nedostaje istraživanje zavisnosti razine digitalne zrelosti organizacije i prihvaćanja novih tehnologija. Uključivanje digitalne zrelosti organizacije u model mjerenja namjere prihvaćanja digitalnih tehnologija pomoći će u dobivanju šire slike „stanja“ organizacije i njenog cjelokupnog promišljanja o digitalizaciji poslovanja, odnosno digitalnoj transformaciji. Prihvaćanje tehnologija motivirano je ostvarivanjem konkurentskih prioriteta te u tom smislu nedostaje istraživanje koje će ukazati koji prioritet ima najjači utjecaj na odluku o prihvaćanju novih tehnologija.

Pored toga, istražit će se i kako različiti stil odlučivanja direktora, kao ključne osobe u mikro i malim organizacijama, utječe na njegovo znanje o digitalnoj tehnologiji koju prihvaća.

Pregledom literature uočeno je i kako nedostaje istraživanje koje bi u potpunosti obuhvatilo ključne karakteristike mikro i malih organizacija, prvenstveno problem nedostatka resursa (financijskih i ljudskih) te način donošenja odluka koji je u potpunosti u rukama direktora, tj. vlasnika [75]. Mikro i male organizacije zaostaju u prihvaćanju novih tehnologija upravo zbog svojih karakteristika koje djeluju kao barijere i dovode do pojave straha od nepoznatog i time percipiranjem tehnologije rizičnom i nepotrebnom [12], [13], [8], [14], [84], [16], [17]. U tom smislu je istraživanje potrebno prilagoditi potrebama i karakteristikama mikro i malih organizacija.

U skladu s navedenim predlaže se model namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama koji će upotpuniti prazninu u postojećim istraživanjima na način da će obuhvatiti ključne karakteristike mikro i malih organizacija te istražiti utjecaj moderirajućih čimbenika. Istražit će se povezanost percipiranog financijskog rizika, percipiranog sigurnosnog rizika, percipiranog gubitaka vremena, percipiranog pritiska države, pritiska sudionika na tržištu, percipiranih kriznih okolnosti te razine znanja donositelja odluke s namjerom

prihvaćanja digitalnih tehnologija u mikro i malim organizacijama. Pritom će se istražiti postoje li razlike u prihvaćanju digitalnih tehnologija između organizacija na različitoj razini digitalne zrelosti, kao i postoji li razlika u prihvaćanju ovisno o konkurentskom prioritetu koji se novom tehnologijom želi postići. Također, istražit će se i kako različiti stil odlučivanja direktora utječe na povezanost pritiska sudionika na tržištu i kriznih okolnosti na razinu znanja direktora o digitalnoj tehnologiji koja se prihvaća. Cilj istraživanja je stjecanje novih znanja o odlučivanju mikro i malih organizacija o usvajanju digitalnih tehnologija. Kao i spoznati kako mikro i male organizacije razmišljaju i što ih motivira i/ili demotivira za ulaganje u digitalne tehnologije.

Istraživanje će obuhvatiti namjeru prihvaćanja digitalnih tehnologija, a ne njihovu implementaciju. Pregledom literature utvrđeno je kako je namjera dovoljni indikator samog prihvaćanja te će se time i istraživanje fokusirati na istraživanje čimbenika koji utječu na namjeru prihvaćanja.

6.2. Konceptualni model

U nastavku (slika 7) prikazan je model namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama. Model je proizašao iz analize literature vodeći se preporukama Rogersa koji sugerira da je nužan smjer istraživanja razvoj novih modela, a ne potvrđivanje postojećih [26]. Analizom literature utvrđeno je kako je za istraživanje namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama potrebno obratiti pažnju na njihove ključne karakteristike te se fokusirati na moderirajuće čimbenike.

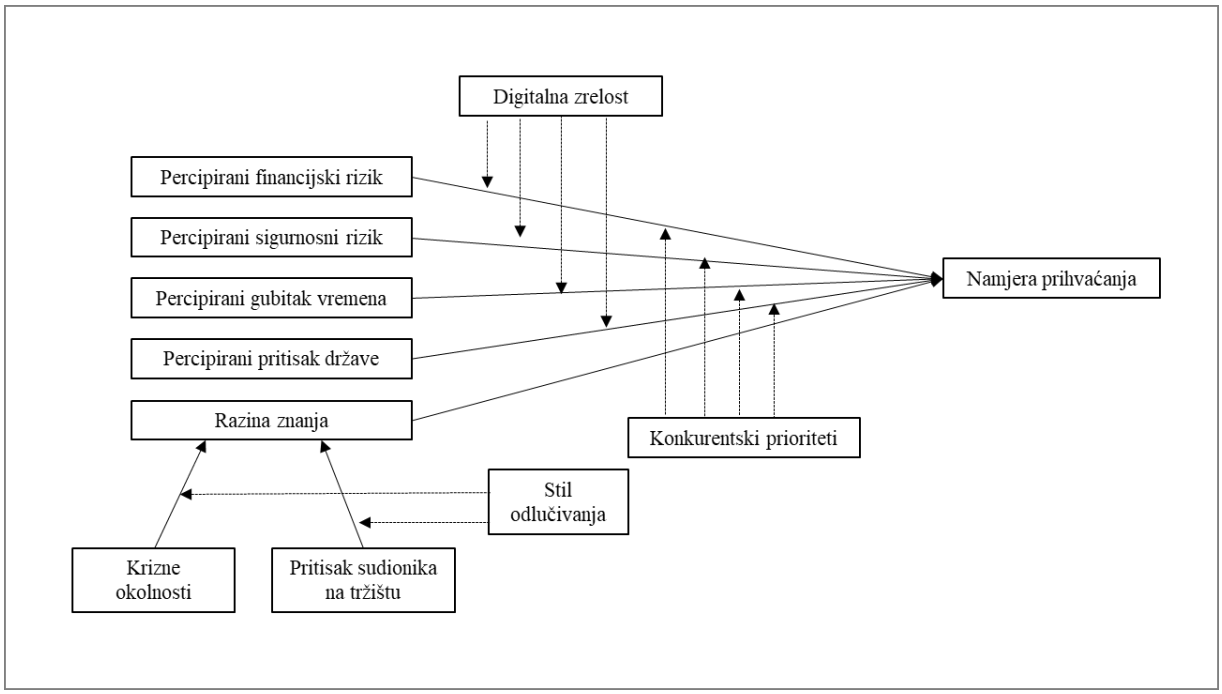

Slika 7 Model namjere prihvaćanja digitalnih tehnologija mikro i malih organizacija

Pregledom literature uočeno je kako je najčešći oblik istraživanja prihvaćanja novih tehnologija uključivao korištenje upitnika kao instrumenta istraživanja [25], [76]. U skladu s time i za potrebe ovog istraživanja kreiran je anketni upitnik kojim će se istražiti utjecaj identificiranih čimbenika na namjeru prihvaćanja digitalnih tehnologija u mikro i malim organizacijama. Kao što je vidljivo na slici 7 predloženi model sastoji se od jedanaest čimbenika, tj. konstrukta koji će biti operacionalizirani kroz primjenu skala. Od jedanaest čimbenika njih sedam u statističkoj analizi predstavljat će nezavisne varijable (prediktorske, eksperimentalne varijable) dok će konstrukt namjera prihvaćanja te konstrukt razina znanja predstavljati zavisne varijable (kriterijske varijable). Konstrukt razina znanja ujedno je nezavisna i zavisna varijabla. Preostali čimbenici predstavljaju moderirajuće varijable.

U nastavku su prikazani i ukratko objašnjeni konstrukti modela namjere prihvaćanja digitalni tehnologija u mikro i malim organizacijama.

Percipirani financijski rizik

Percipirani financijski rizik podrazumijeva možebitne financijske gubitke ukoliko ulaganje u digitalnu tehnologiju ne ispuni očekivanja, tj. mogući gubitak novaca prilikom prihvaćanja novog i nepoznatog [16], [107].

Percipirani sigurnosni rizik

Percipirani sigurnosni rizik podrazumijeva razinu povjerenja u sigurnost korištenja digitalne tehnologije, te percipiranu razinu straha i rizika prilikom prihvaćanja digitalnih tehnologija [64], [25].

Percipirani gubitak vremena

Percipirani gubitak vremena očituje se u percepciji vremena potrebnog za usvajanje digitalne tehnologije. Obuhvaća vrijeme za odabir adekvatne tehnologije, vrijeme za uvođenje te vrijeme za edukaciju zaposlenika [8], [85], [81].

Percipirani pritisak države

Percipirani pritisak države uključuje zahtjeve države da organizacije koje posluju s državom i državnim institucijama koriste određenu tehnologiju i na taj način potiču digitalizaciju i digitalnu transformaciju mikro i malih organizacija [74], [13].

Razina znanja

Razina znanja uključuje razinu znanja i spoznaju o tehnologiji koja se prihvaća od strane donositelja odluke u organizaciji. Nedostatak znanja o tehnologiji koja se prihvaća implicira nedostatak znanja o prednostima koje tehnologija može donijeti [19]. Razina znanja donositelja odluke pod utjecajem je vanjskog pritiska koji se očituje u pritisku sudionika na tržištu i kriznim okolnostima. Način na koji pritisak sudionika na tržištu i krizne okolnosti djeluju na razinu znanja pod utjecajem je stila odlučivanja donositelja odluke.

Krizne okolnosti

Krizne okolnosti uključuju iznenadne poremećaje na tržištu koji za posljedicu imaju značajne ekonomske gubitke. Utjecaj sadašnje pandemije COVID 19 može se smatrati kriznom okolnosti koja je prisilila organizacije da ubrzaju proces digitalizacije, ali je istovremeno uzrokovala financijske poteškoće koje su dovele do odustajanja ili odlaganja većih investicija u digitalne tehnologije. Kako bi nastavile poslovanje u otežanim okolnostima mikro i male organizacije su u kratkom roku morale prilagoditi i digitalizirati svoje poslovanje. COVID 19 pandemija ukazuje na dvije bitne činjenice: prva, da su krizne okolnosti moguće i kao takve predstavljaju velike izazove u poslovanju te druga, da njihova realnost traži ulaganje u digitalne tehnologije kako bi organizacije bile spremne za efikasan odgovor na njihovu pojavu u budućnosti.

Iznenadni poremećaji i problemi na tržištu mogu utjecati na odluke o prihvaćanju digitalnih tehnologija u mikro i malim organizacijama [2].

Pritisak sudionika na tržištu

Pritisak iz poslovne okoline organizacije očituje se u pritisku konkurencije i pritisku poslovnih partnera (kupaca i dobavljača) [88]. Na prihvaćanje digitalnih tehnologija mogu utjecati važni kupci i dobavljači na način da zahtijevaju ili stimuliraju korištenje određene tehnologije.

Konkurentski prioriteti

Konkurentski prioriteti uključuju pet prioriteta definiranih od strane Slacka i ostalih koji omogućavaju stjecanje konkurentske prednosti, a time i postizanje efikasnijeg poslovanja. Konkurentski prioriteti uključuju kvalitetu, brzinu, pouzdanost, fleksibilnost i trošak. Kvaliteta podrazumijeva očekivano povećanje kvalitete u zadovoljavanja potreba tržišta temeljem prihvaćanja digitalnih tehnologija. Brzina podrazumijeva očekivano ubrzanje poslovnih procesa unutar organizacije uslijed prihvaćanja digitalnih tehnologija, kao i brže prepoznavanje i udovoljavanje zahtjevima tržišta. Pouzdanost se odnosi na očekivanja vezana za poštivanje rokova isporuke usluga i proizvoda te percepciju poslovnih partnera, što ima izravnu implikaciju na stjecanje lojalnosti klijenata. Fleksibilnost se odnosi na očekivanja u svezi prilagodbe zahtjevima tržištima, usvajanje digitalnih tehnologija omogućit će se organizacijama da budu agilnije. Naposljetku trošak se odnosi na očekivano smanjenje troškova poslovanja koji mogu rezultirati smanjenjem cijene proizvoda i usluga i/ili omogućavanjem alociranja sredstva u druge svrhe [183], [185].

Stil odlučivanja

Stil donošenja odluka podrazumijeva uobičajeni obrazac odgovora pojedinca kad se suoči sa situacijom odluke. Stil odlučivanja odredit će se pomoću ljestvice stila odlučivanja (*engl. Decision style scale)* razvijene od strane Hamiltona i ostalih [150]. Ljestvica sadrži dva stila odlučivanja: racionalni i intuitivni. Racionalni stil odlučivanja uključuje: sustavno prikupljanje i pretraživanje informacija, sustavno vrednovanje svih mogućnosti i potencijalnih alternativa, razmatranje raspoloživih opcija djelovanja i upotrebljavanje analitičkih metoda i tehnika u procesu odlučivanja [140], [150]. Intuitivni stil donošenja odluka uključuje način donošenja odluke temeljen na spoznaji bez očite racionalne misli potkrijepljen iskustvom i stručnosti donositelja odluke. Podrazumijeva podsvjesne mentalne obrade zasnovane na vrijednostima i

etici [160]. Karakterizira ga brzo donošenje odluka i oslanjanje na predosjećaje i osjećaje, on je automatski, podsvjestan, relativno brzi, nabijen, heuristički i temelji se na iskustvu [150].

Digitalna zrelost

Razina digitalne zrelosti organizacije promatrat će se s aspekta menadžmenta te prema Channias i Hessu podrazumijeva stanje organizacije u procesu digitalne transformacije i opis promjena koje je organizacija ostvarila u tom procesu [132]. Koristit će se deskriptivan model digitalne zrelosti organizacije razvijen od strane Kruljca [130]. Model zrelosti uključuje tri razine: [190]

Prva razina - Utjecaj digitalizacije i digitalnih tehnologija na organizaciju i njeno poslovanje je minimalan. Prepoznata je potreba za digitalizacijom poslovanja, no još nisu poduzeti nikakvi koraci u tom smjeru. Nedostaje potpora rukovodstva te motivacija za korištenje digitalnih tehnologija i rješenja.

Druga razina - Formirani su određeni koraci prema digitalizaciji poslovanja. Promiče se upotreba digitalnih rješenja. Postoje naznake digitalne strategije, no nisu jasno definirane uloge, ciljevi i modeli mjerenja istih.

Treća razina - Postoji jasna strategija digitalne transformacije unutar organizacije te su definirani ciljevi za postizanje iste. U organizaciji postoji odgovarajuća informacijska infrastruktura i odgovarajuće vodstvo koje brine o digitalizaciji poslovanja.

6.3. Hipoteze istraživanja

U okviru teorijskog istraživanja, a na temelju postojećih teorija, postavljene su hipoteze koje predstavljaju i zadnju fazu teorijskog istraživanja nakon čega slijedi empirijsko istraživanje.

Postavljene hipoteze su sljedeće:

H1 Percipirani rizici (financijski, sigurnosni i gubitak vremena) negativno su povezani s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H1.1 Percipirani financijski rizik negativno je povezan s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H1.2 Percipirani sigurnosni rizik negativno je povezan s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H1.3 Percipirani gubitaka vremena negativno je povezan s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H2 Percipirani pritisak države i razina znanja direktora pozitivno su povezani s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H2.1 Percipirani pritisak države pozitivno je povezan s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H2.2 Razina znanja direktora pozitivno je povezana s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama..

H3 Povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja različita je ovisno o razini digitalne zrelosti organizacije.

H3.1 Razina digitalne zrelosti organizacije moderira odnos između percipiranog financijskog rizika i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H3.2 Razina digitalne zrelosti organizacije moderira odnos između percipiranog sigurnosnog rizika i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H3.3 Razina digitalne zrelosti organizacije moderira odnos između percipiranog gubitka vremena i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H3.4 Razina digitalne zrelosti organizacije moderira odnos između percipiranog pritiska države i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H4 Povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja različita je ovisno o konkurentskom prioritetu koji se želi postići.

H4.1 Konkurentski prioritet moderira odnos između percipiranog financijskog rizika i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H4.2 Konkurentski prioritet organizacije moderira odnos između percipiranog sigurnosnog rizika i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H4.3 Konkurentski prioritet organizacije moderira odnos između percipiranog gubitka vremena i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H4.4 Konkurentski prioritet organizacije moderira odnos između percipiranog pritiska države i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.

H5 Povezanost vanjskih pritiska (krizne okolnosti i pritisak sudionika na tržištu) s razinom znanja donositelja odluke različita je ovisno o stilu odlučivanja.

H5.1 Stil odlučivanja moderira odnos između pritiska sudionika na tržištu i razine znanja direktora o digitalnoj tehnologiji koja se prihvaća.

H5.2 Stil odlučivanja moderira odnos između kriznih okolnosti i razine znanja direktora o digitalnoj tehnologiji koja se prihvaća.

Postavljene hipoteze predstavljaju zadnju fazu teorijskog istraživanja, te slijedi empirijsko istraživanje.

7. METODOLOGIJA EMPIRIJSKOG ISTRAŽIVANJA

Empirijski dio istraživanja provest će se kako bi se provjerio predloženi model. Model će se testirati prihvaćanjem jedne primarne i jedne sekundarne digitalne tehnologije u mikro i malim organizacijama. Primarna tehnologija obuhvatit će uslužno računalstvo koje u kontekstu ovog istraživanja podrazumijeva „tehnološke i infrastrukturne digitalne platforme, koje omogućavaju efikasno i sigurno korištenje gotovo neograničenih digitalnih (hardverskih, podatkovnih i softverskih) kapaciteta za upravljanje podacima, njihovu pohranu i upotrebu“ [7]. Unatoč činjenici kako uslužno računalstvo nije nešto novo na tržištu i da je prisutno već nekoliko godina ono se i dalje može percipirati novim od strane onog tko ga prihvaća. U tom smislu Thong i Yap definirajući pojam inovacije obrazlažu istu kao „obnovu“, tj. oživljavanje pomoću tehnologije i/ili obnovu u smislu novog razmišljanja i djelovanja. Inovacija sama po sebi ne mora biti nova odnosno nešto novo mjereno u smislu vremena njena otkrića ili izuma, već mora biti nešto novo onome tko ju usvaja, tj. mora biti percipirana kao nešto novo od strane onog tko prihvaća inovaciju [17], [26]. Sekundarna digitalna tehnologija obuhvatit će blockchain tehnologiju koja će u kontekstu ovog istraživanja obuhvatit pametne ugovore. Pametni ugovori pružaju mogućnosti sigurne razmjene novca (kriptovalute), dionica i druge imovine izravno, bez sudjelovanja posrednika (financijskih i javnih službi).

Pregledom literature uočeno je da se upitnik kao instrument istraživanja najčešće koristi u istraživanju prihvaćanja novih tehnologija, te će se i u ovom istraživanju u svrhu testiranja predloženog modela razvit mjerni instrument (anketni upitnik) [25], [76]. Slika 8 u nastavku prikazuje postupak razvoja i prijevoda mjernog instrumenta sugeriran od strane Tsanga i ostalih.

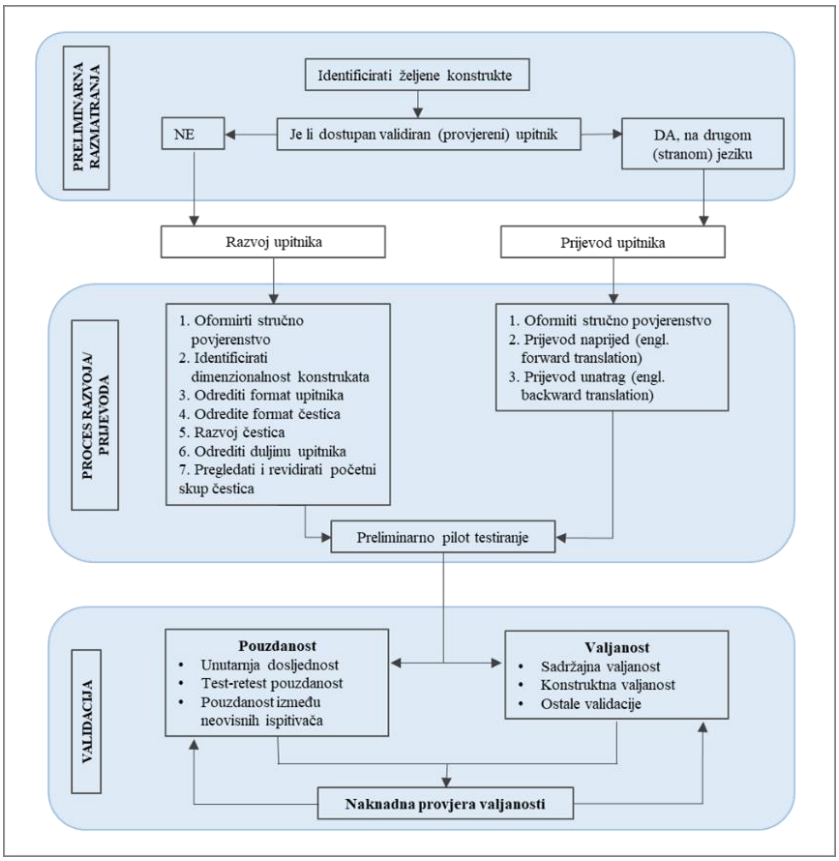

Slika 8 Razvoj i prijevod upitnika

Izvor: preuzeto iz [191]

7.1. Instrument istraživanja

Podaci u istraživanju prikupiti će se metodom anketiranja kako u predistraživanju tako i u glavnom istraživanju. Mjerni instrument (anketni upitnik) sastojati će se od konstrukata preuzetih iz prethodnih istraživanja koji će sadržavati čestice prilagođene definiranom cilju istraživanja. Klačmer referirajući nekoliko autora navodi kako je najčešći oblik kreiranja anketnog upitnika upravo preuzimanje postojećih konstrukata i čestica iz prethodnih istraživanja. Navodi nekoliko razloga koji čine preuzimanje čestica poželjnijim od samostalnog razvijanja anketnog upitnika, a to su: prethodno potvrđena pouzdanost i valjanost instrumenta kao i povezivanje istraživanja s prethodnim istraživanjima koja su primijenila isti instrument [21].

Milas navodi kako „poput svih drugih mjernih instrumenata, anketni upitnici i s njima prikupljeni odgovori ne posjeduju vrijednost sami za sebe, već isključivo kao način mjerenja

subjektivne pojave koju nastoje zahvatiti“ [192]. Navedenim pojašnjava kako je odgovor na pojedino anketno pitanje vrijedan u onoj mjeri u kojoj je povezan sa stavom ili mišljenjem na koje se odnosi. Slijedom navedenog zaključuje kako je kvalitetan onaj upitnik kod kojeg je slaganje između dobivenog odgovora i samog predmeta mjerenja na visokoj razini. Ističe kako je nužno da anketni upitnik posjeduje svojstvo dosljednosti podataka prikupljenih u različito usporedivim situacijama [192]. Navedeno označava dvije ključne metrijske karakteristike mjernog instrumenta: valjanost i pouzdanost.

Instrument istraživanja sastavljen je od skupa tvrdnji (čestica) pri čemu su ispitanici izrazili svoje slaganje/ne slaganje s predočenom tvrdnjom. Korištene su čestice zatvorenog tipa mjerene ordinalnom skalom od 1 do 5 (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). Za mjerenje stava ispitanika koristila se Likertova skala. Izuzetak je pitanje o konkurentskim prioritetima gdje se od ispitanika zahtijevalo da odaberu jedan od ponuđenih odgovora s kojim se najviše slažu.

U literaturi su za veći dio mjernog instrumenta bile dostupne čestice na engleskom jeziku te je stoga bilo potrebno napraviti prijevod na hrvatski jezik. Prijevod mjernog instrumenta napravio se pomoću neovisnih prevoditelja i to *engl. forward* i *backward* prijevod. Početni prijevod s izvornog jezika upitnika (engleski jezik) na ciljni jezik (hrvatski jezik) izradio je neovisni prevoditelji. Nakon prijevoda s engleskog na hrvatski napravio se prijevod unatrag s ciljanog jezika na izvorni jezik kako bi se osigurala točnost prijevoda [191]. Ključno je da se osigura podudarnost između riječi i značenja izvornog jezika i ciljanog jezika. Adekvatan i kvalitetan prijevod mjernog instrumenta omogućit će prikupljanje usporedivih podataka i mjerenje konstrukata koji se trebaju mjeriti. Dobar prijevod mjernog instrumenta anulira greške uzorkovanja, povećava odaziv ispitanika i općenitost rezultata istraživanja [193]. Za potrebe ovog istraživanja predfinalna verzija upitnika napravljena je na temelju dobivenih prijevoda od strane neovisnih prevoditelja te prilagodbe od strane autorice.

U svrhu kreiranja finalne verzija upitnika predfinalna verzija upitnika testirana je na grupi od deset ispitanika - pet muškaraca i pet žena u dobnoj skupini od 30 do 60 godina, sedam je ispitanika imalo fakultetsko obrazovanje (VSS) a troje srednjoškolsko obrazovanje. Od deset ispitanika njih četvero su vlasnici i direktori male organizacije, dok su preostali vlasnici i direktori mikro organizacije. S ciljem potvrđivanja razumljivosti pitanja nakon provedenog prijevoda od ispitanika se tražilo da ispune predfinalnu verziju upitnika i ukažu na čestice koja

im eventualno nisu razumljive. Svi ispitanici su potvrdili razumljivost upitnika stoga nije bilo potrebe za modifikacijama u anketnom upitniku. Čestice uključene u finalni anketni upitnik prikazane su u nastavku.

Konstrukt digitalna zrelost

Konstrukt digitalna zrelost preuzeo se iz istraživanja Kruljac-a koji je izvorno u istraživanju koristio četiri dimenzije: digitalna zrelost organizacije, organizacijska spremnost, tehnološka spremnost i inovativna organizacijska spremnost. Dimenzija organizacijska spremnost uključivala je dvije poddimenzije - resursi za provedbu digitalne transformacije i efikasnost poslovnog upravljanja, dimenzija tehnološke spremnosti uključivala je također dvije poddimenzije - korištenje naprednih tehnologija i efikasnost upravljanja tehnologijama. Dimenzija inovativna organizacijska kultura uključivala je tri poddimenzije – suradnja između timova i odjela, otvorenost i komunikacija te prihvaćanje rizika [130]. U sklopu istraživanja Kruljac je utvrdio kako poddimenzija efikasnost poslovnog upravljanja kao i poddimenzija suradnja između timova i odjela nemaju utjecaj na razinu digitalne zrelosti organizacije, te su navedene poddimenzije isključene iz ovog istraživanja. Isključena je i dimenzija digitalna zrelost koja za potrebe ovog istraživanja nije nužna pošto će se razina digitalne zrelosti mjeriti metodom preuzetom iz istraživanja Blatz i ostali [190] (Poglavlje 7.6). U tablici 10 u nastavku prikazane su dimenzije konstrukta digitalna zrelost.

Tablica 10 Konstrukt digitalna zrelost

Konstrukt	Šifra čestice	Čestica	Izvor
Digitalna zrelost	***Resursi za provedbu digitalne transformacije***		
	D_REST1	Imamo adekvatan budžet za podršku provođenja digitalne poslovne strategije.	
	D_REST2	Investirali smo značajna sredstva u edukaciju zaposlenika i treninge na području digitalne transformacije.	
	D_REST3	Moja organizacija danas ima dovoljno talenata da podrži digitalnu transformaciju.	
	Korištenje naprednih tehnologija		

Konstrukt	Šifra čestice	Čestica	Izvor
	D_KNT1	Arhitektura naše tehnologije omogućava da se lako integrira sa svim pristupnim kanalima (web, mobilni uređaji..).	
	D_KNT2	Tehnologija kojom raspolažemo u potpunosti je usklađena s ciljevima digitalne transformacije poslovanja.	
	D_KNT3	Naši stručnjaci u potpunosti poznaju nove tehnologije i njihov utjecaj na poslovanje našeg poduzeća.	
	D_KNT4	Naša tehnologija je naprednija nego tehnologija naših konkurenata.	
	D_KNT5	Naše aktivnosti u procesu digitalne transformacije nisu limitirane postojećom tehnologijom u organizaciji.	
	Efikasnost upravljanja tehnologijama		
	D_EUT1	U našoj organizaciji IT ima stratešku ulogu.	
	D_EUT2	Postoje jasna pravila i procedure upravljanja IT-em.	
	D_EUT3	Definirali smo dugoročne planove implementacije novih IT-a.	
	D_EUT4	Mjerimo učinak našeg IT tima ne samo kroz stabilnost tehnologije nego i kroz poslovne rezultate.	
	D_EUR5	Naš budžet za tehnologiju je fleksibilan na način da omogućava promjene prioriteta nabavke novih tehnologija.	
	Otvorenost i komunikacija		
	D_OK1	Vrlo jasno komuniciramo našu strategiju sa zaposlenicima.	
	D_OK2	Naši zaposlenici su svjesni da će se njihova uloga značajno promijeniti.	
	D_OK3	Otvoreno komuniciramo na svim razinama o problemima i prilikama poslovanja.	
	Prihvaćanje rizika		
	D_PR1	Naši menadžeri su sposobni prepoznati prilike i prijetnje i potrebu za inovacijama.	
	D_PR2	Moja organizacija uspješno balansira između inoviranja i kontrole rizika.	

Konstrukt	Šifra čestice	Čestica	Izvor
	D_PR3	Primarnu odgovornost u inoviranju uglavnom snosi menadžment organizacije.	

Tablicama u nastavku prikazani su konstrukti i čestice uz napomenu kako se upitnik konstruirao na način da su ispitanici izražavali stupanj svojeg (ne)slaganja s tvrdnjama odvojeno za svaku od tehnologija (uslužno računalstvo i pametni ugovori). Navedeno je vidljivo u Prilogu 1.

Tablica 11 Konstrukt percipirani financijski rizik

Konstrukt	Šifra čestice	Čestica	Izvor
Percipirani financijski rizik (PFR)	PFR1	Korištenje digitalnih tehnologija dovelo bi organizaciju u financijske gubitke.	[194], [195]
	PFR2	Trošak prihvaćanja digitalnih tehnologija je daleko veći od koristi.	
	PFR3	Trošak održavanja i podrške digitalnih tehnologija je previsok za naše poslovanje.	
	PFR4	Troškovi obuke naših zaposlenika za korištenje digitalnih tehnologija su previsoki.	

Tablica 12 Konstrukt percipirani sigurnosni rizik

Konstrukt	Šifra čestice	Čestica	Izvor
Percipirani sigurnosni rizik (PSR)	PSR1	Brine me što bi drugi mogli imati pristup podacima organizacije upotrebom digitalnih tehnologija.	[113], [64], [196]
	PSR2	Uvjeren/a sam da su podaci organizacije pohranjeni na digitalnim tehnologijama sigurni.	
	PSR3	Vjerujem da nitko ne može vidjeti informacije i podatke pohranjene na digitalnim tehnologijama bez moje suglasnosti.	

Konstrukt	Šifra čestice	Čestica	Izvor
	PSR4	Vjerujem da su informacije i podaci organizacije na digitalnim tehnologijama sigurni od manipulacije (treće strane) neodgovarajućih korisnika.	
	PSR5	Mislim da upotreba digitalnih tehnologija ima potencijalni sigurnosni rizik.	

Tablica 13 Konstrukt percipirani gubitak vremena

Konstrukt	Šifra čestice	Čestica	Izvor
Percipirani gubitak vremena (PGV)	PGV1	Potrebno je previše vremena da se nauči koristiti digitalne tehnologije.	[197], [194], [113], [195]
	PGV2	S obzirom na potrebno vrijeme prelazak na digitalne tehnologije smatram neisplativim i nevrijednim truda.	
	PGV3	Mogući gubitak vremena uzrokovan implementacijom i učenjem kako koristiti digitalne tehnologije čini njihovo prihvaćenje neisplativim i nevrijednim truda.	
	PGV4	Količina vremena koja je potrebna da se obući zaposlenike za rad s digitalnim tehnologijama je prevelika.	

Tablica 14 Konstrukt percipirani pritisak države

Konstrukt	Šifra čestice	Čestica	Izvor
Percipirani pritisak države (PPD)	PPD1	Organizacija bi koristila digitalne tehnologije ukoliko bi postojale progresivne obavezne mjere uvedene od strane vlade koje bi uvjetovale upotrebu.	[13], [74], [198]
	PPD2	Organizacija bi koristila digitalne tehnologije ukoliko bi vlada uvjetovala upotrebu u javnoj nabavi i u poslovanju s državom.	
	PPD3	Organizacija bi koristila digitalne tehnologije ukoliko bi postojali vladini poticaji za korištenje.	

Konstrukt	Šifra čestice	Čestica	Izvor
	PPD4	Organizacija bi koristila digitalne tehnologije ukoliko bi bila pod pritiskom vlade.	

Tablica 15 Konstrukt razina znanja

Konstrukt	Šifra čestice	Čestica	Izvor
Razina znanja (RZ)	RZ1	Svoje razumijevanje digitalnih tehnologija ocjenjujem vrlo dobrim.	[17], [90]
	RZ2	Imam vrlo malo znanja o tome kako digitalne tehnologije mogu pomoći u poboljšanju poslovanja i povećanju prihoda organizacije.	
	RZ3	Koristio/la bi digitalne tehnologije ukoliko bi mi na raspolaganju bilo više informacija o prednostima koje može donijeti poslovanju moje organizacije.	
	RZ4	Ne posjedujem adekvatno tehničko znanje i vještine potrebne za rad i upotrebu digitalnih tehnologija.	

Tablica 16 Konstrukt krizne okolnosti

Konstrukt	Šifra čestice	Čestica	Izvor
Krizne okolnosti (KO)	KO1	Covid 19 pandemija potaknula me na prikupljanje više informacija o digitalnim tehnologijama.	Izrada autorice
	KO2	Covid 19 pandemija utjecala je na moju razinu znanja o digitalnim tehnologijama.	
	KO3	Prije Covid 19 pandemije moje znanje o digitalnim tehnologijama bilo je na niskoj razini.	
	KO4	Prije Covid 19 pandemije nisam imao/la interesa pretraživati informacije o digitalnim tehnologijama.	

Konstrukt	Šifra čestice	Čestica	Izvor
	KO5	Covid 19 pandemija potaknula me da istražim prednosti koje digitalne tehnologije mogu pružiti u poslovanju moje organizacije.	

Tablica 17 Konstrukt pritisak sudionika na tržištu

Konstrukt	Šifra čestice	Čestica	Izvor
Pritisak sudionika na tržištu (PST)	PST1	Upotrebu digitalnih tehnologija zahtijevaju važni poslovni partneri (kupci i dobavljači).	[13], [198].
	PST2	Upotrebu digitalnih tehnologija preporuča većina poslovnih partnera.	
	PST3	Glavni konkurenti koriste ili će uskoro koristiti digitalne tehnologije.	
	PST4	Ovisimo o drugim organizacijama koje već koriste digitalne tehnologije.	

Tablica 18 Konstrukt konkurentski prioriteti

Konstrukt	Čestica	Izvor
Konkurentski prioritet	Prihvaćanjem digitalnih tehnologijama prvenstveno želim postići sljedeće:	[183]
	Povećanje kvalitete. *Podići razinu kvalitete proizvoda i/ili usluga organizacije na način da se podigne njihova kvaliteta ili da se podigne kvaliteta samih aktivnosti unutar organizacija.*	
	Povećanje brzine. *Ubrzati procese unutar organizacije (ubrzanje isporuke proizvoda i/ili usluge, ubrzanje samih procesa unutar organizacije, skratiti vrijeme isporuke i osigurati isporuku što je prije moguće, ubrzati proces razvoja ideja, tj. skratiti vrijeme od ideje do tržišta).*	

Konstrukt	Čestica	Izvor
	Povećanje pouzdanosti. *Podići razinu pouzdanosti, pri čemu pouzdanost uključuje izgradnju povjerenja kupca i dobavljača u samu organizaciju te usluge i/ili proizvode koje organizacija nudi.*	
	Povećanje fleksibilnost. *Povećati fleksibilnost organizacije, tj. sposobnost organizacije na prilagođavanje različitim situacijama i promjenama na tržištu, kao i mogućnost reorganizacije cijele organizacije ukoliko se ukaže potreba za istim.*	
	Smanjenje troškova. *Pojednostaviti strukturu troškova organizacije. Omogućiti stvaranje uštede u poslovanju organizacije.*	

Tablica 19 Konstrukt stil odlučivanja

Konstrukt	Šifra čestice	Čestica	Izvor
Stil odlučivanja	**Racionalni stil odlučivanja**		
	RS1	Prije donošenja odluka volim prikupiti sve potrebne informacije.	[150]
	RS2	Prije donošenja konačne odluke detaljno procijenim sve mogućnosti (sve moguće alternative).	
	RS3	Prilikom donošenja odluka određeno vrijeme posvetim razmatranju argumenata za i protiv te rizike i benefite date situacije.	
	RS4	Istraživanje činjenica je važan dio mog procesa donošenja odluka.	
	RS5	Pri donošenju odluka važem nekoliko različitih čimbenika.	
	Intuitivni stil odlučivanja		
	IS1	Prilikom donošenja odluka uglavnom se oslanjam na intuiciju.	
	IS2	Prilikom donošenja odluka obično slijedim svoj instinkt.	

Konstrukt	Šifra čestice	Čestica	Izvor
	IS3	Moje odluke zasnivaju se na intuiciji.	
	IS4	Prilikom donošenja odluka oslanjam se na svoje prve utiske.	
	IS5	Prilikom donošenja odluka oslanjam se više na osjećaje nego na analizu.	

Tablica 20 Konstrukt namjera prihvaćanja

Konstrukt	Šifra čestice	Čestica	Izvor
Namjera prihvaćanja (NP)	NP1	Pod pretpostavkom da imam pristup digitalnim tehnologijama, namjeravam ga/ih koristiti.	[199]
	NP2	Pod pretpostavkom da imam pristup digitalnim tehnologijama, pretpostavljam da ću ga/ih koristiti.	

Tablica 21 Karakteristike ispitanika

Konstrukt	Čestica	Modalitet
Spol	Spol ispitanika	Muški Ženski
Dob	Dob ispitanika	do 30 godina 31-40 godina 41-50 godina 51-60 godina više od 60 godina
Obrazovanje	Obrazovanje ispitanika	srednja stručna sprema fakultet - VSŠ ili stručni studij
		fakultet - završen diplomski studij magisterij

Konstrukt	Čestica	Modalitet
		doktorat
Pozicija	Pozicija u organizaciji	direktor/ovlaštena osoba vlasnik, nositelj obrta vlasnik i direktor/ovlaštena osoba

Tablica 22 Karakteristike organizacije

Konstrukt	Čestica	Modalitet
Djelatnost	Djelatnost organizacije prema NKD 2007	A Poljoprivreda, šumarstvo i ribarstvo B Rudarstvo i vađenje C Prerađivačka industrija D Opskrba električnom energijom, plinom, parom i klimatizacija E Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša F Građevinarstvo G Trgovina na veliko i na malo; popravak motornih vozila i motocikla H Prijevoz i skladištenje I Djelatnosti pružanja smještaja te pripreme i usluživanja hrane J Informacije i komunikacije K Financijske djelatnosti i djelatnosti osiguranja L Poslovanje nekretninama M Stručne, znanstvene i tehničke djelatnosti N Administrativne i pomoćne uslužne djelatnosti O Javna uprava i obrana; obvezno socijalno osiguranje P Obrazovanje Q Djelatnosti zdravstvene zaštite i socijalne skrbi R Umjetnost, zabava i rekreacija

Konstrukt	Čestica	Modalitet
		S Ostale uslužne djelatnosti T Djelatnosti kućanstava kao poslodavaca; djelatnosti kućanstava koja proizvode različitu robu i pružaju različite usluge za vlastite potrebe U Djelatnosti izvan teritorijalnih organizacija i tijela
Veličina	Veličina organizacije	Mikro Mala Srednja Velika
Vrsta organizacije	Kojoj vrsti organizacije pripadate	Trgovačko društvo Ustanove, tijela, udruge i organizacije Obrti Zadruge
Županija	U kojoj županije je organizacija registrirana	Zagrebačka Krapinsko-zagorska Sisačko-moslavačka Karlovačka Varaždinska Koprivničko-križevačka Bjelovarsko-bilogorska Primorsko-goranska Ličko-senjska Virovitičko-podravska Požeško-slavonska Brodsko-posavska Zadarska Osječko-baranjska Šibensko-kninska Vukovarsko-srijemska Splitsko-dalmatinska Istarska Dubrovačka-neretvanska

Konstrukt	Čestica	Modalitet
		Međimurska Grad Zagreb

7.2. Populacija i uzorak

Uzorkovanje omogućava istraživaču da istraži mišljenje šire zajednice (populacije) na temelju manjeg ali pažljivo odabranog skupa osoba, kako bi procijenio parametar ili stvarnu prosječnu vrijednost populacije. Kako u većini istraživanja nije moguće ispitati cijelu populaciju primjenjuje se uzorkovanje [192]. Milas tumači populaciju kao širu zajednicu čije se mišljenje nastoji procijeniti, dok je uzorak podskup ili dio populacije izdvojen s ciljem njenog istraživanja i proučavanja [192].

Ciljana populacija u ovom istraživanju su mikro i male organizacije izuzev udruga, ustanova, javnih tijela i organizacija koje obavljaju neku vrstu ekonomske djelatnosti. Iz istraživanja će se isključiti organizacije koje pripadaju tzv. IT industriji. IT industrija podrazumijeva organizacije koje su registrirane za sljedeće djelatnosti prema NKD (2007): C 26.20, C 26.30, G 46.51, G 46.52, G 47.41, G 47.42, J 58.21, J 58.29, J 62.01, J 62.02, J 62.03, J 62.09, J 63.11, S 95.11 S 95.12 [10], [11]. Kako bi se to provelo u anketi se postavilo eliminacijsko pitanje koje je glasilo: „Pripada li Vaša organizacija IT sektoru, tj. je li organizacija registrirana za neku od sljedećih djelatnosti prema Nacionalnoj klasifikaciji djelatnosti**:** NKD (2007): C 26.20, C 26.30, G 46.51, G 46.52, G 47.41, G 47.42, J 58.21, J 58.29, J 62.01, J 62.02, J 62.03, J 62.09, J 63.11, S 95.11 S 95.12“?. U nastavku je podrobnije opisano što se smatra IT industrijom.

7.2.1. IT industrija

IT industrija uključuje organizacije koje se bave pružanjem IT usluga, proizvodnjom IT opreme i trgovinom IT proizvodima. Organizacije koje pružaju IT usluge se dijele na IT uslužna poduzeća u užem smislu, IT outsourcing poduzeća i softverski dobavljači *(engl. vendors)* [200].

- **IT uslužne organizacije** podrazumijevaju organizacije koje pružaju usluge kao što su razvoj i programiranje softvera po narudžbi klijenta. Čine najzastupljeniju kategoriju u IT industriji u Republici Hrvatskoj.

- **Softverski dobavljači** čine organizacije koje razvijaju gotove, pakirane softverske proizvode (engl. *packaged software*) te prodaju licence i pružaju usluge održavanja za upotrebu aplikacija u oblaku.

- **Proizvođači IT opreme i komponenata** podrazumijevaju organizacije koje proizvode softverom prožete proizvode, hardverske komponente i sastavljaju osobna računala.

- **Pružatelji outsourcing IT usluga** predstavljaju tri vrste organizacija: (1) organizacije u javnom vlasništvu koje pružaju usluge outsourcinga informatičkih sustava te upravljanja i hostinga aplikacija za tijela središnje i lokalne uprave, (2) organizacije koje pružaju informatičke usluge za svoja matična poduzeća (izdvojene informatičke usluge privatnih organizacija), (3) organizacije koje čine izdvojenu IT funkciju banaka, pretežito se bave procesiranjem kartičnog poslovanja.

- **Trgovci IT opremom** su organizacije koje prodaju IT opremu, njene komponente, rezervne dijelove i slično.

Prema Nacionalnoj klasifikaciji djelatnosti (NKD 2007) IT industrija uključuje organizacije registrirane za sljedeće djelatnosti: C 26.20 Proizvodnja računala i periferne opreme C 26.30 Proizvodnja komunikacijske opreme G 46.51 Trgovina na veliko računalima, perifernom opremom i softverom G 46.52 Trgovina na veliko elektroničkim i telekomunikacijskim dijelovima i opremom G 47.41 Trgovina na malo računalima, perifernim jedinicama i softverom u specijaliziranim prodavaonicama G 47.42 Trgovina na malo telekomunikacijskom

opremom u specijaliziranim prodavaonicama J 58.21 Izdavanje računalnih igara J 58.29 Izdavanje ostalog softvera J 62.01 Računalno programiranje J 62.02 Savjetovanje u vezi s računalima J 62.03 Upravljanje računalnom opremom i sustavom J 62.09 Ostale uslužne djelatnosti u vezi s informacijskom tehnologijom i računalima J 63.11 Obrada podataka, usluge poslužitelja i djelatnosti povezane s njima S 95.11 Popravak računala i periferne opreme S 95.12 Popravak komunikacijske opreme [200].

Prema podacima Hrvatske gospodarske komore broj IT organizacija u 2019. godini iznosio je 5.718, od čega njih 1.650 nije ostvarilo promet. IT organizacije čine 4,2% ukupnih organizacija u Republici Hrvatskoj, te zapošljavaju 3,4% ukupnog broja zaposlenih u nefinancijskom sektoru (33.031 zaposleni) [200]. Gledajući njihovu strukturu njih 50,6% su mikro uslužne IT organizacije [200]. U Republici Hrvatskoj vidljiv je i trend porasta tzv. softverskih „obrtnika“ malih IT uslužnih organizacija. Njihov procvat donijeli su porezni propisi koji su omogućili povoljniji porezni tretman novim malim organizacijama.

Organizacije koje pripadaju IT industriji isključit će se iz istraživanja zbog činjenice da pružaju usluge tipa: savjetovanja u vezi s računalima, upravljanja računalnom opremom i sustavima, računalnog programiranja i obrade podataka, kao i usluge u vezi s informacijskom tehnologijom i računalima, usluge poslužitelja i djelatnosti povezane s istim i slično [10]. Iz navedenog je vidljivo kako te organizacije svoje poslovne modele temelje na digitalnim tehnologijama, te je velika većina njih i pružatelj istih ostalim organizacijama. Upravo ta činjenica čini logičnim njihovo isključivanje iz istraživanja namjere korištenja digitalnih tehnologija.

7.2.2. Uzorak

Prema podacima Državnog zavoda za statistiku za lipanj 2020. godine u Republici Hrvatskoj ukupno je registrirano 285.869 pravnih osoba (svih veličina) od čega je njih 166.524 aktivno. Od 166.524 aktivnih pravnih osoba 62,2% odnosi se na trgovačka društva (132.258), 24,1% na zadruge (857) i 47,1% na ustanove, tijela, udruge i organizacije (33.409) [201]. Također je registrirano 87.310 obrta i slobodnih zanimanja [201], [202]. Prema podacima za 2014-2018. godinu postotak mikro i malih organizacija u ukupnom broju organizacija iznosio je 98% [46]. Prema podacima Državnog zavoda za statistiku i Hrvatske obrtničke komore u rujnu 2021. godine ukupan broj organizacija (mikro, malih i velikih) iznosio je 269.889 aktivnih

organizacija [44], [45]. Za pretpostaviti je kako se broj mikro i malih organizacija i dalje kreće u istom postotku.
Upitnici su upućeni direktorima i/ili vlasnicama organizacije koji su ključne osobe u organizaciji po odlučivanju [156].

U literaturi se izdvajaju dvije metode uzorkovanja: probalističke i neprobalističke metode. Probalistička metoda uzorkovanja temelji se na zakonima vjerojatnosti i pretpostavci da svaki član populacije ima znatnu ili nenultu vjerojatnost izbora u uzorak. Uključuje jednostavni slučajan uzorak, sustavni uzorak, stratificirani uzorak, uzorak klastera te stupnjeviti (višeetapni) uzorak [192]. Neprobalistička metoda uzorkovanja temelji se na prosudbi istraživača i potrebama istraživanja te uključuje: prigodni, kvotni i namjerni uzorak te tehniku snježne grude [192]. U glavnom istraživanju kao i u predistraživanju koristila se neprobabilistička metoda uzorkovanja – prigodni uzorak.

