REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Darko Lugonja,
mr.oec.

EVALUACIJA DIGITALNE ZRELOSTI I PLANIRANJE DIGITALNE TRANSFORMACIJE POLJOPRIVREDNIH GOSPODARSTAVA U REPUBLICI HRVATSKOJ

DOKTORSKI RAD

PRIMLJENO: 15.10.2026
KLASA: 643-03/26-01/02
URBROJ: 2158-94-02-26-09



Osijek, 2026.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Darko Lugonja,
mr.oec.

EVALUACIJA DIGITALNE ZRELOSTI I PLANIRANJE DIGITALNE TRANSFORMACIJE POLJOPRIVREDNIH GOSPODARSTAVA U REPUBLICI HRVATSKOJ

- Doktorski rad -

Osijek, 2026.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Darko Lugonja,
mr.oec.

EVALUACIJA DIGITALNE ZRELOSTI I PLANIRANJE DIGITALNE TRANSFORMACIJE POLJOPRIVREDNIH GOSPODARSTAVA U REPUBLICI HRVATSKOJ

- Doktorski rad -

Mentori: prof. dr. sc. Tihana Sudarić, prof.dr.sc. Ivan Plaščak, Fakultet agrobiotehničkih znanosti Osijek

Povjerenstvo za ocjenu doktorskog rada:

1. **----------, Fakultet agrobiotehničkih znanosti Osijek, predsjednik**
2. **----------, Fakultet agrobiotehničkih znanosti Osijek, član/ica**
3. **----------, Fakultet agrobiotehničkih znanosti Osijek, član/ica**

Osijek, 2026.

REPUBLIKA HRVATSKA
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET AGROBIOTEHNIČKIH ZNANOSTI OSIJEK

Darko Lugonja,
mr.oec.

EVALUACIJA DIGITALNE ZRELOSTI I PLANIRANJE DIGITALNE TRANSFORMACIJE POLJOPRIVREDNIH GOSPODARSTAVA U REPUBLICI HRVATSKOJ

- Doktorski rad -

Mentori: prof. dr. sc. Tihana Sudarić, prof.dr.sc. Ivan Plaščak, Fakultet agrobiotehničkih znanosti Osijek

Javna obrana doktorskog rada održana je _____ *(datum i godina)* pred Povjerenstvom za obranu:

1. **----------, Fakultet agrobiotehničkih znanosti Osijek, predsjednik**
2. **----------, Fakultet agrobiotehničkih znanosti Osijek, član/ica**
3. **----------, Fakultet agrobiotehničkih znanosti Osijek, član/ica**

Osijek, 2026.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku

Doktorski rad

Fakultet agrobiotehničkih znanosti Osijek
Doktorski studij: Poljoprivredne znanosti
Modul: Agroekonomika

UDK:

Znanstveno područje: Biotehničke znanosti

Znanstveno polje: Poljoprivreda

Evaluacija digitalne zrelosti i planiranje digitalne transformacije poljoprivrednih gospodarstava u Republici Hrvatskoj

Darko Lugonja

Doktorski rad je izrađen na Sveučilištu Josipa Jurja Strossmayera Fakultet agrobiotehničkih znanosti Osijek.

Mentori: prof. dr. sc. Tihana Sudarić, prof.dr.sc. Ivan Plaščak, Fakultet agrobiotehničkih znanosti Osijek

Sažetak

Doktorski rad usmjeren je na utvrđivanje razine digitalne zrelosti i razvoj metodološkog okvira za planiranje digitalne transformacije poljoprivrednih gospodarstava u Republici Hrvatskoj, s ciljem povećanja njihove konkurentnosti, učinkovitosti i održivosti poslovanja. Istraživanje je usmjereno na procjenu sposobnosti poljoprivrednih subjekata za usvajanje i učinkovitu primjenu digitalnih tehnologija, razvoj digitalnih kompetencija, upravljanje podacima te njihovu integraciju u poslovne i proizvodne procese. Poseban naglasak stavljen je na identifikaciju čimbenika koji utječu na razinu digitalne zrelosti te razvoj podloge za učinkovitije planiranje i upravljanje procesom digitalne transformacije. Glavni cilj istraživanja bio je utvrditi razinu digitalne zrelosti poljoprivrednih subjekata u Republici Hrvatskoj primjenom razvijenog Globalnog DRI indeksa, dok su specifični ciljevi uključivali utvrđivanje demografskih, organizacijskih i prostornih čimbenika povezanih s razinom digitalne zrelosti te oblikovanje smjernica i preporuka za planiranje digitalne transformacije poljoprivrednih gospodarstava. U skladu s ciljevima postavljene su tri hipoteze. Prva hipoteza (H1) pretpostavlja da poljoprivredni subjekti u Republici Hrvatskoj imaju nižu razinu digitalne zrelosti u odnosu na prosjek digitalne zrelosti malih i srednjih poduzeća u drugim sektorima gospodarstva. Druga hipoteza (H2) pretpostavlja postojanje statistički značajne povezanosti između organizacijskih i demografskih čimbenika, uključujući veličinu gospodarstva, razinu obrazovanja, dob i iskustvo nositelja gospodarstva, i razine digitalne zrelosti poljoprivrednih gospodarstava. Treća hipoteza (H3) polazi od pretpostavke da ne postoji jedinstvena i općeprihvaćena metodologija za evaluaciju digitalne zrelosti prilagođena specifičnostima poljoprivrednog sektora. Empirijsko istraživanje provedeno je na uzorku od 565 poljoprivrednih gospodarstava. Podaci su prikupljeni neposrednim anketiranjem, pri čemu su educirani anketari osobno posjećivali nositelje gospodarstava, pružali potrebna pojašnjenja te odgovore izravno unosili u digitalni obrazac. Takav način prikupljanja podataka omogućio je visoku razinu odaziva, smanjio mogućnost pogrešnog razumijevanja specifičnih digitalnih i tehnoloških pojmova te omogućio uključivanje gospodarstava koja bi mogla biti nedovoljno zastupljena u istraživanjima provedenima isključivo digitalnim metodama. Statistička obrada podataka provedena je primjenom statističkog softvera Jamovi i programskog jezika R. U analitičkom postupku primijenjene su deskriptivne i inferencijalne statističke metode, uključujući analizu glavnih komponenti (PCA), analizu unutarnje konzistentnosti mjernog instrumenta, K-means klastersku analizu, analizu varijance (ANOVA) te višestruku linearnu regresiju. Pouzdanost pojedinih stupova digitalne zrelosti procijenjena je Cronbachovim koeficijentom alfa, dok su dimenzionalnost i opravdanost konstrukcije Globalnog DRI indeksa ispitane PCA analizom. Za utvrđivanje razlika u razini digitalne zrelosti prema demografskim, organizacijskim i prostornim obilježjima primijenjena je ANOVA, dok su regresijski modeli korišteni za identifikaciju ključnih prediktora Globalnog DRI indeksa i pojedinačnih stupova digitalne zrelosti. Klasterska analiza omogućila je izdvajanje homogenih skupina poljoprivrednih gospodarstava prema njihovim obilježjima digitalne zrelosti. Rezultati istraživanja potvrđuju sve tri postavljene hipoteze. Utvrđeno je da se hrvatska poljoprivreda nalazi u ranim fazama digitalne transformacije, s vrijednošću Globalnog DRI indeksa od 2,75. U fazama „U nastajanju“ i „Prijelazna“ nalazi se ukupno 59,8 % istraživanih gospodarstava. U usporedbi s pokazateljima digitalne zrelosti drugih sektora gospodarstva, poljoprivreda značajno zaostaje, osobito u dimenzijama integracije podataka i digitalnih javnih usluga. Rezultati pokazuju da dob i razina obrazovanja nositelja gospodarstva predstavljaju najrobustnije prediktore digitalne zrelosti. Istodobno, veličina gospodarstva prvenstveno je povezana s nabavom i dostupnošću tehnologije, ali nije jednako značajna za razvoj „mekih“ kapaciteta, poput analitike podataka, upravljanja i strateškog planiranja digitalne transformacije. Provedena validacija pokazala je visoku pouzdanost razvijenog mjernog instrumenta, pri čemu je Cronbachov α za sve stupove digitalne zrelosti bio veći od 0,80. PCA analiza potvrdila je opravdanost konstrukcije Globalnog DRI indeksa, pri čemu je model objasnio 76,4 % ukupne varijance. Rezultati potvrđuju primjenjivost razvijenog