Prilikom odabira uzorka potrebno je voditi računa o njegovoj reprezentativnosti za koju ne postoji neki striktni i objektivni kriterij prosuđivanja. Reprezentativan uzorak je onaj koji će omogućiti dobivanje istih rezultata kao da se ispitivala cijela populacija [192]. Dakle, uzorak bi trebao imati ista obilježja kao i ukupna populacija. U ovom istraživanju to se postiglo na način da je u uzorku zastupljen isti udio različitih vrsta organizacija kao u ukupnoj populaciji, tj. raspodjela različitih vrsta organizacija (trgovačka društva, obrti) poklapa se sa stanjem u cijeloj populaciji.

Za izračun potrebne veličine uzoraka kod primjene PLS-SEM metode u literaturi se predlaže tzv. „rules of thumb“ koji govori kako bi minimalni uzorak za PLS-SEM trebao biti [203]:

- deset puta veći od broja formativnih manifestnih varijabli latentnog konstrukta, što bi značilo deset ispitanika po čestici ili
- deset puta veći od broja puteva strukturalnog modela usmjerenih prema endogenom latentnom konstruktu.

Prema navedenom kriteriju minimalan uzorak za ovo istraživanje iznosio bi 300 ispitanika. Hair i ostali naglašavaju kako pravilo 10 ispitanika po čestici tzv. „rule of thumb“ daje tek grube smjernice za minimalnu veličinu uzorka te naglašavaju kako istraživači prilikom definiranja veličine uzorka moraju istu prilagoditi svom modelu i cilju istraživanja [203].

Kao drugi način određivanja veličine uzorka pri primjeni PLS-SEM metode Hair i ostali navode da se istraživači mogu osloniti na Cohenova pravila dana u njegovoj statističkoj analizi snage za višestruke regresijske modele, pod uvjetom da mjerni modeli imaju prihvatljivu kvalitetu u smislu vanjskih opterećenja (opterećenja bi trebala biti iznad uobičajenog praga od 0,70) [203]. Za 8 varijabli, koliko ih je u ovom istraživanju, prema Cohenu potreban je uzorak od 238 ispitanika kako bi se postigla statistička snaga od 80% za detektiranje eksplanatorne (prediktivne) snage (R^2) od najmanje 0,10 uz vjerojatnost pogreške od 1% [203].

Klačmer u svom istraživanju za izračun veličine uzorka koristi Cochran-ovu formulu koja glasi [204], [21]:

$$n_0 = \frac{Z^2\, pq}{e^2} = \frac{(1.96)^2\,(.5).5)}{(.05)^2} = 385$$

n_0 = veličina uzorka,
e = stupanj preciznosti (pogreška uzorkovanja) podrazumijeva raspon pogreške koji se preuzima u istraživanju, uobičajeno se izražava u postotnim bodovima ± 5,
Z = ovisi o željenom stupnju pouzdanosti, kao standard u društvenim istraživanjima, stupanj pouzdanosti je 95% pri čemu je Z=1,96
p = stupanj varijabilnosti predstavlja postotak pojavnosti, predlaže se koristiti 50%
q = p-1

Primjenjujući navedenu formulu veličina uzorka za ovo istraživanja iznosila bi 385 organizacija. Za izračun potrebne veličine uzoraka dostupno je i nekoliko statističkih formula te nekoliko tablica i programa [205]. Veličina uzorka prema dostupnim tablicama za izračun veličine uzorka, uz isti stupanj pouzdanosti, iznosi 384 [205], [206].

Iz navedenog se može zaključiti kako bi adekvatna veličina uzorka za ovo istraživanje iznosila 400 organizacija. Pristigli broj adekvatno ispunjenih upitnika iznosio je 432 čime je zadovoljen uvjet veličine uzorka.

7.3. Validacija mjernog instrumenta – anketnog upitnika

Finalni anketni upitnik predočen je u Google forms aplikaciji te je provjera razumljivosti pitanja i konteksta istraživanja napravljena u predistraživanju. Isto je tako u predistraživanju provjerena i pouzdanost mjernog instrumenta.

Unatoč tome što se anketni upitnik većinom temelji na preuzetim konstruktima koji su pomoću sitnih preinaka prilagođeni cilju istraživanja i koji su u prethodnim istraživanjima potvrđeni kao pouzdani i valjani, u glavnom istraživanju će se provesti provjera valjanosti i pouzdanosti mjernog instrumenta.

7.3.1. Predistraživanje

Nakon testiranja upitnika, koji je sadržavao čestice prevedene s engleskog na hrvatski jezik, u aplikaciji Google forms je formiran finalni oblik upitnika. Napravljeno je predistraživanje sa svrhom provjere razumljivost pitanja i konteksta istraživanja. Ispitanicima je poslan link na anketu te ih se zamolilo da povratno jave svoja zapažanja i predlože izmjene ukoliko procijene da su iste potrebne. Ukupno je 30 ispitanika sudjelovalo u predistraživanju.

Predistraživanje je ključna faza u kreiranju mjernog instrumenta istraživanja s obzirom da se na taj način provjerava da li ciljana skupina razumije postavljena pitanja i predložene opcije odgovora [207]. Literatura sugerira 30 do 50 ispitanika za pilot istraživanje, 30 je minimum kako bi se detektirale i otklonile eventualne nejasnoće u upitniku [207]. Ispitanici u predistraživanju nisu imali primjedbe na odaslani upitnik te su ocijenili pitanja razumljivim i jasnim. Predistraživanjem se provjerila pouzdanost mjernog instrumenta.

7.3.2. Glavno istraživanje

Glavno istraživanje provedeno je koristeći aplikaciju Google forms koja se pokazala prikladna i zadovoljavajuća za njegovo provođenje. Kako bi se izbjegla neodgovorena pitanja *(engl. missing values)* u aplikaciji su sva pitanja označena kao obvezna.

Pouzdanost i valjanost mjernog instrumenta testirana je u glavnom istraživanju.

7.3.2.1. Pouzdanost

Ocjenjivanje pouzdanosti moguće je kroz dvije metode: metodu stabilnosti i metodu unutarnje konzistentnosti. U ovom istraživanju pouzdanost se ocijenila metodom konzistentnosti koja se „temelji na mjerenju istog konstrukta s više jednako vrijednih varijabli, tj. primjenom više različitih varijabli koje mjere istovjetan konstrukt“ [208]. Uključuje metodu ekvivalentnih polovina i koeficijent unutarnje dosljednosti. U ovom istraživanju primijenit će se koeficijent unutarnje dosljednosti koji je ujedno i najčešći postupak u testiranju pouzdanosti mjernog instrumenta. Koeficijent unutarnje dosljednosti mjeri unutarnju dosljednost, tj. konzistentnost mjernog instrumenta. Podrazumijeva postupak koji se temelji na varijancama i kovarijancama među česticama mjernog instrumenta [208]. Unutarnja dosljednost mjernog instrumenta mjeri se koeficijentom pouzdanosti Cronbach alfa koji nudi odgovor na pitanje da li skup čestica u pojedinom konstruktu donosi dosljedne rezultate [208]. Za prihvatljivu pouzdanost navodi se kako bi vrijednosti koeficijenta pouzdanosti trebale biti veće od 0,7, no naglašava se kako treba težiti koeficijentima iznad 0,8 [208]. Pouzdanost mjernog instrumenta osigurat će da drugi istraživači pri ponovljenim istraživačkim postupcima dobiju istovjetne rezultate o njegovoj pouzdanosti [208].

7.3.2.2. Valjanost

Za razliku od pouzdanosti koja govori o preciznosti mjerenja, valjanost govori o točnosti mjerenja. Procjenjujući valjanost u suštini se mjeri da li mjerni instrument mjeri uistinu ono što mislimo da mjerimo, tj. pokušava se utvrditi mjeri li instrument i u kojem stupnju ono što zapravo njime želimo mjeriti [192]. U tom smislu Horvat i Mijoč ističu kako se „valjanost mjernog instrumenta odnosi na ispravnost mjerenja konstrukta“, tj. utvrđuje se da li kreirani konstrukt mjeri ono što se želi mjeriti [208]. Valjanost je teže procijeniti za razliku od pouzdanosti pošto ne postoji striktna statistička procedura. Najvažnije i najčešće vrste valjanosti su sadržajna, konstruktna te kriterijska valjanost [203], [21].

Sadržajna valjanost procjenjuje „koliko je dobro mjernim instrumentom pokriven sadržaj predmeta mjerenja te je li zastupljenost pojedinih sadržaja odgovarajuća“ [209]. Zapravo se odnosi na sadržajnu i logičku analizu čestica unutar mjernog instrumenta kao i cijelog upitnika [208]. Instrument je sadržajno valjan ukoliko adekvatno prikazuje područja sadržaja koji se

mjeri zajedno s njegovih specifičnim svojstvima. Za sadržajnu valjanost ne postoje statistički kriteriji te ju nije moguće izraziti nekim relativno objektivnim brojčanim pokazateljem, već uključuje kvalitativnu procjenu i teorijsko dokazivanje [209]. Činjenica kako je većina konstrukta i čestica u ovom istraživanju preuzeta iz prethodnih istraživanja ukazuje na sadržajnu valjanost instrumenta. Samani ističe kako procjena sadržajne valjanosti u većini istraživanja uključuje: 1) opsežan pregled literature u području istraživanja, 2) analizu čestica od strane stručnjaka iz područja istraživanja, 3) provođenje predistraživanja te 4) selekciju čestica temeljenu na koeficijentima i faktorskoj analizi [210].

Kriterijska valjanost utvrđuje „u kojoj su mjeri rezultati dobiveni na instrumentu povezani s rezultatima na nekoj drugoj varijabli koja figurira vanjski kriterij valjanosti. Stupanj povezanosti rezultata na instrumentu i kriterija jedini je relevantni pokazatelj kriterijske valjanosti instrumenta“ [209].

Konstruktna valjanost nudi odgovor na pitanje „je li odnos među rezultatima mjerenja različitih entiteta u skladu s teorijskim hipotezama koje se tiču konstrukta koji se mjeri“ [209]. Drugim riječima, ukoliko je teorijski model razrađeniji njegova procjena konstruktne valjanosti instrumenta će biti detaljnija i potpunija [209]. Prilikom procjene konstruktne valjanosti izdvajaju se dvije vrste valjanosti: konvergentna i diskriminantna valjanost. Konvergentna valjanost služi kako bi se ispitao stupanj povezanosti testiranog mjernog instrumenta s istim ili sličnim mjernim instrumentom, dok diskriminantna valjanost služi kako bi se ispitala povezanost dva konceptualno različita konstrukta [208].

Brown navodi kako konvergentna valjanost ukazuje da različiti pokazatelji teorijski sličnih ili preklapajući konstrukata međusobno snažno koreliraju, dok diskriminantna valjanost ukazuje da pokazatelji teoretski različitih konstrukta međusobno ne koreliraju [211].

Konvergentna valjanost mjerena je pomoću prosječne ekstrahirane varijance *(engl. Avarage Variance Extracted -AVE)* [212]. AVE vrijednost za pojedini konstrukt mora iznosit 0,5 ili više [78].

Diskriminantna valjanost testirana je kako bi se potvrdilo da varijable unutar određenog faktora ne koreliraju jako sa varijablama u nekom drugom faktoru. Kako bi se to potvrdilo potrebno je da kvadrat AVE vrijednosti svakog konstrukta bude veći od korelacije tog konstrukta i bilo

kojeg drugog konstrukta, isto tako korelacija između svakog para latentnog egzogenog konstrukta trebala bi biti manja od 0,85 [212], [78].

Kako bi se procijenila valjanost mjernog instrumenta primijenila se konfirmativna faktorska analiza (*engl. confirmatory factor analysis CFA*). Konfirmativna faktorska analiza „pretpostavlja postojanje unaprijed formuliranog modela, hipoteze ili teorije o strukturi temeljnih izvora varijacija i kovarijacija među promatranim varijablama“ [209]. Najčešće se upotrebljava prilikom provjere postojećeg mjernog instrumenta s ciljem provjere strukture upitnika. Brown ističe kako je konfirmatorna faktorska analiza jedan od primjenjivijih analitičkih alata u istraživanjima na području društvenih i bihevioralnih znanosti naglašavajući kako upravo ta analiza pruža dokaze o konvergentnoj i diskriminantnoj valjanosti teorijskih konstrukcija [211].

7.4. Validacija konceptualnog modela istraživanja

Za testiranje konceptualnog modela i za evaluaciju postavljenih hipoteza koristilo se modeliranje strukturalnim jednadžbama (*engl. Structural equation modeling, SEM*). Strukturalno modeliranje jednadžbama predstavlja složenu multivarijantnu statističku metodu koja osim što omogućuje testiranje teorija omogućuje i utvrđivanje uzročno-posljedičnih odnosa između pojava [213].

SEM predstavlja statistički pristup koji ima za cilj provjeriti pretpostavljene odnose između opaženih i latentnih varijabli [192]. Složenost metode vidljiva je u činjenici kako je utemeljena na konfirmatornoj faktorskoj analizi, regresijskoj analizi i drugim multivarijantnim statističkim metodama [213]. Milas navodi kako se u najvećoj mjeri metoda oslanja na regresijsku i faktorsku analizu [192]. Svrha strukturalnog modeliranja je utvrđivanje „struktura manifestnih (opaženih) varijabli koje opisuju latentnu varijablu (konstrukt), pojavu ili proces i određuju njihov hipotetički uzročno-posljedični odnos. Struktura latentnih varijabli i njihov hipotetički kauzalni odnos prikazuju se dijagramom“ [214]. Orehovački ističe kako se SEM upotrebljava u analizi konceptualnog modela koji je sačinjen od različitih međuodnosa latentnih i manifestnih varijabli te povezanosti između endogenih i egzogenih latentnih konstrukata [216].

Terminologiju SEM metode u svom radu iscrpno objašnjava Klačmer navodeći kako se upotreba termina „zavisna“ i „nezavisna“ varijabla u SEM modelu zamjenjuje endogenom (unutarnjom) i egzogenom (vanjskom) latentnom varijablom. Varijable koje nisu uzrokovane drugim varijablama u modelu su egzogene (vanjske, „nezavisne“) varijable dok one koje su uzrokovane drugim varijablama su endogene (unutarnje, „zavisne“) [21].

SEM model sastoji se od dva podmodela i to: 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) [21].

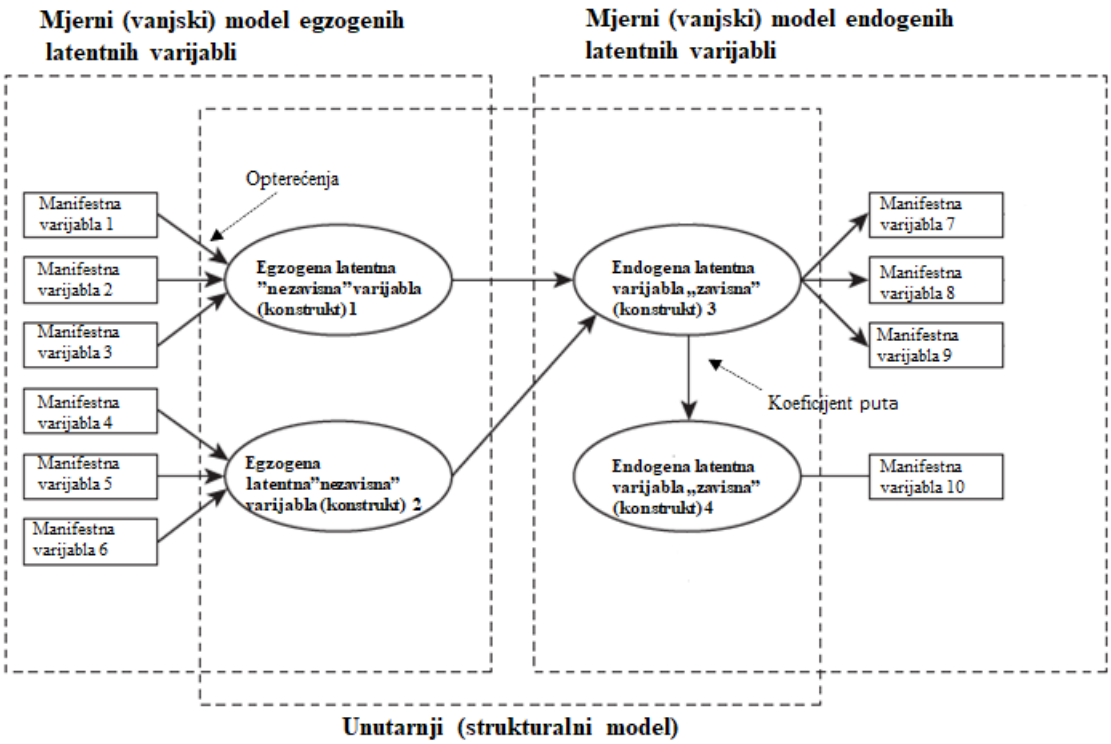

Slika 9 SEM dijagram puta

Izvor: [215]

Grafički prikaz sustava jednadžbi u SEM metodi naziva se dijagram puta (slika 9), koji omogućava pojednostavljenje u odnosu na matematički iskazane jednadžbe [192]. Konvencije koje sadrži uključuju pravokutnike koji predstavljaju opažene ili mjerene varijable (tzv. indikatori ili manifestne varijable koje predstavljaju pitanja mjerena na skali), dok elipse ili kružnice predstavljaju latentne varijable (tzv. čimbenici ili konstrukti ili neopažene varijable) [192], [21].

Promatrajući istraživanja u području informacijskih sustava upravo je SEM jedna od najučestalijih metoda razvoja novih i testiranja postojećih teorija. Orehovečki navodi dvije skupine tehnika modeliranja strukturalnim jednadžbama [216]:

- SEM baziran na kovarijanci (*engl. covariance based SEM, CB-SEM*) koji omogućava analizu modela strukturalnih jednadžbi primjenom alata kao što su AMOS i LISREL,
- SEM baziran na varijanci (*engl. variance based SEM, component based SEM*) s dva smjera: 1) *engl.Generalized Structured Component Analysis* - GSCA koja primjenjuje alat VisualGSCA te 2) analiza puta tehnikom parcijalnih najmanjih kvadrata (*engl. partial least squares SEM, PLS-SEM*) koja je ujedno i najznačajnija predstavnica skupine koja primjenjuje alate kao što su: PLSGraph i SmartPLS.

Hair i ostali objašnjavajući razlike između dviju navedenih skupina (PLS-SEM- a i CB- SEM- a) naglašavaju potrebu sagledavanja njihovih ciljeva i karakteristika te načina na koji pojedini model tretira latentnu varijablu uključenu u model [215]. U vezi s navedenim ističu kako se PLS-SEM primjenjuje kada je [215]:

- cilj predviđanje ključnih konstrukta ili identificiranje ključnog „pokretača“ konstrukta,
- mjerni formativni konstrukt dio strukturalnog modela,
- složen strukturalni model (puno konstrukata i indikatora),
- uzorak mali i podaci nisu normalno distribuirani,
- namjera primjenjivati latentne varijable u naknadnim analizama.

Dok se CB-SEM primjenjuje kada:

- je cilj testirati, potvrditi ili usporediti alternativne teorije,
- uvjeti pogreške zahtijevaju dodatne specifikacije,
- strukturalni model ima rekurzivne odnose,
- istraživanje zahtijeva pokazatelje podudaranja *(engl. goodness-of-fit).*

Iz prethodno navedenog razvidno je kako je za ovo istraživanje prikladna upotreba PLS SEM metode koja omogućava analizu kompleksnih modela. Metoda se koristi u istraživanjima gdje je cilj predviđanje ili proširenje postojeće strukturne teorije te je primjenjiva na malom uzorku [216].

Kao što je ranije navedeno SEM metoda uključuje procjenu vanjskog (mjernog) i unutarnjeg (strukturalnog) modela. Vanjski (mjerni) model opisuje povezanost između opaženih i latentnih varijabli, dok unutarnji (strukturalni) model uključuje povezanost između latentnih varijabli bez da uključuje opažene varijable.

7.4.1. Procjena vanjskog (mjernog) modela

Procjena vanjskog (mjernog) modela, kao što je vidljivo na slici 9, uključuje ispitivanje povezanosti između manifestnih (opaženih) varijabli i latentnih varijabli, odnosno ispituje povezanost između definiranih konstrukta i definiranih čestica. Procjena vanjskog modela odvija se na način da se:

- ispituje pouzdanost i valjanost manifestnih (opaženih) varijabli, tj. definiranih čestica. Kako bi se ispitala pouzdanost svake pojedine čestice potrebno je utvrditi njihova vanjska faktorska opterećenja *(engl. indicator outer loadings)* koja se trebaju kretati u rasponu između 0,60 i 0,70 [215]. Prije uklanjanja manifestnih varijabli s vrijednosti između 0,4 i 0,7 treba provjeriti da li njihovo uklanjanje rezultira povećanjem kompozitne pouzdanosti [215],

- ispituje unutarnja dosljednost *(engl. internal consistency reliability),* tj. pouzdanost konstrukta primjenom Cronbach alfa koeficijenta i kompozitne pouzdanosti (CR – composite reliability). Kompozitna pouzdanost izračunava se pomoću kvadrirane sume standardiziranih faktorskih opterećenja za sve latentne konstrukte i sume greške varijance latentnih konstrukta [215]. Vrijednosti jednake ili veće od 0,7 ukazuju na dobru pouzdanost i unutarnju povezanost, dok vrijednosti između 0,6 i 0,7 ukazuju na prihvatljivu pouzdanost [215],

- ispituje diskriminantnu i konvergentnu valjanost. Diskriminantna valjanost ukazuje koliko se konstrukt razlikuje od drugih konstrukta u modelu, dok konvergentna valjanost ukazuje na povezanost između varijabli koje mjere isti konstrukt. Konvergentna valjanost procjenjuje se prosječnom ekstrahiranom (izlučnom) varijancom *(engl. Avarage Varianve Extracted -AVE),* čija je prihvatljiva vrijednost 0,5 i više, što znači da određeni konstrukt objašnjava u prosjeku 50% ili više

varijance pridruženih manifestnih varijabli [215]. Diskriminantna vrijednost procjenjuje se Fornell Larcker kriterijem koji je drugi korijen AVE indikatora. Konstrukt posjeduje diskriminantnu vrijednost onda kada je drugi korijen AVE indikatora pojedinog konstrukta veći od korelacije tog konstrukta i ostalih konstrukata u vanjskom reflektivnom modelu [215]. Ispitivanje diskriminantne valjanosti može se izvesti i izračunom unakrsnih standardiziranih faktorskih opterećenja *(engl. cross-loadings)* pri čemu je potrebno da manifestne varijable imaju veći stupanj korelacije s onom latentnom varijablom koju opisuju nego s ostalim latentnim varijablama.

7.4.2. Procjena unutarnjeg (strukturalnog) modela

Procjenom unutarnjeg (strukturalnog) modela procjenjuje se povezanost egzogenih latentnih konstrukata (koji predstavljaju nezavisne varijable) s endogenim latentnim konstruktima (koji predstavljaju zavisne varijable) (slika 9). Strukturni model u svojoj biti predstavlja konceptualni model gdje se ispituje strukturalna povezanost latentnih konstrukata, kao i evaluacija postavljenih hipoteza [213], [215]. Uključuje sljedeće korake:

- ispitivanje kolinearnosti između latentnih konstrukta kako bi se provjerilo postojanje značajne razine kolinearnosti između pojedinog skupa predikatorskih varijabli. Ispituje se pomoću faktora inflacije varijance *(engl. variance inflation factor VIF)* koji bi trebao biti u rasponu od 0,2 do 5. VIF vrijednost viša od 5 kod PLS-SEM metode ukazuje na problem kolinearnosti [215],

- izračun korigiranog koeficijenta determinacije (R^2) koji ima ulogu ukazati na kvalitetu prilagođenog modela. Koeficijent predstavlja „mjeru prediktivne snage i ukazuje na količinu varijance u konstruktu (endogenoj varijabli) koja je objašnjena prethodnim varijablama u strukturalnom modelu“ [215],

- izračun prediktivne relevantnosti *(engl. predictive relevance)* „koja se utvrđuje blindfolding procedurom primjenom unakrsno validirane redudance *(engl. cross valid redudance)* i koja isto tako vrši predikciju izostavljenih endogenih manifestnih varijabli s pomoću vrijednosti egzogenih latentnih konstrukata

izračunom Stone-Geisserov Q^2 pokazatelja“ [213]. Vrijednost Q^2 veća od 0 ukazuje da model ima prediktivnu relevantnost za određeni endogeni konstrukt, vrijednosti od 0 i niže ukazuju na nedostatak prediktivne relevantnosti. Vrijednosti veće od 0 ukazuju na malu prediktivnu relevantnost, vrijednost veća od 0,25 ukazuje na srednju prediktivnu relevantnost, dok vrijednost veća od 0,50 ukazuje na veliku prediktivnu relevantnost PLS modela [215], [217],

- izračun koeficijenta veličine učinka - Cohen-ov f^2 koeficijent *(engl. effect size)* koji govori o jačini utjecaja pojedinog egzogenog latentnog konstrukta na endogeni latentni konstrukt, tj. ima li nezavisna latentna varijabla značajan utjecaj na zavisnu. Vrijednost od 0,02 predstavlja mali utjecaj, vrijednost od 0,15 srednji utjecaj te vrijednost od 0,35 predstavlja veliki utjecaj [218],

- izračun relevantnosti koeficijenta puta *(engl. path coefficient)* i njihove statističke značajnosti. Koeficijent puta ukazuje na utjecaj na endogenu varijablu, tj. ukoliko je jedan koeficijent puta veći od drugog time je i njegov utjecaj na endogenu varijablu veći. Vrijednosti se kreću od -1,00 do +1,00 pri čemu vrijednosti bliže +1,00 ukazuju na statistički jaku pozitivnu vezu među varijablama. Koeficijent puta zapravo prikazuje direktan utjecaj nezavisne varijable na zavisnu, tj. ukazuje udio određenih endogenih latentnih varijabli u objašnjavanju zajedničke varijance [215]. Za utvrđivanje statističke značajnosti koeficijenta puta između egzogenih i endogenih latentnih konstrukata u unutarnjem modelu upotrebljava se tzv. bootstrapping procedura. Iz originalnog uzorka nasumično se odabiru opažanja iz kojih se generiraju uzorci. Bootstrapping uzorci generiraju se tako da se iz originalnog uzorka nasumično odabiru opažanja te zatim PLS algoritam za sve bootstrapping uzorke izračunava koeficijente puta, odnosno distribuciju procijenjenih koeficijenata puta. Na temelju te distribucije algoritam računa standardnu pogrešku i standardnu devijaciju procijenjenih koeficijenata. Vrijednosti dobivene bootstrapping procedurom omogućuju izračun t-statistike na temelju koje se može utvrditi signifikantnost određenog koeficijenta puta [21]. Ukoliko je t-vrijednost veća od referentne vrijednosti 1,96 za stupanj signifikantnosti $\alpha = 5$ %, pretpostavlja se da je koeficijent puta signifikantno drugačiji od nule i prihvaća se hipoteza o značajnosti koeficijenta puta. Za procjenu signifikantnosti u literaturi se izdvaja

p- vrijednost *(engl. p values).* P vrijednost se dobiva zajedno s t vrijednosti u bootstrapping proceduri te je njena primjena učestalija prilikom potvrđivanja hipoteza, tj. utvrđivanja povezanosti dviju varijabli. Uobičajeni stupanj signifikantnosti iznosi 5% pri čemu p vrijednost manja od 0,5 ukazuje na postojanje signifikantnosti [203].

7.5. Moderirajući utjecaj

Istraživanje uključuje ispitivanje moderirajućeg utjecaja digitalne zrelosti, stila odlučivanja i konkurentskih prioriteta. Moderirajuća varijabla, tj. konstrukt direktno utječe na vezu egzogene na endogenu latentnu varijablu - konstrukt. Moderirajući utjecaj odnosi se na situaciju kada moderator (nezavisna varijabla ili konstrukt) promjeni jačinu ili smjer utjecaja, tj. veze između dva konstrukta u modelu [203]. Moderator varijabla je zapravo određeno obilježje ispitanika koje može utjecati na povezanost dviju varijabli [214]. Postoje dva tipa moderirajućeg utjecaja i to: kontinuirani i kategorički. Kontinuirani moderirajući utjecaj postoji kada se moderirajuća varijabla mjeri metrički, dok je kategorički moderirajući utjecaj kada je moderirajuća varijabla kategorička. Kategorička varijabla služi kao varijabla za grupiranje te dijeli uzorak u podskupine, tj. poduzorke. Nakon što se podijeli u poduzorke isti teoretski model se procjenjuje za svaku skupinu. Cilj je utvrditi postoje li statistički značajne razlike između pojedinih grupa što se postiže upotrebom višegrupne analize. Višegrupna analiza uspoređuje isti model kroz različite grupe u uzorku [203].
U istraživanju su sve tri varijable (digitalna zrelost, stil odlučivanja i konkurentski prioriteti) kategoričke pri čemu digitalna zrelost ima tri grupe, stil odlučivanja dvije grupe i konkurentski prioriteti pet grupa.

7.6. Izračun digitalne zrelosti

Izračun digitalne zrelosti organizacije preuzet će se iz istraživanja Blatz i ostalih koji u svojem istraživanju predlažu model digitalne zrelosti za mala i srednja poduzeća [190]. U anketnom upitniku čestice digitalne zrelosti mjerene su ordinalnom skalom od 1 do 5. Za potrebe izračuna digitalne zrelosti svaka čestica vrednovala se na način da 1 na ordinalnoj skali iznosi 0 bodova, dok 5 na ordinalnoj skali iznosi 4 boda.

Nakon vrednovanja izračunala se srednja vrijednost za svaku pojedinu česticu. Zatim se izračunala srednja vrijednost za svaku pojedinu dimenziju. Na taj način dobio se uvid u razvijenost svake pojedine dimenzije.

Za izračun sveukupne razine digitalne zrelosti izračunat će se težine (važnost, udio) svake pojedine dimenzije u odnosu na sve dimenzije. Nakon dobivene važnosti svake pojedine dimenzije zbrojio se umnožak srednje vrijednosti pojedine dimenzije s njenom važnošću kako bi se dobila razina zrelosti.

8. REZULTATI EMPIRIJSKOG ISTRAŽIVANJA

U nastavku su prikazani rezultati provedene univarijantne i multivarijantne statističke analize prikupljenih podataka. Podaci su prikupljeni putem aplikacije Google forms koja je onemogućila nedostatak podataka *(engl. missing data).* Uključivanjem opcije obveznog odgovora ispitanici su morali odgovoriti na svako od postavljenih pitanja ukoliko su željeli anketu ispuniti u cijelosti. Anketni upitnici distribuirani su u razdoblju siječanj-ožujak 2022. godine. Karakteristike ispitanika i organizacija iz uzorka kao i deskriptivna statistika obrađeni su pomoću Microsoft Excela i IBM SPSS-a.

Multivarijantna analiza izvedena je putem PLS SEM-a koji je napravljen u programu SmartPLS3, dok je za potrebe konfirmativne faktorske analize korišten programa IBM SPSS Amos 26 i CB-SEM.

Nakon prikaza rezultata predistraživanja, koje je obuhvatilo obradu karakteristika ispitanika i organizacija te provjeru pouzdanosti mjernog instrumenta, prikazani su rezultati glavnog istraživanja. Nakon obrade karakteristika ispitanika i organizacija iz uzorka prikazat će se rezultati izračuna digitalne zrelosti organizacija iz uzorka, stil donositelja odluke iz uzorka te željeni konkurentski prioriteti organizacija prilikom prihvaćanja digitalnih tehnologija (uslužnog računalstva i pametnih ugovora). Zatim slijedi validacija konceptualnog modela istraživanja i rezultati testiranja postavljenih hipoteza. Na kraju su prikazani rezultati moderirajućeg utjecaja i rezultati pripadajućih hipoteza.

8. 1. Predistraživanje

8.1.1. Karakteristike ispitanika i organizacija predistraživanja

U tablicama u nastavku prikazane su karakteristike ispitanika i karakteristike organizacija iz uzorka predistraživanja (tablica 23 i 24). U predistraživanju sudjelovalo je ukupno 30 ispitanika, od čega je 56,7% bilo žena i 43,3% muškaraca. Većina ispitanika (26,7%) bilo je u dobnoj skupini od 31 do 40 godina sa završenim diplomskim studijem (43,3%) (tablica 23). Prema karakteristikama organizacija u predistraživanju 40% organizacija su mikro organizacije, dok je 60% malih organizacija koje većinom čine trgovačka društva (63,33%).

Većini organizacija pretežita djelatnost je građevinarstvo (23,3%) te se nalaze u Gradu Zagrebu (23,3%) (tablica 24).

Tablica 23 Karakteristike ispitanika iz uzorka predistraživanja

Varijabla	**Kategorija**	**Broj**	**Struktura %**
Spol	Muški	13	43,3
	Ženski	17	56,7
Ukupno		***30***	***100***
Dob	do 30 godina	2	6,7
	31-40 godina	8	26,7
	41-50 godina	12	40
	51-60 godina	4	13,3
	više od 60 godina	4	13,3
Ukupno		***30***	***100***
Obrazovanje	srednja stručna sprema	8	26,7
	fakultet - VSŠ ili stručni studij	4	13,3
	fakultet - završen diplomski studij	13	43,3
	magisterij	4	13,3
	doktorat	1	3,3
Ukupno		***30***	***99,9***
Pozicija u organizaciji	direktor/ovlaštena osoba	7	23,3
	vlasnik i direktor/ovlaštena osoba	12	40
	vlasnik/nositelj obrta	11	36,7
Ukupno		***30***	***100***

Tablica 24 Karakteristike organizacija iz uzorka predistraživanja

Varijabla	**Kategorija**	**Broj**	**Struktura %**
	Mikro	12	40

Varijabla	Kategorija	Broj	Struktura %
Veličina organizacije	Mala	18	60
Ukupno		***30***	***100***
Vrsta organizacije	Trgovačko društvo	19	63,33
	Obrti	11	36,67
Ukupno		***30***	***100***
Pretežita djelatnost organizacije	C Prerađivačka industrija	2	6,7
	F Građevinarstvo	7	23,3
	G Trgovina na veliko i na malo; popravak motornih vozila i motocikla	2	6,7
	H Prijevoz i skladištenje	1	3,3
	K Financijske djelatnosti i djelatnosti osiguranja	3	10
	M Stručne, znanstvene i tehničke djelatnosti	5	16,7
	N Administrativne i pomoćne uslužne djelatnosti	3	10
	P Obrazovanje	1	3,3
	Q Djelatnosti zdravstvene zaštite i socijalne skrbi	2	6,7
	S Ostale uslužne djelatnosti	4	13,3
Ukupno		***30***	***100***
Županija sjedišta organizacije	Zagrebačka	2	6,7
	Karlovačka	1	3,3
	Varaždinska	9	30
	Primorsko-goranska	3	10
	Virovitičko-podravska	2	6,7
	Brodsko-posavska	1	3,3
	Zadarska	1	3,3
	Osječko-baranjska	1	3,3
	Istarska	2	6,7
	Međimurska	1	3,3
	Grad Zagreb	7	23,3
Ukupno		***30***	***100***

U tablici 25 prikazan je stil odlučivanja donositelja odluka organizacija u predistraživanju kao i razina digitalne zrelosti organizacija u pogledu digitalne transformacije. Većina donositelja odluka ima racionalni stil odlučivanja (83,3%) te većina organizacija pripada drugoj razini digitalne zrelosti (43,3%). I na kraju u tablici 26 prikazani su konkurentski prioriteti koje organizacije iz uzorka predistraživanja žele postići prihvaćanjem uslužnog računalstva i pametnih ugovora. Prihvaćanjem uslužnog računalstva organizacije iz predistraživanja prvenstveno žele postići smanjenje troškova (23,3%), kao i kod prihvaćanja pametnih ugovora (36,7%).

Tablica 25 Stil odlučivanja donositelja odluka u organizacijama iz uzorka predistraživanja i razina njihove digitalne zrelosti

Varijabla		**Broj**	**Struktura %**
Stil odlučivanja	Intuitivni	5	16,7
	Racionalni	25	83,3
Ukupno		***30***	***100***
Digitalna zrelost	1 razina	11	36,7
	2 razina	13	43,3
	3 razina	6	20
Ukupno		***30***	***100***

Tablica 26 Konkurentski prioriteti organizacija iz uzorka predistraživanja

Varijabla		**Broj**	**Struktura %**
Uslužno računalstvo	Brzina	2	6,7
	Fleksibilnost	6	20
	Kvaliteta	12	40
	Pouzdanost	3	10
	Troškovi	7	23,3
Ukupno		**30**	**100**
Pametni ugovori	Brzina	4	13,3
	Fleksibilnost	4	13,3

Varijabla		Broj	Struktura %
	Kvaliteta	7	23,3
	Pouzdanost	4	13,3
	Troškovi	11	36,7
Ukupno		**30**	**100**

8.1.2. Pouzdanost mjernog instrumenta predistraživanja

Pouzdanost mjernog instrumenta provjerila se Cronbach alfa koeficijentom koji pretpostavlja da su sve čestice jednako pouzdane. Vrijednosti iznad 0,7 ukazuju na pouzdanost skale [215]. Dobiveni rezultati ukazali su na potrebu modifikacije unutar konstrukta „Razina znanja (RZ)“ kako kod prihvaćanja uslužnog računalstva tako i kod prihvaćanja pametnih ugovora. Modifikacija je uključivala uklanjanje jedne čestice *RZ1 (Svoje razumijevanje uslužnog računalstva/pametnih ugovora ocjenjujem vrlo dobrim)*. Tablicama u nastavku prikazane su vrijednosti Cronbach alfa prije i nakon uklanjanja čestice (tablica 27 i 28).

Tablica 27 Cronbach alfa prije i nakon modifikacija – uslužno računalstvo

Uslužno računalstvo				
Konstrukt	**Prije modifikacije**		**Nakon modifikacije**	
	Broj čestica	**Cronbach alfa**	**Broj čestica**	**Cronbach alfa**
Razina znanja (RZ)	4	0,641	3	0,815

Tablica 28 Cronbach alfa prije i nakon modifikacija – pametni ugovori

Pametni ugovori				
Konstrukt	**Prije modifikacije**		**Nakon modifikacije**	
	Broj čestica	**Cronbach alfa**	**Broj čestica**	**Cronbach alfa**
Razina znanja (RZ)	4	0,609	3	0,793

Nakon provedene modifikacije finalni rezultati Cronbach alfa koeficijenta prikazani su u tablici 29. Razvidno je kako su svi konstrukti iznad 0,7 kako za prihvaćanje uslužnog računalstva tako i za prihvaćanje pametnih ugovora. U glavno istraživanje krenulo se s modificiranim mjernim instrumentom.

Tablica 29 Cronbach alfa koeficijent pouzdanosti skala korištenih u predistraživanju

Konstrukt	**Uslužno računalstvo**		**Pametni ugovori**	
	Broj čestica	**Cronbach alfa**	**Broj čestica**	**Cronbach alfa**
Percipirani financijski rizik (PFR)	4	0,896	4	0,796
Percipirani sigurnosni rizik (PSR)	5	0,834	5	0,729
Percipirani gubitak vremena (PGV)	4	0,927	4	0,903
Percipirani pritisak države (PPD)	4	0,903	4	0,893
Razina znanja (RZ)	3	0,815	3	0,793
Krizne okolnosti (KO)	5	0,837	5	0,881
Pritisak sudionika na tržištu (PST)	4	0,795	4	0,842
Namjera prihvaćanja (NP)	2	0,968	2	0,956

U tablici 30 prikazani su rezultati pouzdanosti skale za digitalnu zrelost i stil odlučivanja.

Tablica 30 Cronbach alfa koeficijent pouzdanosti skala korištenih u predistraživanju – digitalna zrelost i stil odlučivanja

Konstrukt	**Broj čestica**	**Cronbach alfa**
Resursi za provedbu digitalne transformacije (D_RESDT)	3	0,813
Korištenje naprednih tehnologija (D_KNT)	5	0,880
Efikasnost upravljanja tehnologijama (D_EUT)	5	0,925
Otvorenost i komunikacija (D_OK)	3	0,902
Prihvaćanje rizika (D_PR)	3	0,860

Konstrukt	Broj čestica	Cronbach alfa
Racionalni stil odlučivanja (RS)	5	0,951
Intuitivni stil odlučivanja (IS)	5	0,937

8.2. Glavno istraživanje

8.2.1. Karakteristike i analiza uzorka glavnog istraživanja

U nastavku se prikazuje analiza karakteristika ispitanika iz uzorka glavnog istraživanja. Pristiglo je ukupno 457 ispunjenih anketnih upitnika od čega se 25 anketnih upitnika odnosilo na organizacije koje pripadaju IT industriji te su isti uklonjeni iz daljnje analize. Nakon uklanjanja uzorak je činilo 432 organizacije što predstavlja povrat od 28% a što je unutar prihvatljivih granica za društvena istraživanja [219]. Ukupno je odaslano 1.670 anketnih upitnika na mail adrese prikupljene iz javno dostupnih izvora.

$$\% \text{ povrata} = \frac{ukupan\ broj\ vraćenih\ anketnih\ upitnika}{ukupan\ broj\ odaslanih\ anketnih\ upitnika - neprikladni} = \frac{457}{1670-25} = 28 \text{ [220]}$$

8.2.2.1. Karakteristike ispitanika

U tablici 31 prikazane su karakteristike ispitanika iz uzorka. Uzorak čini 58,1% ispitanika muškog spola i 41,9% ženskog spola. Promatrajući dobnu strukturu ispitanika vidljivo je da najveći broj ispitanik pripada dobnoj skupini od 41-50 godina starosti (30,1%), dok je najmanji broj ispitanika iz dobne skupine do 30 godina (3,7%). Promatrajući razinu obrazovanja većina ispitanika (48,1%) ima visoku stručnu spremu, tj. završen fakultet (diplomski studij). Najmanje su zastupljeni ispitanici sa završenim doktoratom (1,6%).
Većina ispitanika su vlasnici i ujedno direktori, tj. ovlaštene osobe u organizaciji (51,4%).

Tablica 31 Karakteristike ispitanika iz uzorka

Varijabla	Kategorija	Broj organizacija	Struktura %
Spol	Muški	251	58,1

Varijabla	Kategorija	Broj organizacija	Struktura %
	Ženski	181	41,9
Ukupno		***432***	***100***
Dob	do 30 godina	16	3,7
	31-40 godina	116	26,9
	41-50 godina	130	30,1
	51-60 godina	105	24,3
	više od 60 godina	65	15
Ukupno		***432***	***100***
Razina obrazovanja	srednja stručna sprema	70	16,2
	fakultet - VSŠ ili stručni studij	88	20,4
	fakultet - završen diplomski studij	208	48,1
	magisterij	59	13,7
	doktorat	7	1,6
Ukupno		***432***	***100***
Pozicija u organizaciji	direktor/ovlaštena osoba	130	30,1
	vlasnik i direktor/ovlaštena osoba	222	51,4
	vlasnik/nositelj obrta	80	18,5
Ukupno		***432***	***100***

8.2.2.2. Karakteristike organizacija iz uzorka

U tablici 32 prikazana je struktura uzorka prema veličini i vrsti organizacije. Uzorak čini 49,8% mikro organizacija i 50,2% malih organizacija, od čega 18,5% čine obrti a 81,5% trgovačka društva.

Tablica 32 Veličina i vrsta organizacije iz uzorka

Varijabla	Kategorija	Broj organizacija	Struktura u %
Veličina organizacije	Mikro	215	49,8
	Mala	217	50,2

Varijabla	Kategorija	Broj organizacija	Struktura u %
Ukupno		***432***	***100***
Vrsta organizacije	Obrt	80	18,5
	Trgovačko društvo	352	81,5
Ukupno		***432***	***100***

Promatrajući županiju sjedišta organizacija iz uzorka najveći broj organizacija registrirano je u Varaždinskoj županiji (27,1%) i u gradu Zagrebu (25,7%). U uzorku nisu zastupljene organizacije iz Ličko-senjske, Vukovarsko-srijemske i Dubrovačko-neretvanske županije (tablica 33, slika 10).

Tablica 33 Županija sjedišta organizacija iz uzorka

Županija sjedišta organizacije	Broj organizacija	Struktura %
Zagrebačka	30	6,9
Krapinsko-zagorska	6	1,4
Sisačko-moslavačka	3	0,7
Karlovačka	7	1,6
Varaždinska	117	27,1
Koprivničko-križevačka	4	0,9
Bjelovarsko-bilogorska	18	4,2
Primorsko-goranska	17	3,9
Ličko-senjska	0	0
Virovitičko-podravska	10	2,3
Požeško-slavonska	3	0,7
Brodsko-posavska	10	2,3
Zadarska	7	1,6
Osječko-baranjska	25	5,8
Šibensko-kninska	7	1,6
Vukovarsko-srijemska	0	0

Županija sjedišta organizacije	Broj organizacija	Struktura %
Splitsko-dalmatinska	22	5,1
Istarska	13	3
Dubrovačka-neretvanska	0	0
Međimurska	22	5,1
Grad Zagreb	111	25,7
Ukupno	***432***	***100***

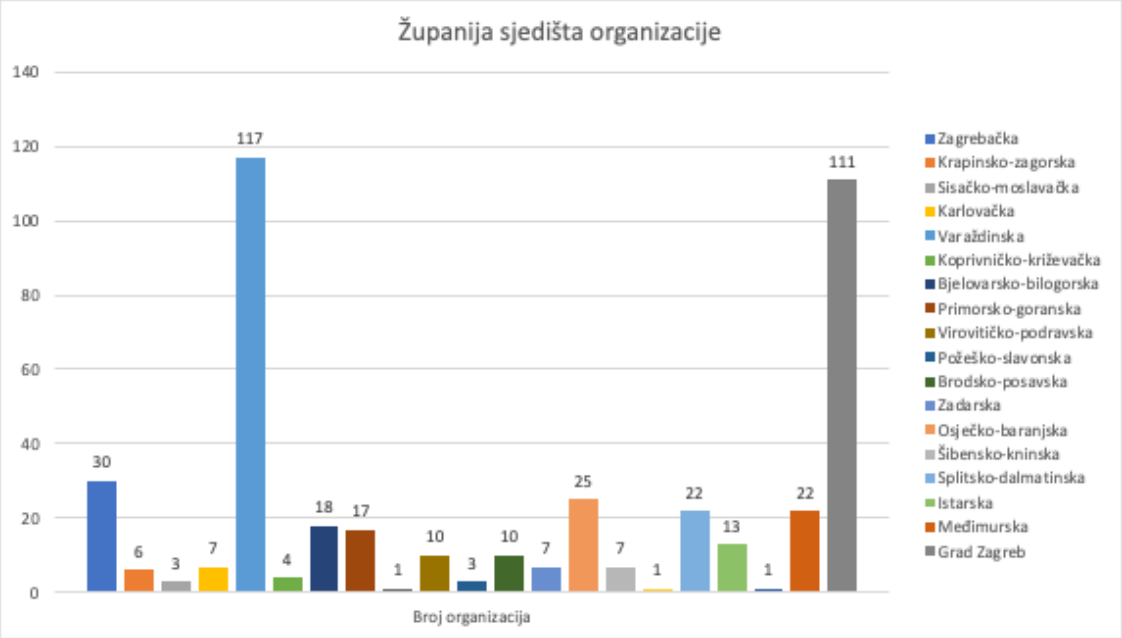

Slika 10 Grafički prikaz županije sjedišta organizacija iz uzorka

Pretežita djelatnost organizacija iz uzorka prema NKD-u je građevinarstvo (19,2%), nakon čega slijede organizacije iz djelatnosti stručne, znanstvene i tehničke djelatnosti (16,9%) te iz financijske djelatnosti i djelatnosti osiguranje (12,3%) (tablica 34, slika 11).

Tablica 34 Pretežita djelatnost organizacija iz uzorka

Pretežita djelatnost organizacije	Broj organizacija	Struktura u %
A Poljoprivreda, šumarstvo i ribarstvo	12	2,8

Pretežita djelatnost organizacije	**Broj organizacija**	**Struktura u %**
C Prerađivačka industrija	35	8,1
E Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša	13	3
F Građevinarstvo	83	19,2
G Trgovina na veliko i na malo; popravak motornih vozila i motocikla	25	5,8
H Prijevoz i skladištenje	17	3,9
I Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	17	3,9
K Financijske djelatnosti i djelatnosti osiguranja	53	12,3
L Poslovanje nekretninama	3	0,7
M Stručne, znanstvene i tehničke djelatnosti	73	16,9
N Administrativne i pomoćne uslužne djelatnosti	40	9,3
P Obrazovanje	12	2,8
Q Djelatnosti zdravstvene zaštite i socijalne skrbi	7	1,6
R Umjetnost, zabava i rekreacija	3	0,7
S Ostale uslužne djelatnosti	39	9
Ukupno	***432***	***100***

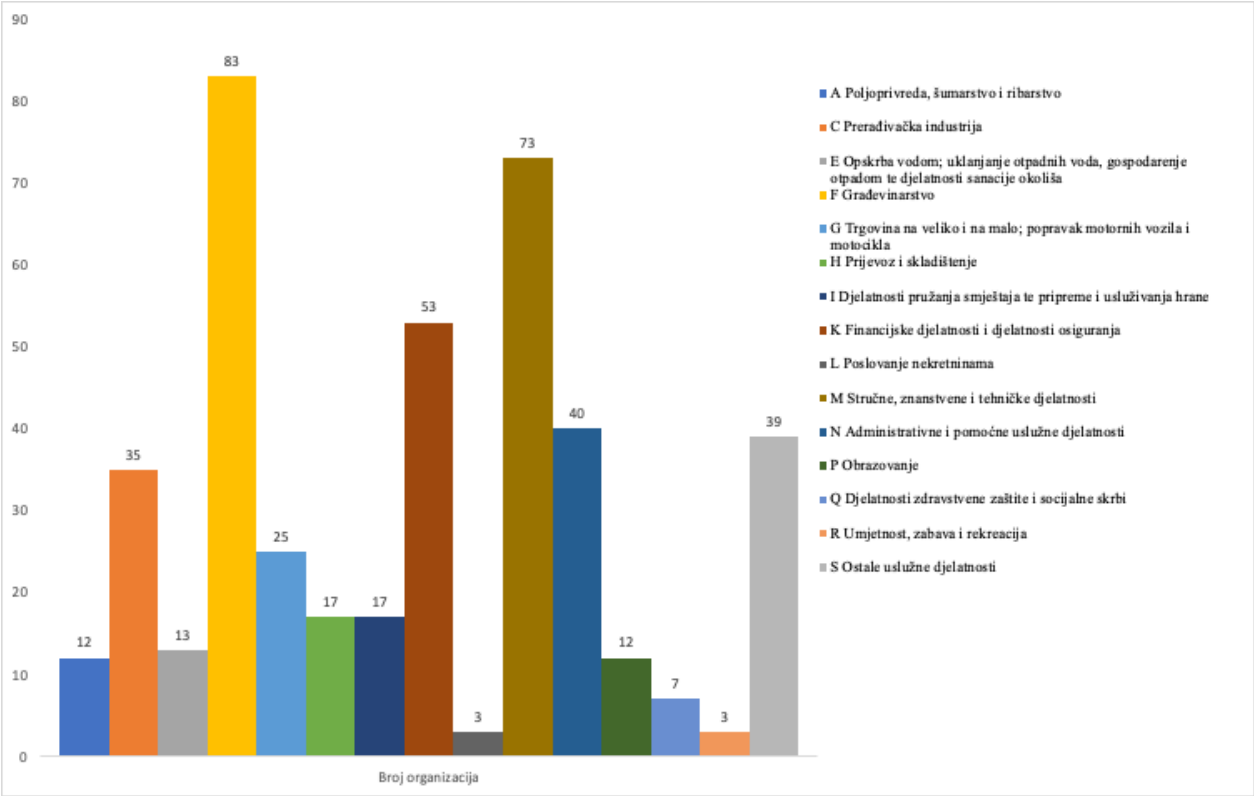

Slika 11 Pretežita djelatnost organizacija iz uzorka

8.2.2.3. Digitalna zrelost organizacija iz uzorka

U tablici 35 u nastavku prikazane su dimenzije modela digitalne zrelosti zajedno s pripadajućim česticama. Prikazana je srednja vrijednost, standardna devijacija i koeficijent Cronbach alfa. Kako bi se potvrdila homogenost tvrdnji (čestica) unutar svake pojedine dimenzije testirana je njihova unutarnja pouzdanost pomoću Cronbach alfa koeficijenta. Svi faktori su kao što je vidljivo u tablici 35 unutar prihvatljivih granica, tj. iznad preporučene vrijednosti 0,7 [221].

Tablica 35 Unutarnja pouzdanost dimenzija digitalne zrelosti

Čestica	**Srednja vrijednost**	**Standardna devijacija**	**Cronbach alfa**
Resursi za provedbu digitalne transformacije (D_RESDT)			
D_RESDT1	2,917	1,3147	0,830
D_RESDT2	2,817	1,2676	
D_RESDT3	3,197	1,2321	
Korištenje naprednih tehnologija (D_KNT)			

Čestica	Srednja vrijednost	Standardna devijacija	Cronbach alfa
D_KNT1	3,530	1,1577	
D_KNT2	3,345	1,1676	
D_KNT3	3,262	1,2313	0,922
D_KNT4	2,968	1,1189	
D_KNT5	3,373	1,1224	
Efikasnost upravljanja tehnologijama (D_EUT)			
D_EUT1	2,780	1,1780	
D_EUT2	2,894	1,1946	
D_EUT3	2,803	1,2582	0,925
D_EUT4	2,669	1,2277	
D_EUT5	3,104	1,2564	
Otvorenost i komunikacija (D_OK)			
D_OK1	3,407	1,2434	
D_OK2	3,174	1,2634	0,897
D_OK3	3,609	1,1140	
Prihvaćanje rizika (D_PR)			
D_PR1	3,572	1,1457	
D_PR2	3,426	1,0593	0,883
D_PR3	3,780	1,1090	

Za potrebe određivanja razine digitalne zrelosti organizacija iz uzorka primijenjen je izračun digitalne zrelosti preuzet od Blatz-a i Dietel-a [190].

Čestice u upitniku vrednovane su ordinalnom skalom od 1 do 5. Za potrebe izračuna digitalne zrelosti svakoj čestici dodijeljeni su bodovi pri čemu je 1 na ordinalnoj ljestvici iznosio nula (0) bodova a 5 četiri (4) boda. Temeljem dodijeljenih bodova izračunata je srednja vrijednost svake čestice te srednja vrijednost za svaku pojedinu dimenziju. Na taj način dobio se uvid u razvijenost svake pojedine dimenzije (slika 12).

Kako bi se izračunala razina digitalne zrelosti organizacije izračunata je težina (važnost, udio) svake pojedine dimenzije u odnosu na preostale dimenzije (tablica 38). To je izvedeno na način da se izračunala srednja vrijednost za svaku pojedinu dimenziju. Temeljem zbroja srednjih vrijednosti svih dimenzija izračunat je udio (važnost) svake pojedine dimenzije u ukupnom zbroju. Zbrojem umnoška udjela (važnosti) i srednje vrijednosti svake pojedine dimenzije

dobiveni su bodovi temeljem kojih je izračunata razina digitalne zrelosti primjenjujući vrijednosti iz tablice 36 [190].

Tablica 36 Razine digitalne zrelosti

Razina	Opis	Bodovi
1 Razina	Utjecaj digitalizacije i digitalnih tehnologija na samu organizaciju i njeno poslovanje je minimalan. Prepoznata je potreba za digitalizacijom poslovanje no još nisu poduzeti nikakvi koraci u tom smjeru. Nedostaje potpora rukovodstva te motivacija za korištenje novih tehnologija i rješenja.	> 0
2 Razina	Formirani su određeni koraci prema digitalizaciji poslovanja. Promiče se upotreba digitalnih rješenja. Postoje naznake digitalne strategije, no nisu jasno definirane uloge, ciljevi i modeli mjerenja istih.	> 2
3 Razina	Jasno su postavljeni ciljevi unutar digitalne strategije i redovito se provjeravaju i revidiraju. Unutar organizacije postoji odgovarajuća informacijska infrastruktura i odgovarajuće vodstvo koje brine o digitalizaciji poslovanja.	> 3

Na slici 12 prikazane su srednje vrijednosti dimenzija nakon bodovanja iz kojih je razvidno kako su najrazvijenije dimenzija prihvaćanja rizika te dimenzija otvorenost i komunikacija, dok je najmanje razvijena dimenzija efikasnost upravljanja tehnologijom. Isto je potvrđeno i promatranjem prosječne vrijednosti pojedinih čestica, gdje je vidljivo kako su najveće vrijednosti upravo kod dimenzije prihvaćanja rizika i dimenzije otvorenost i komunikacija (tablica 37).

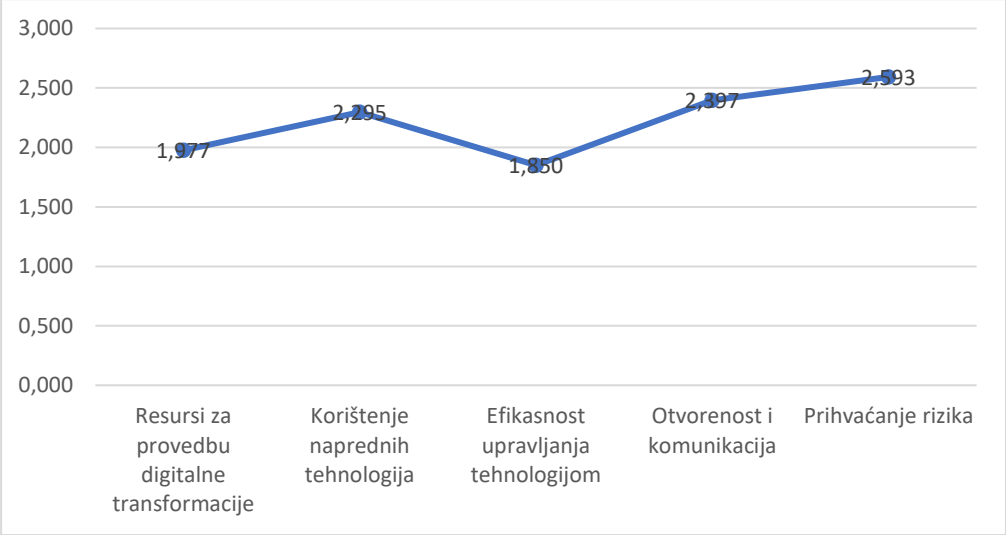

Slika 12 Srednja vrijednost pojedine dimenzije

Tablica 37 Srednja vrijednost čestica nakon bodovanja

Čestica		**Srednja vrijednost***
D_PR3	Primarnu odgovornost u inoviranju uglavnom snosi menadžment organizacije.	2,780
D_OK3	Otvoreno komuniciramo na svim razinama o problemima i prilikama poslovanja.	2,609
D_PR1	Naši menadžeri su sposobni prepoznati prilike i prijetnje i potrebu za inovacijama.	2,572
D_KNT1	Arhitektura naše tehnologije omogućava da se lako integrira sa svim pristupnim kanalima (web, mobilni uređaji..).	2,530
D_PR2	Moja organizacija uspješno balansira između inoviranja i kontrole rizika.	2,426
D_OK1	Vrlo jasno komuniciramo našu strategiju sa zaposlenicima.	2,407
D_KNT5	Naše aktivnosti u procesu digitalne transformacije nisu limitirane postojećom tehnologijom u organizaciji.	2,373
D_KNT2	Tehnologija kojom raspolažemo u potpunosti je usklađena sa ciljevima digitalne transformacije poslovanja.	2,345
D_KNT3	Naši stručnjaci u potpunosti poznaju nove tehnologije i njihov utjecaj na poslovanje našeg poduzeća.	2,262

Čestica		Srednja vrijednost*
D_RESDT3	Moja organizacija danas ima dovoljno talenata da podrži digitalnu transformaciju.	2,197
D_OK2	Naši zaposlenici su svjesni da će se njihova uloga značajno promijeniti.	2,174
D_EUT5	Naš budžet za tehnologiju je fleksibilan na način da omogućava promjene prioriteta nabavke novih tehnologija.	2,104
D_KNT4	Naša tehnologija je naprednija nego tehnologija naših konkurenata.	1,968
D_RESDT1	Imamo adekvatan budžet za podršku provođenja digitalne poslovne strategije.	1,917
D_EUT2	Postoje jasna pravila i procedure upravljanja IT-em.	1,894
D_RESDT2	Investirali smo značajna sredstva u edukaciju zaposlenika i treninge na području digitalne transformacije.	1,817
D_EUT3	Definirali smo dugoročne planove implementacije novih IT-a.	1,803
D_EUT1	U našoj organizaciji IT ima stratešku ulogu.	1,780
D_EUT4	Mjerimo učinak našeg IT tima ne samo kroz stabilnost tehnologije nego i kroz poslovne rezultate.	1,669

* srednja vrijednost dobivena nakon bodovanja čestica (1 = 0 bodova, 5= 4 bodova)

U tablici 38 prikazana je izračunata važnost svake dimenzije u odnosu na drugu dimenziju, razvidno je kako je najrazvijenija dimenzija prihvaćanje rizika.

Tablica 38 Važnost pojedine dimenzije digitalne zrelosti

Dimenzija	Važnost/udio %
Resursi za provedbu digitalne transformacije (D_RESDT)	18
Korištenje naprednih tehnologija (D_KNT)	21
Efikasnost upravljanja tehnologijama (D_EUT)	17
Otvorenost i komunikacija (D_OK)	21
Prihvaćanje rizika (D_PR)	23

Grafički prikaz razvijenost pojedine dimenzije unutar svake razine digitalne zrelosti prikazan je na slikama u nastavku (slika 13,14 i 15).

Prvu razinu digitalne zrelosti karakterizira slaba razvijenost svih dimenzija posebice dimenzije efikasnost upravljanja tehnologijom te dimenzije resursi za provedbu digitalne transformacije. Najviše razvijena dimenzija na prvoj razini digitalne zrelosti je dimenzija prihvaćanja rizika.

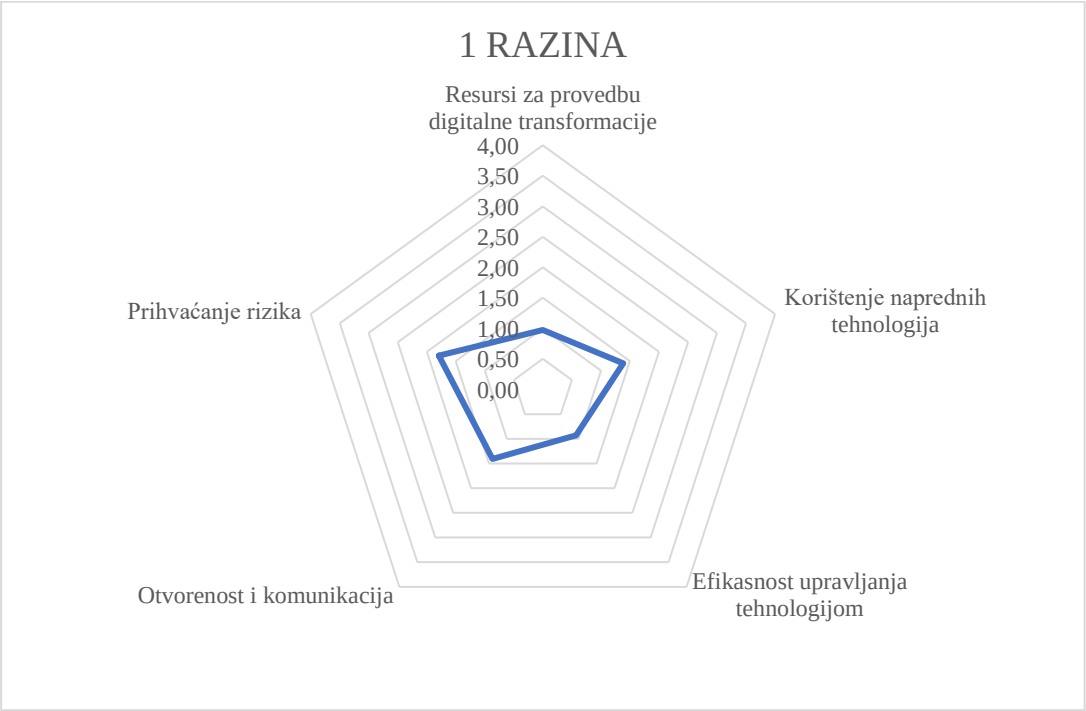

Slika 13 Razvijenost dimenzija na 1 razini digitalne zrelosti

Drugu razina zrelosti karakterizira lagani rast razvijenosti svih dimenzijama, nešto manje izražen kod dimenzije efikasnost upravljanja tehnologijom i dimenzije resursi za provedbu digitalne transformacije.

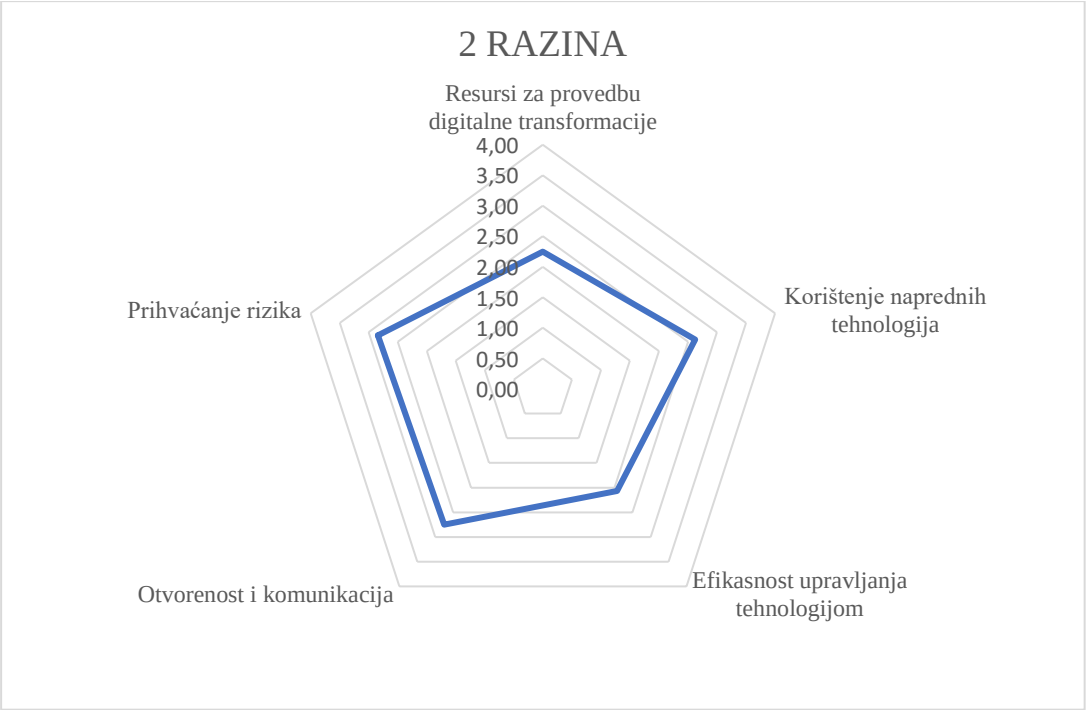

Slika 14 Razvijenost dimenzija na 2 razini digitalne zrelosti

Na trećoj razini digitalne zrelosti ujedno i zadnjoj razini vidljivo je da su sve dimenzije na najvišem nivou, iako je i dalje dimenzija efikasnost upravljanja tehnologijom slabije razvijena dimenzija u odnosi na ostale.

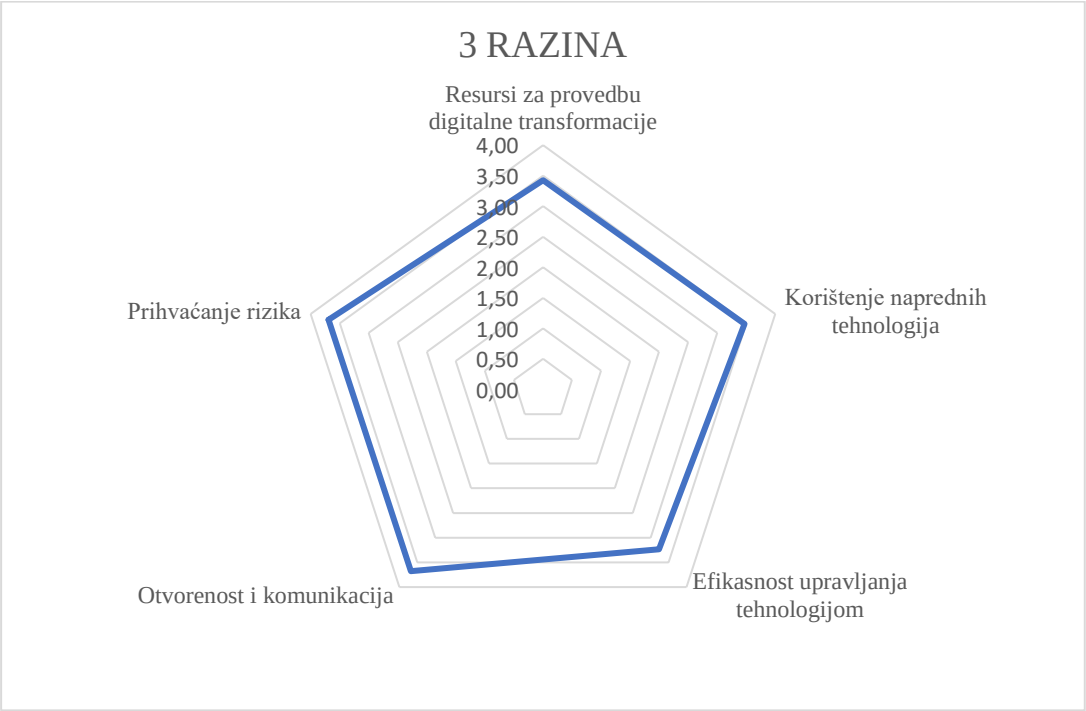

Slika 15 Razvijenost dimenzija na 3 razini digitalne zrelosti

Na slici 16 u nastavku prikazan je usporedni prikaz razina digitalne zrelosti i razvijenosti pojedinih dimenzija unutar svake razine zrelosti.

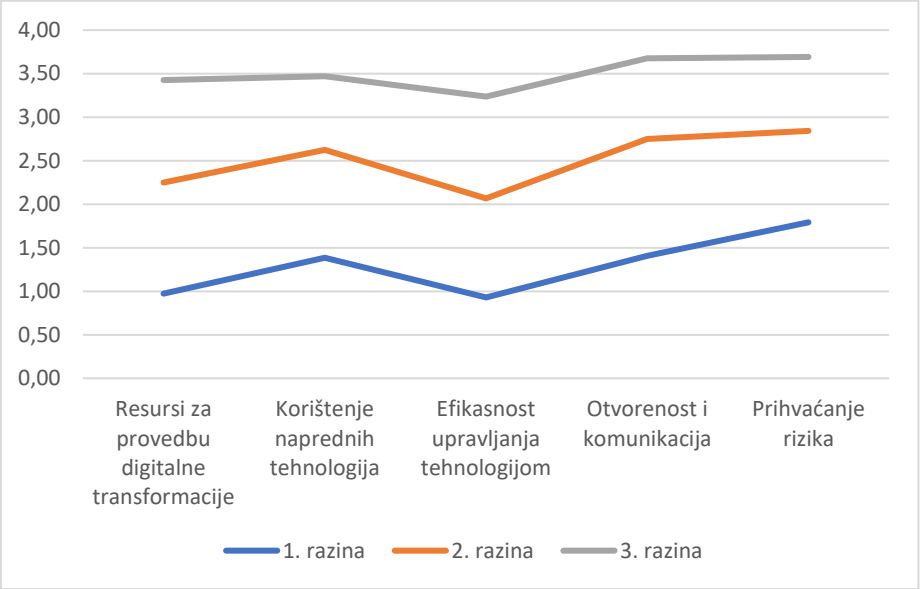

Slika 16 Prikaz razvijenosti dimenzija unutar pojedine razine digitalne zrelosti

Izračun digitalne zrelosti organizacija iz uzorka pokazao je kako se najveći broj organizacija (41,20%) nalazi na prvoj razini. Na drugoj razini nalazi se 37,3%, dok se tek 21,5% organizacija nalazi na trećoj razini digitalne zrelosti.

Tablica 39 Digitalna zrelost organizacija iz uzorka

Razina digitalne zrelosti	**Broj organizacija**	**Struktura %**
1 razina	178	41,2
2 razina	161	37,3
3 razina	93	21,5
Ukupno	***432***	***100***

Promatrajući veličinu organizacija iz uzorka vidljivo je kako se najveći broj mikro organizacija njih 95 (44,19%) nalazi na prvoj razini digitalne zrelosti, dok se najveći broj malih organizacija njih 92 (42,40%) nalazi na drugoj razini digitalne organizacije (tablica 40). Promatrajući treću razinu digitalne zrelosti 23,72% mikro organizacije i 29,35% malih organizacija nalazi se na trećoj razini digitalne zrelosti.

Tablica 40 Digitalna zrelost organizacija iz uzorka prema veličini organizacija

Razina digitalne zrelosti	Veličina organizacije				Ukupno
	Mikro		Male		
	Broj	Struktura %	Broj	Struktura %	
1 razina	95	44,19	83	38,25	178
2 razina	69	32,09	92	42,40	161
3 razina	51	23,72	42	19,35	93
Ukupno	***215***	***100,00***	***217***	***100,00***	***432***

U tablici 41 prikazana je struktura vrste organizacija u odnosu na postignutu razinu digitalne zrelosti. Razvidno je kako se 37,50% obrta nalazi na prvoj razini digitalne zrelosti, 35% se nalazi na drugoj razini, dok se 27,50% nalazi na trećoj razini digitalne zrelosti. Promatrajući trgovačka društva 42,05% nalazi se na prvoj razini digitalne zrelosti, 37,78% na drugoj razini te 20,17% na trećoj razini digitalne zrelosti.

Tablica 41 Digitalna zrelost organizacija iz uzorka prema vrsti organizacija

Razina digitalne zrelosti	Vrsta organizacije				Ukupno
	Obrt		Trgovačko društvo		
	Broj	Struktura %	Broj	Struktura %	
1 razina	30	37,50	148	42,05	178
2 razina	28	35,00	133	37,78	161
3 razina	22	27,50	71	20,17	93
Ukupno	***80***	***100,00***	***352***	***100,00***	***432***

Analizirajući digitalnu zrelost organizacija u odnosu na djelatnost organizacija, iz tablice 42 i slike 17 razvidno je kako su organizacije iz djelatnosti prijevoza i skladištenja i iz djelatnosti financijske djelatnosti i djelatnosti osiguranja najrazvijenije. Najveći postotak organizacija na prvoj razini digitalne zrelosti nalazi se u djelatnostima pružanja smještaja te pripreme i usluživanja hrane te iz djelatnosti poslovanja nekretninama.

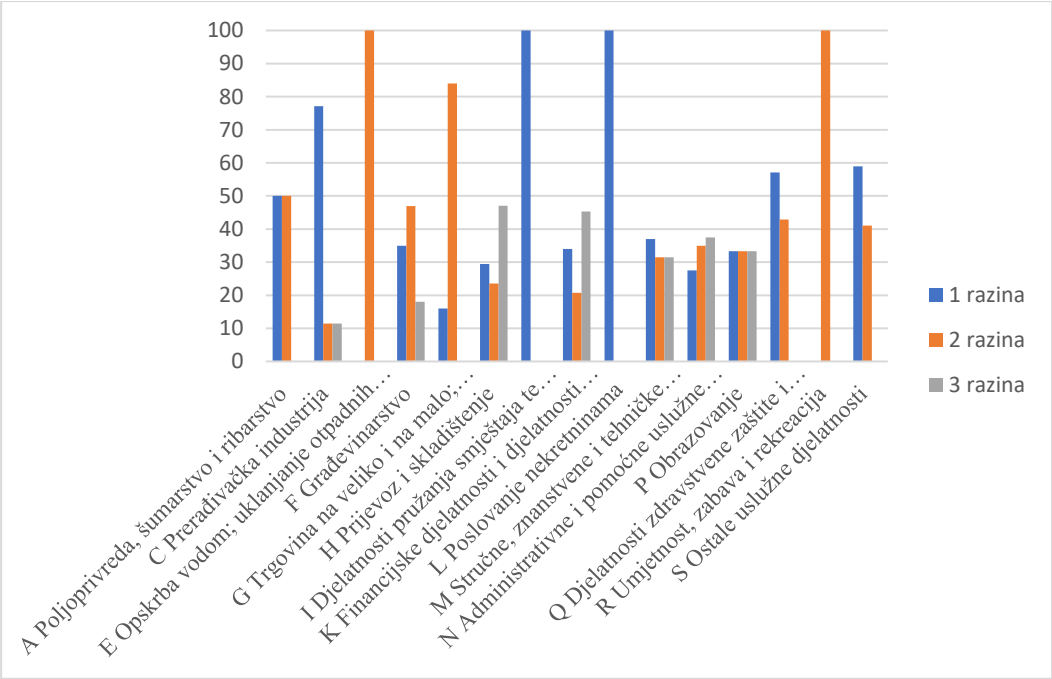

Slika 17 Grafički prikaz digitalne zrelosti organizacija prema djelatnosti organizacija iz uzorka

Tablica 43 i slika 18 pokazuju kako se najviše organizacija na trećoj razini digitalne zrelosti nalazi u Šibensko kninskoj županiji, dok se najveći broj organizacija na prvoj razini digitalne zrelosti nalazi u Koprivničko-križevačkoj, Požeško-slavonskoj i Brodsko-posavskoj županiji.

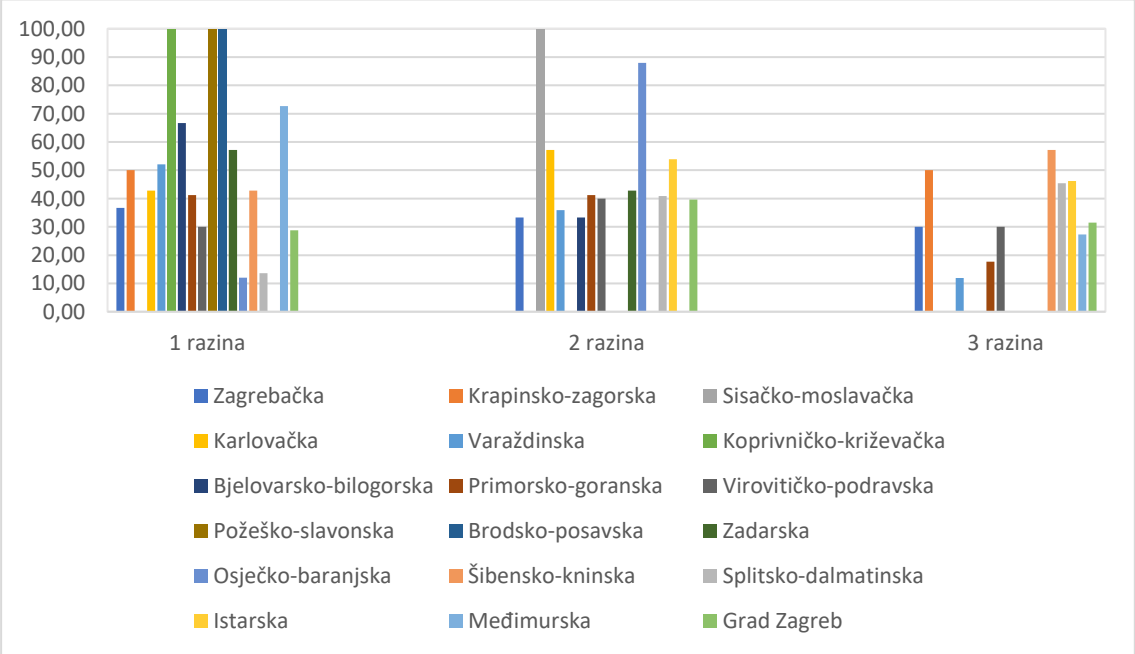

Slika 18 Grafički prikaz digitalne zrelosti organizacija prema županiji sjedišta organizacije

Tablica 42 Digitalna zrelost organizacija prema djelatnosti organizacija iz uzorka

Pretežita djelatnost organizacije	Digitalna zrelost						Ukupno
	1 razina		2 razina		3 razina		
	Broj	Struktura %	Broj	Struktura %	Broj	Struktura %	
A Poljoprivreda, šumarstvo i ribarstvo	6	50,00	6	50,00	0	0,00	12
C Prerađivačka industrija	27	77,14	4	11,43	4	11,43	35
E Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša	0	0,00	13	100,00	0	0,00	13
F Građevinarstvo	29	34,94	39	46,99	15	18,07	83
G Trgovina na veliko i na malo; popravak motornih vozila i motocikla	4	16,00	21	84,00	0	0,00	25
H Prijevoz i skladištenje	5	29,41	4	23,53	8	47,06	17
I Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	17	100,00	0	0,00	0	0,00	17
K Financijske djelatnosti i djelatnosti osiguranja	18	33,96	11	20,75	24	45,28	53
L Poslovanje nekretninama	3	100,00	0	0,00	0	0,00	3
M Stručne, znanstvene i tehničke djelatnosti	27	36,99	23	31,51	23	31,51	73
N Administrativne i pomoćne uslužne djelatnosti	11	27,50	14	35,00	15	37,50	40

P Obrazovanje	4	33,33	4	33,33	4	33,33	12
Q Djelatnosti zdravstvene zaštite i socijalne skrbi	4	57,14	3	42,86	0	0,00	7
R Umjetnost, zabava i rekreacija	0	0,00	3	100,00	0	0,00	3
S Ostale uslužne djelatnosti	23	58,97	16	41,03	0	0,00	39
Ukupno	***178***		***161***		***93***		***432***

Tablica 43 Digitalna zrelost organizacija prema županiji sjedišta organizacije

Županija sjedišta organizacija	**Digitalna zrelost**						**Ukupno**
	1 razina		**2 razina**		**3 razina**		
	Broj	**Struktura%**	**Broj**	**Struktura %**	**Broj**	**Struktura%**	
Zagrebačka	11	36,67	10	33,33	9	30,00	30
Krapinsko-zagorska	3	50,00	0	0,00	3	50,00	6
Sisačko-moslavačka	0	0,00	3	100,00	0	0,00	3
Karlovačka	3	42,86	4	57,14	0	0,00	7
Varaždinska	61	52,14	42	35,90	14	11,97	117
Koprivničko-križevačka	4	100,00	0	0,00	0	0,00	4
Bjelovarsko-bilogorska	12	66,67	6	33,33	0	0,00	18
Primorsko-goranska	7	41,18	7	41,18	3	17,65	17
Virovitičko-podravska	3	30,00	4	40,00	3	30,00	10
Požeško-slavonska	3	100,00	0	0,00	0	0,00	3

Županija sjedišta organizacija	Digitalna zrelost						Ukupno
	1 razina		2 razina		3 razina		
	Broj	Struktura%	Broj	Struktura %	Broj	Struktura%	
Brodsko-posavska	10	100,00	0	0,00	0	0,00	10
Zadarska	4	57,14	3	42,86	0	0,00	7
Osječko-baranjska	3	12,00	22	88,00	0	0,00	25
Šibensko-kninska	3	42,86	0	0,00	4	57,14	7
Splitsko-dalmatinska	3	13,64	9	40,91	10	45,45	22
Istarska	0	0,00	7	53,85	6	46,15	13
Međimurska	16	72,73	0	0,00	6	27,27	22
Grad Zagreb	32	28,83	44	39,64	35	31,53	111
Ukupno	***178***		***161***		***93***		***432***

8.2.2.4. Stil odlučivanja donositelja odluka organizacija iz uzorka

U tablici 44 prikazane su čestice stila odlučivanja (intuitivni i racionalni). U svrhu potvrđivanja homogenosti čestica unutar intuitivnog i racionalnog stila testirana je unutarnja pouzdanost pomoću Cronbach alfa koeficijenta. Oba faktora su, kao što je vidljivo u tablici 44, unutar prihvatljivih granica, tj. iznad preporučene vrijednosti 0,7 [221].

Tablica 44 Unutarnja pouzdanost stila odlučivanja

Čestica	**Srednja vrijednost**	**Standardna devijacija**	**Cronbach alfa**
Racionalni stil odlučivanja (RS)			
RS1	4,569	0,8116	0,956
RS2	4,493	0,8343	
RS3	4,426	0,8198	
RS4	4,317	0,9235	
RS5	4,389	0,8706	
Intuitivni stil odlučivanja (IS)			
IS1	3,051	1,1264	0,928
IS2	3,153	1,1172	
IS3	2,803	1,1919	
IS4	2,942	1,2220	
IS5	2,296	1,2243	

Određivanje stila odlučivanja ispitanika vršeno je pomoću srednje vrijednosti. Ispitaniku je dodijeljen stil odlučivanja ovisno o tome je li srednja vrijednost bila veća na ljestvici intuitivnog ili racionalnog stila. Analizom je utvrđeno kako 56 ispitanika posjeduje intuitivni stil odlučivanja (13%), dok njih 376 (87%) donosi odluke racionalnim stilom odlučivanja.

Tablica 45 Stil odlučivanja donositelja odluka organizacija iz uzorka

Stil odlučivanja	**Broj organizacija**	**Struktura %**
Intuitivni	56	13

Stil odlučivanja	Broj organizacija	Struktura %
Racionalni	376	87
Ukupno	***432***	***100***

Stil odlučivanja u odnosu na karakteristike ispitanika (spol, dob, obrazovanje i pozicija u organizaciji) prikazan je tablicom 46 u nastavku. Ispitanici su pretežito racionalnog stila odlučivanja bez obzira na spol, dob, obrazovanje ili poziciju unutar organizacije. Jedini izuzetak predstavljaju ispitanici s doktoratom koji su pretežito intuitivnog stila odlučivanja (57,14%).

Tablica 46 Stil odlučivanja i karakteristike ispitanika iz uzorka

Varijabla	Kategorija	Stil odlučivanja				Ukupno
		Intuitivni		Racionalni		
		Broj	Struktura %	Broj	Struktura %	
Spol	Muški	22	8,76	229	91,24	251
	Ženski	34	18,78	147	81,22	181
Ukupno		***56***		***376***		432
Dob	do 30 godina	3	18,75	13	81,25	16
	31-40 godina	17	14,66	99	85,34	116
	41-50 godina	7	5,38	123	94,62	130
	51-60 godina	25	23,81	80	76,19	105
	više od 60 godina	4	6,15	61	93,85	65
Ukupno		***56***		***376***		432
Obrazovanje	srednja stručna sprema	13	18,57	57	81,43	70
	fakultet - VSŠ ili stručni studij	14	15,91	74	84,09	88
	fakultet - završen diplomski studij	18	8,65	190	91,35	208
	magisterij	7	11,86	52	88,14	59
	doktorat	4	57,14	3	42,86	7
Ukupno		***56***		***376***		432

Varijabla	Kategorija	Stil odlučivanja				Ukupno
		Intuitivni		Racionalni		
		Broj	Struktura %	Broj	Struktura %	
Pozicija u organizaciji	direktor/ovlaštena osoba	21	16,15	109	83,85	130
	vlasnik i direktor/ovlaštena osoba	23	10,36	199	89,64	222
	vlasnik/nositelj obrta	12	15,00	68	85,00	80
Ukupno		***56***		***376***		432

Promatrajući karakteristike organizacija iz uzorka (tablica 47) vidljivo je kako su donositelji odluka u organizacijama iz uzorka pretežito racionalnog stila odlučivanja bez obzira na veličinu ili vrstu organizacije. Promatrajući djelatnost organizacije i županiju sjedišta iznimka su djelatnosti pružanja smještaja te pripreme i usluživanja hrane gdje prevladava intuitivni stil. Isto tako intuitivni stil prevladava u organizacijama koje svoje sjedište imaju u Koprivničko-križevačkoj, Požeško-slavonskoj, Zadarskoj i Šibensko-kninskoj županiji.

Tablica 47 Stil odlučivanja i karakteristike organizacija iz uzorka

Varijabla	Kategorija	Stil odlučivanja				Ukupno
		Intuitivni		Racionalni		
		Broj	Struktura %	Broj	Struktura %	
Veličina organizacije	Mikro	25	11,63	190	88,37	215
	Mala	31	14,29	186	85,71	217
Ukupno		***56***		***376***		***432***
Vrsta organizacije	Trgovačko društvo	44	12,50	308	87,50	352
	Obrti	12	15,00	68	85,00	80
Ukupno		***56***		***376***		**432**
Djelatnost	A Poljoprivreda, šumarstvo i ribarstvo	0	0,00	12	100,00	12
	C Prerađivačka industrija	4	11,43	31	88,57	35
	E Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša	0	0,00	13	100,00	13
	F Građevinarstvo	9	10,84	74	89,16	83
	G Trgovina na veliko i na malo; popravak motornih vozila i motocikla	4	16,00	21	84,00	25
	H Prijevoz i skladištenje	6	35,29	11	64,71	17

Varijabla	Kategorija	Stil odlučivanja				Ukupno
		Intuitivni		Racionalni		
		Broj	Struktura %	Broj	Struktura %	
	I Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	10	58,82	7	41,18	17
	K Financijske djelatnosti i djelatnosti osiguranja	0	0,00	53	100,00	53
	L Poslovanje nekretninama	0	0,00	3	100,00	3
	M Stručne, znanstvene i tehničke djelatnosti	12	16,44	61	83,56	73
	N Administrativne i pomoćne uslužne djelatnosti	7	17,50	33	82,50	40
	P Obrazovanje	0	0,00	12	100,00	12
	Q Djelatnosti zdravstvene zaštite i socijalne skrbi	0	0,00	7	100,00	7
	R Umjetnost, zabava i rekreacija	0	0,00	3	100,00	3
	S Ostale uslužne djelatnosti	4	10,26	35	89,74	39
Ukupno		***56***		***376***		***432***
Županija	Zagrebačka	4	13,33	26	86,67	30
	Krapinsko-zagorska	0	0,00	6	100,00	6

Varijabla	Kategorija	Stil odlučivanja				Ukupno
		Intuitivni		Racionalni		
		Broj	Struktura %	Broj	Struktura %	
	Sisačko-moslavačka	0	0,00	3	100,00	3
	Karlovačka	0	0,00	7	100,00	7
	Varaždinska	10	8,55	107	91,45	117
	Koprivničko-križevačka	4	100,00	0	0,00	4
	Bjelovarsko-bilogorska	6	33,33	12	66,67	18
	Primorsko-goranska	3	17,65	14	82,35	17
	Virovitičko-podravska	0	0,00	10	100,00	10
	Požeško-slavonska	3	100,00	0	0,00	3
	Brodsko-posavska	0	0,00	10	100,00	10
	Zadarska	4	57,14	3	42,86	7
	Osječko-baranjska	0	0,00	25	100,00	25
	Šibensko-kninska	4	57,14	3	42,86	7
	Splitsko-dalmatinska	0	0,00	22	100,00	22
	Istarska	4	30,77	9	69,23	13
	Međimurska	0	0,00	22	100,00	22
	Grad Zagreb	14	12,61	97	87,39	111
Ukupno		***56***		***376***		***432***

8.2.2.5. Konkurentski prioriteti

Tablica 48 prikazuje konkurentske prioritete koje organizacije žele postići prihvaćanjem uslužnog računalstva i pametnih ugovora. Iz tablice je razvidno kako je najzastupljeniji željeni konkurentski prioritet kod prihvaćanja uslužnog računalstva povećanje kvalitete (24,8%) te smanjenje troškova (24,1%). Promatrajući prihvaćanje pametnih ugovora najpoželjniji konkurentski prioritet je smanjenje troškova (31,3%) slijedi ga fleksibilnost (19,9%), dok je pouzdanost (13%) na posljednjem mjestu. Pouzdanost je posljednja i kada je u pitanju prihvaćanje uslužnog računalstva (24,1%). Isto je prikazano slikom u nastavku (slika 19).

Tablica 48 Konkurentski prioriteti

Konkurentski prioritet	**Uslužno računalstvo**		**Pametni ugovori**	
	Broj organizacija	**Struktura %**	**Broj organizacija**	**Struktura %**
Brzina	85	19,7	75	17,4
Fleksibilnost	84	19,4	86	19,9
Kvaliteta	107	24,8	80	18,5
Pouzdanost	52	12	56	13
Smanjenje troškova	104	24,1	135	31,3
Ukupno	***432***	***100***	***432***	***100***

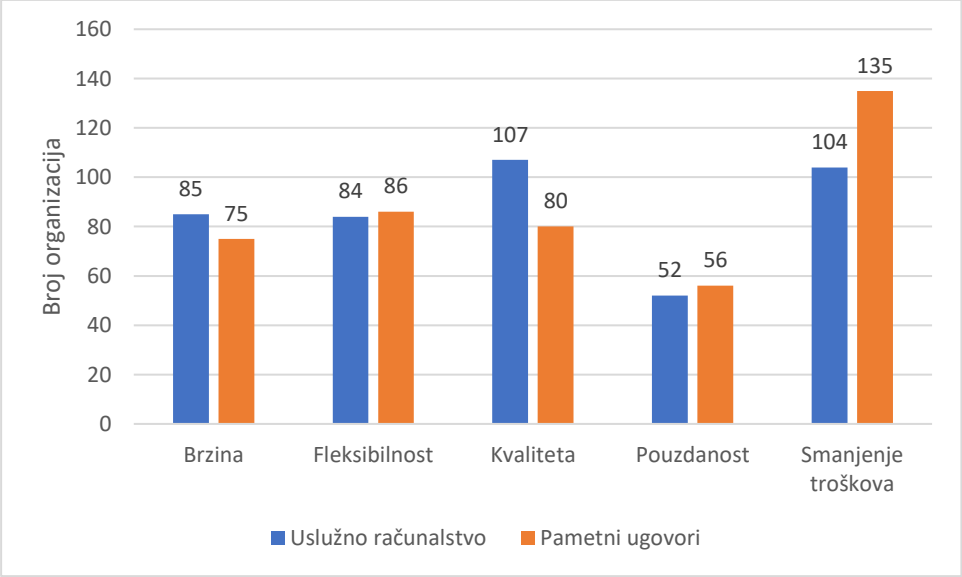

Slika 19 Grafički prikaz konkurentskih prioriteta

U tablici 49 prikazani su željeni konkurentski prioriteti u odnosu na karakteristike ispitanika u uzorku. Promatrajući spol ispitanika željeni konkurentski prioritet prihvaćanja uslužnog računalstva kod muškaraca je smanjenje troškova (25,50%), dok je to kod žena povećanje kvalitete (27,07%). S obzirom na dob ispitanika mlađi ispitanici do 30 godina prihvaćanjem uslužnog računalstva ponajviše žele postići povećanje brzine (62,50%). Ispitanici u dobnoj skupini od 31 do 40 godina prvenstveno žele postići povećanje kvalitete (30,17%) a ispitanici u dobnoj skupini od 41 do 50 godina žele postići povećanje fleksibilnosti (26,92%). Stariji ispitanici od 51 do 60 godina žele postići povećanje kvalitete (30,48%), dok oni iznad 60 godina prihvaćanjem uslužnog računalstva teže smanjenju troškova (38,46%). S obzirom na stupanj obrazovanja ispitanici sa srednjom stručnom spremom, kao i oni sa završenim diplomskim studijem, prvenstveno žele postići povećanje kvalitete. Ispitanici sa završenim stručnim studijem i magisterijem prihvaćanjem uslužnog računalstva prvenstveno žele postići smanjenje troškova. Nadalje, ispitanici s doktoratom prihvaćanjem uslužnog računalstva teže povećanju brzine. S obzirom na poziciju unutar organizacije direktori/ovlaštene osobe naginju ostvarivanju povećanja kvalitete (35,38%), direktori/ovlaštene osobe koji su ujedno i vlasnici organizacije naginju ostvarivanju smanjenja troškova (28,38%), dok nositelji obrta naginju ostvarivanju povećanja kvalitete (28,75%).