instrumenta za sustavnu procjenu i dijagnostiku digitalne zrelosti poljoprivrednih gospodarstava u hrvatskom kontekstu te ukazuju na potrebu prilagodbe generičkih modela digitalne zrelosti, poput CSIRO modela, specifičnostima poljoprivrednog sektora. Znanstveni doprinos rada ogleda se u uspostavljanju prve empirijske polazne osnove za procjenu digitalne zrelosti hrvatske poljoprivrede te razvoju metodološkog okvira prilagođenog njezinim sektorskim specifičnostima. Posebna znanstvena novost istraživanja jest identifikacija fenomena „vještinskog jaza“ u kontinentalnoj Hrvatskoj, koji se očituje u nesrazmjeru između dostupnosti digitalnih tehnologija i razine analitičkih i digitalnih kompetencija potrebnih za njihovu učinkovitu primjenu. Istraživanje dodatno pokazuje da u malim obiteljskim gospodarstvima ljudski kapital, odnosno znanje, obrazovanje i kompetencije nositelja gospodarstva, predstavlja važniji čimbenik digitalne transformacije od fizičkog kapitala, odnosno veličine gospodarstva. Dobiveni rezultati predstavljaju znanstvenu i metodološku osnovu za daljnja istraživanja te oblikovanje ciljanih politika, mjera potpore i strategija usmjerenih na ubrzavanje digitalne transformacije hrvatske poljoprivrede.

Broj stranica: 168
Broj slika: 23
Broj tablica: 54
Broj literaturnih navoda: 126
Jezik izvornika: Hrvatski

Ključne riječi: digitalna transformacija, ocjena digitalne zrelosti, poljoprivredna gospodarstva

Datum obrane:

Povjerenstvo za obranu :

1. ----------, Fakultet agrobiotehničkih znanosti Osijek - predsjednik
2. ----------, Fakultet agrobiotehničkih znanosti Osijek - članica
3. ----------, Fakultet agrobiotehničkih znanosti Osijek članica

Doktorski rad pohranjen je u:
Nacionalnoj i sveučilišnoj knjižnici, Gradskoj i sveučilišnoj knjižnici i na Sveučilištu Josipa Jurja Strossmayera u Osijeku.

BASIC DOCUMENTATION CARD

University of Josip Juraj Strossmayer in Osijek

PhD thesis

Faculty of Agrobiotechnical Sciences Osijek
Doctoral study: Agricultural sciences
Course: Agroeconomics

UDK:
Scientific Area: Biotechnical Sciences
Scientific Field: Agriculture

Evaluation of Digital Maturity and Digital Transformation Planning for Agricultural Holdings in the Republic of Croatia

Darko Lugonja

Thesis performed at University of Josip Juraj Strossmayer in Osijek Faculty of Agrobiotechnical Sciences Osijek.

Supervisors: Tihana Sudarić, Ivan Plaščak, Faculty of Agrobiotechnical Sciences Osijek

Summary

This doctoral thesis focuses on determining the level of digital maturity and developing a methodological framework for planning the digital transformation of agricultural holdings in the Republic of Croatia, with the aim of enhancing their competitiveness, efficiency, and business sustainability. The research centers on assessing the capacity of agricultural entities to adopt and effectively apply digital technologies, develop digital competencies, and manage and integrate data into business and production processes. Particular emphasis is placed on identifying factors influencing the level of digital maturity and developing a foundation for more effective planning and management of the digital transformation process. The primary research objective was to determine the digital maturity level of agricultural entities in the Republic of Croatia using the developed Global DRI Index, while specific objectives included identifying demographic, organizational, and spatial factors associated with digital maturity levels and formulating guidelines and recommendations for planning the digital transformation of agricultural holdings. Three hypotheses were formulated in alignment with these objectives. The first hypothesis (H1) posits that agricultural entities in the Republic of Croatia exhibit a lower level of digital maturity compared to the average digital maturity of small and medium-sized enterprises in other economic sectors. The second hypothesis (H2) posits the existence of a statistically significant relationship between organizational and demographic factors—including farm size, education level, and the age and experience of the farm operator—and the level of digital maturity of agricultural holdings. The third hypothesis (H3) is based on the premise that there is no unified and generally accepted methodology for evaluating digital maturity tailored to the specific characteristics of the agricultural sector. Empirical research was conducted on a sample of 565 agricultural holdings.