Tablica 49 Konkurentski prioriteti prihvaćanja uslužnog računalstva i karakteristike ispitanika iz uzorka

Varijabla	Kategorija	Konkurentski prioriteti - uslužno računalstvo										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
Spol	Muški	53	21,12	55	21,91	58	23,11	21	8,37	64	25,50	251
	Ženski	32	17,68	29	16,02	49	27,07	31	17,13	40	22,10	181
Ukupno		**85**		**84**		**107**		**52**		**104**		**432**
Dob	do 30 godina	10	62,50	3	18,75	0	0,00	0	0,00	3	18,75	16
	31-40 godina	25	21,55	13	11,21	35	30,17	12	10,34	31	26,72	116
	41-50 godina	18	13,85	35	26,92	30	23,08	24	18,46	23	17,69	130
	51-60 godina	22	20,95	19	18,10	32	30,48	10	9,52	22	20,95	105
	više od 60 godina	10	15,38	14	21,54	10	15,38	6	9,23	25	38,46	65
Ukupno		***85***		***84***		***107***		***52***		***104***		**432**
Obrazovanje	srednja stručna sprema	7	10,00	9	12,86	27	38,57	10	14,29	17	24,29	70
	fakultet - VSŠ ili stručni studij	26	29,55	15	17,05	13	14,77	6	6,82	28	31,82	88
	fakultet - završen diplomski studij	39	18,75	51	24,52	51	24,52	26	12,50	41	19,71	208
	magisterij	9	15,25	9	15,25	13	22,03	10	16,95	18	30,51	59

Varijabla	Kategorija	Konkurentski prioriteti - uslužno računalstvo										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
	doktorat	4	57,14	0	0,00	3	42,86	0	0,00	0	0,00	7
Ukupno		***85***		***84***		***107***		***52***		***104***		**432**
Pozicija u organizaciji	direktor/ovlaštena osoba	21	16,15	19	14,62	46	35,38	10	7,69	34	26,15	130
	vlasnik i direktor/ovlaštena osoba	48	21,62	45	20,27	38	17,12	28	12,61	63	28,38	222
	vlasnik/nositelj obrta	16	20,00	20	25,00	23	28,75	14	17,50	7	8,75	80
Ukupno		***85***		***84***		***107***		***52***		***104***		**432**

U tablici 50 prikazani su konkurentski prioriteti koji se žele postići prihvaćanjem pametnih ugovora u odnosu na karakteristike ispitanika, tj. donositelja odluka u organizacijama iz uzorka. Željeni konkurentski prioritet prihvaćanja pametnih ugovora kod muškaraca je smanjenje troškova (36,25%), dok je kod žena to povećanje fleksibilnosti (27,62%). S obzirom na dob ispitanika, mlađi ispitanici do 30 godina prihvaćanjem pametnih ugovora ponajviše žele postići povećanje brzine (62,50%). Ispitanici u dobnoj skupini od 31 do 40 godina prvenstveno žele postići povećanje kvalitete (26,72%), ispitanici u dobnoj skupini od 41 do 50 godina žele postići smanjenje troškova (35,38%), dok stariji ispitanici od 51 do 60 godina i stariji od 60 godina teže smanjenju troškova. S obzirom na stupanj obrazovanja ispitanici sa srednjom stručnom spremom, završenim diplomskim studijem i sa završenim stručnim studijem prvenstveno žele postići smanjenje troškova, dok ispitanici sa doktoratom žele postići

povećanje brzine. S obzirom na poziciju unutar organizacije direktori/ovlaštene osobe kao i direktori/ovlaštene osobe koji su ujedno i vlasnici organizacije naginju smanjenju troškova, dok nositelji obrta podjednako žele povećati kvalitetu i smanjiti troškove.

Tablica 50 Konkurentski prioriteti prihvaćanja pametnih ugovora i karakteristike ispitanika iz uzorka

Varijabla	**Kategorija**	**Konkurentski prioriteti -pametni ugovori**										**Ukupno**
		Brzina		**Fleksibilnost**		**Kvaliteta**		**Pouzdanost**		**Smanjenje troškova**		
		Broj	**%**	**Broj**	**%**	**Broj**	**%**	**Broj**	**%**	**Broj**	**%**	
Spol	Muški	55	21,91	36	14,34	42	16,73	27	10,76	91	36,25	251
	Ženski	20	11,05	50	27,62	38	20,99	29	16,02	44	24,31	181
Ukupno		***75***		***86***		***80***		***56***		***135***		***432***
Dob	do 30 godina	10	62,50	0	0,00	3	18,75	0	0,00	3	18,75	16
	31-40 godina	26	22,41	23	19,83	31	26,72	9	7,76	27	23,28	116
	41-50 godina	16	12,31	32	24,62	17	13,08	19	14,62	46	35,38	130
	51-60 godina	16	15,24	22	20,95	19	18,10	22	20,95	26	24,76	105
	više od 60 godina	7	10,77	9	13,85	10	15,38	6	9,23	33	50,77	65
Ukupno		***75***		***86***		***80***		***56***		***135***		**432**
Obrazovanje	srednja stručna sprema	3	4,29	13	18,57	13	18,57	20	28,57	21	30,00	70
	fakultet - VSŠ ili stručni studij	22	25,00	16	18,18	16	18,18	9	10,23	25	28,41	88

Varijabla	Kategorija	Konkurentski prioriteti -pametni ugovori										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
	fakultet - završen diplomski studij	40	19,23	45	21,63	37	17,79	24	11,54	62	29,81	208
	magisterij	6	10,17	12	20,34	11	18,64	3	5,08	27	45,76	59
	doktorat	4	57,14	0	0,00	3	42,86	0	0,00	0	0,00	7
Ukupno		***75***		***86***		***80***		***56***		***135***		**432**
Pozicija u organizaciji	direktor/ovlaštena osoba	24	18,46	30	23,08	26	20,00	12	9,23	38	29,23	130
	vlasnik i direktor/ovlaštena osoba	33	14,86	42	18,92	35	15,77	34	15,32	78	35,14	222
	vlasnik/nositelj obrta	18	22,50	14	17,50	19	23,75	10	12,50	19	23,75	80
Ukupno		***75***		***86***		***80***		***56***		***135***		**432**

U tablicama 51 i 52 u nastavku prikazani su konkurentski prioriteti prihvaćanja uslužnog računalstva i pametnih ugovora u odnosu na karakteristike organizacija iz uzorka.

Promatrajući veličinu organizacije mikro organizacije prilikom prihvaćanja uslužnog računalstva primarno žele postići povećanje kvalitete (22,33%), dok male organizacije teže povećanju fleksibilnosti (48,81%). Trgovačka društva teže postizanju fleksibilnosti (76,19%), dok obrti teže povećanju kvalitete (28,75%). Promatrajući željene konkurentske prioritete i djelatnost organizacije može se zaključiti da većina djelatnosti želi podići kvalitetu i smanjiti troškove.

Tablica 51 Konkurentski prioriteti prihvaćanja uslužnog računalstva i karakteristike organizacija iz uzorka

Varijabla	**Kategorija**	**Konkurentski prioriteti - uslužno računalstvo**										**Ukupno**
		Brzina		**Fleksibilnost**		**Kvaliteta**		**Pouzdanost**		**Smanjenje troškova**		
		Broj	**%**	**Broj**	**%**	**Broj**	**%**	**Broj**	**%**	**Broj**	**%**	
Veličina organizacije	Mikro	46	21,40	43	20,00	48	22,33	35	16,28	43	20,00	215
	Mala	39	17,97	41	48,81	59	27,19	17	7,83	61	28,11	217
Ukupno		***85***		***84***		***107***		***52***		***104***		***432***
Vrsta organizacije	Trgovačko društvo	69	19,60	64	76,19	84	23,86	38	10,80	97	27,56	352
	Obrti	16	20,00	20	23,81	23	28,75	14	17,50	7	8,75	80
Ukupno		***85***		***84***		***107***		***52***		***104***		***432***
Djelatnost	A Poljoprivreda, šumarstvo i ribarstvo	3	25,00	0	0,00	6	50,00	0	0,00	3	25,00	12
	C Prerađivačka industrija	7	20,00	3	3,57	9	25,71	0	0,00	16	45,71	35

Varijabla	Kategorija	Konkurentski prioriteti - uslužno računalstvo										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
	E Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša	3	23,08	3	3,57	4	30,77	3	23,08	0	0,00	13
	F Građevinarstvo	13	15,66	13	15,48	19	22,89	13	15,66	25	30,12	83
	G Trgovina na veliko i na malo; popravak motornih vozila i motocikla	7	28,00	4	4,76	3	12,00	1	4,00	10	40,00	25
	H Prijevoz i skladištenje	1	5,88	5	5,95	7	41,18	4	23,53	0	0,00	17
	I Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	4	23,53	0	0,00	6	35,29	4	23,53	3	17,65	17
	K Financijske djelatnosti i	12	22,64	6	7,14	16	30,19	10	18,87	9	16,98	53

Varijabla	Kategorija	Konkurentski prioriteti - uslužno računalstvo										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
	djelatnosti osiguranja											
	L Poslovanje nekretninama	0	0,00	3	3,57	0	0,00	0	0,00	0	0,00	3
	M Stručne, znanstvene i tehničke djelatnosti	21	28,77	22	26,19	10	13,70	0	0,00	20	27,40	73
	N Administrativne i pomoćne uslužne djelatnosti	7	17,50	9	10,71	8	20,00	10	25,00	6	15,00	40
	P Obrazovanje	0	0,00	4	4,76	8	66,67	0	0,00	0	0,00	12
	Q Djelatnosti zdravstvene zaštite i socijalne skrbi	0	0,00	3	3,57	4	57,14	0	0,00	0	0,00	7
	R Umjetnost, zabava i rekreacija	0	0,00	3	3,57	0	0,00	0	0,00	0	0,00	3
	S Ostale uslužne djelatnosti	7	17,95	6	7,14	7	17,95	7	17,95	12	30,77	39
Ukupno		***85***		***84***		***107***		***52***		***104***		***432***

Varijabla	Kategorija	Konkurentski prioriteti - uslužno računalstvo										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
Županija	Zagrebačka	10	33,33	6	6,98	8	26,67	3	10,00	3	10,00	30
	Krapinsko-zagorska	0	0,00	3	3,49	0	0,00	0	0,00	3	50,00	6
	Sisačko-moslavačka	0	0,00	0	0,00	3	100,00	0	0,00	0	0,00	3
	Karlovačka	0	0,00	0	0,00	4	57,14	3	42,86	0	0,00	7
	Varaždinska	18	15,38	13	15,12	31	26,50	7	5,98	48	41,03	117
	Koprivničko-križevačka	0	0,00	4	4,65	0	0,00	0	0,00	0	0,00	4
	Bjelovarsko-bilogorska	6	33,33	0	0,00	3	16,67	3	16,67	6	33,33	18
	Primorsko-goranska	0	0,00	4	4,65	3	17,65	0	0,00	10	58,82	17
	Virovitičko-podravska	3	30,00	0	0,00	3	30,00	4	40,00	0	0,00	10
	Požeško-slavonska	0	0,00	0	0,00	3	100,00	0	0,00	0	0,00	3
	Brodsko-posavska	3	30,00	7	8,14	0	0,00	0	0,00	0	0,00	10
	Zadarska	0	0,00	7	8,14	0	0,00	0	0,00	0	0,00	7
	Osječko-baranjska	9	36,00	7	8,14	0	0,00	6	24,00	3	12,00	25

Varijabla	Kategorija	Konkurentski prioriteti - uslužno računalstvo										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
	Šibensko-kninska	0	0,00	4	4,65	0	0,00	0	0,00	3	42,86	7
	Splitsko-dalmatinska	0	0,00	0	0,00	6	27,27	3	13,64	13	59,09	22
	Istarska	7	53,85	3	3,49	0	0,00	3	23,08	0	0,00	13
	Međimurska	3	13,64	3	3,49	3	13,64	0	0,00	13	59,09	22
	Grad Zagreb	16	14,41	25	29,07	13	11,71	24	21,62	33	29,73	111
Ukupno		***75***		***86***		***80***		***56***		***135***		***432***

Sagledavanjem prihvaćanja pametnih ugovora temeljem veličine organizacije može se zaključiti kako mikro i male organizacije (nevezano na vrstu organizacije) teže smanjenju troškova, tj. i obrti i trgovačka društva žele smanjiti troškove. Promatrajući željene konkurentske prioritete i djelatnost organizacije vidljivo je da se niti jedan od definiranih konkurentski prioriteta posebno ne izdvaja.

Tablica 52 Konkurentski prioriteti prihvaćanja pametnih ugovora i karakteristike organizacija iz uzorka

Varijabla	Kategorija	Konkurentski prioriteti - pametni ugovori										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
	Mikro	50	23,26	43	20,00	23	10,70	33	15,35	66	30,70	215

Varijabla	Kategorija	Konkurentski prioriteti - pametni ugovori										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
Veličina organizacije	Mala	25	11,52	43	19,82	57	26,27	23	10,60	69	31,80	217
Ukupno		***75***		***86***		***80***		***56***		***135***		***432***
Vrsta organizacije	Trgovačko društvo	57	16,19	72	20,45	61	17,33	46	13,07	116	32,95	352
	Obrti	18	22,50	14	17,50	19	23,75	10	12,50	19	23,75	80
Ukupno		***75***		***86***		***80***		***56***		***135***		***432***
Djelatnost	A Poljoprivreda, šumarstvo i ribarstvo	3	25,00	0	0,00	6	50,00	0	0,00	3	25,00	12
	C Prerađivačka industrija	3	8,57	14	40,00	3	8,57	3	8,57	12	34,29	35
	E Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša	3	23,08	4	30,77	6	46,15	0	0,00	0	0,00	13
	F Građevinarstvo	17	20,48	6	7,23	9	10,84	16	19,28	35	42,17	83
	G Trgovina na veliko i na malo; popravak motornih vozila i motocikla	2	8,00	0	0,00	3	12,00	6	24,00	14	56,00	25
	H Prijevoz i skladištenje	1	5,88	5	29,41	4	23,53	7	41,18	0	0,00	17

Varijabla	Kategorija	Konkurentski prioriteti - pametni ugovori										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
	I Djelatnosti pružanja smještaja te pripreme i usluživanja hrane	0	0,00	11	64,71	3	17,65	0	0,00	3	17,65	17
	K Financijske djelatnosti i djelatnosti osiguranja	6	11,32	9	16,98	13	24,53	6	11,32	19	35,85	53
	L Poslovanje nekretninama	0	0,00	0	0,00	0	0,00	3	100,00	0	0,00	3
	M Stručne, znanstvene i tehničke djelatnosti	24	32,88	16	21,92	7	9,59	3	4,11	23	31,51	73
	N Administrativne i pomoćne uslužne djelatnosti	9	22,50	9	22,50	8	20,00	8	20,00	6	15,00	40
	P Obrazovanje	0	0,00	0	0,00	8	66,67	0	0,00	4	33,33	12
	Q Djelatnosti zdravstvene zaštite i socijalne skrbi	0	0,00	3	42,86	0	0,00	4	57,14	0	0,00	7
	R Umjetnost, zabava i rekreacija	0	0,00	0	0,00	0	0,00	0	0,00	3	100,00	3
	S Ostale uslužne djelatnosti	7	17,95	9	23,08	10	25,64	0	0,00	13	33,33	39

Varijabla	Kategorija	Konkurentski prioriteti - pametni ugovori										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
Ukupno		***75***		***86***		***80***		***56***		***135***		***432***
Županija	Zagrebačka	10	33,33	6	20,00	8	26,67	3	10,00	3	10,00	30
	Krapinsko-zagorska	0	0,00	3	50,00	0	0,00	0	0,00	3	50,00	6
	Sisačko-moslavačka	0	0,00	0	0,00	3	100,00	0	0,00	0	0,00	3
	Karlovačka	0	0,00	0	0,00	4	57,14	3	42,86	0	0,00	7
	Varaždinska	18	15,38	13	11,11	31	26,50	7	5,98	48	41,03	117
	Koprivničko-križevačka	0	0,00	4	100,00	0	0,00	0	0,00	0	0,00	4
	Bjelovarsko-bilogorska	6	33,33	0	0,00	3	16,67	3	16,67	6	33,33	18
	Primorsko-goranska	0	0,00	4	23,53	3	17,65	0	0,00	10	58,82	17
	Virovitičko-podravska	3	30,00	0	0,00	3	30,00	4	40,00	0	0,00	10
	Požeško-slavonska	0	0,00	0	0,00	3	100,00	0	0,00	0	0,00	3
	Brodsko-posavska	3	30,00	7	70,00	0	0,00	0	0,00	0	0,00	10
	Zadarska	0	0,00	7	100,00	0	0,00	0	0,00	0	0,00	7
	Osječko-baranjska	9	36,00	7	28,00	0	0,00	6	24,00	3	12,00	25
	Šibensko-kninska	0	0,00	4	57,14	0	0,00	0	0,00	3	42,86	7
	Splitsko-dalmatinska	0	0,00	0	0,00	6	27,27	3	13,64	13	59,09	22
	Istarska	7	53,85	3	23,08	0	0,00	3	23,08	0	0,00	13
	Međimurska	3	13,64	3	13,64	3	13,64	0	0,00	13	59,09	22
	Grad Zagreb	16	14,41	25	22,52	13	11,71	24	21,62	33	29,73	111

Varijabla	Kategorija	Konkurentski prioriteti - pametni ugovori										Ukupno
		Brzina		Fleksibilnost		Kvaliteta		Pouzdanost		Smanjenje troškova		
		Broj	%	Broj	%	Broj	%	Broj	%	Broj	%	
Ukupno		***75***		***86***		***80***		***56***		***135***		***432***

Tablicama 53 i 54 te slikama 20 i 21 prikazan je odnos između željenih konkurentskih prioriteta prilikom prihvaćanja uslužnog računalstva i pametnih ugovora i razine digitalne zrelosti organizacija iz uzorka. Razvidno je kako organizacije na trećoj razini digitalne zrelosti usvajanjem uslužnog računalstva teže povećanju fleksibilnosti (27,96%), dok organizacije na prvoj razini digitalne zrelosti prihvaćanjem uslužnog računalstva teže smanjenju troškova (33,15%). Organizacije na drugoj razini digitalne zrelosti prihvaćanjem uslužnog računalstva teže podizanju kvalitete. Promatrajući prihvaćanje pametnih ugovora vidljivo je da organizacije na svim raznima digitalne zrelosti teže smanjenju troškova.

Tablica 53 Konkurentski prioriteti prihvaćanja uslužnog računalstva i digitalna zrelost organizacija iz uzorka

Konkurentski prioriteti-uslužno računalstvo	**Razina digitalne zrelosti**						**Ukupno**
	1 razina		**2 razina**		**3 razina**		
	Broj	**Struktura %**	**Broj**	**Struktura %**	**Broj**	**Struktura %**	
Brzina	33	18,54	39	24,22	13	13,98	85
Fleksibilnost	25	14,04	33	20,50	26	27,96	84
Kvaliteta	44	24,72	44	27,33	19	20,43	107
Pouzdanost	17	9,55	23	14,29	12	12,90	52
Smanjenje troškova	59	33,15	22	13,66	23	24,73	104
Ukupno	***178***	***100***	***161***	***100***	***93***	***100***	***432***

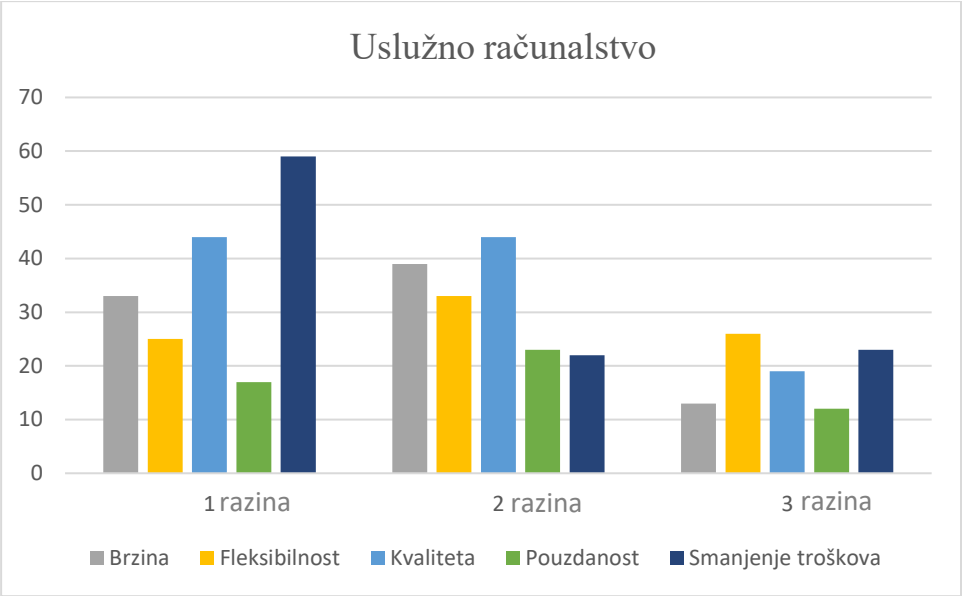

Slika 20 Grafički prikaz odnosa konkurentskih prioriteta prihvaćanja uslužnog računalstva i digitalne zrelost organizacija iz uzorka

Tablica 54 Konkurentski prioriteti prihvaćanja pametnih ugovora i digitalna zrelost organizacija iz uzorka

Konkurentski prioriteti - pametni ugovori	**Razina digitalne zrelosti**						**Ukupno**
	1 razina		**2 razina**		**3 razina**		
	Broj	**Struktura %**	**Broj**	**Struktura %**	**Broj**	**Struktura %**	
Brzina	33	18,54	29	18,01	13	13,98	75
Fleksibilnost	34	19,10	32	19,88	20	21,51	86
Kvaliteta	33	18,54	31	19,25	16	17,20	80
Pouzdanost	19	10,67	19	11,80	18	19,35	56
Smanjenje troškova	59	33,15	50	31,06	26	27,96	135
Ukupno	***178***	***100***	***161***	***100***	***93***	***100***	***432***

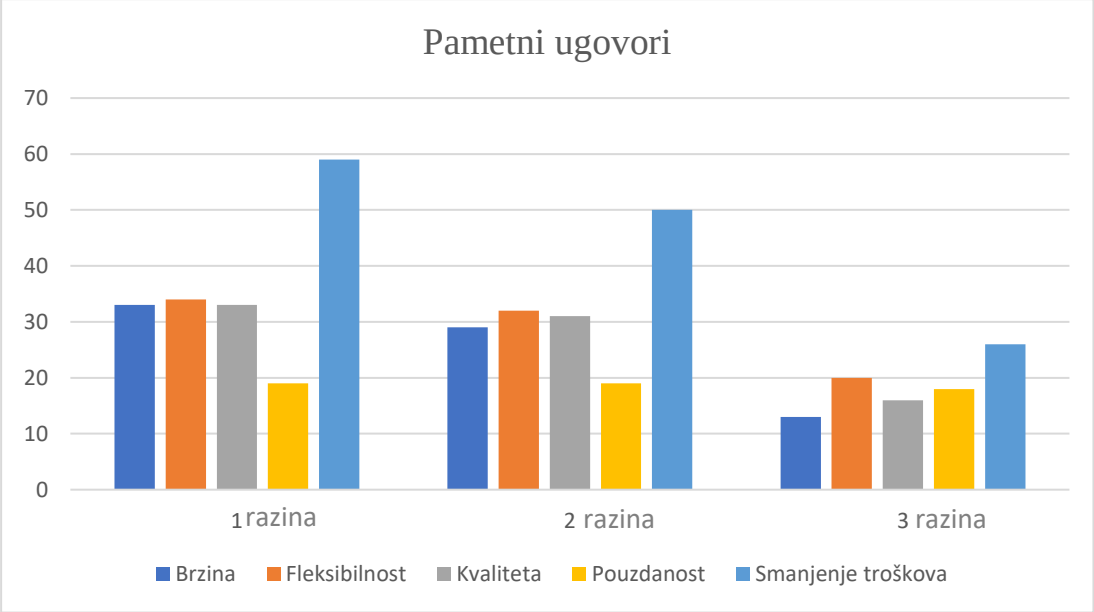

Slika 21 Grafički prikaz odnosa konkurentskih prioriteta prihvaćanja pametnih ugovora i digitalne zrelost organizacija iz uzorka

Promatrajući odnos između stila odlučivanja donositelja odluka u organizacijama iz uzorka i konkurentskog prioriteta kojem organizacije teže prihvaćanjem uslužnog računalstva i pametnih ugovora, razvidno je kako oni s racionalnim stilom prilikom prihvaćanja uslužnog računalstva teže povećanju kvalitete (25,53%), dok oni s intuitivnim stilom teže smanjenju troškova (28,57%) (tablica 55). Intuitivni donositelji odluka prilikom prihvaćanja pametnih ugovora teže povećanju brzine (26,79%) i fleksibilnosti (26,79%), dok racionalni žele smanjiti troškove (32,71%) (tablica 56).

Tablica 55 Konkurentski prioriteti prihvaćanja uslužnog računalstva i stil odlučivanja donositelja odluka u organizacijama iz uzorka

Konkurentski prioriteti - uslužno računalstvo	**Stil odlučivanja**				**Ukupno**
	Intuitivni		**Racionalni**		
	Broj	**Struktura %**	**Broj**	**Struktura %**	
Brzina	12	21,43	73	19,41	85
Fleksibilnost	10	17,86	74	19,68	84
Kvaliteta	11	19,64	96	25,53	107

Konkurentski prioriteti - uslužno računalstvo	Stil odlučivanja				Ukupno
	Intuitivni		Racionalni		
	Broj	Struktura %	Broj	Struktura %	
Pouzdanost	7	12,50	45	11,97	52
Smanjenje troškova	16	28,57	88	23,40	104
Ukupno	***56***	***100,00***	***376***	***100,00***	***432***

Tablica 56 Konkurentski prioriteti prihvaćanja pametnih ugovora i stil odlučivanja donositelja odluka u organizacijama iz uzorka

Konkurentski prioriteti - pametni ugovori	Stil odlučivanja				Ukupno
	Intuitivni		Racionalni		
	Broj	Struktura %	Broj	Struktura %	
Brzina	15	26,79	60	15,96	75
Fleksibilnost	15	26,79	71	18,88	86
Kvaliteta	8	14,29	72	19,15	80
Pouzdanost	6	10,71	50	13,30	56
Smanjenje troškova	12	21,43	123	32,71	135
Ukupno	***56***	***100***	***376***	***100***	***432***

8.3. Deskriptivna statistika

U tablicama u nastavku (tablica 57,58,59 i 60) prikazana je deskriptivna statistika za svaku pojedinu česticu u istraživanju prihvaćanja uslužnog računalstva i u istraživanju prihvaćanja pametnih ugovora. U tablici 57 prikazana je srednja vrijednost, standardna devijacija te koeficijent asimetrije i zaobljenosti za čestice u istraživanju prihvaćanja uslužnog računalstva, dok tablica 58 prikazuje rezultate deskriptivne statistike istraživanja prihvaćanja pametnih ugovora [221].

Prema dobivenim rezultatima istraživanja prihvaćanja uslužnog računalstva najveća srednja vrijednost iznosi 3,801 i odnosi se na česticu C_NP2, dok najniža srednja vrijednost iznosi

2,285 i odnosi se na česticu C_PFR1. Standardna devijacija kreće se u rasponu od 0,8610 do 1,1108. Koeficijent asimetrije i zaobljenosti ukazuje na normalnost distribucije podatka, prema tom koeficijentu što su vrijednosti udaljenije od 0 to je veća vjerojatnost da podaci nisu normalno distribuirani. Koeficijent asimetrije obično se kreće u intervalu između -2 i 2 osim u slučaju vrlo jake asimetrije kada može prijeći tu granicu [222]. Smjernica za koeficijent zaobljenosti je više od +1 i manje od -1, vrijednost veća od +1 ukazuje na šiljastu zaobljenost a manja od -1 na previše ravnu zaobljenost [215]. Koeficijent asimetrije kreće se u rasponu od -0,580 do 0,432 dok se koeficijent zaobljenosti kreće u rasponu od -0,845 do 0,268 čime su zadovoljeni uvjeti normalne distribucije (tablica 57).

Tablica 57 Deskriptivna statistika čestica u istraživanja prihvaćanju uslužnog računalstva

Čestica	**Srednja vrijednost**	**Standardna devijacija**	**Koeficijent asimetrije**	**Koeficijent zaobljenosti**
C_PFR1	2,285	0,9414	0,209	-0,363
C_PFR2	2,669	1,0549	0,288	-0,304
C_PFR3	2,796	1,0554	0,093	-0,343
C_PFR4	2,762	1,0246	0,140	-0,231
C_PSR1	2,894	1,1017	-0,081	-0,695
C_PSR2rev	2,606	0,9428	0,258	0,092
C_PSR3rev	2,875	1,0209	-0,037	-0,480
C_PSR4rev	2,808	1,0162	-0,034	-0,448
C_PSR5	3,370	0,9762	-0,542	0,026
C_PGV1	2,627	0,9977	0,068	-0,688
C_PGV2	2,556	0,9879	0,432	0,112
C_PGV3	2,521	0,9535	0,408	0,268
C_PGV4	2,576	0,9531	0,354	-0,100
C_PPD1	3,301	1,0650	-0,346	-0,310
C_PPD2	3,461	1,0612	-0,370	-0,213
C_PPD3	3,694	1,0549	-0,580	-0,083
C_PPD4	3,477	1,1108	-0,472	-0,345
C_RZ2	2,778	1,0842	0,231	-0,594
C_RZ3	3,491	0,9585	-0,577	0,242

Čestica	Srednja vrijednost	Standardna devijacija	Koeficijent asimetrije	Koeficijent zaobljenosti
C_RZ4	2,662	1,0799	0,115	-0,845
C_KO1	3,042	1,0141	-0,070	-0,457
C_KO2	3,025	1,0735	-0,141	-0,558
C_KO3	2,704	1,0036	0,399	0,016
C_KO4	2,664	1,0601	0,339	-0,270
C_KO5	2,887	1,0392	-0,058	-0,595
C_PST1	2,806	1,0981	0,307	-0,572
C_PST2	2,836	1,0165	0,161	-0,508
C_PST3	3,000	1,0058	0,247	-0,198
C_PST4	2,620	0,9915	0,316	-0,248
C_NK1	3,757	0,8610	-0,255	-0,271
C_NK2	3,801	0,8997	-0,481	0,062

U tablici 58 prikazane su vrijednosti dobivene u istraživanju prihvaćanja pametnih ugovora. Najveća srednja vrijednost iznosi 3,648 i odnosi se na česticu B_PPD3, dok najniža srednja vrijednost iznosi 2,463 i odnosi se na česticu B_PFR1. Standardna devijacija kreće se u rasponu od 0,8769 do 1,0870. Koeficijent asimetrije kreće se u rasponu od -0,451 do 0,335, dok se koeficijent zaobljenosti kreće u rasponu od -0,653 do 0,486 čime su zadovoljeni uvjeti normalne distribucije.

Tablica 58 Deskriptivna statistika čestica u istraživanju prihvaćanja pametnih ugovora

Čestica	Srednja vrijednost	Standardna devijacija	Koeficijent asimetrije	Koeficijent zaobljenosti
B_PFR1	2,463	0,8769	-0,115	0,048
B_PFR2	2,852	0,9519	0,024	0,365
B_PFR3	2,956	0,9708	0,134	0,390
B_PFR4	2,977	0,9337	0,218	0,389
B_PSR1	2,975	1,0561	-0,127	-0,244
B_PSR2rev	2,711	0,9150	0,075	0,165
B_PSR3rev	2,928	0,9857	-0,104	-0,091

Čestica	Srednja vrijednost	Standardna devijacija	Koeficijent asimetrije	Koeficijent zaobljenosti
B_PSR4rev	2,905	0,9575	-0,080	-0,014
B_PSR5	3,331	0,9581	-0,434	-0,123
B_PGV1	2,755	1,0058	0,053	-0,368
B_PGV2	2,676	0,9996	0,335	0,179
B_PGV3	2,625	0,9721	0,276	0,213
B_PGV4	2,688	0,9498	0,187	0,058
B_PPD1	3,363	1,0034	-0,265	-0,109
B_PPD2	3,495	0,9895	-0,196	-0,148
B_PPD3	3,648	1,0018	-0,335	-0,268
B_PPD4	3,470	1,0788	-0,451	-0,277
B_RZ2	3,088	1,1179	-0,014	-0,611
B_RZ3	3,562	0,9194	-0,500	0,486
B_RZ4	2,822	1,0870	-0,011	-0,653
B_KO1	2,940	1,0109	-0,028	-0,242
B_KO2	2,938	1,0698	-0,035	-0,394
B_KO3	2,854	1,0351	0,270	-0,056
B_KO4	2,799	1,0851	0,232	-0,253
B_KO5	2,847	1,0486	-0,007	-0,438
B_PST1	2,766	1,1311	0,315	-0,538
B_PST2	2,769	1,0541	0,223	-0,447
B_PST3	2,863	0,9883	0,291	0,066
B_PST4	2,609	0,9975	0,282	-0,191
B_NK1	3,509	0,9240	-0,240	0,103
B_NK2	3,637	0,9364	-0,273	-0,120

U tablicama 59 i 60 u nastavku prikazani su rezultati deskriptivne statistike za moderirajuće varijable: digitalna zrelost i stil odlučivanja. Za digitalnu zrelost najveća srednja vrijednost iznosi 3,780 i odnosi se na česticu D_PR3, dok najniža srednja vrijednost iznosi 2,669 i odnosi se na česticu D_EUT4. Standardna devijacija kreće se u rasponu od 1,0593 do 1,3147. Koeficijent asimetrije kreće se u rasponu od -0,715 do 0,231, dok se koeficijent zaobljenosti kreće u rasponu od -1,078 do -0,353 čime su zadovoljeni uvjeti normalne distribucije (tablica

59). Promatrajući čestice stila odlučivanja najveća srednja vrijednost iznosi 4,569 i odnosi se na česticu RS1, dok najniža srednja vrijednost iznosi 2,296 i odnosi se na česticu IS5. Standardna devijacija kreće se u rasponu od 0,8116 do 1,2243. Koeficijent asimetrije kreće se u rasponu od -2.305 do 0,813 dok se koeficijent zaobljenosti kreće u rasponu od -0,897 do 5,625 čime su zadovoljeni uvjeti normalne distribucije.

Tablica 59 Deskriptivna statistika čestica za mjerenje digitalne zrelosti

Čestica	**Srednja vrijednost**	**Standardna devijacija**	**Koeficijent asimetrije**	**Koeficijent zaobljenosti**
D_RESDT1	2,917	1,3147	0,142	-1.078
D_RESDT2	2,817	1,2676	0,231	-0,937
D_RESDT3	3,197	1,2321	-0,088	-1.002
D_KNT1	3,530	1,1577	-0,240	-1.048
D_KNT2	3,345	1,1676	-0,250	-0,919
D_KNT3	3,262	1,2313	-0,247	-0,827
D_KNT4	2,968	1,1189	-0,036	-0,670
D_KNT5	3,373	1,1224	-0,159	-0,818
D_EUT1	2,780	1,1780	0,074	-0,897
D_EUT2	2,894	1,1946	0,206	-0,920
D_EUT3	2,803	1,2582	0,200	-0,934
D_EUT4	2,669	1,2277	0,221	-0,903
D_EUT5	3,104	1,2564	-0,148	-0,973
D_OK1	3,407	1,2434	-0,351	-0,947
D_OK2	3,174	1,2634	-0,143	-0,980
D_OK3	3,609	1,1140	-0,579	-0,353
D_PR1	3,572	1,1457	-0,521	-0,487
D_PR2	3,426	1,0593	-0,340	-0,434
D_PR3	3,780	1,1090	-0,715	-0,384

Tablica 60 Deskriptivna statistika čestica za mjerenje stila odlučivanja

Čestica	Srednja vrijednost	Standardna devijacija	Koeficijent asimetrije	Koeficijent zaobljenosti
RS1	4,569	0,8116	-2,305	5,625
RS2	4,493	0,8343	-1,760	2,762
RS3	4,426	0,8198	-1,589	2,513
RS4	4,317	0,9235	-1,629	2,709
RS5	4,389	0,8706	-1,712	3,120
IS1	3,051	1,1264	-0,022	-0,756
IS2	3,153	1,1172	-0,204	-0,600
IS3	2,803	1,1919	0,162	-0,793
IS4	2,942	1,2220	0,134	-0,897
IS5	2,296	1,2243	0,813	-0,256

8.4. Procjena mjernog (vanjskog) modela

Procjena mjernog modela kao što je navedeno u poglavlju 7.4.1 uključuje [215]:

- ispitivanje pouzdanosti i valjanosti opaženih varijabli,
- ispitivanje unutarnje dosljednosti, tj. pouzdanost konstrukta te
- diskriminantnu i konvergentnu valjanost.

Iako konvergentna i diskriminantna valjanost ukazuju na konstruktnu valjanost, provest će se konfirmativna faktorska analiza (CFA) pomoću CB-SEM metode koristeći IBM SPSS Amos 26.

CFA omogućava provjeru „ispravnosti“ mjernog modela, tj. da li odabrane čestice odgovaraju pojedinom konstruktu na način na koji je to istraživač specificirao [223].

Provjera mjernog modela, konvergentna i diskriminantna valjanost napravljena je pomoću programa SmartPLS3, putem PLS Algoritma (v.3.3.3.).

U nastavku slijedi prikaz rezultata procjene mjernog modela u istraživanju prihvaćanja uslužnog računalstva nakon čega se daje prikaz rezultata u istraživanju prihvaćanja pametnih ugovora.

8.4.1. Procjena mjernog (vanjskog) modela – USLUŽNO RAČUNALSTVO

U nastavku slijedi procjena mjernog modela istraživanja prihvaćanja uslužnog računalstva. Nakon provjere pouzdanosti i konvergentne valjanosti, slijedi provjera diskriminantne valjanosti.

8.4.1.1. Pouzdanost i konvergentna valjanost - USLUŽNO RAČUNALSTVO

Kako bi se provjerila pouzdanosti svake pojedine čestice utvrđena su vanjska faktorska opterećenja (*engl. indicator outer loadings*) čija se vrijednost mora kretati između 0,60 i 0,70 [215]. Za česticu C_PSR1 faktorsko opterećenje iznosilo je 0,624, dok je za česticu C_PSR5 faktorsko opterećenje iznosilo je 0,358 pri čemu je za konstrukt C_PSR Cronbach alfa iznosio 0,837, CR 0,955, AVE 0,602. Hair i ostali napominju kako prije uklanjanja manifestnih (opaženih) varijabli s vrijednosti između 0,4 i 0,7 nužno je provjeriti da li njihovo uklanjanje rezultira povećanjem kompozitne pouzdanosti [215]. Nakon uklanjanja čestica Cronbach alfa iznosi 0,903, CR 0,939 i AVE 0,837. U tablici 61 u nastavku prikazani su rezultati Cronbach alfa, CR i AVE nakon uklanjanja čestice C_PSR1 i C_PSR5.

Za provjeru unutarnje dosljednosti i pouzdanosti konstrukta primijenjen je Cronbach alfa koeficijenta i koeficijent kompozitne pouzdanosti. Iz tablice je razvidno kako su vrijednosti za oba koeficijenta iznad 0,7 što ukazuju na dobru pouzdanost i unutarnju povezanost konstrukta [215].

Konvergentna valjanost procijenjena je prosječnom ekstrahiranom (izlučnom) varijancom (*engl. Avarage Varianve Extracted* - AVE). Dobivene vrijednosti za svaki pojedini konstrukt su iznad 0,5 što ukazuje na dobru konvergentnu valjanost [215].

Tablica 61 Procjena mjernog modela – uslužno računalstvo

Čestica	Vanjska opterećenja	Cronbach alfa	Kompozitna pouzdanost CR	Prosječna ekstrahirana varijanca AVE
Percipirani financijski rizik (PFR)				
C_PFR1	0,828	**0,805**	**0,872**	**0,632**
C_PFR2	0,668			
C_PFR3	0,840			
C_PFR4	0,831			
Percipirani sigurnosni rizik (PSR)				
C_PSR2rev	0,907	**0,903**	**0,939**	**0,837**
C_PSR3rev	0,930			
C_PSR4rev	0,908			
Percipirani gubitak vremena (PGV)				
C_PGV1	0,798	**0,929**	**0,948**	**0,822**
C_PGV2	0,958			
C_PGV3	0,961			
C_PGV4	0,901			
Percipirani pritisak države (PPD)				
C_PPD1	0,854	**0,883**	**0,918**	**0,738**
C_PPD2	0,897			
C_PPD3	0,869			
C_PPD4	0,813			
Razina znanja (RZ)				
C_RZ2	0,846	**0,702**	**0,834**	**0,629**
C_RZ3	0,682			
C_RZ4	0,841			
Krizne okolnosti (KO)				
C_KO1	0,713	**0,885**	**0,909**	**0,668**
C_KO2	0,743			
C_KO3	0,886			
C_KO4	0,885			
C_KO5	0,845			

Čestica	Vanjska opterećenja	Cronbach alfa	Kompozitna pouzdanost CR	Prosječna ekstrahirana varijanca AVE
Pritisak sudionika na tržištu (PST)				
C_PST1	0,827	**0,854**	**0,889**	**0,669**
C_PST2	0,847			
C_PST3	0,712			
C_PST4	0,875			
Namjera prihvaćanja (NP)				
C_NP1	0,980	**0,961**	**0,981**	**0,963**
C_NP2	0,982			

Nakon provjere pouzdanosti i konvergentne valjanosti provjerila se diskriminantna valjanost.

8.4.1.2. Diskriminantna valjanost – USLUŽNO RAČUNALSTVO

Diskriminantna valjanost ukazuje koliko se konstrukt razlikuje od drugih konstrukta u modelu. Procijenila se Fornell Larcker kriterijem te izračunom unakrsnih standardiziranih faktorskih opterećenja (*engl. cross-loadings*) [215].

Iz tablice unakrsnih standardiziranih faktorskih opterećenja razvidno je kako manifestne (opažene) varijable (čestice) imaju veći stupanj korelacije s onim konstruktom (latentnom varijablom) koji opisuju nego s ostalim latentnim varijablama (konstruktima). Hair i ostali sugeriraju kako vrijednost faktorskog opterećenja treba biti 0,7 ili više [215].

Tablica 62 Unakrsna standardizirana faktorska opterećenja - uslužno računalstvo

	C_KO	C_NP	C_PFR	C_PGV	C_PPD	C_PSR	C_PST	C_RZ
C_KO1	0,713	0,229	0,101	0,120	0,082	-0,093	0,414	0,232
C_KO2	0,743	0,180	0,081	0,118	0,119	-0,153	0,338	0,252
C_KO3	0,886	0,071	0,309	0,367	0,156	-0,056	0,224	0,577
C_KO4	0,885	0,048	0,302	0,393	0,215	-0,066	0,282	0,474
C_KO5	0,845	0,264	0,104	0,214	0,170	-0,180	0,372	0,364
C_NP1	0,175	0,980	-0,211	-0,171	0,360	-0,378	0,331	0,055

	C_KO	C_NP	C_PFR	C_PGV	C_PPD	C_PSR	C_PST	C_RZ
C_NP2	0,145	0,982	-0,217	-0,164	0,382	-0,396	0,284	0,091
C_PFR1	0,230	-0,221	0,828	0,585	0,028	0,178	0,253	0,415
C_PFR2	0,130	-0,150	0,668	0,474	0,115	0,018	0,127	0,324
C_PFR3	0,150	-0,144	0,840	0,703	0,089	0,078	0,171	0,421
C_PFR4	0,277	-0,157	0,831	0,728	0,129	0,129	0,208	0,441
C_PGV1	0,352	-0,100	0,581	0,798	0,109	0,150	0,255	0,514
C_PGV2	0,300	-0,202	0,764	0,958	0,177	0,156	0,203	0,564
C_PGV3	0,293	-0,173	0,740	0,961	0,199	0,155	0,221	0,569
C_PGV4	0,312	-0,087	0,720	0,901	0,280	0,156	0,161	0,573
C_PPD1	0,230	0,256	0,168	0,278	0,854	-0,165	0,118	0,285
C_PPD2	0,228	0,261	0,126	0,185	0,897	-0,230	0,082	0,233
C_PPD3	0,114	0,420	0,053	0,125	0,869	-0,243	0,046	0,231
C_PPD4	0,120	0,307	0,048	0,148	0,813	-0,184	-0,011	0,201
C_PSR2rev	-0,091	-0,410	0,124	0,171	-0,229	0,907	-0,108	0,089
C_PSR3rev	-0,128	-0,328	0,100	0,096	-0,221	0,930	-0,081	0,005
C_PSR4rev	-0,112	-0,332	0,152	0,189	-0,219	0,908	-0,015	0,049
C_PST1	0,346	0,346	0,112	0,110	0,189	-0,080	0,827	0,093
C_PST2	0,293	0,260	0,210	0,114	0,102	-0,112	0,847	0,112
C_PST3	0,298	0,383	0,083	0,054	0,032	-0,202	0,712	0,018
C_PST4	0,301	0,213	0,275	0,307	-0,049	-0,015	0,875	0,172
C_RZ2	0,402	-0,069	0,522	0,563	0,109	0,128	0,112	0,846
C_RZ3	0,308	0,317	0,194	0,277	0,487	-0,126	0,108	0,682
C_RZ4	0,478	-0,026	0,459	0,568	0,108	0,102	0,140	0,841

Napomena: Krizne okolnosti (C_KO), Namjera prihvaćanja (C_NP), Percipirani financijski rizik (C_PFR), Percipirani gubitak vremena (C_PGV), Percipirani pritisak države (C_PPD), Percipirani sigurnosni rizik (C_PSR), Pritisak sudionika na tržištu (C_PST), Razina znanja (C_RZ)

Fornell Larcker kriterij predstavlja drugi korijen AVE indikatora te ukazuje na diskriminantnu valjanost konstrukta onda kada je drugi korijen AVE indikatora pojedinog konstrukta veći od korelacije tog konstrukta i ostalih konstrukata u vanjskom reflektivnom modelu [215]. Iz tablice u nastavku vidljivo je kako je navedeni uvjet zadovoljen.

Tablica 63 Fornell-Larcker kriterij – uslužno računalstvo

	C_KO	C_NP	C_PFR	C_PGV	C_PPD	C_PSR	C_PST	C_RZ
C_KO	**0,817**							
C_NP	0,162	**0,981**						
C_PFR	0,253	-0,218	**0,795**					
C_PGV	0,335	-0,170	0,778	**0,907**				
C_PPD	0,190	0,379	0,106	0,203	**0,859**			
C_PSR	-0,119	-0,394	0,137	0,168	-0,244	**0,915**		
C_PST	0,364	0,312	0,247	0,229	0,063	-0,078	**0,818**	
C_RZ	0,508	0,075	0,506	0,606	0,274	0,056	0,153	**0,793**

Napomena: Krizne okolnosti (C_KO), Namjera prihvaćanja C_NP), Percipirani financijski rizik (C_PFR), Percipirani gubitak vremena (C_PGV), Percipirani pritisak države (C_PPD), Percipirani sigurnosni rizik (C_PSR), Pritisak sudionika na tržištu (C_PST), Razina znanja (C_RZ)

Kako bi se dodatno provjerila diskriminantna valjanost napravljen je Heterotrait-monotrait omjer korelacije (HTMT) koji zahtjeva vrijednost manju od 1 [224], [217]. Iz tablice u nastavku vidljivo je kako je navedeni uvjet zadovoljen.

Tablica 64 Heterotrait-monotrait omjer korelacije (HTMT) – uslužno računalstvo

	C_KO	C_NP	C_PFR	C_PGV	C_PPD	C_PSR	C_PST	C_RZ
C_KO								
C_NP	**0,208**							
C_PFR	0,252	**0,240**						
C_PGV	0,336	0,164	**0,899**					
C_PPD	0,214	0,391	0,153	**0,243**				
C_PSR	0,150	0,417	0,163	0,183	**0,266**			
C_PST	0,465	0,399	0,236	0,202	0,144	**0,141**		
C_RZ	0,573	0,210	0,656	0,742	0,379	0,186	**0,158**	

Napomena: Krizne okolnosti (C_KO), Namjera prihvaćanja C_NP), Percipirani financijski rizik (C_PFR), Percipirani gubitak vremena (C_PGV), Percipirani pritisak države (C_PPD), Percipirani sigurnosni rizik (C_PSR), Pritisak sudionika na tržištu (C_PST), Razina znanja (C_RZ)

Analiza mjernog (vanjskog) modela pokazala je da konceptualni model udovoljava zadanim kriterijima valjanosti i pouzdanosti.

8.4.2. Procjena mjernog (vanjskog) modela – PAMETNI UGOVORI

U nastavku slijedi procjena mjernog modela istraživanja prihvaćanja pametnih ugovora. Nakon provjere pouzdanosti i konvergentne valjanosti slijedi provjera diskriminantne valjanosti.

8.4.2.1. Pouzdanost i konvergentna valjanost – PAMETNI UGOVORI

U tablici 65 prikazane su vrijednosti vanjskih faktorskih opterećenja, Cronbach alfa koeficijent, koeficijent kompozitne pouzdanosti i AVE vrijednost. Vanjska faktorska opterećenja za čestice B_PFR3 (0,561), B_PFR4 (0,529), B_PSR1 (0,436), B_PSR5 (0,156) i B_PGV2 (0,437) ispod su preporučenih vrijednosti 0,6 i 0,7. U skladu s napomenom Hair i ostali kako je prije uklanjanja manifestnih (opaženih) varijabli s vrijednosti između 0,4 i 0,7 nužno provjeriti da li njihovo uklanjanje rezultira povećanjem kompozitne pouzdanosti, isto je provjereno [215]. Utvrđeno je kako uklanjanje čestica B_PFR3 i B_PFR4 ne rezultira znatnim povećanjem kompozitne pouzdanosti (prije uklanjanja CR=0,797, nakon uklanjanja CR=0,837), te iz tog razloga iste nisu uklonjene iz daljnje analize. No to nije bio slučaj za čestice B_PSR1, B_PSR2 (CR prije uklanjanja 0,739, CR nakon uklanjanja 0,938) i česticu B_PGV2 (CR prije uklanjanja 0,753, CR nakon uklanjanja 0,911) te su iste uklonjene iz daljnje analize. U tablici 65 u nastavku prikazani su rezultati Cronbach alfa, CR i AVE nakon uklanjanja čestica C_PSR1, C_PSR5, B_PGV2. Preostale čestice imaju zadovoljavajuće vrijednosti, tj. iznad preporučenih 0,7.

Svi konstrukti imaju zadovoljavajući Cronbach alfa koeficijenta i koeficijent kompozitne pouzdanosti (iznad 0,7) što ukazuje na dobru pouzdanost i unutarnju povezanost konstrukta [215]. AVE vrijednost za svaki konstrukt iznosi više od 0,5 što ukazuje na dobru konvergentnu valjanost [215] (tablica 65).

Tablica 65 Procjena mjernog modela – pametni ugovori

Čestica	Vanjska opterećenja	Cronbach alfa	Kompozitna pouzdanost CR	Prosječna ekstrahirana varijanca AVE
Percipirani financijski rizik (B_PFR)				
B_PFR1	0,896	**0,796**	**0,797**	**0,508**
B_PFR2	0,797			

Čestica	Vanjska opterećenja	Cronbach alfa	Kompozitna pouzdanost CR	Prosječna ekstrahirana varijanca AVE
B_PFR3	0,561			
B_PFR4	0,529			
Percipirani sigurnosni rizik (B_PSR)				
B_PSR2rev	0,925	**0,907**	**0,938**	**0,834**
B_PSR3rev	0,913			
B_PSR4rev	0,903			
Percipirani gubitak vremena (B_PGV)				
B_PGV1	0,922	**0,894**	**0,911**	**0,773**
B_PGV3	0,808			
B_PGV4	0,904			
Percipirani pritisak države (B_PPD)				
B_PPD1	0,863	**0,883**	**0,919**	**0,739**
B_PPD2	0,898			
B_PPD3	0,856			
B_PPD4	0,821			
Razina znanja (B_RZ)				
B_RZ2	0,760	**0,707**	**0,830**	**0,620**
B_RZ3	0,732			
B_RZ4	0,864			
Krizne okolnosti (B_KO)				
B_KO1	0,768	**0,888**	**0,914**	**0,681**
B_KO2	0,791			
B_KO3	0,882			
B_KO4	0,846			
B_KO5	0,833			
Pritisak sudionika na tržištu (B_PST)				
B_PST1	0,779	**0,890**	**0,919**	**0,741**
B_PST2	0,863			
B_PST3	0,909			

Čestica	Vanjska opterećenja	Cronbach alfa	Kompozitna pouzdanost CR	Prosječna ekstrahirana varijanca AVE
B_PST4	0,887			
Namjera prihvaćanja (B_NP)				
B_NP1	0,972	**0,942**	**0,972**	**0,945**
B_NP2	0,972			

Nakon provjere pouzdanosti i konvergentne valjanosti provjerila se diskriminantna valjanost.

8.4.2.2. Diskriminantna valjanost – PAMETNI UGOVORI

Diskriminantna valjanost pokazuje koliko se konstrukt razlikuje od drugih konstrukta u modelu. Procijenila se Fornell Larcker kriterijem te izračunom unakrsnih standardiziranih faktorskih opterećenja *(engl. cross-loadings)* [215].

Iz tablice 66 razvidno je da je ispunjen traženi uvjet da manifestne varijable (čestice) (izuzev čestica B_PFR3 i B_PFR4 koje su prethodno objašnjenje) imaju veći stupanj korelacije s onim konstruktom (latentnom varijablom) kojeg opisuju nego s ostalim latentnim varijablama [215].

Tablica 66 Unakrsna standardizirana faktorska opterećenja – pametni ugovori

	B_KO	B_NP	B_PFR	B_PGV	B_PPD	B_PSR	B_PST	B_RZ
B_KO1	0,768	0,301	0,252	0,276	0,152	-0,178	0,476	0,256
B_KO2	0,791	0,274	0,227	0,256	0,167	-0,238	0,399	0,243
B_KO3	0,882	0,191	0,290	0,345	0,285	-0,151	0,196	0,455
B_KO4	0,846	0,154	0,347	0,382	0,304	-0,166	0,254	0,415
B_KO5	0,833	0,374	0,182	0,254	0,233	-0,303	0,462	0,301
B_NP1	0,326	0,972	-0,076	0,116	0,480	-0,354	0,534	0,114
B_NP2	0,243	0,972	-0,103	0,051	0,482	-0,366	0,435	0,151
B_PFR1	0,290	-0,089	0,896	0,556	0,043	0,060	0,251	0,483
B_PFR2	0,252	-0,067	0,797	0,449	0,128	-0,092	0,141	0,448
B_PFR3	0,132	0,000	0,561	0,630	0,108	-0,034	0,197	0,437
B_PFR4	0,255	-0,005	0,529	0,683	0,217	-0,004	0,204	0,477

	B_KO	B_NP	B_PFR	B_PGV	B_PPD	B_PSR	B_PST	B_RZ
B_PGV1	0,366	0,070	0,556	0,922	0,129	0,010	0,281	0,496
B_PGV3	0,299	-0,013	0,623	0,808	0,182	0,029	0,275	0,501
B_PGV4	0,323	0,072	0,584	0,904	0,278	0,032	0,248	0,519
B_PPD1	0,295	0,364	0,176	0,237	0,863	-0,329	0,119	0,416
B_PPD2	0,254	0,352	0,067	0,130	0,898	-0,381	0,106	0,359
B_PPD3	0,212	0,514	0,018	0,174	0,856	-0,354	0,167	0,314
B_PPD4	0,253	0,427	0,101	0,227	0,821	-0,288	0,074	0,324
B_PSR2rev	-0,222	-0,439	0,053	0,057	-0,346	0,925	-0,180	-0,094
B_PSR3rev	-0,225	-0,243	-0,069	-0,024	-0,358	0,913	-0,122	-0,195
B_PSR4rev	-0,208	-0,263	-0,043	0,000	-0,385	0,903	-0,114	-0,179
B_PST1	0,341	0,505	0,099	0,138	0,275	-0,171	0,779	0,061
B_PST2	0,287	0,468	0,156	0,162	0,145	-0,165	0,863	0,072
B_PST3	0,372	0,408	0,256	0,294	0,113	-0,176	0,909	0,135
B_PST4	0,357	0,413	0,249	0,304	0,044	-0,073	0,887	0,125
B_RZ2	0,241	-0,058	0,482	0,435	0,263	-0,093	-0,027	0,760
B_RZ3	0,219	0,349	0,251	0,227	0,581	-0,330	0,083	0,732
B_RZ4	0,474	0,027	0,555	0,587	0,180	-0,001	0,173	0,864

Napomena: Krizne okolnosti (B_KO), Namjera prihvaćanja (B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR), Pritisak sudionika na tržištu (B_PST), Razina znanja (B_RZ)

Tablica 67 u nastavku ukazuje na zadovoljenje Fornell Larcker kriterija, tj. drugi korijen AVE indikatora pojedinog konstrukta veći je od korelacije tog konstrukta i ostalih konstrukata u vanjskom reflektivnom modelu [215].

Tablica 67 Fornell-Larcker kriterij – pametni ugovori

	B_KO	B_NP	B_PFR	B_PGV	B_PPD	B_PSR	B_PST	B_RZ
B_KO	**0,825**							
B_NP	0,292	**0,972**						
B_PFR	0,324	-0,092	**0,713**					
B_PGV	0,377	0,086	0,611	**0,879**				
B_PPD	0,291	0,495	0,099	0,224	**0,860**			
B_PSR	-0,239	-0,370	-0,006	0,022	-0,393	**0,913**		

	B_KO	B_NP	B_PFR	B_PGV	B_PPD	B_PSR	B_PST	B_RZ
B_PST	0,397	0,498	0,242	0,285	0,140	-0,161	**0,861**	
B_RZ	0,427	0,137	0,555	0,550	0,407	-0,157	0,125	**0,787**

Napomena: Krizne okolnosti (B_KO), Namjera prihvaćanja (B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR), Pritisak sudionika na tržištu (B_PST), Razina znanja (B_RZ)

Heterotrait-monotrait omjer korelacije (HTMT) kao dodatni način provjere diskriminantne valjanosti također ispunjava zadane kriterije, tj. vrijednosti manje od 1 [224], [217].

Tablica 68 Heterotrait-monotrait omjer korelacije (HTMT) – pametni ugovori

	B_KO	B_NP	B_PFR	B_PGV	B_PPD	B_PSR	B_PST	B_RZ
B_KO								
B_NP	**0,340**							
B_PFR	0,338	**0,070**						
B_PGV	0,389	0,066	**0,919**					
B_PPD	0,313	0,528	0,199	**0,245**				
B_PSR	0,275	0,371	0,079	0,040	**0,442**			
B_PST	0,478	0,564	0,268	0,302	0,183	**0,177**		
B_RZ	0,459	0,224	0,759	0,669	0,550	0,252	**0,156**	

Napomena: Krizne okolnosti (B_KO), Namjera prihvaćanja (B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR), Pritisak sudionika na tržištu (B_PST), Razina znanja (B_RZ)

Analiza mjernog (vanjskog) modela pokazala je da konceptualni model udovoljava zadanim kriterijima valjanosti i pouzdanosti.

8.5. Procjena prikladnosti modela podataka

PLS SEM analiza ne nudi adekvatan kriterij za procjenu podobnosti modela (*engl. goodnes of fit*), te se iz tog razloga u primjeni PLS SEM ne preporuča objavljivanje kriterija za procjenu podobnosti modela [203].

Stoga je u svrhu provjere podobnosti modela napravljena konfirmativna faktorska analiza (CFA) kao jedna od SEM tehnika koja omogućava procjenu podobnosti modela. Konfirmativna faktorska analiza omogućuje testiranje u kojoj mjeri empirijski podaci odgovaraju teorijski zasnovanom modelu. CFA je izvedena u programu IBM SPSS Amos 26.

Postoji nekoliko indeksa čija je svrha procjena podobnosti modela. U tablici 69 prikazani su indeksi podobnosti modela s njihovim preporučenim vrijednostima.

Tablica 69 Indeks procjene podobnosti modela

Indeks	**Preporučene vrijednosti**	**Izvor**
x^2/d.f.	< 5,00	[225]
GFI	> 0,90	[226]
AGFI	>0.90	[211]
SRMR	<0,08	[211]
RMSEA	< 0,08	[227]
NFI	> 0,90	[228]
CFI	> 0,90	[229]
IFI	> 0,90	[230]
TLI	> 0,91	[228]

Preporučene vrijednosti indeksa podobnosti modela često su predmet rasprava u literaturi zbog osjetljivosti pojedinih indeksa na veličinu uzorka, kompleksnost modela, normalnost podataka, vrstu podataka i slično [211], [231], [231]. Tako primjerice Cole i Nunnely za GFI navode vrijednosti jednake ili veće od 0,85 a vrijednosti za AGFI jednake ili veće od 0,80 [232], [233], dok Browne i Cudeck navode kako je prihvatljiva vrijednost za RMSEA manja od 0,10 [234], [235]. Brown navodi kako se vrijednost SRMR kreće između 0,0 i 1,0 gdje 0 označava savršenu podobnost modela [234].

Prvi korak u analizi procjene podobnosti modela bio je provjera svakog konstrukta zasebno, izuzev konstrukta koji su imali samo tri čestice a koji su kasnije provjereni u sklopu analize cjelokupnog modela [236]. U sklopu analize napravljene su pojedine modifikacije koje su uključivale povezivanje grešaka pojedine čestice unutar istog konstrukta onda i samo onda kada

je to bilo teorijski opravdano, sve u svrhu postizanja bolje podobnosti modela [207]. Modifikacije su prikazane na slici pojedinog konstrukta (slika 22,24). Cjelokupni model zahtijevao je nešto više modifikacija što je vidljivo na slici 23 i 25.

U nastavku slijedi prikaz rezultata procjene prikladnosti modela podataka u istraživanju prihvaćanja uslužnog računalstva nakon čega slijedi prikaz rezultata istraživanja prihvaćanja pametnih ugovora.

8.5.1. Procjena prikladnosti modela podataka – USLUŽNO RAČUNALSTVO

U nastavku su prikazane procijene podobnosti modela u istraživanju prihvaćanja uslužnog računalstva. Nakon provjere pojedinog konstrukta i prikaza rezultata istog, napravljena je provjera cijelog modela te su prikazani dobiveni indeksi podobnosti modela.

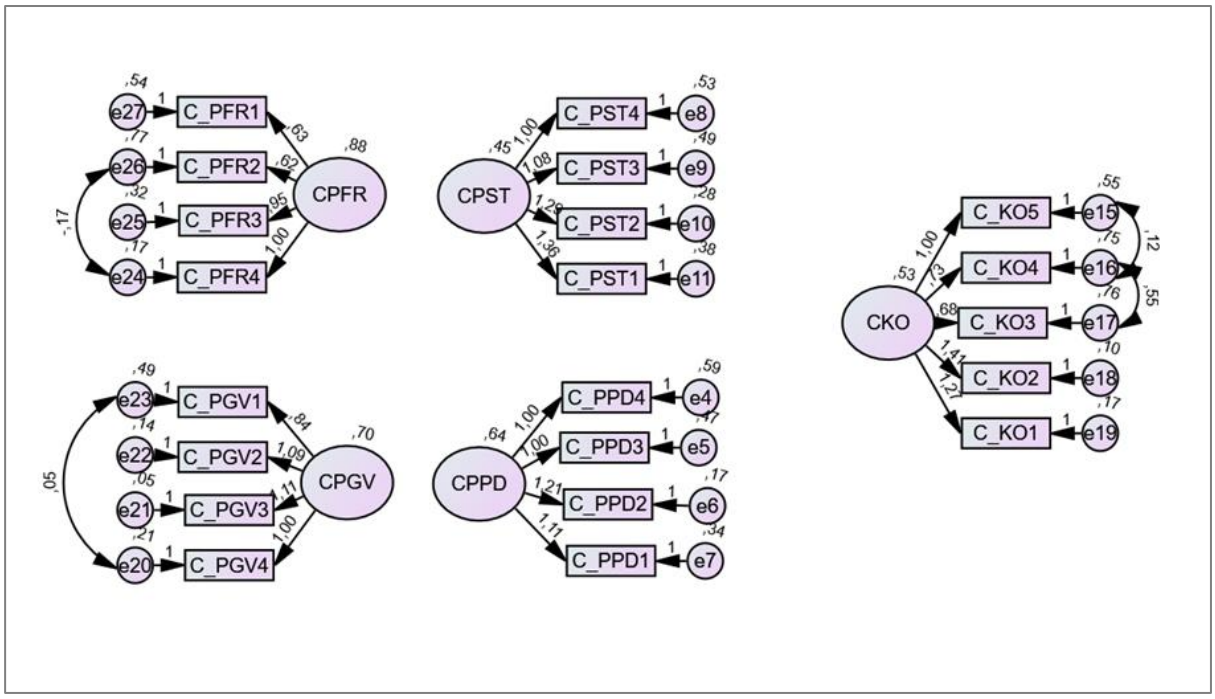

Slika 22 Prikaz modifikacija po pojedinim konstruktima – uslužno računalstvo

U tablici u nastavku prikazane su vrijednosti indeksa za svaki pojedeni konstrukt iz kojih je razvidno kako su vrijednosti u skladu s preporučenim vrijednostima, osima za RMSEA koja je za većinu konstrukata iznad preporučene vrijednosti 0,06.

Tablica 70 Indeksi podobnosti za pojedinačne konstrukte – uslužno računalstvo

	C_PFR	**C_PST**	**C_PGV**	**C_PPD**	**C_KO**
SRMR (<0,08)	0,0161	0,0369	0,0060	0,0187	0,0848
RMSEA (<0,06)	0,066	0,168	0,074	0,110	0,274
CFI (>0,9)	0,997	0,968	0,999	0,989	0,941
TLI (>0,9)	0,984	0,905	0,991	0,968	0,803
NFI (>0,9)	0,996	0,966	0,998	0,987	0,939
GFI (>0,9)	0,997	0,969	0,996	0,986	0,921

Napomena: Percipirani financijski rizik (C_PFR), Percipirani sigurnosni rizik (C_PSR), Percipirani gubitak vremena (C_PGV), Percipirani pritisak države (C_PPD), Krizne okolnosti (C_KO)

Dobivene vrijednosti za cjelokupni model prikazane su u tablici 71 u nastavku.

Tablica 71 Indeksi podobnosti modela – uslužno računalstvo

SRMR (<0,08)	0,0807
RMSEA (<0,06)	0,094
CFI (>0,9)	0,874
TLI (>0,9)	0,847
NFI (>0,9)	0,846
GFI (>0,9)	0,818

Razvidno je kako dobivene vrijednosti ne zadovoljavaju u potpunosti preporučene vrijednosti. No prema pojedinim autorima vrijednost iznad 0,8 za indeks GFI se smatra prihvatljivom zbog činjenice kako je isti osjetljiviji na veličinu uzorka [237], [238], [239]. Vrijednost CFI je veoma blizu preporučenoj vrijednosti što je prema pojedinim autorima dovoljan pokazatelj [240] [238]. Preostali indeksi nalaze se veoma blizu preporučenim vrijednostima što također određeni autori smatraju dovoljnim za definiranje modela podobnim [238].

Uzimajući u obzir kako su rezultati dobiveni u testiranju konvergentne valjanosti ukazali na dobru unutarnju povezanost konstrukta te kako su rezultati diskriminantne valjanosti isto tako unutar prihvatljivih vrijednosti, može se zaključiti kako je postignuta konstruktna valjanost modela.

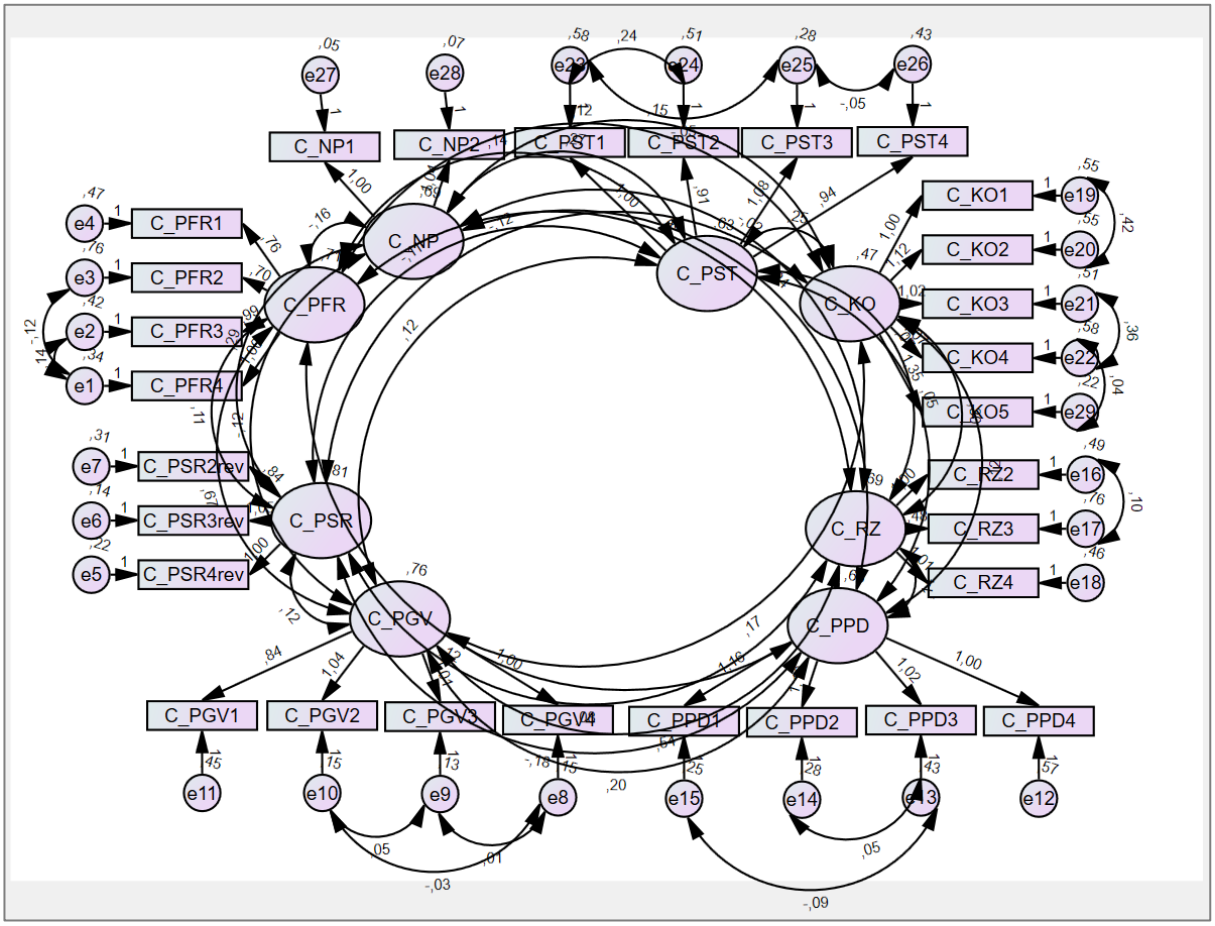

Slika 23 Prikaz modifikacija u cijelom modelu – uslužno računalstvo

8.5.2. Procjena prikladnosti modela podataka - PAMETNI UGOVORI

U nastavku su prikazani rezultati procijene podobnosti modela u istraživanju prihvaćanja pametnih ugovora. Prvo su provjereni pojedini konstrukti zasebno, nakon čega je provjeren cjelokupni model.

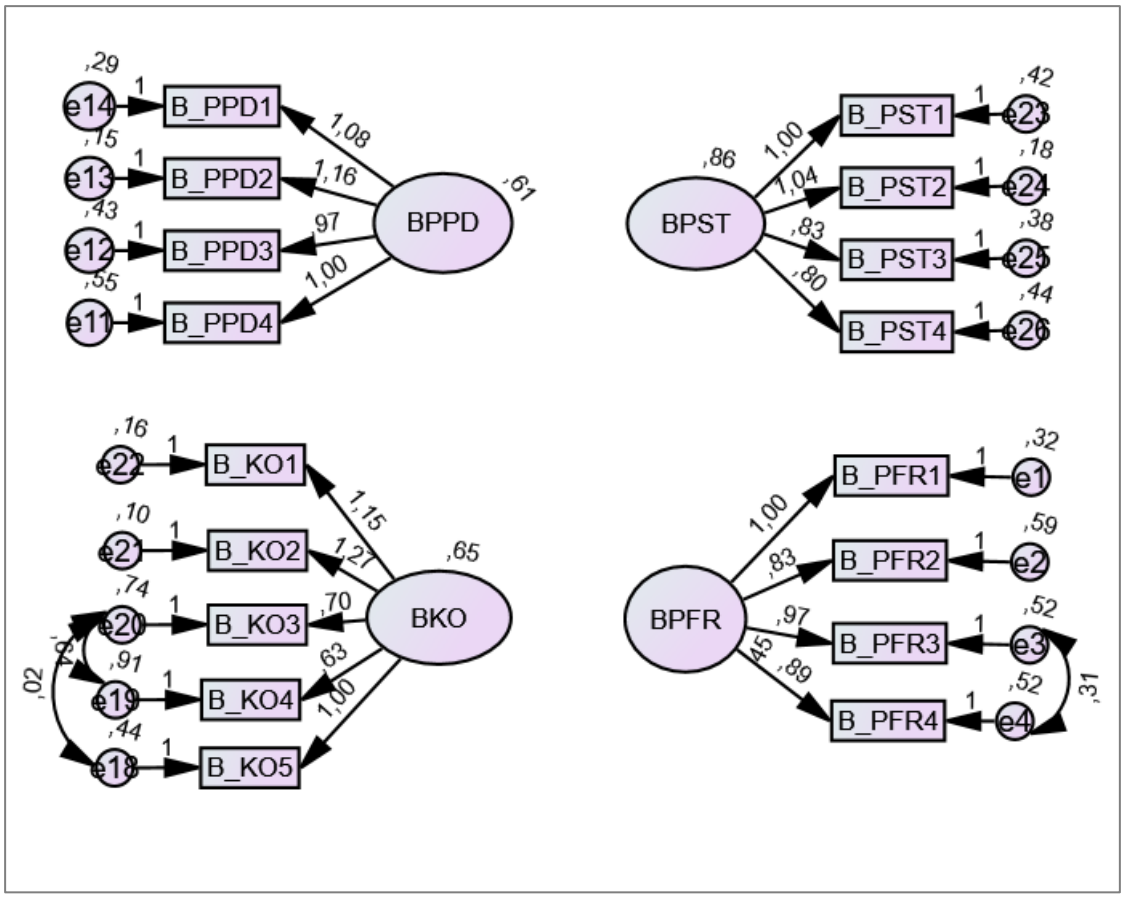

Slika 24 Prikaz modifikacija po pojedinim konstruktima – pametni ugovori

U tablici 72 u nastavku prikazane su vrijednosti indeksa podobnosti modela za svaki pojedini konstrukt. Razvidno je da nije zadovoljen uvjet za RMSEA indeks te indeks TLI za konstrukt B_PST. Preostali indeksi su zadovoljavajuće vrijednosti.

Tablica 72 Indeksi podobnosti za pojedinačne konstrukte – pametni ugovori

	B_PFR	**B_PST**	**B_PPD**	**B_KO**
SRMR (<0,08)	0,0254	0,0522	0,0127	0,0655
RMSEA (<0,06)	0,210	0,297	0,068	0,220
CFI (>0,9)	0,971	0,929	0,996	0,964
TLI (>0,9)	0,825	0,786	0,988	0,880
NFI (>0,9)	0,970	0,927	0,994	0,962
GFI (>0,9)	0,978	0,913	0,993	0,945

Napomena: Percipirani financijski rizik (B_PFR), Percipirani sigurnosni rizik (B_PSR), Percipirani pritisak države (B_PPD), Krizne okolnosti (B_KO)

Dobivene vrijednosti za cjelokupni model prikazane su u tablici 73 u nastavku.

Tablica 73 Indeksi podobnosti modela - pametni ugovori

SRMR (<0,08)	0,0862
RMSEA (<0,06)	0,106
CFI (>0,9)	0,849
TLI (>0,9)	0,815
NFI (>0,9)	0,825
GFI (>0,9)	0,793

Iz tablice 73 razvidno je kako dobivene vrijednosti ne zadovoljavaju u potpunosti preporučene vrijednosti. GFI je blizu preporučene vrijednosti 0,8 [237], [238], [239]. Vrijednosti CFI, NFI, TLI, SRMR blizu su preporučenoj vrijednosti što je prema pojedinim autorima dovoljni pokazatelj [240], [238].

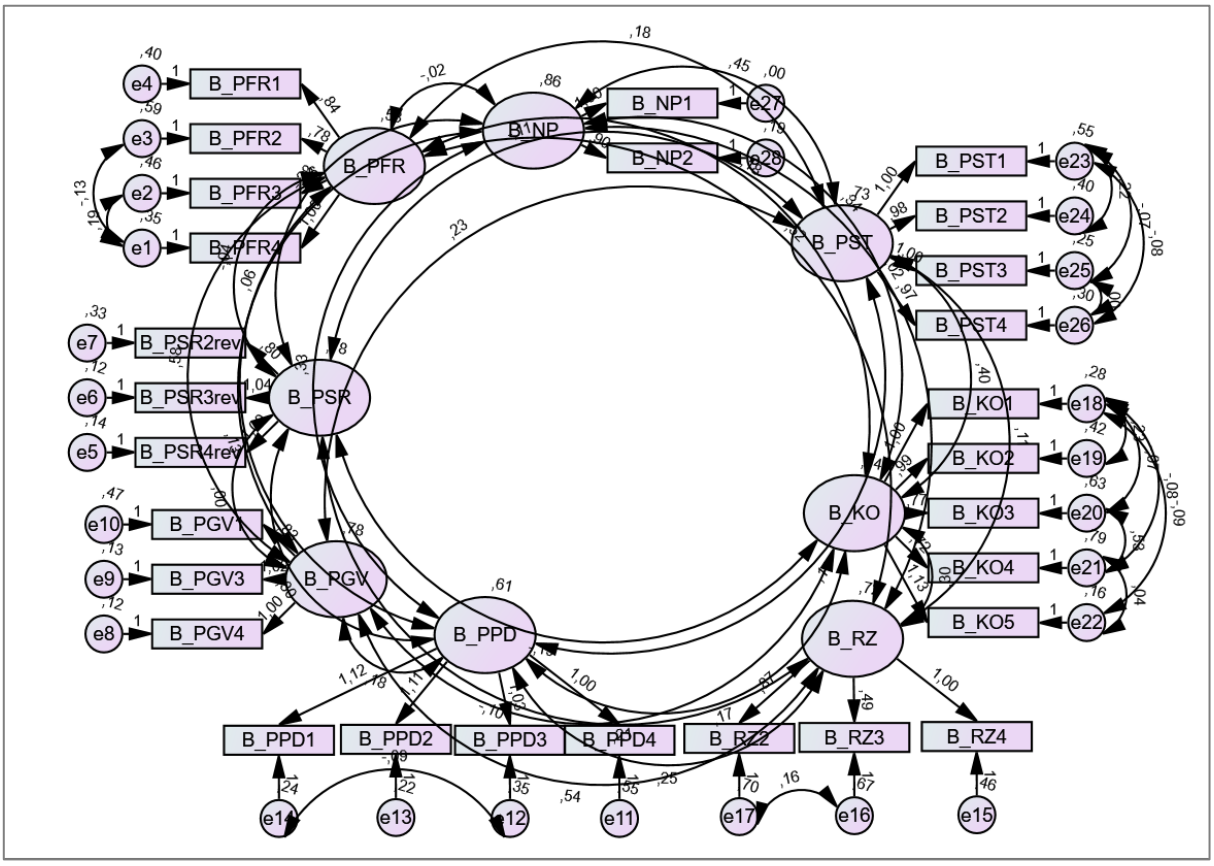

Slika 25 Prikaz modifikacija u cjelokupnom modelu – pametni ugovori

Uzimajući u obzir prethodno potvrđenu konvergentnu i diskriminantnu valjanost može se zaključiti kako je postignuta konstruktna valjanost modela.

8.6. Procjena strukturalnog (unutarnjeg) modela i testiranje hipoteza

Procjena strukturalnog modela, kao što je navedeno u poglavlju 7.4.2 uključuje [215]:

- provjera kolinearnosti,
- izračun korigiranog koeficijenta determinacije (R^2),
- izračun koeficijenta veličine učinka - Cohen-ov f^2 koeficijent (*engl. effect size*),
- izračun relevantnosti koeficijenta puta (*engl. path coefficient*).

U nastavku slijedi prikaz rezultata procjene strukturalnog (unutarnjeg) modela i testiranje hipoteza u istraživanju prihvaćanja uslužnog računalstva nakon čega slijedi prikaz rezultata istraživanja prihvaćanja pametnih ugovora.

8.6.1. Procjena strukturalnog (unutarnjeg) modela i testiranje hipoteza – USLUŽNO RAČUNALSTVO

Provjera kolinearnosti napravljena je pomoću faktora inflacije varijance (*engl. variance inflation factor* VIF). Iz tablice 74 razvidno je kako su sve vrijednosti unutar preporučenog raspona od 0,2 do 5 čime se može zaključiti kako ne postoji multikolinearnost između nezavisnih i zavisnih varijabli u strukturalnom modelu [215]. Dobivene vrijednosti kreću se u rasponu od 1,123 do 3,095 za nezavisne varijable C_PFR, C_PGV, C_PPD, C_PSR, C_RZ čija je zavisna varijabla namjera korištenja (C_NP) te iznos od 1,153 za nezavisne varijable C_KO i C_PST čija je zavisna varijabla razina znanja (C_RZ).

Tablica 74 Faktor inflacije varijance (VIF) - uslužno računalstvo

	C_KO	**C_NP**	**C_PFR**	**C_PGV**	**C_PPD**	**C_PSR**	**C_PST**	**C_RZ**
C_KO								1,153
C_NP								
C_PFR		2,574						

	C_KO	C_NP	C_PFR	C_PGV	C_PPD	C_PSR	C_PST	C_RZ
C_PGV		3,095						
C_PPD		1,190						
C_PSR		1,123						
C_PST								1,153
C_RZ		1,653						

Napomena: Krizne okolnosti (C_KO), Namjera prihvaćanja (C_NP), Percipirani financijski rizik (C_PFR), Percipirani gubitak vremena (C_PGV), Percipirani pritisak države (C_PPD), Percipirani sigurnosni rizik (C_PSR), Pritisak sudionika na tržištu (C_PST), Razina znanja (C_RZ)

Kako bi se ispitalo koliko je varijance endogene latentne varijable objašnjeno drugim egzogenim varijablama koristi se koeficijent determinacije (R^2) koji ima ulogu ukazati na kvalitetu prilagođenog modela.

Hair i ostali navode kako vrijednost R^2 od 0,75 ukazuje na jaku prediktivnu snagu, vrijednost od 0,5 na umjerenu i vrijednost od 0,25 na slabu prediktivnu snagu modela [215]. Pritom naglašavaju kako sama vrijednost ovisi o pojedinom modelu i području istraživanja. Ublažavajući stroge kriterije Haira i ostalih Cohen navodi kako vrijednosti od 0,26, 0,13 i 0,02 ukazuju na jaku, umjerenu i slabu prediktivnu snagu [218]. Dobivene vrijednosti, uzimajući u obzir kriterije predstavljene od strane Cohena, ukazuju na jaku prediktivnu snagu endogenih varijabli na namjeru prihvaćanja (R^2= 0,310) i slabu snagu endogenih varijabli na razinu znanja (R^2= 0,259).

Tablica 75 Koeficijent determinacije – uslužno računalstvo

	R^2	Prediktivna snaga
Namjera prihvaćanja	0,310	Jaka
Razina znanja	0,259	Slaba

U tablici 76 prikazane su vrijednosti koeficijenta veličine učinka (Cohenov f^2 koeficijent) koji predstavlja jačinu utjecaja pojedinog koeficijenta puta strukturalnog modela. Vrijednost od 0,02 predstavlja mali utjecaj, vrijednost od 0,15 srednji utjecaj te vrijednost od 0,35 predstavlja veliki utjecaj [218]. Vidljivo je kako krizne okolnosti (C_KO) imaju srednji utjecaj na razinu znanja

(C_RZ) (0,318). Pritisak sudionika na tržištu (C_PST) ima poprilično mali utjecaj na razinu znanja (C_RZ) (0,002). Percipirani financijski rizik (C_PFR), percipirani gubitak vremena (C_PGV), percipirani pritisak države (C_PPD), percipirani sigurnosni rizik (C_PSR) i razina znanja (C_RZ) na namjeru prihvaćanja (C_NP) imaju mali utjecaj (0,020, 0,012, 0,116, 0,099, 0,034).

Tablica 76 f^2 vrijednost – uslužno računalstvo

	C_KO	**C_NP**	**C_PFR**	**C_PGV**	**C_PPD**	**C_PSR**	**C_PST**	**C_RZ**
C_KO								0,318
C_NP								
C_PFR		0,020						
C_PGV		0,012						
C_PPD		0,116						
C_PSR		0,099						
C_PST								0,002
C_RZ		0,034						

Napomena: Krizne okolnosti (C_KO), Namjera prihvaćanja (C_NP), Percipirani financijski rizik (C_PFR), Percipirani gubitak vremena (C_PGV), Percipirani pritisak države (C_PPD), Percipirani sigurnosni rizik (C_PSR), Pritisak sudionika na tržištu (C_PST), Razina znanja (C_RZ)

Za procjenu prediktivne točnosti napravljen je izračun Stone-Geisser indikatora (Q^2) blindfolding procedurom. Vrijednost Q^2 veća od 0 ukazuje da model ima prediktivnu relevantnost za određeni endogeni konstrukt, vrijednosti od 0 i niže ukazuju na nedostatak prediktivne relevantnosti [215]. Konkretnije vrijednosti veće od 0 ukazuje na malu prediktivnu relevantnost, vrijednost veća od 0,25 ukazuje na srednju prediktivnu relevantnost i vrijednost veća od 0,50 ukazuje na veliku prediktivnu relevantnost PLS modela [217].

U tablici 77 prikazani su rezultati iz kojih je vidljivo da vrijednost endogenog konstrukta namjera prihvaćanja iznosi Q^2=0,291 što ukazuje na srednju prediktivnu relevantnost, dok vrijednost endogenog konstrukta razina znanja iznosi Q^2= 0,157 što ukazuje na malu predektivnu relevantnost.

Tablica 77 Q^2 vrijednost - uslužno računalstvo

	Q^2
Namjera prihvaćanja	0,291
Razina znanja	0,157

8.6.1.1. Analiza signifikantnosti i relevantnosti koeficijenta puta (*engl. Path analysis*) -USLUŽNO RAČUNALSTVO

Analizom koeficijent puta (*engl. path analysis*) istražuje se utjecaj na endogenu varijablu, tj. ukoliko je jedan koeficijent puta veći od drugog time je i njegov utjecaj na endogenu varijablu veći. Vrijednosti se kreću od -1,00 do +1,00 pri čemu vrijednosti bliže +1,00 ukazuju na statistički jaku pozitivnu vezu među varijablama.

Kako bi se utvrdila statistička značajnost koeficijenta puta između egzogenih i endogenih latentnih konstrukata u unutarnjem modelu upotrijebila se tzv. bootstrapping procedura (5.000 poduzoraka i značajnost na razini $p<0,05$) kojom je dobivana t- vrijednost i p- vrijednost. Uz stupanj signifikantnosti od 5% p-vrijednost mora biti niža od 0,05 kako bi se moglo zaključiti da je veza između konstrukata značajna. T-vrijednost veća od 1,96 uz stupanj signifikantnosti $\alpha=5\%$, ukazuje na značajnosti koeficijenta puta. U tablici 78 u nastavku prikazane su vrijednosti koeficijenta puta, t- vrijednost i p- vrijednost za pojedine veze te interpretacija rezultata, tj. postavljenih hipoteza.

Tablica 78 Sažetak vrijednosti strukturalnog modela – uslužno računalstvo

Hipoteza	Povezanost	Koeficijent puta ß	t-vrijednost	p-vrijednost	Interpretacija	Hipoteza podržana
H1.1	C_PFR → NP	-0,188	2,996	0,003	Značajan	DA
H1.2	C_PSR → NP	-0,277	6,610	0,000	Značajan	DA
H1.3	C_PGV → NP	-0,160	2,442	0,015	Značajan	DA
H2.1	C_PPD → NP	0,309	7,548	0,000	Značajan	DA
H2.2	C_RZ → NP	0,198	3,208	0,001	Značajan	DA
	C_KO → RZ	0,521	13,331	0,000	Značajan	

Hipoteza	Povezanost	Koeficijent puta ß	t-vrijednost	p-vrijednost	Interpretacija	Hipoteza podržana
	C_PST → RZ	-0,037	0,588	0,557	Nije značajan	

Napomena: Krizne okolnosti (C_KO), Namjera prihvaćanja (C_NP), Percipirani financijski rizik (C_PFR), Percipirani gubitak vremena (C_PGV), Percipirani pritisak države (C_PPD), Percipirani sigurnosni rizik (C_PSR), Pritisak sudionika na tržištu (C_PST), Razina znanja (C_RZ

Iz tablice je razvidno kako se u potpunosti prihvaća H1 zbog potvrđivanja svih podhipoteza H1.1, H1.2. i H.1.3 (H1.1 ß=-0,188, t=2,996, p=0,003, H1.2 ß=-0,277, t=6,610, p=0,000, H1.3 ß=-0,160, t=2,442, p=0,015). U potpunosti se prihvaća H2 zbog potvrđivanja svih podhipotezea (H2.1 ß=0,309, t=7,548, p=0,000, H2.2 ß=0,198, t=3,208, p=0,001).

U tablici su prikazane i veze koje nisu obuhvaćene hipotezama ali imaju važnost za daljnju analizu moderirajućeg utjecaja. Veza između kriznih okolnosti i razine znanja prema dobivenim vrijednostima ukazuje na statistički značajnu vezu, dok veza između pritiska sudionika na tržištu i razine znanja nije statistički značajna.

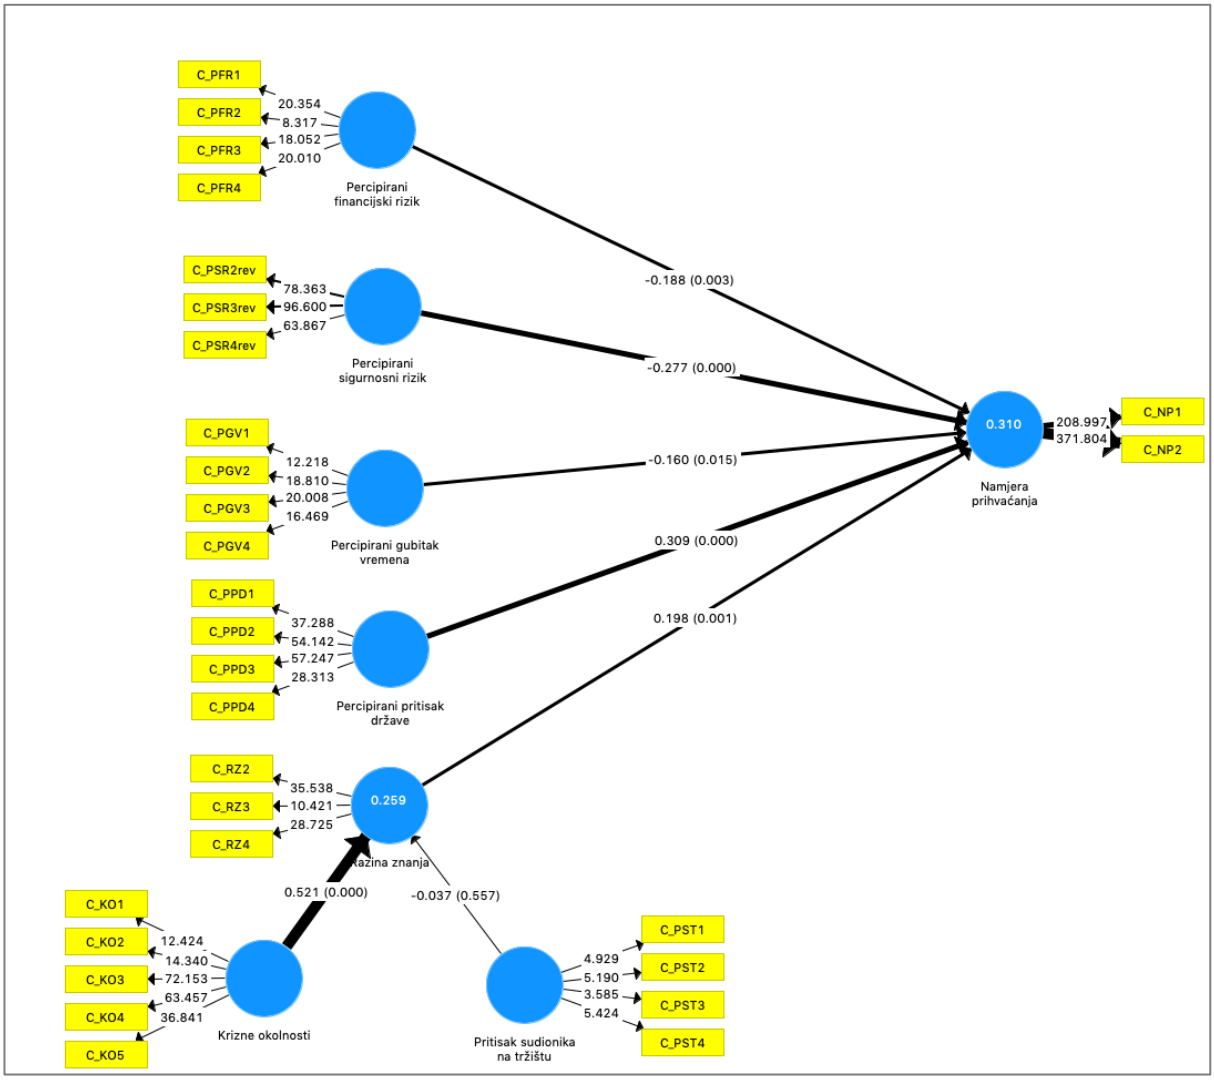

Slika 26 Strukturalni model (unutarnji model: path analiza i p vrijednost, konstrukti R^2, vanjski model: t vrijednost) - uslužno računalstvo

8.6.2. Procjena strukturalnog (unutarnjeg) modela i testiranje hipoteza prihvaćanja - PAMETNI UGOVORI

U tablici 79 prikazani su rezultati provjere kolinearnosti putem faktora inflacije varijance (VIF faktor). Rezultati ukazuju kako ne postoji multikolinearnost između nezavisnih i zavisnih varijabli u strukturalnom modelu.

Vrijednosti VIF faktora kreću se u rasponu od 1,208 do 1,899 za nezavisne varijable B_PFR, B_PGV, B_PPD, B_PSR, B_RZ čija je zavisna varijabla namjera korištenja B_NP te 1,187 za

nezavisne varijable B_KO i B_PST čija je zavisna varijabla razina znanja B_RZ. Sve vrijednosti su unutar preporučenog raspona od 0,2 do 5 [215].