Data were collected through direct surveying, wherein trained interviewers personally visited farm operators, provided necessary clarifications, and entered responses directly into a digital form. This data collection method ensured a high response rate, minimized the risk of misinterpreting specific digital and technological terms, and enabled the inclusion of farms that might otherwise be underrepresented in surveys conducted solely via digital methods. Statistical data processing was performed using Jamovi statistical software and the R programming language. The analytical process employed descriptive and inferential statistical methods, including Principal Component Analysis (PCA), analysis of the measurement instrument's internal consistency, K-means cluster analysis, Analysis of Variance (ANOVA), and multiple linear regression. The reliability of individual digital maturity pillars was assessed using Cronbach's alpha coefficient, while the dimensionality and construct validity of the Global DRI Index were examined via PCA. ANOVA was used to determine differences in digital maturity levels based on demographic, organizational, and spatial characteristics, whereas regression models were employed to identify key predictors of the Global DRI Index and individual digital maturity pillars. Cluster analysis enabled the identification of homogeneous groups of agricultural holdings based on their digital maturity characteristics. The research results confirm all three proposed hypotheses. It has been determined that Croatian agriculture is in the early stages of digital transformation, with a Global DRI index value of 2.75. A total of 59.8% of the surveyed farms fall into the "Emerging" and "Transitional" stages. Compared to digital maturity indicators in other economic sectors, agriculture lags significantly behind, particularly in the dimensions of data integration and digital public services. The results indicate that the age and education level of the farm operator are the most robust predictors of digital maturity. At the same time, farm size is primarily associated with the acquisition and availability of technology but is not equally significant for the development of "soft" capabilities, such as data analytics, management, and strategic planning for digital transformation. Validation demonstrated the high reliability of the developed measurement instrument, with Cronbach's α exceeding 0.80 for all digital maturity pillars. PCA analysis confirmed the validity of the Global DRI index construction, with the model explaining 76.4% of the total variance.

The results confirm the applicability of the developed instrument for the systematic assessment and diagnosis of

BASIC DOCUMENTATION CARD

the digital maturity of agricultural holdings within the Croatian context and highlight the need to adapt generic digital maturity models—such as the CSIRO model—to the specificities of the agricultural sector. The study's scientific contribution lies in establishing the first empirical baseline for assessing the digital maturity of Croatian agriculture and developing a methodological framework tailored to its sectoral characteristics. A particular scientific novelty of the research is the identification of a "skills gap" phenomenon in continental Croatia, manifested as a disparity between the availability of digital technologies and the level of analytical and digital competencies required for their effective application. Furthermore, the research demonstrates that in small family farms, human capital—specifically the knowledge, education, and competencies of the farm operator—is a more significant factor in digital transformation than physical capital, such as farm size. The findings provide a scientific and methodological foundation for future research and for the formulation of targeted policies, support measures, and strategies aimed at accelerating the digital transformation of Croatian agriculture.

Number of pages: 168
Number of figures: 23
Number of tables: 54
Number of references: 126
Original in: Croatian

Key words: digital transformation, digital transformation maturity assessment, agricultural farms

Date of the thesis defense:

Reviewers:

1. ----------, Faculty of Agrobiotechnical Sciences Osijek – president
2. ----------, Faculty of Agrobiotechnical Sciences Osijek – member
3. ----------, Faculty of Agrobiotechnical Sciences Osijek – member

Thesis is deposited in:
The National and University Library, the City and University Library, and the Josip Juraj Strossmayer University in Osijek.

ZAHVALA

Zahvaljujem svojim roditeljima koji su me poticali i podržavali u osobnom i poslovnom razvoju, usadivši mi temeljne ljudske, osobne i profesionalne vrijednosti, odgovornost i predanost, kao i spremnost za osobni i profesionalni razvoj. I roditelji i obitelj, rodbina i prijatelji, uvijek su bili tu u blizini, spremni pomoći i podržati me u ostvarivanju ciljeva i životnih koraka. Supruga Dijana, imala je, ima i nadalje će imati jednu od najvažnijih uloga u podršci, poticanju i razumijevanju za sve moje napore, od profesionalnih, stručnih i znanstvenih, preko društvenih i osobnih do obiteljskih. Moj otac Anđelko, iako nije više s nama, uvijek je pružao podršku, ljubav i razumijevanje, vrijednosti i ljudsku dobrotu, a majka Terezija, pomogla mi je razviti kritički i samokritički pristup, red, rad i odgovornost, kao temelj za uspjeh u svakom radu. Stoga se ovdje posebno zahvaljujem njima.

Od same zamisli, preko konzultacija, priprema, istraživanja, učenja, niza uputa, savjeta, konzultacija i pune profesionalne, znanstvene, ali i osobne podrške, posebnu su ulogu imali moji mentori i profesori savjetnici, prijatelji, kolege i svi suradnici koji su pomogli u pripremi, metodologiji, istraživanju i radu na obrani ovog rada. Tu su prije svega profesori – prof. dr. sc. Tihana Sudarić, prof. dr. sc. Ivan Plaščak, te prof. dr. sc. Mladen Jurišić, koji me je podržao u odluci oko upisa na studij i uputio me u pravom smjeru po pitanju istraživanja, te aktivnosti na putu prema doktorskom radu. Svima im zahvaljujem na strpljenju, mentorskom radu, uputama, konstruktivnim savjetima i kritikama kako bi oblikovao svoj sustav zamisli, od prvog istraživačkog pitanja i razmatranja problema pa do provedbe istraživanja, obrade rezultata, tumačenja, ali i privođenja kraju ovog dugog puta. Njihova je spremnost za pomoć bila i ostala neupitna i trajna, a znanje, metodičnost, sustavnost, inovativnost i proaktivnost – ključni za ostvarenje svih ciljeva i kvalitetu ovog rada.

Zahvaljujem i kolegama na poslu, osobito Mladenu Fruku, koji je kao kolega i rukovoditelj znao prepoznati inovacije, izazove, prednosti i mogućnosti mojih i vezanih angažmana, a osobito kolegama u Sektoru i na terenu, koji su omogućili provedbu anketa u dijelu koji je pokrio istraživanje na terenu.

Zahvaljujem i članovima povjerenstva na vremenu, trudu, komentarima i smjernicama, odnosno pomoći u oblikovanju i finalizaciji ovog rada.

Svima zahvaljujem, jer vaša je podrška omogućila ovaj put od zamisli do cilja.

Uspjeh je jednako i moj i vaš.