Tablica 79 Faktor inflacije varijance (VIF) - pametni ugovori

	B_KO	**B_NP**	**B_PFR**	**B_PGV**	**B_PPD**	**B_PSR**	**B_PST**	**B_RZ**
B_KO								1,187
B_NP								
B_PFR		1,857						
B_PGV		1,826						
B_PPD		1,434						
B_PSR		1,208						
B_PST								1,187
B_RZ		1,899						

Napomena: Krizne okolnosti (B_KO), Namjera prihvaćanja (B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR), Pritisak sudionika na tržištu (B_PST), Razina znanja (B_RZ)

Endogena vrijednost konstrukta namjera prihvaćanja ukazuju na jaku prediktivnu snagu endogenih varijabli na namjeru prihvaćanja (R^2=0,310), dok vrijednost za konstrukt razina znanja ukazuje na slabu prediktivnu snagu endogenih varijabli na razinu znanja (R^2=0,185) [218].

Tablica 80 Koeficijent determinacije – pametni ugovori

	R^2	**Prediktivna snaga**
Namjera prihvaćanja	0,310	Jaka
Razina znanja	0,185	Slaba

U tablici 81 prikazane su vrijednosti koeficijenta veličine učinka - Cohenov f^2 koeficijent. Vrijednost od 0,02 predstavlja mali utjecaj, vrijednost od 0,15 srednji utjecaj te vrijednost od 0,35 veliki utjecaj [218]. Krizne okolnosti (B_KO) imaju srednji utjecaj na razinu znanja (B_RZ) (f^2=0,208), kao i percipirani pritisak države (B_PPD) na namjeru korištenja (B_NP) (f^2=0,169). Pritisak sudionika na tržištu (B_PST) ima neznatni utjecaj na razinu znanja (B_RZ)

(f^2=0,003), kao i razina znanja (B_RZ) i percipirani gubitak vremena (B_PGV) na namjeru prihvaćanja (B_NP) (f^2=0,001, f^2=0,015). Percipirani financijski rizik (B_PFR) i percipirani sigurnosni rizik (B_PSR) imaju mali utjecaj (f^2=0,032, f^2=0,057).

Tablica 81 f^2 vrijednost – pametni ugovori

	B_KO	**B_NP**	**B_PFR**	**B_PGV**	**B_PPD**	**B_PSR**	**B_PST**	**B_RZ**
B_KO								0,208
B_NP								
B_PFR		0,032						
B_PGV		0,015						
B_PPD		0,169						
B_PSR		0,057						
B_PST								0,003
B_RZ		0,001						

Napomena: Krizne okolnosti (B_KO), Namjera prihvaćanja B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR), Pritisak sudionika na tržištu (B_PST), Razina znanja (B_RZ)

U tablici 82 prikazani su rezultati Stone-Geisser indikatora prediktivne točnosti (Q^2). Vrijednost endogenog konstrukta namjera prihvaćanja iznosi Q^2=0,285 što ukazuje na srednju prediktivnu relevantnost, dok vrijednost endogenog konstrukta razina znanja ukazuje na malu prediktivnu relevantnost Q^2=0,102 [217].

Tablica 82 Q^2 vrijednost- pametni ugovori

	Q^2
Namjera prihvaćanja	0,285
Razina znanja	0,102

8.6.1.2. Analiza signifikantnosti i relevantnosti koeficijenta puta (*engl. Path analysis*) – PAMETNI UGOVORI

U tablici 83 u nastavku prikazane su vrijednosti koeficijenta puta, t- vrijednosti i p- vrijednost za pojedine veze te interpretacija rezultata, tj. postavljenih hipoteza u istraživanju prihvaćanja pametnih ugovora. Razvidno je kako postoji statistički značajna veza između percipiranog

sigurnosnog rizika i namjere prihvaćanja čime se prihvaća hipoteza H1.2 i percipiranog pritiska države i namjere prihvaćanja čime se prihvaća podhipoteza H2.1. Ostale veze nisu statistički značajne što ukazuje na odbacivanje preostalih podhipoteza. Iz tablice je razvidno i kako je identificirana statistički značajna veza između kriznih okolnosti i razine znanja.

Tablica 83 Sažetak vrijednosti strukturalnog modela – pametni ugovori

Hipoteza	Povezanost	Koeficijent puta ß	t-vrijednost	p-vrijednost	Interpretacija	Hipoteza podržana
H1.1.	B_PFR → NP	-0,202	1,911	0,056	Nije značajan	NE
H1.2.	B_PSR → NP	-0,218	5,638	0,000	Značajan	DA
H1.3	B_PGV → NP	0,138	1,240	0,215	Nije značajan	NE
H2.1.	B_PPD → NP	0,409	8,129	0,000	Značajan	DA
H2.2	B_RZ → NP	-0,028	0,357	0,721	Nije značajan	NE
	B_KO → RZ	0,448	8,444	0,000	Značajan	
	B_PST → RZ	-0,053	0,801	0,423	Nije značajan	

Napomena: Krizne okolnosti (B_KO), Namjera prihvaćanja B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR), Pritisak sudionika na tržištu (B_PST), Razina znanja (B_RZ)

Djelomično se prihvaća H1 i H2. Prihvaća se podhipoteza H1.2. (H1.2 ß=-0,218, t=5,638, p=0,000,) i podhipoteza H.2.1 (H2.1 ß=0,409, t=8,129, p=0,000).

Promatrajući veza kriznih okolnosti i razine znanja postoji statistički značajna veza, dok između pritiska sudionika na tržištu i razine znanja ne postoji statistički značajna veza.

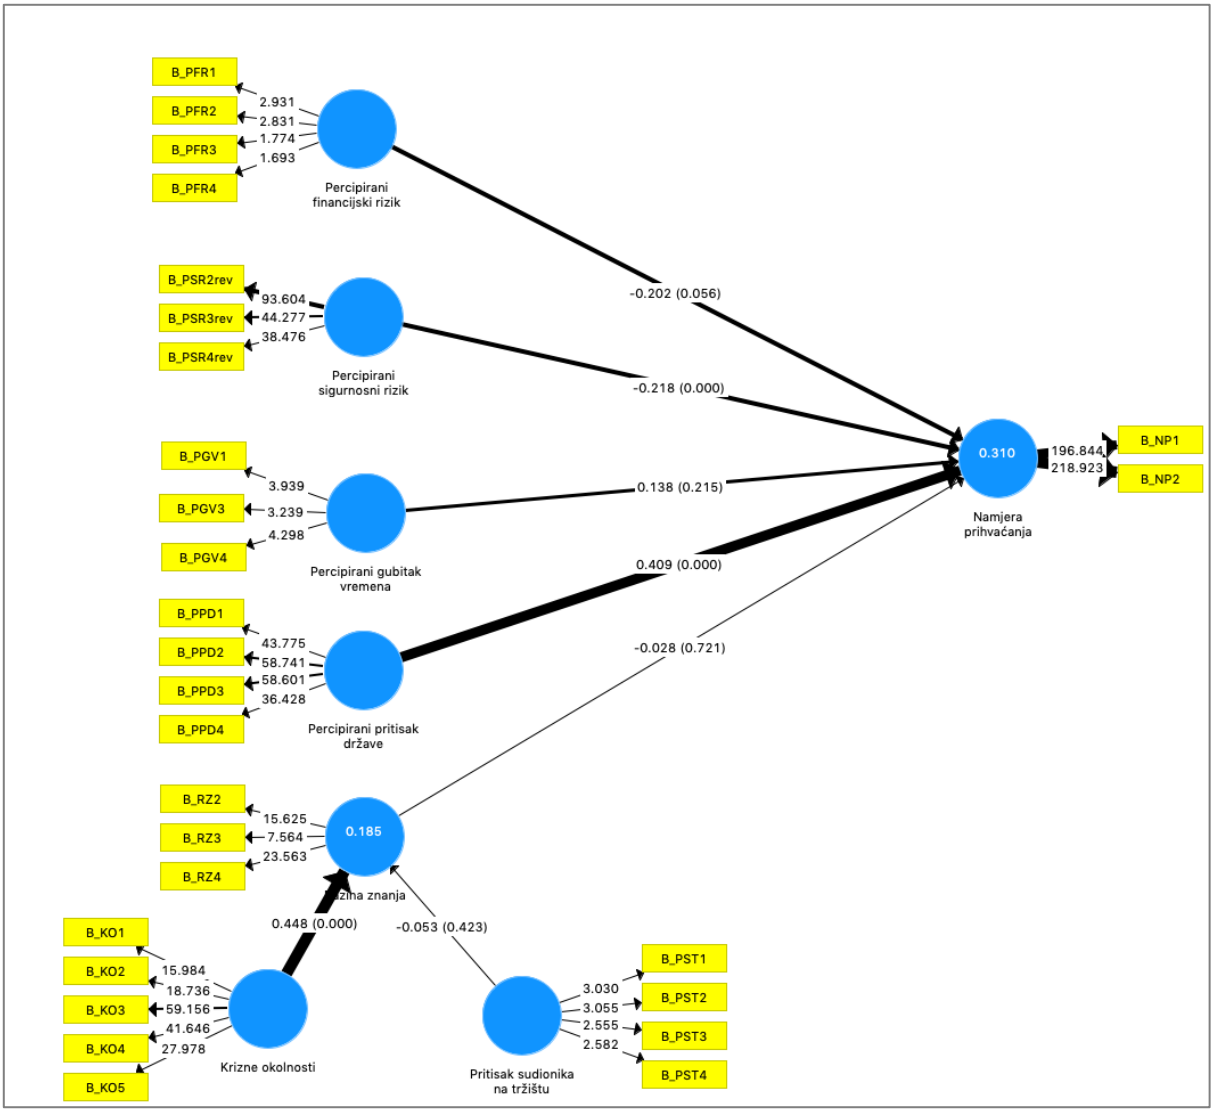

Slika 27 Strukturalni model (unutarnji model: path analiza i p vrijednost, konstrukti R^2, vanjski model: t vrijednost) - pametni ugovori

8.7. Moderirajući utjecaj

Kako bi se ispitao moderirajući utjecaj digitalne zrelosti organizacije i konkurentskih prioriteta na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja, i utjecaj stila odlučivanja na povezanost vanjskih pritiska (kriznih okolnosti i pritiska sudionika na tržištu) i razine znanja, napravljena je analiza moderirajućeg utjecaja.

Moderirajući utjecaj odnosi se na situaciju kada moderator (nezavisna varijabla ili konstrukt) promjeni jačinu ili smjer utjecaja, tj. veze između dva konstrukta u modelu [203].

Cilj je utvrditi postoje li razlike između pojedinih grupa što se postiže upotrebom višegrupne analize, pri čemu se uspoređuje isti model kroz različite grupe u uzorku [203].

U istraživanju sve tri moderirajuće varijable: digitalna zrelost, konkurentski prioriteti i stil odlučivanja su kategoričke, pri čemu digitalna zrelost ima tri grupe, konkurentski prioriteti pet grupa i stil odlučivanja dvije grupe.

U nastavku su prikazani rezultati višegrupne analize moderirajućeg utjecaja digitalne zrelosti i konkurentskih prioriteta na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja. Prikazani su i rezultati višegrupne analize moderirajućeg utjecaja stila odlučivanja na povezanost vanjskih pritiska (krizne okolnosti i pritisak sudionika na tržištu) s razinom znanja donositelja odluka.

8.7.1. Moderirajući utjecaj digitalne zrelosti– USLUŽNO RAČUNALSTVO

Kako bi se provjerio moderirajući utjecaj digitalne zrelosti na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja uslužnog računalstva napravljena je višegrupna analiza.

Prije same analize provjerilo se postoje li razlike između promatranih grupa što je napravljeno univarijantnom analizom varijance (ANOVA). ANOVA je metoda kojom se uspoređuju aritmetičke sredine više uzoraka, te se na temelju F-testa donosi zaključak o (ne)postojanju značajnih razlika između sredina više populacija [241]. Analiza varijance (ANOVA) upotrebljava se pri testiranju razlika aritmetičkih sredina triju i više skupina (uzoraka) a testira se odnos varijabiliteta između i unutar skupina ispitanika [208].

Tablica 84 ANOVA – razina digitalne zrelosti – uslužno računalstvo

		Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	F	Sig.
C_PFR	Između grupa	15,942	2	7,971	12,817	0,000
	Unutar grupa	266,804	429	0,622		
	Ukupno	282,746	431			
C_PSR	Između grupa	15,044	2	7,522	9,437	0,000
	Unutar grupa	341,937	429	0,797		
	Ukupno	356,981	431			
C_PGV	Između grupa	19,706	2	9,853	13,350	0,000
	Unutar grupa	316,613	429	0,738		
	Ukupno	336,319	431			
C_PPD	Između grupa	0,157	2	0,079	0,092	0,912
	Unutar grupa	367,158	429	0,856		
	Ukupno	367,316	431			
C_NP	Između grupa	12,244	2	6,122	8,489	0,000
	Unutar grupa	309,394	429	0,721		
	Ukupno	321,638	431			

Kada je p-vrijednost F-omjera manja od 0,05 moguće je ustvrditi da su razlike između aritmetičkih sredina skupina (grupa) statistički značajne ($p < 0,05$). Rezultati ukazuju kako postoje statistički značajne razlike u aritmetičkim sredinama između grupa za sve varijable, osim za varijablu C_PPD.

U nastavku su prikazani rezultati višegrupne analize moderirajućeg utjecaja razine digitalne zrelosti organizacije na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja uslužnog računalstva.

Tablica 85 Višegrupna analiza – razina digitalne zrelosti– uslužno računalstvo

Povezanost	Koeficijent puta (1 razina)	Koeficijent puta (2 razina)	Koeficijent puta (3 razina)	t-vrijednost (1 razina)	t-vrijednost (2 razina)	t-vrijednost (3 razina)	p-vrijednost (1 razina)	p-vrijednost (2 razina)	p-vrijednost (3 razina)
C_PFR -> C_NP	-0,093	-0,358	-0,277	0,846	3,556	1,471	0,398	**0,000**	0,141
C_PSR -> C_NP	-0,178	-0,280	-0,324	3,073	4,416	2,658	**0,002**	**0,000**	**0,008**
C_PGV -> C_NP	-0,070	-0,315	0,065	0,587	3,194	0,245	0,557	**0,001**	0,806
C_PPD -> C_NP	0,471	0,074	0,310	5,368	1,045	1,947	**0,000**	0,296	0,052

Napomena: Namjera prihvaćanja (C_NP), Percipirani financijski rizik (C_PFR), Percipirani gubitak vremena (C_PGV), Percipirani pritisak države (C_PPD), Percipirani sigurnosni rizik (C_PSR)

Rezultati višegrupne analize ukazuju kako za prvu razinu digitalne zrelosti postoji statistički značajni utjecaj percipiranog sigurnosnog rizika (C_PSR) i percipiranog pritiska države (C_PPD) na namjeru prihvaćanja. Za drugu razinu digitalne zrelosti postoji statistički značajna veza između percipiranog financijskog rizika (C_PFR), percipiranog sigurnosnog rizika (C_PSR) i percipiranog gubitka vremena (C_PGV) na namjeru prihvaćanja. Za treću razinu digitalne zrelosti postoji statistički značajna veza između percipiranog sigurnosnog rizika (C_PSR) i namjere prihvaćanja. Promatrajući utjecaj sigurnosnog rizika na namjeru prihvaćanja on je najjači na trećoj razini digitalne zrelosti.

Prethodno je ANOVOM utvrđeno kako ne postoje razlike u aritmetičkim sredinama unutar grupa za varijablu percipirani pritisak države (C_PPD), stoga je za istu napravljen parametrijski test kako bi se potvrdilo da postoje razlike između grupa (tablica 86). Parametrijski test, pretpostavljajući jednaku varijancu u grupama, ukazuje postoje li razlike između promatranih grupa.

Iz tablice 86 vidljivo je kako postoji statistički značajna razlika između prve i druge razine digitalne zrelosti u povezanosti percipiranog pritiska države (C_PPD) i namjere prihvaćanja (C_NP) te je ta veza, kao što je vidljivo na tablici 85, jača na prvoj razini.

Tablica 86 Parametrijski test razlika razine digitalne zrelosti– uslužno računalstvo

Povezanost	Usporedba	Koeficijent puta razlika	t-vrijednost	p-vrijednost
C_PPD -> C_NP	1 RAZINA vs 2 RAZINA	0,397	3,494	**0,001**
	1 RAZINA vs 3 RAZINA	0,161	0,964	0,336
	2 RAZINA vs 3 RAZINA	-0,237	1,554	0,121

Napomena: Namjera prihvaćanja (C_NP), Percipirani pritisak države (C_PPD)

U skladu s rezultatima višegrupne analize i parametrijskog testa može se potvrditi kako je povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja različita ovisno o razini digitalne zrelosti organizacije, čime se prihvaća hipoteza H3.

8.7.2. Moderirajući utjecaj konkurentskih prioriteta – USLUŽNO RAČUNALSTVO

Kako bi se provjerio moderirajući utjecaj konkurentskih prioriteta (brzina, fleksibilnost, kvaliteta, pouzdanost, troškovi) na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja uslužnog računalstva napravljena je višegrupna analiza.

Prvo se provjerilo postoje li razlike između promatranih grupa (brzina, fleksibilnost, kvaliteta, pouzdanost, troškovi). Za testiranje razlika aritmetičkih sredina grupa primijenjena je ANOVA, te su rezultati prikazani u tablici 87 u nastavku.

Tablica 87 ANOVA –konkurentski prioriteti– uslužno računalstvo

		Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	F	Sig.
C_PFR	Između grupa	10,228	4	2,557	4,006	0,003
	Unutar grupa	272,518	427	0,638		
	Ukupno	282,746	431			

		Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	F	Sig.
C_PSR	Između grupa	16,177	4	1,044	5,067	0,001
	Unutar grupa	340,804	427	0,798		
	Ukupno	356,981	431			
C_PGV	Između grupa	11,068	4	2,767	3,633	0,006
	Unutar grupa	325,251	427	0,762		
	Ukupno	336,319	431			
C_PPD	Između grupa	16,429	4	4,107	4,998	0,001
	Unutar grupa	350,887	427	0,822		
	Ukupno	367,316	431			
C_NP	Između grupa	28,399	4	7,100	10,338	0,000
	Unutar grupa	293,239	427	0,687		
	Ukupno	321,638	431			

Napomena: Namjera prihvaćanja (C_NP), Percipirani financijski rizik (C_PFR), Percipirani gubitak vremena (C_PGV), Percipirani pritisak države (C_PPD), Percipirani sigurnosni rizik (C_PSR)

Rezultati ANOVE ukazuju kako postoje statistički značajne razlike u aritmetičkim sredinama između promatranih grupa za sve varijable ($p<0,05$).

U nastavku su prikazani rezultati višegrupne analize moderirajućeg utjecaja konkurentskih prioriteta (brzina, fleksibilnost, kvaliteta, pouzdanost, troškovi) na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja uslužnog računalstva.

Razvidno je kako za konkurentski prioritet brzina postoji statistički značajan utjecaj percipiranog financijskog rizika (C_PFR) i percipiranog pritiska države (C_PPD) na namjeru prihvaćanja (C_NP). Za fleksibilnost i za pouzdanost postoji statistički značajan utjecaj percipiranog sigurnosnog rizika (C_PSR) na namjeru prihvaćanja.

Za kvalitetu postoji statistički značaj utjecaj percipiranog sigurnosnog rizika (C_PSR) i percipiranog gubitka vremena (C_PGV) na namjeru prihvaćanja (C_NP) dok za troškove postoji statistički značajna utjecaj percipiranog sigurnosnog rizika (C_PSR) i percipiranog pritiska države (C_PPD) na namjeru prihvaćanja (C_NP). Promatrajući povezanost

percipiranog sigurnosnog rizik i namjere prihvaćanja razvidno je kako je najjači utjecaj kod organizacija koje pri prihvaćanju uslužnog računalstva žele postići povećanje pouzdanosti.

Može se zaključiti kako konkurentski prioriteti utječu na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) i namjere prihvaćanja uslužnog računalstva, čime se prihvaća hipoteza H4.

Tablica 88 Višegrupna analiza –konkurentski prioriteti– uslužno računalstvo

Povezanost	Koeficijent puta (B)	Koeficijent puta (F)	Koeficijent puta (K)	Koeficijent puta (P)	Koeficijent puta (T)	t-vrijednost (B)	t-vrijednost (F)	t-vrijednost (K)	t-vrijednost (P)	t-vrijednost (T)	p-vrijednost (B)	p-vrijednost (F)	p-vrijednost (K)	p-vrijednost (P)	p-vrijednost (T)
C_PFR -> C_NP	-0,561	-0,128	0,204	-0,475	-0,073	3,443	0,714	0,627	1,925	0,412	**0,001**	0,475	0,531	0,054	0,680
C_PSR -> C_NP	-0,020	-0,378	-0,316	-0,593	-0,465	0,200	4,019	3,070	4,074	6,062	0,841	**0,000**	**0,002**	**0,000**	**0,000**
C_PGV -> C_NP	0,254	-0,264	-0,483	0,296	-0,232	1,670	1,202	2,196	1,212	1,270	0,095	0,229	**0,028**	0,226	0,204
C_PPD -> C_NP	0,307	-0,115	0,151	0,218	0,378	2,209	0,641	1,619	1,250	3,839	**0,027**	0,522	0,106	0,211	**0,000**

Napomena: Namjera prihvaćanja C_NP), Percipirani financijski rizik (C_PFR), Percipirani gubitak vremena (C_PGV), Percipirani pritisak države (C_PPD), Percipirani sigurnosni rizik (C_PSR), Pritisak sudionika na tržištu (C_PST), Brzina (B), Fleksibilnost (F), Kvaliteta (K), Pouzdanost (P), Troškovi (T)

8.7.3. Moderirajući utjecaj stila odlučivanja – USLUŽNO RAČUNALSTVO

Kako bi se provjerio moderirajući utjecaj stila odlučivanja donositelja odluke na povezanost vanjskih pritiska (krizne okolnosti i pritisak sudionika na tržištu) s razinom znanja provedena je višegrupna analiza.

Prije samog provođenja višegrupne analize provjereno je postoje li razlike između dvije promatrane grupe (intuitivni i racionalni stil). Isto je napravljeno T testom koji ukazuje postoje li razlike u aritmetičkim sredinama promatranih grupa. T test nezavisnih uzoraka testira pretpostavku o statistički značajnoj razlici dviju aritmetičkih sredina nezavisnih uzoraka [208].

U tablici 89 u nastavku razvidno je kako rezultati t testa ukazuju (p vrijednost<0,05) da se grupe međusobno razlikuju.

Tablica 89 T test (stil odlučivanja) – uslužno računalstvo

	T-test		
	t	**df**	**P-vrijednost**
C_KO	5,478	430	0,000
C_PST	3,788	430	0,000
C_RZ	2,668	430	0,008

Napomena: Krizne okolnosti (C_KO), Pritisak sudionika na tržištu (C_PST), Razina znanja (C_RZ)

Nakon što je provjereno da se grupe međusobno razlikuju napravljena je višegrupna analiza.

U tablici 90 prikazani su rezultati višegrupne analize utjecaja stila odlučivanja na povezanost pritiska sudionika na tržištu (C_PST) i kriznih okolnosti (C_KO) na razinu znanja donositelja odluke (C_RZ).

Razvidno je kako je za oba stila uočena statistički značajna veza između kriznih okolnosti i razine znanja. Veza između pritiska sudionika i razine znanja nije statistički značajna. Razvidno je i kako je veza između kriznih okolnosti i razine znanja jača kod donositelja odluka s intuitivnim stilom (racionalni ß=0,481, intuitivni ß=0,911).

Tablica 90 Višegrupna analiza – stil odlučivanja– uslužno računalstvo

Povezanost	Koeficijent puta (Intuitivni)	Koeficijent puta (racionalni)	t-vrijednost (Intuitivni)	t-vrijednost (racionalni)	p-vrijednost (Intuitivni)	p-vrijednost (racionalni)
C_KO -> C_RZ	0,911	0,481	9,784	12,222	0,000	0,000
C_PST -> C_KO	-0,193	-0,000	1,562	0,001	0,118	0,999

Napomena: Krizne okolnosti (C_KO), Pritisak sudionika na tržištu (C_PST), Razina znanja (C_RZ)

Može se zaključiti kako stil odlučivanja moderira povezanost između kriznih okolnosti i razine znanja, čime se djelomično prihvaća hipoteza H5, prihvaćanjem podhipoteze H.5.2.

8.7.4. Moderirajući utjecaj digitalne zrelosti– PAMETNI UGOVORI

Kako bi se provjerio moderirajući utjecaj digitalne zrelosti na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja pametnih ugovora napravljena je višegrupna analiza. Prije same analize provjerilo se postoje li razlike između promatranih grupa što je napravljeno univarijantnom analizom varijance (ANOVA).

Tablica 91 ANOVA – razina digitalne zrelosti – pametni ugovori

		Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	F	Sig.
B_PFR	Između grupa	11,897	2	5,948	11,540	0,000
	Unutar grupa	221,134	429	0,515		
	Ukupno	233,031	431			
B_PSR	Između grupa	11,337	2	5,669	7,623	0,001
	Unutar grupa	319,014	429	0,744		
	Ukupno	330,352	431			
B_PGV	Između grupa	15,031	2	7,515	9,986	0,000
	Unutar grupa	322,864	429	0,753		
	Ukupno	337,895	431			
B_PPD	Između grupa	2,991	2	1,496	1,959	0,142

		Zbroj kvadrata	Stupnjevi slobode	Sredina kvadrata	F	Sig.
	Unutar grupa	327,494	429	0,763		
	Ukupno	330,486	431			
B_NP	Između grupa	22,374	2	11,187	14,540	0,000
	Unutar grupa	330,079	429	0,769		
	Ukupno	352,453	431			

Napomena: Namjera prihvaćanja (B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR)

Rezultati ANOVE (tablica 91) ukazuju kako postoje statistički značajne razlike u aritmetičkim sredinama između grupa za sve varijable osim za varijablu B_PPD.

U nastavku su prikazani rezultati višegrupne analize moderirajućeg utjecaja razine digitalne zrelosti organizacije na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja pametnih ugovora.

Tablica 92 Višegrupna analiza – razina digitalne zrelosti pametni ugovori

Povezanost	Koeficijent puta (1 razina)	Koeficijent puta (2 razina)	Koeficijent puta (3 razina)	t-vrijednost (1 razina)	t-vrijednost (2 razina)	t-vrijednost (3 razina)	p-vrijednost (1 razina)	p-vrijednost (2 razina)	p-vrijednost (3 razina)
B_PFR -> B_NP	-0,181	-0,274	0,285	1,465	2,951	1,042	0,143	**0,003**	0,297
B_PSR -> B_NP	-0,172	-0,399	-0,317	3,009	4,530	2,835	**0,003**	**0,000**	**0,005**
B_PGV -> B_NP	0,154	-0,010	-0,249	1,365	0,095	0,696	0,172	0,924	0,486
B_PPD -> B_NP	0,498	0,165	0,388	6,559	1,336	3,177	**0,000**	0,182	**0,001**

Napomena: Krizne okolnosti (B_KO), Namjera prihvaćanja B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR), Pritisak sudionika na tržištu (B_PST), Razina znanja (B_RZ)

Rezultati višegrupne analize ukazuju kako na prvoj razini digitalne zrelosti postoji statistički značajan utjecaj percipiranog sigurnosnog rizika (B_PSR) i percipiranog pritiska države

(B_PPD) na namjeru prihvaćanja (B_NP). Na drugoj razini digitalne zrelosti postoji statistički značajna veza između percipiranog financijskog rizika (B_PFR) i percipiranog sigurnosnog rizika (B_PSR) na namjeru prihvaćanja (B_NP). Na trećoj razini digitalne zrelosti postoji statistički značajna veza između percipiranog sigurnosnog rizika (B_PSR) i percipiranog pritiska države (B_PPD) na namjeru prihvaćanja (B_NP). Promatrajući utjecaj percipiranog sigurnosnog rizika na namjeru prihvaćanja najjači utjecaj je na drugoj razini digitalne zrelosti, dok promatrajući utjecaj na povezanost percipiranog pritiska države i namjere prihvaćanja pametnih ugovora najjači utjecaj je na prvoj razini digitalne zrelosti.

Prethodno je ANOVOM utvrđeno kako između promatranih grupa za varijablu percipirani pritisak države (B_PPD) ne postoje značajne razlike između sredina stoga je u svrhu potvrđivanja razlika između grupa napravljen parametrijski test (tablica 93). Rezultati ukazuju kako postoji statistički značajna razlika između 1 i 2 razine.

Tablica 93 Parametrijski test razlika digitalne razine zrelosti– pametni ugovori

Povezanost	**Usporedba**	**Koeficijent puta razlika**	**t-vrijednost**	**p-vrijednost**
C_PPD -> C_NP	1 RAZINA vs 2 RAZINA	0,333	2,356	**0,019**
	1 RAZINA vs 3 RAZINA	0,110	0,806	0,421
	2 RAZINA vs 3 RAZINA	-0,223	1,202	0,230

Napomena: Namjera prihvaćanja (B_NP), Percipirani pritisak države (B_PPD)

U skladu s provedenom višegrupnom analizom i parametrijskim testom može se zaključiti kako je povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika te percipiranog pritiska države) s namjerom prihvaćanja različita ovisno o razini digitalne zrelosti organizacije. Stoga se djelomično prihvaća hipoteza H.3 zbog prihvaćanja podhipoteza H.3.1, H.3.2, H3.4, dok se podhipoteza H.3.3 odbacuje.

8.7.5. Moderirajući utjecaj konkurentskih prioriteta – PAMETNI UGOVORI

Kako bi se provjerio moderirajući utjecaj konkurentskih prioriteta (brzina, fleksibilnost, kvaliteta, pouzdanost, troškovi) na povezanost čimbenika (percipiranog financijskog i

sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja pametnih ugovora napravljena je višegrupna analiza.

Za početak se provjerilo postoje li razlike između promatranih grupa (brzina, fleksibilnost, kvaliteta, pouzdanost, troškovi) pri čemu se koristeći ANOVU testiralo postoje li razlike u aritmetičkim sredinama grupa. Rezultati su prikazani u tablici 94 u nastavku.

Tablica 94 ANOVA – konkurentski prioriteti – pametni ugovori

		Zbroj kvadrata	**Stupnjevi slobode**	**Sredina kvadrata**	**F**	**Sig.**
B_PFR	Između grupa	16,639	4	4,160	8,208	0,000
	Unutar grupa	216,392	427	0,507		
	Ukupno	233,031	431			
B_PSR	Između grupa	6,64	4	1,660	2,190	0,069
	Unutar grupa	323,711	427	0,758		
	Ukupno	330,352	431			
B_PGV	Između grupa	13,974	4	3,494	4,605	0,001
	Unutar grupa	323,921	427	0,759		
	Ukupno	337,895	431			
B_PPD	Između grupa	6,969	4	1,742	2,300	0,058
	Unutar grupa	323,516	427	0,758		
	Ukupno	330,486	431			
B_NP	Između grupa	7,258	4	1,815	2,245	0,063
	Unutar grupa	345,195	427	0,808		
	Ukupno	352,453	431			

Napomena: Krizne okolnosti (B_KO), Namjera prihvaćanja B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR), Pritisak sudionika na tržištu (B_PST), Razina znanja (B_RZ)

Rezultati ANOVE ukazuju kako postoje statistički značajne razlike u aritmetičkim sredinama između grupa varijable B_PFR i B_PGV, dok za preostale varijable ne postoje statistički značajne razlike u aritmetičkim sredinama promatranih grupa.

U nastavku su prikazani rezultati višegrupne analize moderirajućeg utjecaja konkurentskih prioriteta (brzina, fleksibilnost, kvaliteta, pouzdanost, troškovi) na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja pametnih ugovora (tablica 95).

Razvidno je kako za konkurentski prioritet brzina postoji statistički značajan utjecaj percipiranog pritiska države (B_PPD) na namjeru prihvaćanja (B_NP). Postoji i statistički značajan utjecaj percipiranog gubitka vremena (B_PGV), no on je pozitivan što je u suprotnosti s postavljanom hipotezom. Za fleksibilnost ne postoji statistički značajan utjecaj koji bi bio u skladu s postavljenim hipotezama. Za kvalitetu kao i za troškove postoji statistički značaj utjecaj percipiranog sigurnosnog rizika (B_PSR) i percipiranog pritiska države (B_PPD) na namjeru prihvaćanja (B_NP).

Za pouzdanost postoji statistički značajan utjecaj percipiranog pritiska države (B_PPD) na namjeru prihvaćanja (B_NP). Promatrajući utjecaj sigurnosnog rizika na namjeru prihvaćanja pametnih ugovora najjači utjecaj je kod organizacija koje prihvaćanjem pametnih ugovora žele podići razinu kvalitete, dok kod utjecaja percipiranog pritiska države na namjeru prihvaćanja utjecaj je najjači kod organizacija koje žele podići razinu pouzdanosti.

Tablica 95 Višegrupna analiza –konkurentski prioriteti- pametni ugovori

Povezanost	Koeficijent puta (B)	Koeficijent puta (F)	Koeficijent puta (K)	Koeficijent puta (P)	Koeficijent puta (T)	t-vrijednost (B)	t-vrijednost (F)	t-vrijednost (K)	t-vrijednost (P)	t-vrijednost (T)	p-vrijednost (B)	p-vrijednost (F)	p-vrijednost (K)	p-vrijednost (P)	p-vrijednost (T)
B_PFR -> B_NP	-0,223	-0,267	0,215	-0,152	-0,205	1,264	0,984	1,298	0,656	1,161	0,206	0,325	0,195	0,512	0,246
B_PSR -> B_NP	-0,067	0,351	-0,360	-0,098	-0,298	0,373	2,951	2,606	0,322	4,162	0,709	0,003	**0,009**	0,747	**0,000**
B_PGV -> B_NP	0,317	0,257	-0,317	-0,039	-0,150	2,034	2,108	1,842	0,159	0,772	0,042	0,035	0,065	0,874	0,440
B_PPD -> B_NP	0,467	-0,212	0,494	0,611	0,389	3,581	0,855	3,597	3,594	4,962	**0,000**	0,393	**0,000**	**0,000**	**0,000**

Napomena: Namjera prihvaćanja (B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR), Brzina (B), Fleksibilnost (F), Kvaliteta (K), Pouzdanost (P), Troškovi (T)

Testiranjem razlika aritmetičkih sredina u grupama ANOVOM je prethodno utvrđeno kako ne postoje statistički značajne razlike u aritmetičkim sredinama između grupa za varijable C_PSR i C_PPD stoga se, kako bi se provjerilo jesu li razlike između grupa značajne, napravio parametrijski test čiji rezultati su prikazani u tablici 96 u nastavku.

Tablica 96 Parametrijski test razlika konkurentskih prioriteta– pametni ugovori

Povezanost	**Usporedba**	**Koeficijent puta razlika**	**t-vrijednost**	**p-vrijednost**
C_PSR -> C_NP	Brzina vs Fleksibilnost	-0,418	2,075	**0,040**
	Brzina vs Kvaliteta	0,293	1,341	0,182
	Brzina vs Pouzdanost	0,031	0,093	0,926
	Brzina vs Troškovi	0,231	1,446	0,150
	Fleksibilnost vs Kvaliteta	0,710	3,915	**0,000**
	Fleksibilnost vs Pouzdanost	0,448	1,560	0,121
	Fleksibilnost vs Troškovi	0,649	4,960	**0,000**
	Kvaliteta vs Troškovi	-0,062	0,439	0,661
	Pouzdanost vs Kvaliteta	0,262	0,869	0,386
	Pouzdanost vs Troškovi	0,200	0,897	0,371
C_PPD -> C_NP	Brzina vs Fleksibilnost	0,679	2,301	**0,023**
	Brzina vs Kvaliteta	-0,027	0,146	0,884
	Brzina vs Pouzdanost	-0,144	0,681	0,497
	Brzina vs Troškovi	0,078	0,558	0,577
	Fleksibilnost vs Kvaliteta	-0,706	2,478	**0,014**
	Fleksibilnost vs Pouzdanost	-0,823	2,491	**0,014**
	Fleksibilnost vs Troškovi	-0,601	2,783	**0,006**
	Kvaliteta vs Troškovi	0,105	0,726	0,469
	Pouzdanost vs Kvaliteta	0,117	0,545	0,586
	Pouzdanost vs Troškovi	0,222	1,383	0,168

Napomena: Namjera prihvaćanja (B_NP), Percipirani financijski rizik (B_PFR), Percipirani gubitak vremena (B_PGV), Percipirani pritisak države (B_PPD), Percipirani sigurnosni rizik (B_PSR), Brzina (B), Fleksibilnost (F), Kvaliteta (K), Pouzdanost (P), Troškovi (T)

Rezultati parametrijskog testa ukazuju kako postoje statistički značajne razlike u povezanosti percipiranog sigurnosnog rizika s namjerom prihvaćanja pametnih ugovora između brzine i fleksibilnosti, fleksibilnosti i kvalitete te fleksibilnosti i troškova. Promatrajući povezanost percipiranog pritiska države s namjerom prihvaćanja postoje razlike između brzine i fleksibilnosti, fleksibilnosti i kvalitete te pouzdanosti i troškova. Time se može potvrditi kako konkurentski prioriteti imaju moderirajući utjecaj na navedene veze.

Iz prethodno provedenih testova može se zaključiti kako konkurentski prioriteti moderiraju povezanost čimbenika (sigurnosnog rizika i percipiranog pritiska države) s namjerom prihvaćanja pametnih ugovora, čime se djelomično prihvaća hipoteza H4, prihvaćaju se podhipoteze H.4.2 i H4.4. dok se podhipoteza H.4.1 i H.4.3 odbacuju.

8.7.6. Moderirajući utjecaj stila odlučivanja – PAMETNI UGOVORI

U svrhu provjere moderirajućeg utjecaj stila odlučivanja donositelja odluke na povezanost vanjskih pritiska (krizne okolnosti i pritisak sudionika na tržištu) s razinom znanja u istraživanju prihvaćanja pametnih ugovora provedena je višegrupna analiza.

Prvo se T testom provjerilo postoje li razlike u aritmetičkim sredinama promatranih grupa (intuitivni i racionalni stil).

Rezultati T testa prikazani u tablici 97 pokazuju kako postoje razlike aritmetičkih sredina između dviju grupa (p vrijednost<0,05) .

Tablica 97 T test – pametni ugovori

	T-test		
	t	**df**	**p-vrijednost**
B_KO	6,004	430	0,000
B_PST	4,222	430	0,000
B_RZ	3,291	430	0,001

Napomena: Krizne okolnosti (B_KO), Pritisak sudionika na tržištu (B_PST), Razina znanja (B_RZ)

Rezultati višegrupne analize utjecaja stila odlučivanja na povezanost vanjskih pritiska (krizne okolnosti i pritisak sudionika na tržištu) s razinom znanja u istraživanju prihvaćanja pametnih ugovora prikazani su tablicom 98.

Za oba stila (intuitivni i racionalni) postoji statistički značajna veza između kriznih okolnosti i razine znanja prilikom prihvaćanja pametnih ugovora pri čemu je veza jača kod intuitivng stila odlučivanja (racionalni ß=0,397, intuitivni ß=1,010). Utjecaj percipiranog pritiska države na razinu znanja nije potvrđen.

Tablica 98 Višegrupna analiza –stil odlučivanja– pametni ugovori

Povezanost	**Koeficijent puta (intuitivni)**	**Koeficijent puta (racionalni)**	**t-vrijednost (intuitivni)**	**t-vrijednost (racionalni)**	**p-vrijednost (Intuitivni)**	**p-vrijednost (racionalni)**
B_KO -> B_RZ	1,010	0,397	8,675	6,059	0,000	0,000
B_PST -> B_KO	-0,292	-0,190	1,966	1,346	0,049	0,178

Napomena: Krizne okolnosti (B_KO), Pritisak sudionika na tržištu (B_PST), Razina znanja (B_RZ)

Rezultati višegrupne analize ukazuju kako stil odlučivanja moderira odnos između kriznih okolnosti i razine znanja direktora o pametnim ugovorima, čime se djelomično prihvaća hipoteza H5 zbog odbacivanja podhipoteze H.5.1 i prihvaćanja podhipoteze H5.2.

9. DISKUSIJA

U prethodnom poglavlju predstavljeni su rezultati istraživanja prihvaćanja dviju digitalnih tehnologija, tehnologije uslužnog računalstva i tehnologije pametnih ugovora.

Svi postavljeni ciljevi istraživanja su ispunjeni, što se prikazuje i objašnjava u nastavku.

> ***C1*** *Sintetizirati rezultate prethodnih istraživanja na temu prihvaćanja novih tehnologija na razini organizacija kako bi se identificirali čimbenici koji utječu na namjeru prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*

Pregledom literature identificirani su čimbenici: percipirani financijski rizik, percipirani sigurnosni rizik, percipirani gubitak vremena, percipirani pritisak države, razina znanja donositelja odluke, krizne okolnosti i pritisak sudionika na tržištu.

Identificirani su i moderirajući čimbenici (razina digitalne zrelosti i konkurentski prioriteti) i njihov utjecaj na povezanost percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države s namjerom prihvaćanja. Identificiran je i čimbenik stil odlučivanja i njegov moderirajući utjecaj na povezanost kriznih okolnosti i pritiska sudionika na tržištu na razinu znanja donositelja odluke.

> ***C2*** *Na temelju literature izraditi model namjere prihvaćanja digitalnih tehnologija za mikro i male organizacije.*

Model je kreiran i prikazan u sklopu poglavlja *6.3.* Kvaliteta modela provjerena je putem koeficijenta determinacije koji je pokazao kako je u oba istraživanja prediktivna snaga čimbenika na namjeru prihvaćanja jaka te iznosi $R^2 = 0{,}310$. Prediktivna snaga kriznih okolnosti i pritiska sudionika na tržištu na razinu znanja kod prihvaćanju uslužnog računalstva je slaba ($R^2 = 0{,}185$) kao i u istraživanju prihvaćanja pametnih ugovora ($R^2 = 0{,}259$).

Promatrajući prihvaćanje uslužnog računalstva potvrđen je utjecaj svih čimbenika (percipirani financijski rizik, percipirani sigurnosni rizik, percipirani gubitak vremena, percipirani pritisak države i razina znanja donositelja odluke) na namjeru prihvaćanja. Potvrđen je i utjecaj kriznih okolnosti na razinu znanja, dok utjecaj pritiska sudionika na tržištu nije potvrđen.

U istraživanju prihvaćanja pametnih ugovora od navedenih čimbenika potvrđeni je utjecaj percipiranog sigurnosnog rizika i percipiranog pritiska države. Utjecaj percipiranog financijskog rizika, percipiranog gubitak vremena i razine znanja nije potvrđen. Potvrđen je i utjecaj kriznih okolnosti na razinu znanja, dok utjecaj pritiska sudionika na tržištu nije potvrđen.

Istraživanjem prihvaćanja uslužnog računalstva potvrđen je moderirajući utjecaj digitalne zrelosti i konkurentskih prioriteta na povezanost percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države s namjerom prihvaćanja. Potvrđen je i moderirajući utjecaj stila odlučivanja na povezanost kriznih okolnosti i razine znanja donositelja odluke. Stil odlučivanja nije imao moderirajući utjecaj na povezanost pritiska sudionika na tržištu i razine znanja.

Promatrajući istraživanje prihvaćanja pametnih ugovora rezultati su nešto drugačiji. Moderirajući utjecaj digitalne zrelosti potvrđen je za povezanost percipiranog financijskog, sigurnosnog rizika i percipiranog pritiska države, dok moderirajući utjecaj na povezanost percipiranog gubitka vremena i namjere prihvaćanja nije potvrđen.

Moderirajući utjecaj konkurentskih prioriteta u istraživanju prihvaćanja pametnih ugovora potvrđen je kod povezanosti percipiranog sigurnosnog rizika, percipiranog gubitka vremena i percipiranog pritiska države s namjerom prihvaćanja, dok povezanost percipiranog financijskog rizika i namjere prihvaćanja nije potvrđen.

Moderirajući utjecaj stila odlučivanja u prihvaćanju pametnih ugovora je, kao i u slučaju prihvaćanja uslužnog računalstva, djelomično potvrđen. Stil odlučivanja moderirao je povezanost kriznih okolnosti i razine znanja, dok utjecaj na povezanost pritiska sudionika na tržištu i razine znanja nije potvrđen.

> ***C3*** *Razviti mjerni instrument (anketni upitnik) za mjerenje namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*

Razvijen mjerni instrument prezentiran je u poglavlju *7.1*. Testirala se pouzdanost i valjanost mjernog instrumenta. Rezultati su ukazali na potrebu za određenim modifikacijama unutar instrumenta što je prikazano u poglavlju *8.4*.

9.1. Analiza hipoteza istraživanja

U radu je postavljeno ukupno pet hipoteza s pripadajućim podhipotezama, koje su zajedno s rezultatima prikazane tablicom u nastavku.

Usporedno su prikazani rezultati hipoteza u istraživanju prihvaćanja uslužnog računstva i u istraživanju prihvaćanja pametnih ugovora.

Tablica 99 Sumarni prikaz hipoteza istraživanja prihvaćanja uslužnog računalstva i pametnih ugovora

Hipoteze		**Uslužno računalstvo**	**Pametni ugovori**
H1	**Percipirani rizici (financijski, sigurnosni, gubitak vremena) negativno su povezani s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.**	**Prihvaća se**	**Djelomično se prihvaća**
H1.1	*Percipirani financijski rizik negativno je povezan s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	Odbacuje se
H1.2	*Percipirani sigurnosni rizik negativno je povezan s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	*Prihvaća se*
H1.3	*Percipirani gubitaka vremena negativno je povezan s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	Odbacuje se
H.2	**Percipirani pritisak države i razina znanja direktora pozitivno su povezani s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.**	**Prihvaća se**	**Djelomično se prihvaća**
H.2.1	*Percipirani pritisak države pozitivno je povezan s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	*Prihvaća se*
H.2.2	*Razina znanja direktora pozitivno je povezana s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	Odbacuje se
H3	**Povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja različita je ovisno o razini digitalne zrelosti organizacije.**	**Prihvaća se**	**Djelomično se prihvaća**
H3.1	*Razina digitalne zrelosti organizacije moderira odnos između percipiranog financijskog rizika i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	*Prihvaća se*

Hipoteze		Uslužno računalstvo	Pametni ugovori
H3.2	*Razina digitalne zrelosti organizacije moderira odnos između percipiranog sigurnosnog rizika i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	*Prihvaća se*
H3.3	*Razina digitalne zrelosti organizacije moderira odnos između percipiranog gubitka vremena i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	*Odbacuje se*
H3.4	*Razina digitalne zrelosti organizacije moderira odnos između percipiranog pritiska države i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama*	*Prihvaća se*	*Prihvaća se*
H4	**Povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja različita je ovisno o konkurentskom prioritetu koji se želi postići.**	**Prihvaća se**	**Djelomično se prihvaća**
H4.1	*Konkurentski prioritet moderira odnos između percipiranog financijskog rizika i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	Odbacuje se
H4.2	*Konkurentski prioritet organizacije moderira odnos između percipiranog sigurnosnog rizika i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	*Prihvaća se*
H4.3	*Konkurentski prioritet organizacije moderira odnos između percipiranog gubitka vremena i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacijama.*	*Prihvaća se*	*Odbacuje se*
H4.4	*Konkurentski prioritet organizacije moderira odnos između percipiranog pritiska države i namjere prihvaćanja digitalnih tehnologija u mikro i malim organizacija.*	*Prihvaća se*	*Prihvaća se*
H5	**Povezanost vanjskih pritiska (krizne okolnosti i pritisak sudionika na tržištu) s razinom znanja donositelja odluke različita je ovisno o stilu odlučivanja.**	**Djelomično se prihvaća**	**Djelomično se prihvaća**
H5.1	*Stil odlučivanja moderira odnos između pritiska sudionika na tržištu i razine znanja direktora o digitalnoj tehnologiji koja se prihvaća.*	*Odbacuje se*	*Odbacuje se*
H5.2	*Stil odlučivanja moderira odnos između kriznih okolnosti i razine znanja direktora o digitalnoj tehnologiji koja se prihvaća.*	*Prihvaća se*	*Prihvaća se*

Iz tablice je razvidno kako se rezultati istraživanja prihvaćanja uslužnog računalstva i prihvaćanja pametnih ugovora razlikuju. Promatrajući istraživanje prihvaćanja uslužnog računalstva razvidno je da su u potpunosti prihvaćene četiri hipoteze, dok se hipoteza H5 djelomično prihvaća zbog odbacivanja hipoteze H.5.1.

Promatrajući prihvaćanje pametnih ugovora razvidno je kako se ni jedna hipoteza u potpunosti ne prihvaća, sve hipoteze se tek djelomično prihvaćaju. Tako se kod hipoteze H1 odbacuju podhipoteze H1.1 i H1.3, kod hipoteze H2 se odbacuje podhipoteza H2.2, kod hipoteze H3 se odbacuje podhipoteza H3.3., kod hipoteze H4 se odbacuju podhipoteze H.4.1 i H4.3 i kod hipoteze H5 se odbacuje podhipoteza H5.1.

Razlog dobivanja različitih rezultata može se tumačiti činjenicom kako su uspoređivane dvije tehnologije od kojih je jedna „starija“ poznatija i s kojom su se ispitanici u svom poslovanju vjerojatno već i susretali i jedna „novija“ ne toliko poznata. Za razliku od uslužnog računalstva pametni ugovori još nisu doživjeli svoju širu primjeni te se ispitanici nisu imali prilike upoznati i raditi s tom tehnologijom, što može biti razlog njihove nemogućnosti da u potpunosti procijene svoj stav prema prihvaćanju iste. Razlog može biti i izostanak realnog, zakonodavnog ili regulatornog okvira primjene pametnih ugovora što može utjecati na percepciju sigurnosti i povjerenja u ovu vrstu tehnologije [67].

Razlog odbacivanja podhipoteza H1.1. i H1.3. u prihvaćanju pametnih ugovora mogao bi se objasniti ključnim prednostima pametnih ugovora koje navode Perkušić i ostali referirajući se na anuliranje bespotrebne administracije i drugih popratnih usluga, obzirom da je sve automatizirano i nema potrebe za posrednikom [66], [72].

U sklopu istraživanja istražila se i razina zrelosti organizacija po pitanju digitalne transformacije. Rezultati su pokazali kako se većina, tj. skoro polovica obuhvaćenih organizacija nalazi tek na prvoj razini digitalne zrelosti (47,2%), što znači da su tek na početku digitalne transformacije svog poslovanja. Istraženo je i koji stil odlučivanje prevladava među donositeljima odluka u mikro i malim organizacija, te je utvrđeno kako većina ispitanika 87% ima racionalni stil odlučivanja. Isto je u skladu s istraživanjem Verme i ostalih koji su utvrdili kako većina menadžera u ekonomijama u razvoju koristi racionalni stil odlučivanja [29].

Istraženo je i koje konkurentske prioritete organizacije žele ostvariti prihvaćanjem uslužnog računalstva i pametnih ugovora. Utvrđeno je da prihvaćanjem uslužnog računalstva organizacije teže podizanju kvalitete i smanjenju troškova poslovanja, dok prihvaćanjem pametnih ugovora većina organizacija želi smanjiti troškove svog poslovanja.

Razinu digitalne zrelosti, stil odlučivanja i željeni konkurentski prioritet bilo je ključno istražiti kako bi se mogao utvrditi njihov moderirajući utjecaj na povezanost čimbenika s namjerom prihvaćanja. Utvrđeno je da razina digitalne zrelosti moderira povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja uslužnog računalstva. Promatrajući povezanost percipiranog financijskog rizika i percipiranog gubitka vremena utjecaj je najjači na drugoj razini digitalne zrelosti, dok pri povezanosti sigurnosnog rizika na namjeru prihvaćanja utjecaj je najjači na trećoj razini zrelosti, a kod percipiranog pritiska države taj utjecaj je najjači na prvoj razini zrelosti. Promatrajući prihvaćanje pametnih ugovora druga razina ima najjači utjecaj na povezanost percipiranog financijskog i sigurnosnog rizika na namjeru prihvaćanja, dok prva razina ima najjači utjecaj na povezanost percipiranog pritiska države na namjeru prihvaćanja. Razina zrelosti nije imala moderirajući utjecaj na povezanost percipiranog gubitka vremena s prihvaćanjem pametnih ugovora.

Promatrajući moderirajući utjecaj konkurentskih prioriteta (brzina, fleksibilnost, kvaliteta, pouzdanost, troškovi) u prihvaćanju uslužnog računalstva rezultati ukazuju kako postoji moderirajući utjecaj na povezanost čimbenika (percipiranog financijskog i sigurnosnog rizika, percipiranog gubitka vremena te percipiranog pritiska države) s namjerom prihvaćanja. Povezanost percipiranog financijskog rizika i namjere prihvaćanja najjača je kod *brzine* a povezanost percipiranog sigurnosnog rizika i namjere prihvaćanja najjača je kod *pouzdanosti*. Kvaliteta ima najjači utjecaj na povezanost percipiranog gubitka vremena, dok troškovi imaju najjači utjecaj na povezanost percipiranog pritiska države i namjere prihvaćanja uslužnog računalstva.

Promatrajući istraživanje prihvaćanja pametnih ugovora konkurentski prioriteti moderiraju povezanost percipiranog sigurnosnog rizika i percipiranog pritiska države s namjerom prihvaćanja. Kod sigurnosnog rizika najjači utjecaj ima *kvaliteta,* dok *pouzdanost* ima najjači utjecaj na povezanost percipiranog pritiska države i namjere prihvaćanja pametnih ugovora. Primjetan je moderirajući utjecaj i na povezanost percipiranog gubitka vremena, no on je suprotan u odnosu na postavljenu hipotezu da percipirani gubitak vremena negativno utječe na namjeru prihvaćanja pametnih ugovora.

Posljednji moderirajući čimbenik koji se promatrao bio je stil odlučivanja i njegov utjecaj na povezanost vanjskih pritisaka (krizne okolnosti i pritisak sudionika na tržištu) na namjeru

prihvaćanja. U oba istraživanja (prihvaćanje pametnih ugovora i uslužnog računalstva) potvrđen je moderirajući utjecaj stila odlučivanja na povezanost kriznih okolnosti i namjere prihvaćanja. Utvrđeno je da je navedeni utjecaj jači kod donositelja odluka koji imaju intuitivni stil odlučivanja. Moderirajući utjecaj stila odlučivanja na povezanost pritiska sudionika na tržištu i namjere prihvaćanja nije potvrđen.

10. ZAKLJUČAK

Cilj ovog rada bio je istražiti prihvaćanje digitalnih tehnologija u mikro i malim organizacijama. Digitalne tehnologije omogućavaju organizacijama da unaprijede svoje poslovanje, osiguraju svoj opstanak na tržištu te postignu konkurentnu prednost i rast [19]. Prihvaćanje novih tehnologija postaje *conditio sine qua non* opstanka na tržištu na što ukazuje i Mazzone ističući kako je za organizacije neophodno da digitaliziraju svoje poslovanje, tj. da prihvate mogućnosti koje digitalne tehnologije pružaju [52].

Rad se fokusirao isključivo na mikro i male organizacije i utjecaj njihovih karakteristika na prihvaćanje digitalnih tehnologija. Razlog toga je pregledom literature uočen nedostatak istraživanja namjere prihvaćanja novih tehnologija kod mikro i malih organizacija. Većina istraživanja koja su obuhvaćala mikro i male organizacije istraživala su prihvaćanje novih tehnologija na razini tzv. MSP-a (male i srednje organizacije). Međutim, sama klasifikacija tih organizacija ukazuje da između njih postaje značajne razlike u smislu njihovih veličina, što može znatno utjecati na samu namjeru prihvaćanja. Iz tih razloga rad se fokusirao isključivo na mikro i male organizacije koje čine većinu organizacija kako u Republici Hrvatskoj tako i u svijetu.

Pregledom dosadašnjih istraživanja uočen je nedostatak istraživanja koja bi se odmaknula od postojećih modela i teorija te objasnila razloge prihvaćanja digitalnih tehnologija kod mikro i malih organizacija. Uočen je i nedostatak istraživanja koja bi istražila utjecaj moderirajućih čimbenika prilikom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama. Postojeća istraživanja većinom su fokusirana na istraživanje direktnog ili indirektnog utjecaja čimbenika na namjeru prihvaćanja, dok se utjecaj moderirajućih čimbenika nije razmatrao. Usmjeravanjem istraživanja prema sagledavanju utjecaja moderirajućih čimbenika nastojalo se nadopuniti prijašnja istraživanja te steći nove spoznaje vezane za odlučivanje mikro i malih organizacija o usvajanju digitalnih tehnologija.

Istražujući moderirajuće čimbenike utvrđena je potreba sagledavanja njihovog šireg spektra, tj. odmaknuti se od postojećih istraživanja koja su se uglavnom fokusirala samo na moderirajući utjecaj veličine organizacije i iskustva. Stoga se prilikom odabira moderirajućih čimbenika vodilo karakteristikama mikro i malih organizacija, te su se u tom smislu odabrali digitalna zrelost organizacije, stil odlučivanja donositelja odluke i konkurentski prioriteti kao

moderirajući čimbenici čiji će se utjecaj istražiti. S time u vezi primarni cilj istraživanja bio je istražiti moderirajući utjecaj digitalne zrelosti i konkurentskih prioriteta na vezu između definiranih čimbenika (percipirani financijski rizik, percipirani sigurnosni rizik, percipirani gubitak vremena i percipirani pritisak države) i namjere prihvaćanja digitalnih tehnologija, te moderirajući utjecaj stila odlučivanja na vezu između vanjskih pritisaka (krizne okolnosti i pritisak sudionika na tržištu) i razine znanja donositelja odluke.

Pored moderirajućih čimbenika u radu se istražio i direktni utjecaj čimbenika (percipirani financijski rizik, percipirani sigurnosnog rizika, percipirani gubitaka vremena, percipirani pritisak države i razine znanja) na namjeru prihvaćanja digitalnih tehnologija u mikro i malim organizacijama. Prilikom odabira čimbenika koji imaju direktni utjecaj pozornost se posvetila ključnim karakteristikama mikro i malih organizacija koje bi mogle utjecati na namjeru prihvaćanja. Kao ključne karakteristike identificirane su nedostatak resursa (financijskih i ljudskih) te način donošenja odluka koji je u potpunosti u rukama pojedinca u većini slučajeva i vlasnika organizacije [75]. Navedene karakteristike djeluju kao barijere u prihvaćanju novih tehnologija te dovode do pojave straha od nepoznatog i time percipiranjem tehnologije rizičnom i nepotrebnom [12], [13], [8], [14], [15], [17], [16].

Istraživanje je započelo definiranjem istraživačkih pitanja koju su služila kao nit vodilja u provedbi cjelokupnog istraživanja. Nakon identificiranja čimbenika koji bi mogli biti povezani s namjerom prihvaćanja digitalnih tehnologija u mikro i malim organizacijama kreiran je model istraživanja. Nakon kreiranja modela za istraživanje namjere prihvaćanja izradio se anketni upitnik te provelo istraživanje na mikro i malim organizacijama u Republici Hrvatskoj.

Nakon istraživanja odnosa između čimbenika u modelu istražilo se kako različiti stil odlučivanja donositelja odluke moderira odnos pritiska sudionika na tržištu i kriznih okolnosti s razinom znanja donositelja odluka, te kako konkurentski prioriteti i razina digitalne zrelosti organizacije moderiraju odnos između čimbenika i namjere prihvaćanja digitalnih tehnologija.

Istraživanje u radu provedeno je na način da se model testirao na prihvaćanju dvije digitalne tehnologije - uslužnom računalstvu i pametnim ugovorima. Odabir tehnologija za testiranje modela zasnovan je na ideji usporednog testiranja jedne učestalije i poznatije tehnologije i jedne čija je primjena tek u povojima. S time u skladu u radu se usporedno prikazuju rezultati istraživanja prihvaćanja uslužnog računalstva i prihvaćanja pametnih ugovora. Dobiveni

rezultati istraživanja se razlikuju što se može objasniti prethodno navedenim, odnosno činjenicom kako ispitanici nisu toliko upoznati s pametnim ugovorima kao što su upoznati s uslužnim računalstvom.

Promatrajući prihvaćanje uslužnog računalstva rezultati ukazuju kako svi identificirani čimbenici imaju utjecaj na namjeru prihvaćanja, što je u skladu s prethodnim istraživanjima gdje je potvrđeno kako percipiranje određenih rizika od strane organizacija posljedično utječe i na njihovo prihvaćanje [2], [82].

Potvrđen je utjecaj percipiranog pritiska države na prihvaćanje digitalnih tehnologija što je u skladu s prethodnim istraživanjima koja ukazuju kako će mikro i male organizacije brže prihvatiti digitalne tehnologije uslijed pritiska države [74], [13]. Potvrđen je i utjecaj razine znanja što je također u skladu s prethodnim istraživanjima koja su ukazala kako na prihvaćanje tehnologija utječu karakteristike donositelja odluke i njegova razina znanja o tehnologiji [12]. Neminovno je kako će prihvaćanje digitalnih tehnologija biti uspješnije ukoliko donositelj odluke procijeni da će investicija donijeti prednosti i da je rizik prihvaćanja minimalan, a to je moguće ukoliko ima prethodno znanje o tehnologiji koju prihvaća.

Istraživanje je ukazalo i na važnost kriznih okolnosti i njihov utjecaj na prihvaćanje digitalnih tehnologija. Novonastale krizne promjene na tržištu uzrokovane Covid 19 pandemijom imaju značajan utjecaj na razinu znanja donositelja odluka o tehnologiji koja se prihvaća.

Za razliku od prihvaćanja uslužnog računalstva rezultati istraživanja prihvaćanja pametnih ugovora ukazuju na drugačiji ishod. U slučaju prihvaćanja pametnih ugovora organizacije ne smatraju da percipirani gubitak vremena ima utjecaj na namjeru prihvaćanja. Ono što negativno utječe na prihvaćanje pametnih ugovora je isključivo sigurnosni rizik. Percipirani gubitak vremena i percipirani financijski rizik nije imao statistički značajan utjecaj na namjeru prihvaćanja. Percipirani pritisak države je kao i kod prihvaćanja uslužnog računalstva imao utjecaj na prihvaćanje. Zanimljivo je kako razina znanja nije imala utjecaj na prihvaćanje pametnih ugovora, no potvrđen je utjecaj kriznih okolnosti, tj. utjecaj Covid 19 pandemije na razinu znanja donositelja odluka o pametnim ugovorima. Može se zaključiti kako su krizne okolnosti važan elemenat prihvaćanja novih tehnologija. Nesretne okolnosti (pandemija) ukazale su na nužnost prihvaćanja novih tehnologija koje omogućavaju brzu prilagodbu poslovanja.

Promatrajući moderirajuće utjecaje, tj. utjecaj razina digitalne zrelosti i konkurentskih prioriteta na povezanost čimbenika i namjere prihvaćanja, dobiveni rezultati pokazuju kako u oba istraživanja (prihvaćanje uslužnog računalstva i prihvaćanje pametnih ugovora) razina zrelosti i konkurentski prioritet imaju utjecaj na povezanost čimbenika.

No za razliku od prihvaćanja uslužnog računalstva, gdje su digitalna zrelost i konkurentski prioriteti moderirali povezanost svih navedenih čimbenika i namjere prihvaćanja, u istraživanju namjere prihvaćanja pametnih ugovora digitalna zrelost nije imala moderirajući utjecaj na povezanost percipiranog gubitka vremena i percipiranog pritiska države s namjerom prihvaćanja pametnih ugovora. Konkurentski prioriteti nisu imali moderirajući utjecaj na povezanost percipiranog financijskog rizika i percipiranog gubitka vremena na namjeru prihvaćanja pametnih ugovora.

Rezultati moderirajućeg utjecaja stila odlučivanja na povezanost vanjskih pritisaka i namjere prihvaćanja jednaki su u oba istraživanja. Utvrđeno je kako stil odlučivanja moderira povezanost kriznih okolnosti i razine znanja donositelja odluke pri čemu je utjecaj jači kod intuitivnog odlučivanja (koje je u uzorku zastupljeno samo sa 13%).

10.1. Znanstveni doprinos

Znanstveni doprinos istraživanja je razvoj višedimenzijalnog modela namjere prihvaćanja tehnologija kojim se proširuju postojeći modeli. Činjenica je da u literaturi postoji nekoliko modela čija je primarna funkcija mjerenje namjere prihvaćanja. No važno je istaknuti kako nedostaju istraživanja fokusirana isključivo na mikro i male organizacije. S time u vezi primjetan je i nedostatak istraživanja utjecaja moderirajućih čimbenika na povezanost čimbenika i namjere prihvaćanja. Upravo je to u fokusu ovog rada te će rezultati doprinijeti proširenju postojećih znanja.

Znanstveni doprinos rada očituje se u:

- pregledu postojećeg znanja o čimbenicima koji utječu na namjeru prihvaćanja digitalnih tehnologija u mikro i malim organizacijama,

- odmicanju od postojećih istraživanja na način da se istodobno testirao model na dvije digitalne tehnologije, što je pridonijelo podrobnijem testiranju i poimanju modela,

- istovremenom istraživanju razine digitalne zrelosti organizacija i namjere prihvaćanja, čime se dobio uvid u razinu digitalne zrelosti po pitanju digitalne transformacije i povezanosti te razine s utjecajem čimbenika na namjeru prihvaćanja,

- poboljšanju modela namjere prihvaćanja digitalnih tehnologija za mikro i male organizacije na način da se uz direktan utjecaj čimbenika na namjeru prihvaćanja istražio i moderirajući utjecaj, te

- razvoju mjernog instrumenta namjere prihvaćanja digitalnih tehnologija.

Pored znanstvenog doprinosa navodi se i društveni doprinos istraživanja koji se odnosi na:

- Spoznaju o tome što sprječava mikro i male organizacije u prihvaćanju digitalnih tehnologija, a samim time i u digitalizaciji i digitalnoj transformaciji njihovog poslovanja.

- Spoznaju, temeljenu na dobivenim različitim rezultatima prihvaćanja uslužnog računalstva i pametnih ugovora, kako mikro i male organizacije još uvijek u velikoj mjeri nisu upoznate s blockchain tehnologijom i pametnim ugovorima te kako uglavnom posluju s osnovnim tehnologijama, kao i da ih karakterizira ograničeno znanje donositelja odluka o digitalnim tehnologijama.

- Ukazivanje na trenutno stanje razine digitalne zrelosti mikro i malih organizacija. Digitalna transformacija se ne odnosi samo na prihvaćanje digitalnih tehnologija u organizacijama, već zahtijeva reviziju organizacijskih struktura, upravljanja, radnih procesa, kulture i načina razmišljanja. Rezultati ukazuju kako se većina mikro i malih organizacija nalazi na prvoj razini digitalne zrelosti (njih 41,2%). Utvrđujući digitalnu zrelost istraživanje je ukazalo kako su najslabije točke u mikro i malim organizacijama upravljanje digitalnim tehnologijama te resursi za provedbu digitalne transformacije.

- Spoznaju važnosti utjecaja države na prihvaćanje digitalnih tehnologija. Mikro i male organizacije u svom digitalnom razvoju uglavnom ovise o državnoj politici i državnim programima, te je time i uloga države nezamjenjiva u poticanju mikro i malih organizacija na prihvaćanje digitalnih tehnologija. Mikro i male organizacije za digitalnu transformaciju trebaju odgovarajuće politike, programe i podršku kako bi se uspješno uhvatile u koštac s transformacijom svog poslovanja. Rezultati niske razine digitalne zrelosti mikro i malih organizacija ukazuju kako su adekvatni programi potpore za digitalnu transformaciju mikro i malih organizacija izostali ili nisu dovoljno efikasni i prepoznati od strane organizacija. Na nužnost uključivanje države ukazuju i rezultati moderirajućeg utjecaja digitalne zrelosti koji govore kako postoje razlike između organizacija na različitim razinama digitalne zrelosti. Navedeno ukazuje na potrebu za potporom države u podizanju razine zrelosti. Utjecaj države može anulirati percipirani negativan utjecaj sigurnosnog rizika na način da podigne razinu znanja o digitalnim tehnologijama kroz organizaciju edukacija, razmjene ekspertiza i slično, ali i definiranjem zakonskih okvira koji će jamčiti privatnost i sigurnost podataka [242]. Isto će tako financijske potpore i subvencije anulirati financijski rizik prihvaćanja digitalnih tehnologija koji je u ovom istraživanju potvrđen. Neminovno je da je uloga države značajna u digitalizaciji i digitalnoj transformaciji organizacija, te je upravo na državi da uspostavi pravila i sustave koji će omogućiti mikro i malim organizacijama da transformiraju svoje poslovanje, koje je postalo nužno za opstanak na tržištu. Važnost utjecaj države na prihvaćanje digitalnih tehnologija vidljiv je u rezultatima istraživanja gdje je potvrđen utjecaj pritiska države, što ukazuje da je prihvaćanje digitalnih tehnologija u mikro i malim organizacijama itekako pod utjecajem države.

- Spoznaju o važnosti konkurentskih prioriteta. Vezano za istraživanje moderirajućeg utjecaja konkurentskih prioriteta istraživanje je ukazalo da mikro i male organizacije, unatoč nužnosti prihvaćanja digitalnih tehnologija i njihove integracije u poslovanje, prihvaćanjem prvenstveno žele postići smanjenje troškova, što implicira kako mikro i male organizacije i dalje imaju ograničeno znanje o digitalnim tehnologijama. To upućuje na nužnost podizanja razine tehnološkog znanja donositelja odluka u mikro i malim organizacijama. Rezultati istraživanja pokazali su kako postoji moderirajući utjecaj konkurentskih prioriteta. To ukazuje na činjenicu kako je potrebno državne programe za podizanje svjesnosti mikro i malih organizacija o digitalnim tehnologijama i poticanju njihovog prihvaćanja prilagoditi ili uskladiti s konkurentskim prioritetima.

Drugim riječima, kako bi programi bili efikasni i postigli svoj cilj od velike je važnosti znati na koji način pristupiti organizacijama i kako ih potaknuti na ulaganje i prihvaćanje digitalnih tehnologija.

10.2. Ograničenja istraživanja i daljnja istraživanja

Kao ograničenje u istraživanju navodi se veličina i vrsta uzorka. Iako je veličina uzorka zadovoljavajuća bilo bi korisno s aspekta točnosti rezultata provesti istraživanje na većem broju ispitanika. Činjenica je kako se u većini društvenih istraživanja zbog ekonomičnosti, manjih izdataka i kraćeg vremena istraživanja koristi prigodni uzorak, međutim, u daljnjim bi istraživanjima bilo dobro pokušati koristiti slučajni uzorak, te snažnije obuhvatiti segment obrtništva. Odabir čimbenika u istraživanju temeljio se na pregledu postojeće literature pri čemu nije provedena njezina sistematska analiza u smislu primjene standardizirane statističke procedure te unaprijed utvrđene i jasne metodologije što bi se, i pored činjenice kako su čimbenici identificirani i obrazloženi kroz znanstvenu i stručnu literaturu korištenu u ovom istraživanju, moglo smatrati i ograničenjem u smislu možebitne subjektivnosti. U skladu s dobivenim rezultatima i utjecajem kriznih okolnosti na razinu znanja donositelja odluke, zanimljivo bi bilo istražiti i povećanje broja korisnika digitalnih tehnologija u usporedbi s godinom koja je prethodila Covid 19 pandemiji te utvrditi pada li taj broj s popuštanjem mjera.

S obzirom da mikro i male organizacija čine većinu organizacija u većem broju zemalja Europske unije buduća bi se istraživanja mogla usmjeriti i prema utvrđivanju razlika između zemalja po pitanju uvođenja digitalne tehnologije, tj. utvrđivanja utjecaja razvijenosti zemlje kako na namjeru prihvaćanja digitalnih tehnologija tako i na utjecaj moderirajućih čimbenika na povezanost čimbenika s namjerom prihvaćanja digitalnih tehnologija. Značajan doprinos dosadašnjim istraživanjima dalo bi i utvrđivanje segmenta poslovanja u koje mikro i male organizacije najviše implementiraju digitalne tehnologije. Izdvajanje određenih segmenata omogućilo bi širenje spoznaja o percepciji digitalne tehnologije i načinu njene implementacije.

REFERENCE

[1] weforum.org, »weforum.org,« 2019. [Mrežno]. Available: https://www.weforum.org/agenda/2019/09/technology-global-goals-sustainable development-sdgs/.. [Pokušaj pristupa 2022].

[2] R. El-Haddadeh, »Digital Innovation Dynamics Influence on Organisational Adoption: The Case of Cloud Computing Services,« *Information Systems Frontiers, Volume 22 Issue 4,* pp. 985-999, 2020.

[3] M. A. Hameed, S. Counsell i S. Swift, »A meta-analysis of relationships between organizational characteristics and IT innovation adoption in organizations,« *Information & Management,* svez. 5, pp. 218-232, 2012.

[4] T. Oliveira i M. Rosario, »Literature Review of Information Technology Adoption Models at Firm Level,« *The Electronic Journal Information Systems Evaluation Volume 14 Issue 1 ,* pp. 110-121, 01 2011.

[5] R. T. Frambach i N. Schillewaert, »Organizational innovation adoption: a multi-level framework of determinants and opportunities for future research,« *Journal of Business Research 55(2),* pp. 163-176, 2002.

[6] »lexico,« [Mrežno]. Available: https://www.lexico.com/definition/new_technology. [Pokušaj pristupa 25 11 2020].

[7] M. Spremić, Digitalna transformacija poslovanja, Zagreb: Sveučilište u Zagrebu, Ekonomski fakultet - Zagreb, 2017.

[8] S. C. Eze, V. C. Chinedu-Eze, A. O. Bello, H. Inegbedion, T. Nwanji i F. Asamu, »Mobile marketing technology adoption in service SMEs: a multi-perspective framework,« *Journal of Science and Technology Policy Management, Volume 10 Issue 3,* pp. 569-596, 2019.

[9] eur-lex.europa.eu, »eur-lex.europa.eu,« 2020. [Mrežno]. Available: https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32003H0361&from=EN.

[10] H. g. komora, »Analiza Hrvatske IT industrije 2014.-2019.,« prosinac 2020. [Mrežno]. Available: https://www.hgk.hr/documents/analiza-hrvatske-it-industrije-20142019-kb602bb6ffa49ca.pdf.

[11] N. novine, »Odluka o nacionalnoj klasifikaciji djelatnosti 2007. -NKD 2007.,« 2007. [Mrežno]. Available: https://narodne-novine.nn.hr/clanci/sluzbeni/2007_06_58_1870.html. [Pokušaj pristupa 15 03 2021].

[12] J. Y. Thong, »An Integrated Model of Information Systems Adoption in Small Businesses,« *Journal of Management Information Systems 15 (4),* pp. 187-214, 1 March 1999.

[13] K. K. Y. Kuan i P. Y. K. Chau, »A perception-based model for EDI adoption in small businesses using a technology–organization–environment framework,« *Information & Management 38(8),* pp. 507-521, 1 October 2001.

[14] B. Richie i C. Brindley, »ICT adoption by SMEs: implications for relationships and management,« *New Technology, Work and Employment, Vol 20 No 3,,* pp. pp. 205-217, 2005.

[15] R. Lucchetti i A. Sterlacchini, »The Adoption of ICT among SMEs: Evidence from an Italian Survey,« *Small Business Economics, Vol 23, ,* pp. 151-168, 2004.

[16] P. Boekhoud i P. van der Stappen, »The Aspect Project Case: a Model for SME Adoption of ICT Innovation,« u *Proceedings of the 6th international conference on Electronic commerce, Delft, The Netherlands, October 25-27. ACM, International Conference Proceeding Series, Vol 60,* The Netherland, 2004.

[17] J. Thong i C. Yap, »CEO characteristics, organizational characteristics and information technology adoption in small businesses,« *Omega 23(4),* pp. 429-442, 1995.

[18] C.-L. Chen, Y.-C. Lin, W.-H. Chen, C.-F. Chao i H. Pandia, »Role of Government to Enhance Digital Transformation in Small Service Business,« *Sustainability,* pp. 1-24, 2021.

[19] M. Kamal, »IT innovation adoption in the government sector: identifying the critical success factors,« *Journal of Enterprise Information Management,* svez. 19, br. 2, pp. 192-222, 2006.

[20] A. Jeyaraj, J. W. Rottman i M. C. Lacity, »A review of the predictors, linkages, and biases in IT innovation adoption research,« *Journal of Information Technology,* svez. 1, br. 21, pp. 1-23, 2006.

[21] M. Klačmer, *Činitelji prihvaćanja javnih usluga e- participacije u Republici Hrvatskoj,* 2020.

[22] I. Ahmed, »Technology organization environment framework in cloud computing,« *TELKOMNIKA Telecommunication, Computing, Electronics and Control, Vol. 18, No. 2,,* pp. 716-725, April 2020.

[23] A. Alomary i J. Woollard, »How is technology accepted by users? A review of technology acceptance models and theories,« u *17th 21st Proceedings of The IRES International Conference,* London, United Kingdom,, 2015.

[24] C. Chiu, S. Chen i C. Chen, »An integrated perspective of TOE framework and innovation diffusion in broadband mobile applications adoption by enterprise,« *International Journal of Management, Economics and Social Sciences,* pp. 14-39, 2017.

[25] K. Kaur Kapoor, Y. K. Dwivedi i M. D. Williams, »Innovation adoption attributes: a review and synthesis of research findings,« *European Journal of Innovation Management,* svez. 3, pp. 327-348, 2014.

[26] E. M. Rogers, Diffusion of innovations, fifth edition, New York: The free Press, 2003.

[27] H. Sun i P. Zhang, »The role of moderating factors in user technology acceptance,« *International Journal of Human-Computer Studies, Volume 64, Issue 2, ,* pp. 53-78, February 2006.

[28] K. Hamilton, S.-I. Shih i S. Mohammed, »The predictive validity of the decision styles scale: An evaluation across task types,« *Personality and Individual Differences 119,* pp. 333-340, 17 2017.

[29] N. Verma, S. N. Rangnekar i M. K. Barua, »Exploring decision making style as a predictor of team effectiveness,« *International Journal of Organizational Analysis,* svez. 1, 2016.

[30] Eurostat, »Structural business statistics overview,« 2018. [Mrežno]. Available: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Structural_business_statistics_overview. [Pokušaj pristupa 2021].

[31] X. Jiang, »Digital economy in the post-pandemic era,« *Journal of Chinese economic and business studies, Vol.18, No.4,* pp. 333-339, 2020.

[32] V. Corvello, S. Verteramo, I. Nocella i S. Ammirato, »Thrive during a crisis: the role of digital technologies in fostering antifragility in small and medium-sized enterprises,« *Journal of Ambient Intelligence and Humanized Computing,* 2022.

[33] R. Cooper i R. Zmud, »Information technology implementation research: a technology diffusion approach,« *Management Science, Vol. 36 No. 2,* pp. 123-139, 1990.

[34] I. Gregurec, M. Tomičić Furjan i K. Tomičić-Pupek, »The Impact of COVID-19 on Sustainable Business Models in SMEs,« *Sustainability,* pp. 1-24, 2021.

[35] S. Moghavvemi, N. A. Mohd Salleh, A. Sulaiman i M. Abessi, »Effect of external factors on intention–behaviour gap,« *Behaviour & Information Technology,* 2015.

[36] P. R. Weerathunga, W. H. M. S. Samarathu, H. N. Rathnayake, S. B. Agampodi, M. Nurunnabi i M. M. S. C. Madhunimasha, »The COVID-19 Pandemic and the Acceptance of E-Learning among University Students: The Role of Precipitating Events,« *Education sciences,* pp. 1-23, 2021.

[37] undatarevolution.org, »www.undatarevolution.org,« 2014. [Mrežno]. Available: https://www.undatarevolution.org/wp-content/uploads/2014/12/A-World-That-Counts2.pdf . [Pokušaj pristupa 2022].

[38] diplomacy.edu, »diplomacy.edu,« [Mrežno]. Available: ". https://www.diplomacy.edu/blog/digital-technology-sdgs/. [Pokušaj pristupa 2022].

[39] ec.europa.eu, »ec.europa.eu,« 14 12 2020. [Mrežno]. Available: https://ec.europa.eu/commission/presscorner/detail/hr/IP_20_2406. [Pokušaj pristupa 12 11 2021].

[40] R. Agarwal i E. Karahanna, »Time Flies When You're Having Fun: Cognitive Absorption and Beliefs about Information Technology Usage,« *MIS Quarterly, Vol. 24, No. 4,* pp. 665-694, 2000.

[41] zakon.hr, »zakon.hr,« 2021. [Mrežno]. Available: https://www.zakon.hr/z/527/Zakon-o-poticanju-razvoja-malog-gospodarstva. [Pokušaj pristupa 23 11 2021].

[42] Z. o. računovodstvu, »www.zakon.hr (ZOR),« [Mrežno]. Available: https://www.zakon.hr/z/118/Zakon-o-ra%C4%8Dunovodstvu. [Pokušaj pristupa 12 2021].

[43] Eurostat, »Key figures on European business — Statistics illustrated — 2021 edition,« 2021. [Mrežno]. Available: https://ec.europa.eu/eurostat/documents/3217494/12601271/KS-01-20-363-EN-N.pdf/57086a1d-ba26-a397-85b6-f28d08f28426?. [Pokušaj pristupa 2021].

[44] hok, »hok.hr,« 2021. [Mrežno]. Available: https://www.hok.hr/sites/default/files/page-docs/2021-08/Statisti%C4%8Dke_informacije_lipanj_2021.pdf. [Pokušaj pristupa 25 11 2021].

[45] DZS, »Broj i struktura poslovnih subjekata u rujnu 2021.,« Državni zavod za statistiku, Zagreb, 2021.

[46] CEPOR, »Small and Medium Enterprises Report −Croatia 2019,« 05 12 2020. [Mrežno]. Available: http://www.cepor.hr/publikacijepolicy-dokumentiprezentacije/izvjesce-o-malim-i-srednjim-poduzecima/.

[47] D. Tapscott, D. Ticoll i A. Lowy, Digital Capital: Harnessing the Power of Business Webs, Boston: Harvard Business School Press, 2000.

[48] H. Øverby i J. A. Audestad, Introduction to Digital Economics: Foundations, Business Models and Case Studies, Springer, 2021.

[49] Deloitte, 3 11 2021. [Mrežno]. Available: https://www2.deloitte.com/mt/en/pages/technology/articles/mt-what-is-digital-economy.html.

[50] K. Pousttchi, A. Gleiss, B. Buzzi i M. Kohlhagen, »Technology Impact Types for Digital Transformation,« u *IEEE 21st Conference on Business Informatics (CBI),* 2019.

[51] M. Tomičić Furjan, K. Tomičić-Pupek i I. Pihir, »Understanding Digital Transformation Initiatives: Case Studies Analysis,« *Business Systems Research, Vol. 11 No. 1,* br. 10.2478/bsrj-2020-0009, pp. 125-141, 2020.

[52] D. Mazzone, Digital or Death: Digital Transformation – The Only Choice for Business to Survive, Smash, and Conquer, Smashbox Consulting Inc., 2014.

[53] »Ey Hrvatska,« 21 prosinac 2020. [Mrežno]. Available: https://www.ey.com/hr_hr/news/2020/57-posto-tvrtki-ne-osjeca-se-spremnima-koristiti-digitalne-tehnologije-kako-bi-odgovorile-na-krizu. [Pokušaj pristupa 17 3 2020].

[54] CARNet, »Centar informacijske sigurnosti,« 2010. [Mrežno]. Available: https://www.cis.hr/www.edicija/LinkedDocuments/NCERT-PUBDOC-2010-03-293.pdf. [Pokušaj pristupa 2021].

[55] S. Marston, Z. Li, S. Bandyopadhyay, J. Zhang i A. Ghalsasi, »Cloud computing — The business perspective,« *Decision Support Systems,* pp. 176-189, 4 2011.

[56] Y. Alshamaila, S. Papagiannidis i F. Li, »Cloud computing adoption by SMEs in the north east of England A multi-perspective framework,« *Journal of Enterprise Information Management,* pp. 250-+, 2013.

[57] M. Pejić Bach, M. Varga, V. Srića , M. Spremić, V. Bosilj Vukšić, K. Ćurko , N. Vlahović, L. Milanović Glavan, I. Strugar, J. Zoroja i B. Jaković, INFORMACIJSKI sustavi u poslovanju, Zagreb: Sveučilište u Zagrebu, Ekonomski fakultet, 2016.

[58] Fluentis, »Fluentis,« 13 02 2021. [Mrežno]. Available: https://www.fluentis.com/hr/blog/tehnoloski-trendovi/poslovanje-u-oblaku/. [Pokušaj pristupa 04 11 2021].

[59] O. infoTrend, »Open infoTrend,« 2021. [Mrežno]. Available: http://www.infotrend.hr/clanak/2016/7/udarni-val-racunalstva-u-oblaku,88,1256.html. [Pokušaj pristupa 04 11 2021].

[60] A. M. Abushofa, »Overview of Cloud Computing Technology,« u *The Libyan Arab International Conference on Electrical and Electronic Engineering LAICEEE,* 2010.

[61] G. Blokdijk i I. Menken, The Complete Cornerstone Guide to Cloud Computing Best Practices, Brisbane: The Art of Service, 2010.

[62] L. Khansa i C. Zobel, »Assessing innovations in cloud security,« *Journal of Computer Information Systems 54(3),* pp. 45-56, 2014.

[63] Y.-C. Lee, »Adoption Intention of Cloud Computing at the Firm Level,« *Journal of Computer Information Systems,* pp. 61-72, 2017.

[64] E. Park i K. J. Kim, »An Integrated Adoption Model of Mobile Cloud Services: Exploration of Key Determinants and Extension of Technology Acceptance Model,« *Telematics and Informatics,* pp. 376-385, 2014.

[65] P. G. Bringas, I. Pastor-López i G. Psaila, »BlockChain Platforms in Financial Services: Current Perspective,« *Business Systems Research : International journal of the Society for Advancing Innovation and Research in Economy,* svez. 3, 2020.

[66] M. Perkušić, Š. Jozipović i D. Piplica, »The Need for Legal Regulation of Blockchain and Smart Contracts in the Shipping Industry,« *Transactions on Maritime Science,* svez. 02, pp. 365-373, 2020.

[67] N. Budimir, »Blockchain tehnologija u osiguranju,« *Zbornik radova Veleučilišta u Šibeniku,* svez. 14, br. 1-2, pp. 171-181, 2020.

[68] J. Dešić i K. Lenac, »Je li blockchain tehnologija budućnost digitalizacije zemljišnih knjiga?,« *Zbornik Pravnog fakulteta Sveučilišta u Rijeci,* svez. 41, br. 2, pp. 609-630, 2020.

[69] E. Čulinović-Herc, A. Zubović i M. Derenčinović Ruk, »Blockchain tehnologija - prema novom regulatornom okviru za tokenizirane vrijednosne papire,« *Zbornik Pravnog fakulteta Sveučilišta u Rijeci,* 2021.

[70] A. Pinna i S. Ibba, »A blockchain-based Decentralized System for proper handling of temporary Employment contracts,« *airXiv,* pp. 1-6, 2018.

[71] »bitclude,« 2021. [Mrežno]. Available: https://bitclude.com/hr/sto-je-blockchain. [Pokušaj pristupa 10 11 2021].

[72] petric-kajic.hr, »petric-kajic.hr,« 2020. [Mrežno]. Available: https://www.petric-kajic.hr/pametni-ugovori-smart-contracts/.

[73] J. Pierce i A. Delbecq, »Organisation structure, individual attributes and innovation,« *Academy of Management Review, Vol. 2 No. 1,* pp. 27-37, 1977.

[74] P.-F. Hsu, K. L. Kraemer i D. Dunkle, »Determinants of E-Business Use in U.S. Firms,« *International Journal of Electronic Commerce 10 (4),* pp. 9-45, 1 June 2006.

[75] C. Liu, »Understanding Electronic Commerce Adoption at Organizational Level: Literature Review of TOE Framework and DOI Theory,« *International Journal of Science and Business,* pp. 179-195, 2019.

[76] L. G. Tornatzky i K. J. Klein, »Innovation characteristics and innovation adoption-implementation: A meta-analysis of findings,« *IEEE Transactions on Engineering Management 29(1),* pp. 28-45, February 1982.

[77] L. Tornatsky i M. Fleischer, The Process of Technology Innovation, Lexington, MA: Lexington Books, 1990.

[78] S. Ahmad , N. Zulkurnain i F. Khairushalimi, »Assessing the Validity and Reliability of a Measurement Model in Structural Equation Modeling (SEM),« *British Journal of Mathematics and Computer Science,* pp. 1-8, 2016.

[79] S. R. Igwe, A. Ebenuwa i O. W. idenedo, »Technology adoption and sales performance of manufacturing small and medium enterprises in port harcourt,« *Journal of Marketing Development,* svez. 5, br. 1, pp. 44-59, 2020.

[80] I. Ekanem i D. Smallbone, »Learning in Small Manufacturing Firms: The Case of Investment Decision-making Behaviour,« *International Small Business Journal,* 2016.

[81] T. Rantapuska i O. Ihanainen, »Knowledge use in ICT investment decision making of SMEs,« *Journal of Enterprise Information Management, Volume 21, Issue 6,* pp. 585-596, 2008.

[82] J. Y. L. Thong i C. S. Yap, »CEO characteristics, organizational characteristics and information technology adoption in small businesses,« *Omega,* svez. 23, br. 4, pp. 429-442, 1995.

[83] D. Smallbone i I. Ekanem, »Learning in Small Manufacturing Firms: The Case of Investment Decision-making Behaviour,« *International Small Business Journal: Researching Entrepreneurship Volume 25 Isseu 2,* pp. 107-129, 04 2007.

[84] R. Lucchetti i A. Sterlacchini, »The Adoption of ICT among SMEs: Evidence from an Italian Survey,« *Small Business Economics, Vol 23,,* pp. 151-168, 2004.

[85] T. Masood i P. Sonntag, »Industry 4.0: Adoption challenges and benefits for SMEs,« *Computers in Industry, Volume 121,* October 2020.

[86] G. G. Gable i K. S. Raman, »Government initiatives for IT adoption in small businesses: experiences of the Singapore Small Enterprise Computerization Programme,« *International Information Systems,* svez. 1, br. 1, pp. 68-93, 1992.

[87] S.-I. Chang, S.-Y. Hung, D. C. Yen i P.-J. Lee, »Critical Factors of ERP Adoption for Small- and Medium- Sized Enterprises: An Empirical Study,« *Journal of Global Information Management,* svez. 3, pp. 82-106, 2010.

[88] C. L. Iacovou, I. Benbasat i A. S. Dexter, »Electronic Data Interchange and Small Organizations: Adoption and Impact of Technology,« *MIS Quarterly, Vol 19, No. 4,* pp. 465-485, December 1995.

[89] J. L. Gibbs i K. L. Kraemer, »A Cross-Country Investigation of the Determinants of Scope of E-commerce Use: An Institutional Approach,« *Electronic Markets,* January 2004.

[90] A. K. Garg i T. Choeu, »The Adoption of Electronic Commerce by Small and Medium Enterprises in Pretoria East,« *The Electronic Journal of Information Systems in Developing Countries,* svez. 7, pp. 1-23, 2015.

[91] NN, »Zakonom o elektroničkom izdavanju računa u javnoj nabavi,« 2018. [Mrežno]. Available: https://narodne-novine.nn.hr/clanci/sluzbeni/2018_10_94_1817.html.

[92] hzmo, »hzmo,« [Mrežno]. Available: https://www.mirovinsko.hr/hr/prijave-i-odjave-na-osiguranje-600/600. [Pokušaj pristupa 04 2021].

[93] S. Stanković, »www.poslovni.hr,« 2021. [Mrežno]. Available: https://www.poslovni.hr/hrvatska/mozda-se-pogrijesilo-kad-se-e-racun-komunicirao-kao-obavezan-trebalo-je-prije-objasniti-benefite-4270937. [Pokušaj pristupa 05 11 2021].

[94] www.poslovni.hr, »www.poslovni.hr,« 2020. [Mrežno]. Available: https://www.poslovni.hr/hrvatska/sve-vise-tvrtki-prepoznaje-prednost-koristenja-e-racuna-4270931. [Pokušaj pristupa 2021].

[95] J. Turner i T. Akinremi, »ERC Insight Paper-The business effects of pandemics,« 2020. [Mrežno]. Available: https://www.enterpriseresearch.ac.uk/wp-content/uploads/2020/04/ERC-Insight-The-business-effects-of-pandemics-%E2%80%93-a-rapid-literature-review-Final.pdf. [Pokušaj pristupa April 2020].

[96] W. H. Long i J. W. Feng, »Research report on companies' survival and development strategy during a novel coronavirus epidemic,« *Beijing: UIBE Press,* Feburary 2020.

[97] D. Strusani i G. V. Houngbonon, »How Firms are Responding and Adapting During COVID-19 and Recovery,« International Finance Corporation, Washington, 2020.

[98] R. Harel, »The Impact of COVID-19 on Small Businesses' Performance and Innovation,« *Global Business Review,* pp. 1-22, 2021.

[99] H. M. Aji, I. Berakon i M. M. Husin, »COVID-19 and e-wallet usage intention: A multigroup analysis between Indonesia and Malaysia,« *Cogent Business & Management,* br. 7, pp. 1-16, 2020.

[100] E. Ishaq, S. Bashir, R. Zakariya i A. Sarwar, »Technology Acceptance Behavior and Feedback Loop: Exploring Reverse Causality of TAM in Post-COVID-19 Scenario,« *HYPOTHESIS AND THEORY article,* 2021.

[101] G. C. Kane, A. N. Phillips, J. Copulsky i R. Nanda, »Deloitte,« 06 August 2020. [Mrežno]. Available: https://www2.deloitte.com/us/en/insights/topics/digital-transformation/digital-transformation-COVID-19.html.

[102] D. Roe, »What 8 Months of COVID-19 Has Taught Us About Digital Transformation,« November 2020. [Mrežno]. Available: https://www.cmswire.com/digital-workplace/what-8-months-of-covid-19-has-taught-us-about-digital-transformation/.

[103] J. Jacoby i L. B. Kaplan, »The Components of Perceived Risk | ACR,« u *Proceedings of the Third Annual Conference of the Association for Consumer Research,* 1972.

[104] S. A. Rijsdijk i E. J. Hultink, »''Honey, Have You Seen Our Hamster?'' Consumer Evaluations of Autonomous Domestic Products,« *The Journal of Product Innovation Management ,20,* p. 204–216, 2003.

[105] T. Roselius, »Consumer Rankings of Risk Reduction Methods,« *Journal of Marketing (35) 1,* pp. 56-61, 1971.

[106] G. W. Downs i L. B. Mohr, »Conceptual Issues in the Study of Innovation,« *Administrative Science Quarterly ,* svez. 4, pp. 700-714, 1976.

[107] S. Piri Rajh, »Usporedba strukturnih modela percipirane vrijednosti,« *Market-Tržište,* pp. 117-133, 2012.

[108] L. Burilović, »Digitalna transformacija poslovanja u maloprodaji, Vol. 14 No. 2,« *Poslovna izvrsnost,* pp. 197-221, 2020.

[109] cis, »Upravljanje sigurnosnim rizicima,« 2003. [Mrežno]. Available: https://www.cis.hr/www.edicija/LinkedDocuments/CCERT-PUBDOC-2003-10-44.pdf.