KAZALO

1. UVOD 4
1.1. Problem i istraživački jaz 8
1.2. Cilj i hipoteze istraživanja 8
1.3. Struktura disertacije 9
2. PREGLED LITERATURE 10
2.1. Evolucija i koncept digitalne transformacije 10
2.2. Digitalna transformacija u poljoprivredi i koncept precizne poljoprivrede 11
2.3. Čimbenici i barijere usvajanja digitalnih tehnologija na razini gospodarstva 12
2.4. Teorijski okviri digitalne transformacije 13
2.5. Modeli procjene digitalne zrelosti s fokusom na CSIRO okvir 14
2.6. Digitalni jaz i nejednakosti u ruralnim područjima 14
2.7. Specifičnosti poljoprivrednih SME-ova 15
2.8. Identificirani istraživački jaz i doprinos ovog istraživanja 16
3. MATERIJAL I METODE RADA 17
3.1. Cilj i dizajn istraživanja 17
3.1. Mjerni instrument i model procjene 17
3.1. Statistička analiza podataka 18
4. REZULTATI ISTRAŽIVANJA 21
4.1. Opis uzorka i prostorna distribucija 21
4.2. Kreiranje indeksa digitalne zrelosti 23
4.3. Deskriptivna analiza i pouzdanost instrumenta 23
4.4. Analiza glavnih komponenti (PCA) 32
4.5. Segmentacija gospodarstava – Klasterska analiza 34
4.5.1 Profiliranje klastera prema demografskim i organizacijskim karakteristikama 37
4.5.1.1. Dob nositelja gospodarstva (D1) 50
4.5.1.2. Razina obrazovanja (D3) 50
4.5.1.3. Veličina poljoprivrednog posjeda (D10) 51
4.5.1.4. Godišnji prihodi gospodarstva (D12) 51
4.5.1.5. Broj zaposlenih (D11) 51
4.5.1.6. Sažetak profila klastera 52
4.5.2 Validacija klastera – ANOVA analiza 53
4.6. Utjecaj demografskih i organizacijskih čimbenika na digitalnu zrelost 57
4.7. Prostorna distribucija digitalne zrelosti (NUTS regije i Županije) 66
4.8. Diferencijalni utjecaj demografskih i prostornih čimbenika na dimenzije digitalne zrelosti 91

4.9. Klasifikacija gospodarstava prema CSIRO fazama digitalne zrelosti 93
4.10. Sažetak testiranja hipoteza 95
5. RASPRAVA 99
5.1. Uvod i sažetak ključnih nalaza 99
5.2. Profil digitalne zrelosti hrvatske poljoprivrede u kontekstu CSIRO modela 99
5.2.1. Asimetrični profil: Paradoks „tehnologije bez podataka“ 100
5.2.2. Klasifikacija po CSIRO fazama: Većina u „Prijelaznoj fazi“ 102
5.2.3. Usporedba s drugim sektorima i međunarodnim kontekstom 102
5.3. Demografski i organizacijski pokretači digitalne transformacije 103
5.3.1. Primat ljudskog kapitala je obrazovanje i dob“ 103
5.3.2. Uloga ekonomskih resursa: Paradoks „tvrdog“ i „mekog“ digitaliziranja 107
5.3.3. Nerelevantnost veličine radne snage 109
5.3.4. Teorijske implikacije demografskih pokretača 109
5.4.Prostorne nejednakosti i fenomen „vještinskog jaza“ (eng. Skills Gap) 109
5.4.1. Paradoks „tehnologije bez znanja“ u kontinentalnoj Hrvatskoj 111
5.4.2. Usporedba s europskim kontekstom i konceptom „digital divide“ 115
5.4.3. Značaj „vještinskog jaza“ za agrarne politike 117
5.5. Segmentacija gospodarstava: od „Početnika“ do „Lidera“ 118
5.5.1. Digitalni jaz kao generacijski jaz 118
5.5.2. „Zamka“ prijelazne faze (eng. The Transitional Trap) 119
5.5.3. Rizik „dvobrzinske“ poljoprivrede 119
5.5.4. Strateške implikacije segmentacije gospodarstava 120
5.6. Praktične i političke implikacije (preporuke za kreiranje politika) 120
5.6.1. Odmak od isključivih „tvrdih“ investicija prema „mekim“ kompetencijama 121
5.6.2. Diferencirane mjere prema profilima digitalne zrelosti (klasterima) 121
5.6.3. Demografski usmjerene politike i generacijska obnova 122
5.6.4. Uspostava okvira za upravljanje i sigurnost podacima 122
5.6.5. Jačanje uloge savjetodavne službe 122
5.6.6. Operativna i strateška razina primjene alata 123
5.7. Ograničenja istraživanja 123
5.7.1. Ograničenja uzorka i generalizacije 124
5.7.2. Ograničenja presječnog dizajna (eng. Cross-sectional design) 124
5.7.3. Pristranost samoprocjene (eng. Self-reporting bias) 124
5.7.4. Metodološka ograničenja prilagodbe modela 125
5.8. Smjernice za buduća istraživanja 125

6. ZAKLJUČAK **127**
6.1. Potvrda istraživačkih hipoteza **127**
6.2. Ključni znanstveni i praktični doprinosi **128**
6.3. Preporuke za kreatora politika i praksu **128**
6.4. Ograničenja i smjernice za buduća istraživanja **130**
7. LITERATURA **130**
8. SAŽETAK **139**
9. SUMMARY **141**
10. PRILOZI **144**
DODACI **145**
Dodatak A Anketni upitnik o digitalnoj zrelosti poljoprivrednih gospodarstava **146**
Dodatak B – Prikaz sučelja digitalnog upitnika **156**
Dodatak C – Kratice **159**
Dodatak D1 – Životopis **163**
Dodatak D2 – Biography **166**

1. UVOD

Okruženje uvelike ovisi o tehnološkim mogućnostima, a praćenje suvremenog rasta i razvoja postaje ključno na mikro i makro razini. Karakteristike društva pod velikim su utjecajem industrijskih revolucija koje su se dogodile u posljednja tri stoljeća. Revolucije su se događale kroz povijest kada su nove tehnologije i novi načini doživljavanja svijeta uzrokovali duboke promjene u ekonomskim sustavima i društvenim strukturama (Schwab, 2016.).

Od prve industrijske revolucije i parnog stroja u 1760-ima, tehnologija se eksponencijalno razvijala neprestano se nadograđujući i ponašajući se kao neka vrsta rekurzije gdje su nove tehnologije stvarane od strane starih. Druga revolucija krajem 19-og i početkom 20-og stoljeća potaknuta je razvojem električne energije i omogućila je masovnu proizvodnju. Nakon toga, 60-tih godina 20. stoljeća počela je uporaba računala koja su oblikovala treću industrijsku revoluciju ili tzv. digitalnu revoluciju.

Ovo doba uvelo je osobna računala i Internet. Konačno, na temelju prethodne digitalne revolucije, četvrta industrijska revolucija predvođena je umjetnom inteligencijom, strojnim učenjem i Internetom stvari (Schwab, 2016.). Schumpeter je ovaj fenomen objasnio svojim valovima inovacija i tvrdi da svaki val inovacija ne traje jednako, te kako se njihova duljina skraćuje zbog brzog razvoja novih tehnologija (The Economist, 1999.; Levi Jakšić i sur., 2018.).

U proteklih 250 godina razvidno je kako su inovacije promijenile svijet u kojem živimo. Od industrijske revolucije do uspona održive tehnologije, bilo je šest različitih valova inovacija koji su preoblikovali naša gospodarstva, društva i svakodnevni život.