[110] G. Tanakinjal, K. Deans i B. Gray, »Third Screen Communication and the Adoption of Mobile Marketing: A Malaysia Perspective,« *International Journal of Marketing Studies, Vol. 2 No. 1,* pp. 36-47, 2010.

[111] M. Tan i T. Teo, »Factors Influencing the Adoption of Internet Banking,« *Journal of the Association for Information Systems, Vol. 1 No. 5,,* pp. 1-42, 2000.

[112] V. Vukšić Bosilj, K. Ćurko, B. Jaković, L. Milanović Glavan, M. Pejić Bach, J. Pivar, M. Spremić, A.-M. Stjepić, I. Strugar, M. Varga, N. Vlahović, V. Srića, D. Vugec Suša i J. Zoroja, Osnove poslovne informatike, Zagreb: Sveučilište u Zagrebu, Ekonomski fakultet, 2019.

[113] M.-C. Lee, »Factors influencing the adoption of internet banking: An integration of TAM and TPB with perceived risk and perceived benefit,« *Electronic Commerce Research and Applications,* pp. 130-141, 1 May 2009.

[114] cyber-edge, »Cyberthreat Defence Report,« 2021. [Mrežno]. Available: https://cyber-edge.com/cdr/. [Pokušaj pristupa 7 12 2021].

[115] tportal.hr, »tportal.hr,« 2019. [Mrežno]. Available: https://www.tportal.hr/tehno/clanak/na-vrijeme-saznajte-sto-je-to-spear-phishing-i-kako-ga-izbjeci-foto-20190427. [Pokušaj pristupa 7 12 2021].

[116] Pwc, »Cyber threats 2020 report on global landscape,« 2020. [Mrežno]. Available: https://www.pwc.co.uk/issues/cyber-security-services/insights/cyber-threats-2020-report-on-global-landscape.html. [Pokušaj pristupa 7 12 2021].

[117] A. H. Alghushami, N. H. Z. Zakaria i M. A. Zahurin, »Factors Influencing Cloud Computing Adoption in Higher Education Institutions of Least Developed Countries: Evidence from Republic of Yemen,« *Applied Sciences,* pp. 1-27, 2020.

[118] A. Susanty, A. Handoko i N. B. Puspitasari, »Push-pull-mooring framework for e-commerce adoption in small and medium enterprises,« *JOURNAL OF ENTERPRISE INFORMATION MANAGEMENT Volume: 33 Issue: 2,* pp. 381-406, 28 FEB 2020.

[119] Apsolon, »apsolon.com,« 2020. [Mrežno]. Available: https://apsolon.com/digitalna-transformacija-hrvatska-2020-hrvatski-digitalni-indeks/. [Pokušaj pristupa 12 2020].

[120] D. Schallmo, C. A. Williams i L. Boardman, »Digital transformation of business models — best practice, enablers, and roadmap,« *International Journal of Innovation Management,* 2017.

[121] europa.eu, »europa.eu,« 2021. [Mrežno]. Available: https://ec.europa.eu/croatia/what_is_digital_transformation_changing_hr. [Pokušaj pristupa 2020].

[122] T. Aguiar, S. Bogea Gomes, P. R. da Cunha i M. M. da Silva, »Digital Transformation Capability Maturity Model Framework,« u *IEEE 23rd International Enterprise Distributed Object Computing Conference (EDOC),* 2019.

[123] M. Kozina, »Framework for assessing the company's maturity of digital business transformation,« u *Economic and Social Development 40th International Scientific Conference on Economic and Social Development Book of Proceedings* , 2019.

[124] E. Henriette, M. Feki i I. Boughzala, »The Shape of Digital Transformation: A Systematic Literature Review,« u *MSCI 2015 Proceedings,* 2015.

[125] E. Bostrom i O. C. Celik, »Towards a Maturity Model for Digital - A qualitative study of how an organization can analyze and assess,« 2017. [Mrežno]. Available: http://www.diva-portal.org/smash/get/diva2:1113444/FULLTEXT01.pdf.

[126] Ž. Kruljac i D. Knežević, »Modeli digitalne zrelosti poduzeća - objašnjenje, pregled literature i analiza,« *Obrazovanje za poduzetništvo - E4E : znanstveno stručni časopis o obrazovanju za poduzetništvo,* pp. 72-84, 2019.

[127] S. Berghaus i A. Back, »Stages in Digital Business Transformation Results of Empirical Maturity Study,« u *MCIS 2016 Proceedings,* 2016.

[128] S. Nambisan, M. Wright i M. Feldman, »The digital transformation od innovation and entrepreneurship: Progress, challenges and key themes,« *Research Policy,* svez. 8, 2019.

[129] D. Ifenthaler i M. Egloffstein, »Development and Implementation of a Maturity Model of Digital Transformation,« *TechTrends 64(2),* pp. 302-309, 2020.

[130] Ž. Kruljac, *Ključni čimbenici digitalne zrelosti poduzeća i utjecaj razine zrelosti na poslovanje poduzeća, doktorska disertacija,* Zagreb: Ekonomski fakultet, 2020.

[131] R. Teichert, »Digital Transformation Maturity: A Systematic Review of Literature,« *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis* , pp. 1673-1687, 2019.

[132] S. Chanias i T. Hess, »How digital are we? Maturity models for assessment of a company's status in digital transformation,« *LMU Munich Management Report 2/2016. Munich_ Munich School of Management.,* 2016.

[133] M. D. Shahiduzzaman, »Digital business: Towards a value centric maturity model. Part A. Queensland: PWC Chair in Digital Economy/Queensland University of Technology.,« 2017.

[134] J. Poeppelbuss i M. Roeglinger, »What makes a useful maturity model? A framework of general design principles for maturity models and its demonstration in business process management,« *Conference: European Conference on Information Systems (ECIS)At: Helsinki, FinlandVolume: 19,* June 2011.

[135] T. DeBruin i M. Rosemann, »Towards a Business Process Management Maturity Model,« *ECIS 2005 Proceedings of the Thirteenth European Conference on Information Systems,* pp. 1-12, 2005.

[136] E. Schein, »Organizational Culture,« *Organizational Culture. American Psychologist,* svez. 45, br. 2, pp. 109-119, 1990.

[137] D. A. Garvin i M. A. Roberto, »What You Don't Know About Making Decisions,« *Harvard Business Review,* 2001.

[138] P. Sikavica i F. Bahtijarević-Šiber, Menadžment, Zagreb: MASMEDIA, 2004, pp. 285-297.

[139] E. Salas, M. A. Rosen i D. DiazGranados, »Expertise-Based Intuition and Decision Making in Organizations,« *Journal of Management,* pp. 1-31, July 2010.

[140] I. Bulog, »Odnos između pristupa odlučivanju na strateškoj razini menadžmenta i organizacijskih performansi na primjeru hrvatskih poduzeća,« *Ekonomska misao i praksa : časopis Sveučilista u Dubrovniku,* pp. 3-29, 2014.

[141] R. Ogarcă P, »Features of the decision-making in SMESs,« *Annals of University of Craiova - Economic Sciences Series,,* svez. 3, br. 38, 2010.

[142] J. de Jong, P. Gibcus i P. A.M. Vermeulen, »Strategic Decision-Making in Small Firms: Towards a Typology of Entrepreneurial Decision-Makers,« *Entrepreneurship Theory & Practice,* pp. 4-30, 2006.

[143] D. Polšek i M. Bokulić, »Dvije paradigme objašnjenja kognitivnih pristranosti u odlučivanju: "bihevioralna ekonomija" i "ekološka racionalnost",« *Društvena istraživanja Zagreb,* pp. 303-323, 2013.

[144] T. Gilovich, D. Griffin i D. Kahneman, Heuristics and biases:The psychology of intuitive judgment, Cambridge: University Cambridge, 2002.

[145] S. P. Robbins i T. A. Judge, Organizacijsko ponašanje, 12 ur., New Yersey: MATE d.o.o., 2009.

[146] G. Berisha, J. Shiroka Pula i B. A. Krasniqi, »Convergent validity of two decision making style measures,« *Journal of Dynamic Decision Making 4(1),* pp. 1-8, April 2018.

[147] J. Baron, Rationality and intelligence, 1985 ur., Cambridge: Cambridge University Press, 1985.

[148] A. Furnham, Personality, style preference and individualdevelopment. In M. Pearn (Ed.),Individual differences and devel-opment in organisations, Chichester: John WIley& Sons, 2002, pp. 89-103.

[149] S. D. Barbosa, M. W. Gerhardt i J. Rich, »The role of cognitive style and risk preferences on entrepreneurial self-efficacy and entrepreneurial intensions,« *Journal of Leadership and Organization Studies,* May 2007.

[150] K. Hamilton, S.-I. Shih i S. Mohammed, »The development and validation of the rational and intuitive decision styles scale,« *Journal of Personality Assessment 98 (5),* pp. 523-535, 2016.

[151] C. W. Allinson, E. Chell i J. Hayes, »Intuition and entrepreneurial behaviour,« *European Journal of Work and Organizational Psychology,* pp. 31-43, March 1 2000.

[152] S. Epstein, »Integration of the cognitive and the psychodynamic unconscious,« *The American Psychologist 49 (8),* pp. 709-724, August 1994.

[153] R. M. Hogarth, »Deciding Analytically or Trusting Your Intuition? The Advantages and Disadvantages of Analytic and Intuitive Thought,« 22 10 2020. [Mrežno]. Available: https://papers.ssrn.com/abstract=394920.

[154] N. L. Wood i S. Highhouse, »Do self-reported decision styles relate with others' impressions of decision quality?,« *Personality and Individual Differences 70,* pp. 224-228, 2014.

[155] K. R. Hammond, R. M. Hamm, J. Grassia i T. Pearson, »Direct comparison of the efficacy of intuitive and analytical cognition in expert judgment,« *IEEE Journals & Magazine,* pp. 753-770, October 1987.

[156] E. Sadler-Smith, »Cognitive Style and the Management of Small and Medium-Sized Enterprises,« *Organization Studies,* 30 June 2016.

[157] D. P. Spicer i E. Sadler-Smith, »An examination of the general decision making style questionnaire in two UK samples,« *Journal of Managerial Psychology,* pp. 137-149, 2005.

[158] I. Chakraborty, P. J.-H. Hu i D. Cui, »Examining the effects of cognitive style in individuals' technology use decision making,« *Decision Support Systems 45 (2),* pp. 228-241, 2008.

[159] S. G. Scott i R. A. Bruce, »Decision-Making Style: The Development and Assessment of a New Measure,« *Sage Journals,* 1995.

[160] P. Sikavica, T. Hunjak, N. Begičević Ređep i T. Hernaus, Poslovno odlučivanje, Zagreb: Školska knjiga, 2014.

[161] M. Sinclair i N. M. Ashkanay, »Intuition: Myth or a Decision - making Tool?,« *Management Learning,* svez. 36, br. 3, pp. 353-370, 2005.

[162] A. M. Abubakar, M. A. Alatailat, A. Elçi i H. Elrehail, »Knowledge management, decision-making style and organizational performance,« *Journal of Innovation & Knowledge Volume 4, Issue 2,* pp. 104-111, April–June 2019.

[163] J. R. Patton, »Intuition in decisions,« *Management Decision,* svez. 41, br. 10, pp. 989-996, 2003.

[164] K. Malewska, »Intuition in decision-making- a review of empirical research in the area of magagement,« u *Theory of Management 8: The Selected Problems for the Development Support of Management Knowledge Base* , University of Zilina, Institute of Management by University of Zilina, 2019, pp. 165-170.

[165] F. A. Russ, K. M. McNeilly i J. M. Comer, »Leadership, Decision Making and Performance of Sales Managers: A Multi-Level Approach,« *Journal of Personal Selling & Sales Management 16 (3),* pp. 1-15, 1996.

[166] P. Drucker, Managing for results, HarperColl, 1993.

[167] J. W. Dean i M. P. Sharfman, »Procedural Rationality in the Strategic Decision-Making Process,« *Journal of Management Studies 30 (4),* pp. 587-610, 1993.

[168] D. Barković i B. Tuševski, »Rational decision versus irrational decision,« *Interdisplinary management research XV,* pp. 402-418, 2019.

[169] H. A. Simon, The New Science of Menagement Decisions, New York : Harper and Row, 1960.

[170] R. L. Daft, J. Murphy i H. Willmott, Organization Theory & Design, IV ur., Andover, UK: Cengage Learning EMA, 2020, pp. 445-455.

[171] N. Verma, A. B. Bhat, S. Rangnekar i M. Barua, »Association between leadership style and decision making style in Indian organisations,« *Journal of Management Development,* br. 3, pp. 246-269, 2015.

[172] M. Mescon, M. Albert i F. Khedouri, Management, New York: Harper and Row, 1985.

[173] R. Vieweg , »Der Einfluss der Organisations auf den Entscheidungsprozess,« *Zeitschrift fur Irganisation 2,* 1979.

[174] M. Buble, M. Cingula, M. Dujanić, Ž. Dulčić, M. G. Božac, L. Galetić, F. Ljubić, S. Pfeifer i D. Tipurić, Strateški menadžment, Zagreb: Sinergija, 2005.

[175] M. E. Porter, Konkurentska prednost, Zagreb: Masmedia, 2008.

[176] N. Alfirević, F. Bahtijarevič-Šiber, V. Bosilj Vukšić, M. Buble , K. Ćurko, Ž. Dulčić, R. Fabac, V. Franičević, L. Galetić, L. Jurčić, M. Kolaković, M. Marušić, S. Marušić, I. Pavić, N. Pološki, A. Pulić, S. Rašić, M. Sadžak, P. Sikavice , H. Skoko i D. Tipurić, Konkurentska sposobnost poduzeća, D. Tipurić, Ur., Zagreb: Sinergija d.o.o., 1999.

[177] J. Barney, »Firm Resources ans Sustained Competitive Advantage,« *Journal of Management,* pp. 99-120, 1991.

[178] S. L. Hart, »A natural-resource-based view of the firm,« *The Academy of Management Review,* svez. 4, pp. 986-1014, 1995.

[179] N. Rupčić, Suvremeni menadžment Teorija i praksa, Rijeka: Ekonomski fakultet Sveučilišta u Rijeci, 2018.

[180] M. Daraboš, Evolucija konkurentske prednosti, Zagreb: Naklada Ljevak, 2015.

[181] V. Venkatesh, M. G. Morris, G. B. Davis i F. D. Davis, »User Acceptance of Information Technology: Toward a Unified View,« *MIS Quarterly, Vol. 27, No. 3,* pp. 425-478, Sep 2003.

[182] D. R. Compeau i C. A. Higgins, »Computer Self-Efficacy: Development of a Measure and Initial Test,« *MIS QuarterlyVol. 19, No. 2,* pp. 189-211, Jun 1995.

[183] N. Slack i M. Lewis, Operations Strategy, Fifth Edition, Edinburgh Gate, Harlow: Pearson Education Limited, 2017.

[184] R. D. Reid i N. R. Sanders, Operations Management An Integrated Approach 5th edition, New Jersey: John Wiley & Sons Singapore Pte. Ltd., 2013.

[185] S. E. D. Board, »Smart industry readiness index - The prioritisation matrix,« 2020. [Mrežno]. Available: https://siri.gov.sg/docs/default-source/default-document-library/the-prioritisation-matrix.pdf. [Pokušaj pristupa 04 2021].

[186] J. A. Maxwell, Qualitative Research Design: An Interactive Approach (Applied Social Research Methods) 3rd Edition, 3 ur., Thousand oaks, California 91320: SAGE Publications, Inc., 2012.

[187] D. Adom, E. K. Hussein i J. A. Agyem, »Theoretical and conceptual framework: mandatory ingredients of a quality research,« *International Journal of Scientific Research,* svez. 1, Siječanj 2018.

[188] M. B. Miles i A. M. Huberman, Qualitative data analysis: An expanded sourcebook (2nd ed.), 2 ur., Thousand Oaks: CA: Sage., 1994.

[189] ec.europa.eu, »europa.eu,« 2020. [Mrežno]. Available: https:///digital-single-market/en/news/sme-strategy-launched-european-commission.

[190] F. Blatz, R. Bulander i M. Dietel, »Maturity Model of Digitization for SMEs,« *2018 IEEE International Conference on Engineering, Technology and Innovation (ICE/ITMC),* pp. 1-9, 2018.

[191] S. Tsang, C. F. Royse i A. S. Terka, »Guidelines for developing, translating, and validating a questionnaire in perioperative and pain medicine,« *Saudi Journal of Anaesthesia,* pp. 80-89, 2017.

[192] G. Milas, Istraživačke metode u psihologiji i drugim društvenim znanostima, 2 ur., Jastrebarsko: Naklada slap, 2009.

[193] M. Kalfoss, »Translation and Adaption of Questionnaires:,« *SAGE Open Nursing,* pp. 1-13, 2019.

[194] M. Featherman i P. A. Pavlou, »Predicting e-services adoption: a perceived risk facets perspective,« *International Journal of Human-Computer Studies 59 (4),* pp. 451-474, 1 October 2003.

[195] G. Premkumar i M. Roberts, »Adoption of new information technologies in rural small,« *Omega,* svez. 27, br. 4, pp. 467-484, 1999.

[196] J.-H. Wu i S.-C. Wang, »What drives mobile commerce?: An empirical evaluation of the revised technology acceptance model,« *Information & Management,* pp. 719-729, 2005.

[197] S. Okcu, K. G. Hancerliogullari, E. Basak i F. Calisir, »Factors Affecting Intention to Use Big Data Tools: An Extended Technology Acceptance Model,« *Industrial Engineering in the Big Data Era,* pp. 401-416, 2019.

[198] E. E. Grandona i J. M. Pearson, »Electronic commerce adoption: an empirical study of small and medium US businesses,« *Information & Management,* svez. 1, p. 197–216., 2004.

[199] V. Venkatesh i F. Davis, »A Theoretical Extension of the Technology Acceptance Model: Four Longitudinal Feld Studies,« *Management Science,,* pp. 186-204, 2000.

[200] HGK, »Analiza Hrvatske IT industrije 2014.-2019.,« 2021. [Mrežno]. Available: https://www.hgk.hr/documents/analiza-hrvatske-it-industrije-20142019-kb602bb6ffa49ca.pdf. [Pokušaj pristupa 2021].

[201] D. z. z. statistiku, »BROJ I STRUKTURA POSLOVNIH SUBJEKATA U LIPNJU 2020.,« [Mrežno]. Available: https://www.dzs.hr/Hrv_Eng/publication/2020/11-01-01_02_2020.htm. [Pokušaj pristupa 05 12 2020].

[202] H. o. komora, »STATISTIČKE INFORMACIJE lipanj 2020.,« [Mrežno]. Available: https://www.hok.hr/sites/default/files/page-docs/2020-09/Statisti%C4%8Dke_informacije_lipanj_2020.pdf. [Pokušaj pristupa 05 12 2020].

[203] J. F. Hair Jr, M. Sarstedt, L. Hopkins i V. G. Kuppelwieser, »Partial least squares structural equation modeling (PLS-SEM),« *European business review., 26(2),* pp. 106-121, 2014.

[204] G. D. Israel, »Determining Sample Size,« 05 12 2020. [Mrežno]. Available: http://www.gjimt.ac.in/web/wp-content/uploads/2017/10/2_Glenn-D.-Israel_Determining-Sample-Size.pdf.

[205] H. Taherdoost, »Determining Sample Size; How to Calculate Survey Sample Size,« *International Jpurnal of Economics and Management Systems, Vo 2,* pp. 237-239, 2017.

[206] U. Sekaran, Research Methods For Business: A Skill Building Approach Fourth edition, Wiley India Pvt. Limited, 2006, p. 294.

[207] T. V. Perneger, D. Courvoisier , P. M. Hudelson i A. Gayet-Ageron, »Sample size for pre-tests of questionnaires,« *Qual Life Res,* pp. 147-151, 2015.

[208] J. Horvat i J. Mijoč, Istraživački SPaSS, Zagreb: Ljevak, 2019.

[209] M. Milošević, »Izrada mjernog instrumenta stresa na radnom mjestu bolničkih zdravstvenih djelatnika i procjena njegove uporabne vrijednosti,« *Doktorska dizertacija,* 2010.

[210] S. A. Samani, »Steps in Research Process (Partial Least Square of Structural Equation (PLS-SEM)),« *International Jpurnal of Social Science and Business,* svez. 2, pp. 55-66, 2016.

[211] T. A. Brown, Confirmatory Factor Analysis for Applied Research, Second Edition ur., New York: The Guilford Press, 2015.

[212] J. Hair Jr, W. Black, B. Babin i R. Anderson, Multivariate Data Analysis 7th Edition, New Delhi: Pearson, India, 2010.

[213] J. Komšić, »Mjerenje reputacije turističke destinacije na društvenim medijima i zadovoljstva turista,« *Doctoral thesis* , 2018.

[214] M. Mejovšek, Metode znanstvenog istraživanja u društvenim i humanističkim znanostima, 2 ur., Jastrebarsko: Naklada Slap, 2013.

[215] J. F. Hair, G. T. M. Hult, C. Ringle i M. Sarstedt, A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM), 5 ur., Los Angeles: Sage Publications, 2017.

[216] T. Orehovački, »Metodologija vrjednovanja kvalitete u korištenju aplikacijama Web 2.0,« *Doktorska dizertacija,* pp. 136-144, 2013.

[217] J. F. Hair, J. J. Rishe, M. Sarstedt i C. M. Ringle, »When to use and how to report the results of PLS-SEM,« *Eur. Bus. Rev.,* svez. 1, p. 2–24, 2019.

[218] J. Cohen, Statistical power analysis for the Behavioral Sciences, 2 ur., New York: Lawrence Erlbaum Associates, Hillsdale, 1988.

[219] D. D. Nulty, »The adequacy of response rates to online and paper surveys: what can be done?,« *Assessment & Evaluation in Higher Education,* pp. 301-314, 2008.

[220] M. Saunders, P. Lewis i A. Thornhill, Research Methods for Business Students, 7th ed ur., Pearson Education Limited, 2016.

[221] A. Field, Discovering statistics using IBM SPSS Statistics, London: SAGE Publications Ltd., 2013.

[222] S. Opić, »Testiranje normalnosti distribucije u istraživanjima odgoja i obrazovanja,« *Školski vjesnik,* svez. 60, br. 2, pp. 181-197, 2011.

[223] D. B. M. &. G. D. Straub, »Validation Guidelines for IS Positivist Research,« *Communications of the Association for Information Systems,* pp. 380-427, 2004.

[224] J. Henseler, C. Ringle i M. Sarstedt, »A new criterion for assessing discriminant validity in variance-based structural equation modeling,« pp. 115-135, 2015.

[225] P. Bentler, »On tests and indices for evaluating structural models,« *Personality and Individual Differences,* pp. 825-829, 2007.

[226] R. P. Bagozzi i Y. Yi, »On the Evaluation of Structure Equation Models,« *Journal of the Academy of Marketing Science 16(1),* pp. 74-94, 1988.

[227] H. Marsh i D. Hocevar, »Application of confirmatory factor analysis to the study of self-concept: First- and higher order factor models and their invariance across groups.,« *Psychological Bulletin,* pp. 562-582, 1985.

[228] P. M. Bentler i D. G. Bonnet, »Significance tests and goodness of fit in the analysis of covariance structures,« *Psychological Bulletin,* pp. 588-606, 1980.

[229] L. Hu i P. Bentler, »Cutoff criteria for fit indexes in covariance structure analysis:,« 1999. [Mrežno].

[230] K. F. Widaman i J. S. Thompson, »On specifying the null model for incremental fit indices in structural equation modeling,« *Psychol Bulletin 88,* pp. 16-37, 2003.

[231] P. J. Curran, F. Chen, K. A. KeBollen, J. B. Kirby i P. Paxton, »An Empirical Evaluation of the Use of Fixed Cutoff Points in RMSEA Test Statistic in Structural Equation Models,« *Sociol Methods Res.,* svez. 36, br. 4, pp. 462-494, 2008.

[232] D. Cole, »Utility of Confirmatory Factor Analysis in test validation research,« *ournal of Consulting and Clinical Psychology,* svez. 55 , br. 4, pp. 584-595., 1987.

[233] J. Nunnely i I. Bernstein, Psychometric Theory, New York.: New York: McGraw-Hill, 1994.

[234] M. Browne i R. Cudeck, Alternative Ways of Assessing Model Fit. In: Bollen, K.; Long, J., editors. Testing Structural Equation Models, Sage; Newbury Park, CA, 1993, pp. 136-162..

[235] L. R. Fabrigar, R. C. MacCallum, D. T. Wegener i E. J. Strahan, »Evaluating the use of exploratory factor analysis in psychological research,« *Psychological Methods,* svez. 4, br. 3, p. 272–299, 1999.

[236] A. H. Segars i V. Grover, »Strategic information systems planning success: An investigation of the construct and its measurement,« *MIS Quarterly: Management Information Systems,* svez. 22, br. 2, pp. 139-162, 1998.

[237] H. Marsh, J. R. Balla i R. P. McDonald, »Goodness-of-Fit Indexes in Confirmatory Factor Analysis: The Effect of Sample Size,« *Psychological Bulletin 103(3),* pp. 391-411, 1988.

[238] H. Kim, B. Ku, J. Y. Kim i Y.-J. Park, »Confirmatory and Exploratory Factor Analysis for Validating the Phlegm Pattern Questionnaire for Healthy Subjects,« *Evidence-based Complementary and Alternative Medicine,* pp. 1-8, 2016.

[239] S. A. Mulaik, L. R. James, J. Van Alstine, N. Bennett, S. Lind i C. D. Stilwell, »Evaluation of goodness-of-fit indices for structural equation models,« *Psychological Bulletin,* svez. 105, br. 3, pp. 430-445, 1989.

[240] P. M. Bentler, »Comparative fit indexes in structural models,« *Psychological Bulletin,* svez. 107, br. 2, p. 238–246, 1990.

[241] J. Arnerić i K. Protrka, »Modeli analize varijance (ANOVA),« *Matematičko-fizički list,* svez. 70, br. 277, pp. 25-32, 2019.

[242] ec.europa.eu, »https://ec.europa.eu/info/strategy/international-strategies/sustainable-development-goals_hr.,« [Mrežno]. Available: https://ec.europa.eu/info/strategy/international-strategies/sustainable-development-goals_hr. . [Pokušaj pristupa 2022].

[243] A. S. Reber, Implicit Learning and Tacit Knowledge: An Essay on the Cognitive Unconscious, Oxford University Press, USA, 1996, p. 15431–15435..

[244] D. Vican, »Znanje vrijedno znanja – znanje vrijedno poučavanja,« *Pedagogijska istraživanja, Vol. 4 No. 2,,* pp. 231-237, 2007.

PRILOG 1

Prihvaćanje uslužnog računalstva i pametnih ugovora od strane mikro i malih organizacija

Poštovani, kako biste mi pomogli u provođenju istraživanja ljubazno Vas molim da odvojite par minuta Vašeg vremena za ispunjavanje ovog anketnog upitnika.
Istraživanje se provodi za potrebe izrade doktorske disertacije pod nazivom „Utjecaj digitalne zrelosti, konkurentskih prioriteta i stilova odlučivanja na namjeru prihvaćanja digitalnih tehnologija u mikro i malim organizacijama".
Upitnik je prvenstveno namijenjen donositeljima odluka u mikro i malim organizacijama (trgovačka društva i obrti) te ima svrhu utvrditi čimbenike utjecaja na prihvaćanje digitalnih tehnologija u mikro i malim organizacijama s posebnim naglaskom na digitalnu zrelost organizacije, konkurentske prioritete i stil odlučivanja donositelja odluke.
Popunjavanje ovog upitnika je anonimno i dobrovoljno i može se popuniti samo jednom.
Popunjavanjem upitnika smatra se da ste suglasni s korištenjem odgovora za statističku obradu isključivo u znanstvene svrhe.

Za sva pitanja stojim na raspolaganju dudobrinic@foi.hr
Unaprijed zahvaljujem,
Dunja Dobrinić

U SLJEDEĆIM PITANJIMA MOLIM OZNAČITE SAMO JEDAN OD PONUĐENIH ODGOVORA.

1. Spol

- [ ] Muško
- [ ] Žensko

2. Dob

- [ ] do 30 godina
- [ ] 31-40 godina
- [ ] 41-50 godina
- [ ] 51-60 godina
- [ ] više od 60 godina

3. Vaše obrazovanje

- [ ] srednja stručna sprema
- [ ] fakultet - VSŠ ili stručni studij
- [ ] fakultet - završen diplomski studij
- [ ] magisterij
- [ ] doktorat

4. Vaša pozicija u organizaciji

- [ ] direktor/ovlaštena osoba
- [ ] vlasnik, nositelj obrta
- [ ] vlasnik i direktor/ovlaštena osoba

5. Pretežita djelatnost organizacije

- [ ] A Poljoprivreda, šumarstvo i ribarstvo
- [ ] B Rudarstvo i vađenje
- [ ] C Prerađivačka industrija
- [ ] D Opskrba električnom energijom, plinom, parom i klimatizacija
- [ ] E Opskrba vodom; uklanjanje otpadnih voda, gospodarenje otpadom te djelatnosti sanacije okoliša
- [ ] F Građevinarstvo
- [ ] G Trgovina na veliko i na malo; popravak motornih vozila i motocikla
- [ ] H Prijevoz i skladištenje
- [ ] I Djelatnosti pružanja smještaja te pripreme i usluživanja hrane
- [ ] J Informacije i komunikacije
- [ ] K Financijske djelatnosti i djelatnosti osiguranja
- [ ] L Poslovanje nekretninama
- [ ] M Stručne, znanstvene i tehničke djelatnosti
- [ ] N Administrativne i pomoćne uslužne djelatnosti
- [ ] O Javna uprava i obrana; obvezno socijalno osiguranje
- [ ] P Obrazovanje
- [ ] Q Djelatnosti zdravstvene zaštite i socijalne skrbi
- [ ] R Umjetnost, zabava i rekreacija
- [ ] S Ostale uslužne djelatnosti
- [ ] T Djelatnosti kućanstava kao poslodavaca; djelatnosti kućanstava koja proizvode različitu robu i pružaju različite usluge za vlastite potrebe
- [ ] U Djelatnosti izvan teritorijalnih organizacija i tijela

6. Veličina organizacije

- [ ] Mikro
- [ ] Mala
- [ ] Srednja
- [ ] Velika

7. Vrsta organizacije

- [ ] Trgovačko društvo
- [ ] Ustanove, tijela, udruge i organizacije
- [ ] Obrti
- [ ] Zadruge

8. U kojoj županije je sjedište organizacije

- [ ] Zagrebačka
- [ ] Krapinsko-zagorska
- [ ] Sisačko-moslavačka
- [ ] Karlovačka
- [ ] Varaždinska
- [ ] Koprivničko-križevačka
- [ ] Bjelovarsko-bilogorska
- [ ] Primorsko-goranska
- [ ] Ličko-senjska
- [ ] Virovitičko-podravska
- [ ] Požeško-slavonska
- [ ] Brodsko-posavska
- [ ] Zadarska
- [ ] Osječko-baranjska
- [ ] Šibensko-kninska
- [ ] Vukovarsko-srijemska
- [ ] Splitsko-dalmatinska
- [ ] Istarska
- [ ] Dubrovačka-neretvanska
- [ ] Međimurska
- [ ] Grad Zagreb

9. Pripada li Vaša organizacija IT sektoru, tj. je li organizacija registrirana za neku od sljedećih djelatnosti prema Nacionalnoj klasifikaciji djelatnosti: NKD (2007): C 26.20, C 26.30, G 46.51, G 46.52, G 47.41, G 47.42, J 58.21, J 58.29, J 62.01, J 62.02, J 62.03, J 62.09, J 63.11, S 95.11 S 95.12

DA

NE

ZA SLJEDEĆE TVRDNJE MOLIM VAS DA OZNAČITE STUPANJ SLAGANJA.

10. Imamo jasnu viziju, misiju i razvijenu strategiju digitalne transformacije.

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

11. Ciljevi temeljem kojih se organizira poslovanje pretežito se temelje na digitalnoj transformaciji.

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

12. U našoj organizaciji strategija digitalne transformacije jasno je komunicirana sa svim zaposlenicima

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

13. Novi projekti koje pokrećemo u organizaciji pretežito su potpora digitalnoj transformaciji.

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

14. Značajan porast prihoda očekuje se u slijedećih pet godina od proizvoda i usluga koji su rezultat digitalne transformacije.

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

15. Imamo adekvatan budžet za podršku provođenja digitalne poslovne strategije.

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

16. Investirali smo značajna sredstva u edukaciju zaposlenika i treninge na području digitalne transformacije.

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

17. Moja organizacija danas ima dovoljno talenata da podrži digitalnu transformaciju.

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

18. Arhitektura naše tehnologije omogućava da se lako integrira sa svim pristupnim kanalima (web, mobilni uređaji..).

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

19. Tehnologija kojom raspolažemo u potpunosti je usklađena sa ciljevima digitalne transformacije poslovanja.

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

20. Naši stručnjaci u potpunosti poznaju nove tehnologije i njihov utjecaj na poslovanje našeg poduzeća.

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

21. Naša tehnologija je naprednija nego tehnologija naših konkurenata.

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

22. Naše aktivnosti u procesu digitalne transformacije nisu limitirane postojećom tehnologijom u organizaciji.

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

23. U našoj organizaciji IT ima stratešku ulogu.

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

24. Postoje jasna pravila i procedure upravljanja IT-em.

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

25. Definirali smo dugoročne planove implementacije novih IT-a.

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

26. Mjerimo učinak našeg IT tima ne samo kroz stabilnost tehnologije nego i kroz poslovne rezultate.

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

27. Naš budžet za tehnologiju je fleksibilan na način da omogućava promjene prioriteta nabavke novih tehnologija.

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

28. Vrlo jasno komuniciramo našu strategiju sa zaposlenicima.

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

29. Naši zaposlenici su svjesni da će se njihova uloga značajno promijeniti.

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

30. Otvoreno komuniciramo na svim razinama o problemima i prilikama poslovanja.

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

31. Naši menadžeri su sposobni prepoznati prilike i prijetnje i potrebu za inovacijama.

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

32. Moja organizacija uspješno balansira između inoviranja i kontrole rizika.

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

33. Primarnu odgovornost u inoviranju uglavnom snosi menadžment organizacije.

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

ZA SLJEDEĆE TVRDNJE MOLIM VAS DA OZNAČITE STUPANJ SLAGANJA ZA POJEDINU TEHNOLOGIJU **1. USLUŽNO RAČUNALSTVO (ENGL. CLOUD)** - TEHNOLOŠKA I INFRASTRUKTURNA DIGITALNA PLATFORMA, KOJA OMOGUĆAVA EFIKASNO I SIGURNO KORIŠTENJE GOTOVO NEOGRANIČENIH DIGITALNIH (HARDVERSKIH, PODATKOVNIH I SOFTVERSKIH) KAPACITETA ZA UPRAVLJANJE PODACIMA, NJIHOVU POHRANU I UPOTREBU, **2. PAMETNI UGOVORI (ENGL. SMART CONTRACTS)**- PRUŽAJU MOGUĆNOSTI SIGURNE RAZMJENE NOVCA (KRIPTOVALUTE), DIONICA I DRUGE IMOVINE IZRAVNO, BEZ SUDJELOVANJA POSREDNIKA (FINANCIJSKIH I JAVNIH SLUŽBI)

34. Korištenje digitalnih tehnologija dovelo bi organizaciju u financijske gubitke.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

35. Trošak prihvaćanja digitalnih tehnologija je daleko veći od koristi.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

36. Trošak održavanja i podrške digitalnih tehnologija je previsok za naše poslovanje.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

37. Troškovi obuke naših zaposlenika za korištenje digitalnih tehnologija su previsoki.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

38. Brine me što bi drugi mogli imati pristup podacima organizacije upotrebom digitalnih tehnologija.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

39. Uvjeren/a sam da su podaci organizacije pohranjeni na digitalnim tehnologijama sigurni.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

40. Vjerujem da nitko ne može vidjeti informacije i podatke pohranjene na digitalnim tehnologijama bez moje suglasnosti.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

41. Vjerujem da su informacije i podaci organizacije na digitalnim tehnologijama sigurni od manipulacije (treće strane) neodgovarajućih korisnika.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

42. Mislim da upotreba digitalnih tehnologija ima potencijalni sigurnosni rizik.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

43. Potrebno je previše vremena da se nauči koristiti digitalne tehnologije.

	1 u potpunosti se ne slažem	2 ne slažem se	3 niti se slažem niti se ne slažem	4 slažem s	5 u potpunosti se slažem
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

44. S obzirom na potrebno vrijeme prelazak na digitalne tehnologije smatram neisplativim i nevrijednim truda.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

45. Mogući gubitak vremena uzrokovan implementacijom i učenjem kako koristiti digitalne tehnologije čini njihovo prihvaćenje neisplativim i nevrijednim truda.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

46. Količina vremena koja je potrebna da se obući zaposlenike za rad s digitalnim tehnologijama je prevelika.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

47. Organizacija bi koristila digitalne tehnologije ukoliko bi postojale progresivne obavezne mjere uvedene od strane vlade koje bi uvjetovale upotrebu.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

48. Organizacija bi koristila digitalne tehnologije ukoliko bi vlada uvjetovala upotrebu u javnoj nabavi i u poslovanju s državom.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

49. Organizacija bi koristila digitalne tehnologije ukoliko bi postojali vladini poticaji za korištenje.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

50. Organizacija bi koristila digitalne tehnologije ukoliko bi bila pod pritiskom vlade.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

51. Svoje razumijevanje digitalnih tehnologija ocjenjujem vrlo dobrim.[5]

	1 u potpunosti se ne slažem	2 ne slažem se	3 niti se slažem niti se ne slažem	4 slažem s	5 u potpunosti se slažem
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

52. Imam vrlo malo znanja o tome kako digitalne tehnologije mogu pomoći u poboljšanju poslovanja i povećanju prihoda organizacije.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

53. Koristio/la bi digitalne tehnologije ukoliko bi mi na raspolaganju bilo više informacija o prednostima koje može donijeti poslovanju moje organizacije.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

[5] Čestica je uklonjena u glavnom istraživanju, temeljem rezultata predistraživanja

54. Ne posjedujem adekvatno tehničko znanje i vještine potrebne za rad i upotrebu digitalnih tehnologija.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

55. Covid 19 pandemija potaknula me na prikupljanje više informacija o digitalnim tehnologijama.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

56. Covid 19 pandemija utjecala je na moju razinu znanja o digitalnim tehnologijama.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

57. Prije Covid 19 pandemije moje znanje o digitalnim tehnologijama bilo je na niskoj razini.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

58. Prije Covid 19 pandemije nisam imao/la interesa pretraživati informacije o digitalnim tehnologijama.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

59. Covid 19 pandemija potaknula me da istražim prednosti koje digitalne tehnologije mogu pružiti u poslovanju moje organizacije.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

60. Upotrebu digitalnih tehnologija zahtijevaju važni poslovni partneri (kupci i dobavljači).

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

61. Upotrebu digitalnih tehnologija preporuča većina poslovnih partnera.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

62. Glavni konkurenti koriste ili će uskoro koristiti digitalne tehnologije.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

63. Ovisimo o drugim organizacijama koje već koriste digitalne tehnologije.

	1 u potpunosti se ne slažem	2 ne slažem se	3 niti se slažem niti se ne slažem	4 slažem s	5 u potpunosti se slažem
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

64. Pod pretpostavkom da imam pristup digitalnim tehnologijama, namjeravam ga/ih koristiti.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

65. Pod pretpostavkom da imam pristup digitalnim tehnologijama, pretpostavljam da ću ga/ih koristiti.

	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
uslužno računalstvo (engl.cloud)					
pametni ugovori (engl. smart contracts)					

66. Prihvaćanjem <u>uslužnog računalstva</u> prvenstveno želim postići sljedeće:

☐	**Povećanje kvalitete**. *Podići razinu kvalitete proizvoda i/ili usluga organizacije na način da se podigne njihova kvaliteta ili da se podigne kvaliteta samih aktivnosti unutar organizacija.*
☐	**Povećanje brzine**. *Ubrzati procese unutar organizacije (ubrzanje isporuke proizvoda i/ili usluge, ubrzanje samih procesa unutar organizacije, skratiti vrijeme isporuke i osigurati isporuku što je prije moguće, ubrzati proces razvoja ideja, tj. skratiti vrijeme od ideje do tržišta).*
☐	**Povećanje pouzdanosti.** *Podići razinu pouzdanosti, pri čemu pouzdanost uključuje izgradnju povjerenja kupca i dobavljača u samu organizaciju te usluge i/ili proizvode koje organizacija nudi.*
☐	**Povećanje fleksibilnost**. *Povećati fleksibilnost organizacije, tj. sposobnost organizacije na prilagođavanje različitim situacijama i promjenama na tržištu, kao i mogućnost reorganizacije cijele organizacije ukoliko se ukaže potreba za istim.*
☐	**Smanjenje troškova.** *Pojednostaviti strukturu troškova organizacije. Omogućiti stvaranje uštede u poslovanju organizacije.*

67. Prihvaćanjem <u>pametnih ugovora</u> prvenstveno želim postići sljedeće:

☐	**Povećanje kvalitete**. *Podići razinu kvalitete proizvoda i/ili usluga organizacije na način da se podigne njihova kvaliteta ili da se podigne kvaliteta samih aktivnosti unutar organizacija.*
☐	**Povećanje brzine**. *Ubrzati procese unutar organizacije (ubrzanje isporuke proizvoda i/ili usluge, ubrzanje samih procesa unutar organizacije, skratiti vrijeme isporuke i osigurati isporuku što je prije moguće, ubrzati proces razvoja ideja, tj. skratiti vrijeme od ideje do tržišta).*
☐	**Povećanje pouzdanosti.** *Podići razinu pouzdanosti, pri čemu pouzdanost uključuje izgradnju povjerenja kupca i dobavljača u samu organizaciju te usluge i/ili proizvode koje organizacija nudi.*
☐	**Povećanje fleksibilnost**. *Povećati fleksibilnost organizacije, tj. sposobnost organizacije na prilagođavanje različitim situacijama i promjenama na tržištu, kao i mogućnost reorganizacije cijele organizacije ukoliko se ukaže potreba za istim.*
☐	**Smanjenje troškova.** *Pojednostaviti strukturu troškova organizacije. Omogućiti stvaranje uštede u poslovanju organizacije.*

68. Prije donošenja odluka volim prikupiti sve potrebne informacije.

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

69. Prije donošenja konačne odluke detaljno procijenim sve mogućnosti (sve moguće alternative).

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

70. Prilikom donošenja odluka određeno vrijeme posvetim razmatranju argumenata za i protiv te rizike i benefite date situacije.

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

71. Istraživanje činjenica je važan dio mog procesa donošenja odluka.

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

72. Pri donošenju odluka važem nekoliko različitih čimbenika.

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

73. Prilikom donošenja odluka uglavnom se oslanjam na intuiciju.

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

74. Prilikom donošenja odluka obično slijedim svoj instinkt.

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

75. Moje odluke zasnivaju se na intuiciji.

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

76. Prilikom donošenja odluka oslanjam se na svoje prve utiske.

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

77. Prilikom donošenja odluka oslanjam se više na osjećaje nego na analizu.

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

ŽIVOTOPIS

Dunja Dobrinić, rođena je 17.09.1988. godine u Varaždinu. Osnovno školsko obrazovanje završava u Varaždinu gdje se upisuje i u Prvu Gimnaziju. Završetkom srednjoškolskog obrazovanja 2006. godine upisuje preddiplomski studij na Ekonomskom fakultetu Sveučilišta u Zagrebu, njegovim završetkom 2010. godini upisuje i diplomski studij na istom fakultetu koji završava 2011. godine.

Jednogodišnje stručno osposobljavanje obavlja u privatnoj organizaciji u Varaždinu u kojoj i ostaje raditi do 2014. godine, nakon čega prelazi u revizorsku tvrtku u Varaždinu, gdje nakon dobivanja certifikata do danas radi kao ovlašteni revizor. Početkom 2019. godine upisuje poslijediplomski doktorski sveučilišni studij Informacijske znanosti na Fakultetu organizacije i informatike Sveučilišta u Zagrebu. U 2021. godini stječe rješenje stalnog sudskog vještaka struke računovodstvo i financije.

Objavila je nekoliko znanstvenih radova te sudjelovala na domaćim i međunarodnim znanstvenim konferencijama.

Popis objavljenih radova

1. Dobrinić, Dunja

Impact of cognitive technologies on selecting and processing samples in financial statements audit. // Proceedings of the Central European Conference on Information and Intelligent Systems, Varaždin, Hrvatska, 2019. str. 155-160 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

2. Dobrinić, Dunja

Digital Maturity of Auditing Companies in the Republic of Croatia. // Central European Conference on Information and Intelligent Systems, Varaždin, Hrvatska, 2020. str. 133-141 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

3. Dobrinić, Dunja

Impact of Social networks on the employment process in the Republic of Croatia. // CroDiM, 3 (2020), 1; 46-54 (međunarodna recenzija, članak, znanstveni)

4. Dobrinić, Dunja

Conceptual Model for Cloud Computing Acceptance in the Audit Profession [Konceptualni model prihvaćanja uslužnog računalstva u revizorskoj profesiji]. // Informatologia, 53 (2020), 3/4; 191-201 doi:10.32914/i.53.3-4.6 (međunarodna recenzija, članak, znanstveni)

5. Dobrinić, Damir; Gregurec, Iva; Dobrinić, Dunja

THE ADVERTISING ATTITUDES OF INTERNET ADS: A STUDY AMONG CROATIAN GENERATION Z. // Book of Proceedings - Economic and Social Development / Milkovic, Marin ; Hammes, Khalid ; Bakhtina, Olga (ur.). Varaždin: Varazdin Development and Entrepreneurship Agency and University North in cooperation with Croatian Academy of Science and Arts, Faculty of Management Universitiy of Warsaw and Faculty of Law, Economics and Social Scienes Sale – Mohammed V University in Rabat, 2020. str. 92-109 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

6. Dobrinić, Dunja; Fabac, Robert

Familiarity with Mission and Vision: Impact on Organizational Commitment and Job Satisfaction. // Business systems research, 12 (2021), 1; 124-143 doi:10.2478/bsrj-2021-0009 (međunarodna recenzija, članak, znanstveni)

7. Dobrinić, Damir; Gregurec, Iva; Dobrinić, Dunja

Examining the factors of influence on avoiding personalized ads on Facebook. // Zbornik radova Ekonomskog fakulteta u Rijeci : časopis za ekonomsku teoriju i praksu, 39 (2021), 2; 401-428 doi:10.18045/zbefri.2021.2.401 (međunarodna recenzija, članak, znanstveni)

8. Dobrinić, Damir; Gregurec, Iva; Dobrinić, Dunja

Attitudes of Croatian Consumers About Mobile Messenger Chatbots. // Journal of information and organizational sciences, 45 (2021), 2; 579-599 doi:10.31341/jios.45.2.13 (međunarodna recenzija, članak, znanstveni)

9. Dobrinić, Dunja

Utjecaj IKT na kvalitetu života starijih osoba: Pregled literature. // CroDiM, 5 (2021), 1; 189-204 (međunarodna recenzija, članak, znanstveni)

10. Dobrinić, Dunja

Development of a conceptual digital technology acceptance model for micro and small organizations. // Central European Conference on Information and Intelligent Systems, 32nd International Conference October 13th - 15th, 2021, Varaždin, Croatia Conference Proceedings / Vrček, Neven, Pergler, Elisabeth Grd, Petra (ur.). Varaždin: University of Zagreb, Faculty of Organization and Informatics Varaždin, 2021. str. 45-55 (ostalo, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni)

11. Dobrinić, Dunja; Vrček, Neven

The influence of digital maturity, competitive priorities and decision-making styles on the acceptance of digital technologies in micro and small organizations //Potvrda o prihvaćanju rada u Journal of Information and Organizational Sciences, 2022.