Teoriju inovacijskih ciklusa razvio je ekonomist Joseph Schumpeter, koji je 1942. osmislio izraz „kreativna destrukcija“. Ispitivao je ulogu inovacija u odnosu na dugovalne poslovne cikluse. Primijetio je kako inovacije dovode do procesa „kreativne destrukcije“, gdje nove tehnologije i poslovni modeli zamjenjuju stare, što dovodi do dugoročnog gospodarskog rasta i razvoja. Identificirao je pet različitih faza u ciklusu inovacija: invencija, inovacija, difuzija, zrelost i zastarjelost. U fazi invencije stvaraju se nove ideje i tehnologije. U fazi inovacije te se ideje i tehnologije primjenjuju na tržište, stvarajući nove proizvode i usluge. U fazi širenja, ti novi proizvodi i usluge postaju široko prihvaćeni. U fazi zrelosti tržište postaje zasićeno, a rast se usporava. Konačno, u fazi zastarjelosti, nove tehnologije i poslovni modeli zamjenjuju stare, što dovodi do novog ciklusa inovacija. Okruženje se transformiralo kroz šest valova inovacija. Prvi val inovacija dogodio se tijekom industrijske revolucije s pojavom prve tvornice pamuka u Britaniji 1785. godine, dok je trenutno u tijeku šesti val inovacija, potaknut porastom AI i IoT tehnologija, robota, bespilotnih letjelica te razvoja tehnologije.

Kako klimatski izazovi postaju sve izraženiji, čista tehnologija ima potencijal preoblikovati poslovne modele i obrasce potrošnje. Ovaj val donosi značajne promjene u načinu na koji živimo, radimo i komuniciramo s tehnologijom.

Prelazak s petog na šesti val inovacija zahtijeva od poduzeća, uključujući male i srednje subjekte u poljoprivredi pripreme za nove izazove i prilike. Kako bi ostala konkurentna, moraju ulagati u nove tehnologije, usvojiti digitalnu transformaciju i razviti kulturu inovacija koja potiče istraživanje i usvajanje novih ideja. Industrijske revolucije kroz povijest oblikovale su društvo, a tehnološke promjene imaju značajan utjecaj na različite sektore. U procesu procjene digitalne zrelosti poduzeća, posebno u kontekstu digitalne transformacije malih i srednjih subjekata u poljoprivredi, važno je obratiti pažnju na metodologiju kojom se ocjenjuje stanje digitalizacije.

Jedan od najvažnijih alata za mjerenje digitalne zrelosti poduzeća je DESI indeks (Digital Economy and Society Index), koji omogućava analizu digitalne spremnosti država članica Europske unije te omogućuje praćenje napretka u digitalnoj transformaciji na temelju ključnih indikatora kao što su širokopojasni internet, digitalne vještine, e-uprava, digitalni poslovni modeli i drugi. S obzirom na sveobuhvatnost DESI-ja, važno je napomenuti da sva poduzeća, neovisno o sektoru u kojem posluju, mogu biti obuhvaćena ovom metodologijom, omogućujući usporedbu između različitih sektora i pružanje uvida u specifične izazove u digitalnoj transformaciji. Međutim, prema brojnim literaturnim izvorima i provedenim istraživanjima, različiti sektori i vrste poduzeća (kao što su poljoprivredna, industrijska, uslužna i tehnološka poduzeća) imaju vrlo različite stupnjeve digitalne zrelosti. Istraživanja su pokazala da postoji značajan digitalni jaz među poduzećima u različitim sektorima, što znači da poduzeća u određenim sektorima (npr. poljoprivredi) često zaostaju u primjeni digitalnih tehnologija u odnosu na poduzeća u tehnološki razvijenijim industrijama (npr. IT sektor, financijski sektor). Izvještaj DESI 2023 ukazuje na to da digitalna zrelost poljoprivrednog sektora u EU značajno varira, dok su industrijska i uslužna poduzeća bolje integrirana u digitalne ekosustave.

Poljoprivreda, odnosno mali i srednji poduzetnici se često suočavaju s ograničenim pristupom naprednim tehnologijama, nedostatkom kvalificirane radne snage i ograničenim financijskim resursima za ulaganje u digitalizaciju. Prema Europskom izvještaju o digitalnoj konkurentnosti (Eurostat, 2023.), poljoprivreda i mala poduzeća općenito imaju veće poteškoće u implementaciji naprednih digitalnih tehnologija, dok industrijski i tehnološki sektor pokazuju veći napredak u digitalnoj transformaciji. Poljoprivredna proizvodnja suočava se s nekoliko ključnih izazova.

Populacija na svjetskoj razini raste, te je potreba za hranom veća, što zahtijeva i povećanje proizvodnje. Klimatske promjene koje imaju za rezultat nepredvidive vremenske uvjete, poput suše, jake i olujne kiše, erozije tla i slično, negativno utječu na proizvodnju. Ograničeni resursi kao nedostatak vode, zemljišta i energije, također predstavljaju izuzetno veliki izazov, zatim, tehnološka zaostalost, jer nije rijedak slučaj da poljoprivrednici često imaju tehnološki zastoj, što izravno smanjuje učinkovitost proizvodnje i konačno, sigurnost hrane koja se ogleda u varijabilnosti cijena i pojavi ekonomskih kriza. Potiče se ekološka održivost, odnosno potreba za održivim poljoprivrednim praksama kako bi se smanjio negativan utjecaj iste na okoliš.

Prema analizama Europske komisije zaključuje se da se digitalni razvoj gospodarstva i društva može postići samo međusobno povezanim razvojem ovih područja (Europska komisija, 2017.). Kako dolazi do tehnoloških promjena, DESI indeks od 2016. godine u izračun uključuje i nove parametre (4G pokrivenost). Što se tiče sustava ponderiranja koji se koristi za izračun DESI rezultata, dimenzije imaju različite udjele (povezanost i ljudski kapital 25%, integracija digitalne tehnologije 20%, korištenje interneta i digitala javnih usluga 15%) kao i različite sustave ponderiranja unutar poddimenzija.

Kako bi se suočili s ovim izazovima, između ostalog, poljoprivrednici sve više koriste napredne tehnologije poput digitalne (pametne i precizne) poljoprivrede, pametnih sustava za uzgoj i inovativnih metoda uzgoja poljoprivrednih proizvoda. Tehnologije digitalne poljoprivrede ili u novije vrijeme poznate kao „Poljoprivrede 4.0“ su samo jedan od mnogih čimbenika koji mijenjaju način rada i upravljanja poljoprivrednim poduzećima. Poljoprivredni strojevi, kao i digitalni uređaji i tehnologije, omogućuju prikupljanje podataka, obradu informacija i podršku odlučivanju koji promiču poboljšanu poljoprivrednu učinkovitost i produktivnost kroz smanjenje ulaznih troškova i povećanu proizvodnju (Adrian i sur. 2005.; Aubert i sur. 2012.; Bramley, 2009.; Jochinke i sur. 2007.).

Iako poljoprivredne digitalne tehnologije dobro napreduju i dostupne su na tržištu, istraživanja su pokazala kako su usvajanje i korištenje i dalje niski u cijelom sektoru. EU ima jasno definirane strategije i smjernice za digitalizaciju poljoprivrede kroz Digital Compass 2030., i Europski zeleni plan, koji uključuju ciljeve za povećanje digitalne zrelosti poduzeća u poljoprivredi, s naglaskom na održivost, konkurentnost i inovacije. Kako bi se postigao uspjeh u digitalnoj transformaciji, važno je osigurati mogućnosti za poljoprivredna poduzeća, posebice mala i srednja - osigurati pristup odgovarajućim alatima, financijskim poticajima i obrazovnim programima.

Digitalna transformacija u poljoprivredi jedna je od prekretnica suvremene poljoprivrede u svakom njezinom aspektu, domeni i sastavnici – od planiranja proizvodnje, analize, razvoja, istraživanja i inovacija do primjene najnovijih i inovativnih tehnologija (pametna poljoprivreda, precizna poljoprivreda, GNSS, daljinska istraživanja, IoT, i mnoga druga srodna područja). Slijedeći suvremene trendove u primjeni novih tehnologija, poljoprivreda otvara različite mogućnosti primjene informacijsko-komunikacijskih tehnologija u raznim područjima. Inovacije i istraživanja u području primjene digitalne tehnologije u poljoprivrednoj proizvodnji sve su prisutniji, zbog njezine sve veće važnosti i složenosti, kao i društvenog utjecaja, globalno i lokalno.

Postizanje digitalne transformacije u poljoprivredi ovisi o različitim komponentama i nizu utjecaja, koji dovode do zrelosti digitalne transformacije poljoprivrede u različitim aspektima i na različitim razinama. Nedavni trendovi digitalne transformacije u svakom aspektu ljudskog života, posebice u industriji, pružili su snažan ireverzibilan utjecaj na poljoprivredu. Mjerenje zrelosti digitalne transformacije u bilo kojoj industriji može dati sliku opće transformacije i potencijalne smjernice za daljnje aktivnosti.

Digitalna zrelost definira se kao „kontinuirani i trajni proces prilagodbe promjenjivom digitalnom krajoliku“, pri čemu se zrelost opisuje kao naučena sposobnost da se na okoliš odgovori na odgovarajući način (Kane i sur., 2017.). Digitalna zrelost ukazuje na to kako se organizacije sustavno pripremaju za dosljednu prilagodbu tekućim digitalnim promjenama, što daleko nadilazi puku implementaciju nove tehnologije. Digitalna zrelost zahtijeva ključne digitalne građevne blokove koji podržavaju cjelokupnu promjenu sustava.

U 2024. godini, a prema podacima iz Upisnika poljoprivrednika i Upisnika obiteljskih poljoprivrednih gospodarstava koje vodi APPRRR, na dan 31. prosinca 2024. godine bilo je upisano 164.629 poljoprivrednika. Od njih je najviše OPG-ova, 122.879 ili 74,6% od ukupnog broja poljoprivrednika. Prema podacima iz Upisnika na dan 31. prosinca 2024. godine, poljoprivrednici su ukupno koristili 1.160.027 ha poljoprivrednog zemljišta. Najveći broj poljoprivrednika, njih 76,5%, koristi površine do 5 ha. Veliki poljoprivrednici, koji obrađuju više od 100 ha, u ukupnom broju poljoprivrednika čine 0,8%, međutim u svojoj proizvodnji koriste gotovo 30% ukupno korištenog poljoprivrednog zemljišta. Najveći dio korištenog poljoprivrednog zemljišta (53,2%) nalazi se u vlasništvu poljoprivrednika, a 34,3% koristi se temeljem zakupa. Jedan od prioriteta poljoprivredne politike je generacijska obnova hrvatskog sela. Iako se broj mladih nositelja kontinuirano povećava, udio nositelja starijih od 65 godina je i dalje visok.

Prosječni hrvatski poljoprivrednici su starije životne dobi. Čak 62.627 gospodarstava ima

nositelje starije od 65 godina (38%), dok njih 23.522 ima nositelje starosti do 41 godine (14,3%). Procjenjuje se da je produktivnost rada u poljoprivredi u Republici Hrvatskoj iznosila 8.434 eura, što je 40% od prosjeka Europske unije. Najveći broj nositelja ima srednju stručnu spremu (39%). Udio nositelja s visokoškolskim obrazovanjem u ukupnom broju iznosi 9%. Udio žena nositeljica poljoprivrednih gospodarstava bio je 29%.

1.1. Problem i istraživački jaz

Unatoč navedenim strukturnim specifičnostima hrvatske poljoprivrede, izraženom zaostajanju u digitalizaciji u odnosu na druge sektore gospodarstva (kako ukazuju DESI izvješća) te postojanju jasnih europskih strateških smjernica, u Republici Hrvatskoj i dalje nedostaje sveobuhvatna, empirijski utemeljena studija koja bi kvantificirala razinu digitalne zrelosti malih i srednjih poljoprivrednih subjekata (SME-ova). Generički modeli procjene digitalne zrelosti, poput DESI indeksa, preširoki su i ne uzimaju u obzir specifičnosti poljoprivredne proizvodnje (ovisnost o prirodnim uvjetima, sezonalnost, specifične regulative). S druge strane, iako je CSIRO model razvijen specifično za poljoprivredu, on nije validiran niti prilagođen za specifičan kontekst hrvatskih obiteljskih gospodarstava koja dominiraju u strukturi posjeda do 100 hektara. Upravo taj nedostatak prilagođene metodologije i empirijskog „baseline-a" predstavlja ključni istraživački jaz koji ova doktorska disertacija nastoji popuniti.

1.2. Cilj i hipoteze istraživanja

Glavni (opći) cilj ovog istraživanja je identificirati razinu digitalne zrelosti poljoprivrednih subjekata (do 100 ha) u Republici Hrvatskoj te razviti metodologiju koja će omogućiti učinkovitije planiranje njihove digitalne transformacije, s ciljem povećanja konkurentnosti i održivosti poslovanja. Kako bi se ostvario glavni cilj, definirani su sljedeći specifični ciljevi:

- utvrditi trenutnu razinu digitalne zrelosti poljoprivrednih subjekata (do 100 ha) prema, za poljoprivredni sektor Republike Hrvatske, prilagođenom CSIRO-vom indeksu digitalne zrelosti,
- odrediti ključne čimbenike (demografske, organizacijske i prostorne) koji utječu na digitalnu zrelost poljoprivrednih gospodarstava za usvajanje digitalnih tehnologija u njihovim proizvodnim i poslovnim procesima i
- razviti metodologiju za primjenu digitalne zrelosti prilagođenu poljoprivrednom sektoru te predložiti smjernice za izradu strategije i preporuke za digitalnu transformaciju.

Polazeći od navedenih ciljeva i pregleda literature, u ovom istraživanju postavljene su sljedeće istraživačke hipoteze:

Hipoteza 1 (H1): ***Poljoprivredni subjekti u Republici Hrvatskoj imaju nižu razinu digitalne zrelosti u usporedbi s prosjekom digitalne zrelosti malih i srednjih poduzeća u drugim sektorima gospodarstva.***

Hipoteza 2 (H2): ***Postoji značajna povezanost između organizacijskih čimbenika (npr. veličina gospodarstva, stupanj obrazovanja vlasnika, dob) i digitalne zrelosti poljoprivrednih gospodarstava za usvajanje digitalnih tehnologija.***

Hipoteza 3 (H3): ***Ne postoji jedinstvena i općeprihvaćena metodologija prilagođena specifičnostima poljoprivrednog sektora za evaluaciju digitalne zrelosti, što otežava preciznu procjenu i planiranje digitalne transformacije.***

Kako empirijsko istraživanje obuhvaća isključivo poljoprivredne subjekte, za testiranje H1 dobiveni Globalni_DRI indeks usporedit će se sa sekundarnim podacima o digitalnoj zrelosti ostalih sektora gospodarstva RH (npr. nacionalni DESI indeks za SME sektor tekuće godine).

1.3 Struktura disertacije

Ova doktorska disertacija strukturirana je u šest međusobno povezanih poglavlja.

Nakon ovog uvodnog poglavlja, **Poglavlje 2** pruža detaljan pregled literature, definira ključne koncepte digitalne transformacije, precizne poljoprivrede i modela digitalne zrelosti, te identificira teorijske okvire i istraživački jaz. **Poglavlje 3** opisuje materijale i metode korištene u istraživanju, uključujući prilagodbu CSIRO modela, dizajn uzorka i statističke metode obrade podataka. **Poglavlje 4** prezentira rezultate empirijskog istraživanja, uključujući deskriptivnu statistiku, analizu glavnih komponenti, klastersku analizu, regresijske modele i prostornu distribuciju digitalne zrelosti. **Poglavlje 5** nudi detaljnu raspravu o dobivenim nalazima, njihovu interpretaciju u kontekstu teorije ljudskog kapitala, pristupa utemeljenog na resursima (RBV) i fenomena „vještinskog jaza“, te iznosi konkretne političke i praktične preporuke. Konačno, **Poglavlje 6** donosi sažetak ključnih nalaza, potvrdu postavljenih hipoteza i završne zaključke disertacije. **Poglavlja 7, 8, 9** i **10** donose popis izvora, sažetak i priloge – anketni upitnik, tablice i grafikone, te životopis doktoranda.

2. PREGLED LITERATURE

2.1. Evolucija i koncept digitalne transformacije

U suvremenoj znanstvenoj literaturi pojam digitalne transformacije definiran je iz više perspektiva, najčešće u kontekstu evolucije poslovnih modela ili stvaranja potpuno novih načina generiranja vrijednosti (Berman, 2012.). Iako se termini digitizacija i digitalizacija često koriste kao sinonimi, u akademskom diskursu važno je razlučiti njihova značenja. Digitizacija predstavlja temeljni proces pretvorbe analognih informacija u digitalni oblik i često se poistovjećuje s trećom industrijskom revolucijom (Greenwood, 1997.). Digitalizacija ide korak dalje; ona opisuje društveno-tehničke procese i njihove utjecaje na ljudske aktivnosti koji proizlaze iz uporabe međusobno povezane digitalne tehnologije (Nambisan i sur., 2017.).

Jedna od najznačajnijih revolucija u modernom poslovanju jest upravo prelazak s tradicionalnih na digitalne poslovne modele radi postizanja više razine konkurentnosti (Jovanović i sur., 2018.). U tranziciji prema šestom valu inovacija, moguće je izdvojiti tri ere digitalne transformacije (I-scoop, 2016.):

1. **Digitizacija:** pretvorba analognih stavki u digitalne verzije (npr. elektronička verzija papirnatih dokumenata).
2. **Digitalizacija:** uporaba digitalnih tehnologija za promjenu poslovnih modela, stvaranje novih izvora prihoda, poboljšanje poslovanja i prilika za stvaranje vrijednosti.
3. **Digitalna transformacija:** sveobuhvatna uporaba digitalnih tehnologija za promjenu svih aspekata poslovanja i organizacijske kulture.

Trenutačno živimo u trećoj eri, gdje su novi izazovi stavljeni pred vlade, tvrtke, poduzetnike i potrošače (Schwab, 2016.). Schmarzo (2017.) naglašava da ovo doba predstavlja „primjenu digitalnih mogućnosti na procese, proizvode i imovinu“ s ciljem „poboljšanja učinkovitosti, povećanja vrijednosti za kupce, upravljanja rizikom i otkrivanja novih prilika za unovčavanje“. Slično, Bertini (2016.) ističe da „digitalna transformacija ne utječe samo na živote, već i na iskustva pojedinaca“. Prema Algebri (2023.), digitalna transformacija je proces mijenjanja tradicionalnih ili pokretanja novih poslovnih inicijativa na kreativan način, korištenjem društvenih, mobilnih i drugih digitalnih tehnologija, što zahtijeva promjenu vodstva i intenzivno korištenje dostupnih tehnologija. Ona se bavi i tehnološkim i netehnološkim aspektom, prikazujući prioritetno utjecaj na društvo transformacijom aktivnosti, procesa, kompetencija i cjelokupnih poslovnih modela. Isti autor navodi kako su digitalne tehnologije uglavnom tehnologije vezane uz industriju 4.0.

Spremić (2017.) definira digitalnu transformaciju poslovanja kao duboku transformaciju poslovnih i organizacijskih aktivnosti, procesa, kompetencija i modela koja u potpunosti iskorištava promjene i mogućnosti kombinacije digitalnih tehnologija i njihov ubrzani utjecaj na društvo na strateški i prioritetan način. Matt i sur. (2015.) istaknuli su da strategije digitalne transformacije imaju elemente koje je moguće prikazati kroz četiri dimenzije:

1. primjena tehnologija,
2. promjene u sustavu stvaranja vrijednosti,
3. strukturne promjene i
4. financijski aspekti.

U pregledu perspektiva digitalne transformacije, Westerman i sur. (2014.) kategorizirali su sve digitalne inicijative u tri glavne skupine:

1. **Zamjena** (digitalne tehnologije zamjenjuju postojeći proces),
2. **Proširenje** (digitalne tehnologije poboljšavaju funkcionalnost postojećeg procesa) i
3. **Transformacija** (digitalne tehnologije iz temelja redefiniraju ili stvaraju novi proces).

Cilj Europske unije za digitalne inovacije, postavljen sveobuhvatnim okvirom pod nazivom „Digitalno desetljeće Europe“, usmjeren je na omogućavanje ljudima svih aspekata tehnološkog i inovacijskog rada, s glavnim ciljevima koji uključuju digitalno kvalificirano stanovništvo, sigurnu digitalnu infrastrukturu, digitalnu transformaciju tvrtki i digitalizaciju javnih usluga (Procjena digitalne zrelosti, 2023.).

2.2. Digitalna transformacija u poljoprivredi i koncept precizne poljoprivrede

Poljoprivreda, sukladno globalnim trendovima, prolazi kroz niz transformacija, ističući područja djelovanja i stručnosti prepoznate na različite načine. Zbog svoje složenosti i multidisciplinarnog karaktera, postoji sve veći broj komponenti kojima je potreban pristup po mjeri. Sukladno tome, precizna poljoprivreda (eng. Precision Agriculture) i pametna poljoprivreda (eng. Smart Farming) predstavljaju novi način promišljanja, analiziranja, planiranja i obavljanja aktivnosti, bilo u uredu, laboratoriju ili na terenu. U današnje vrijeme umjetna inteligencija, upotreba satelitskih sustava (Shannon i sur., 2018.) i različiti elementi precizne poljoprivrede usvojeni su i nalaze se u primjeni širom svijeta (Kumar i sur., 2021.). Uspješna primjena globalnih satelitskih navigacijskih sustava (GNSS) u preciznoj poljoprivredi revolucionirala je poljoprivrednu praksu, nudeći značajne prednosti u smislu poboljšane učinkovitosti, produktivnosti i održivosti (Radočaj i sur., 2023.).

Buntak i sur. (2021.) pružili su model mjerenja zrelosti za digitalnu transformaciju za opskrbni

lanac na temelju identificiranih teorija i potreba, kako bi se poboljšala komunikacija između dionika, kao i učinkovitost i djelotvornost. Slično kao i mnogi drugi sektori, poljoprivreda doživljava dinamičan i raznolik razvoj u digitalizaciji poslovanja i operativne infrastrukture. Posljedično, poljoprivrednici u srednjoj i zapadnoj Europi imaju pristup sve većem broju digitalnih aplikacija i tehnologija precizne poljoprivrede. Dostupan je širok raspon tehnologija i specifičnih web-lokacija kao alata za podršku pri donošenju odluka za poljoprivrednike i praktičare te za olakšavanje složenijih procesa učinkovitosti kako u uzgoju usjeva tako i u stočarstvu (Paustian i Theuvsen, 2017.).

Na širu digitalnu transformaciju poljoprivrede sve više utječu i regulatorni okviri Europske unije. Strategija „Od polja do stola“ (Farm to Fork) i Europski zeleni plan (EU Green Deal) postavljaju stroge zahtjeve za održivošću i smanjenjem inputa, što poljoprivrednike prisiljava na usvajanje preciznih digitalnih alata kako bi dokazali svoju ekološku i ekonomsku učinkovitost (Europska komisija, 2020.).

2.3. Čimbenici i barijere usvajanja digitalnih tehnologija na razini gospodarstva

Kako se digitalizacija u poljoprivrednom sektoru intenzivirala, povećao se i broj studija koje se bave usvajanjem i korištenjem digitalnih tehnologija. Broj korisnika precizne poljoprivrede u razvijenim zemljama uvelike varira između zemalja (Lowenberg-DeBoer i Erickson, 2019.) i regija (Pfeiffer i sur., 2021.; Schimmelpfennig i Ebel, 2016.; Llewellyn i Ouzman, 2014.). U europskom kontekstu, najveće stope korisnika digitalne poljoprivredne tehnologije trenutno su u Njemačkoj, Francuskoj, Nizozemskoj i Ujedinjenom Kraljevstvu (Maloku, 2020.). U dvadesetogodišnjem istraživanju, Lowenberg-DeBoer i Erickson (2019.) pokazali su da je upotreba tehnologija precizne poljoprivrede u uzgoju usjeva znatno veća u SAD-u, Australiji i Južnoj Americi nego u Europi.

Velik dio literature istraživao je čimbenike koji utječu na prihvaćanje digitalnih tehnologija na razini gospodarstva. Meta-studija Pierpaoli i sur. (2013.) sažela je glavne utjecaje na usvajanje tehnologija precizne poljoprivrede među poljoprivrednicima. Autori su identificirali veličinu gospodarstva, očekivane koristi od tehnologija i pojedinačne karakteristike upravitelja gospodarstva kao kritične čimbenike. Veličina gospodarstva identificirana je u mnogim studijama kao ključni čimbenik koji utječe na usvajanje više tehnologija (Walton i sur., 2008.; Robertson i sur., 2012.; Tamirat i sur., 2017.). Relativno viša razina prihoda koju ostvaruju veća gospodarstva smanjuje percipirani rizik ulaganja (Barnes i sur., 2019.) i omogućuje veći pristup kapitalu (Tamirat i sur., 2017.). Pokazalo se da su stope usvajanja veće na gospodarstvima koje koriste vlasnici (Paustian i Theuvsen,

2017.).

Nedavna meta-analiza usvajanja tehnologija precizne poljoprivrede istaknula je kako različiti dizajni studija i statističke metode korištene u binarnim pristupima ometaju usporedivost rezultata (Tey i Brindal, 2021.). Grupa australskih istraživača otišla je dalje od binarnih mjera kako bi razvila model predviđanja ADOPT koji kvantificira brzinu i vršnu razinu širenja tehnologije na razini gospodarstva (Kuehne i sur., 2017.).

ADOPT model sastoji se od više varijabli koje uzimaju u obzir karakteristike korisničke populacije i same tehnologije, odražavajući klasične atribute teorije širenja inovacija (Rogers, 2003.), poput relativne prednosti, kompatibilnosti, složenosti i vidljivosti tehnologije.

2.4. Teorijski okviri digitalne transformacije

Razumijevanje digitalne transformacije u poljoprivredi zahtijeva oslanjanje na provjerene ekonomske i menadžment teorije.

Tri ključna teorijska okvira posebno su relevantna za ovo istraživanje:

1. Teorija ljudskog kapitala (eng. Human Capital Theory). Temeljena na radovima Schultza i Beckera, ova teorija postulira da ulaganja u obrazovanje i vještine pojedinca izravno povećavaju njegovu produktivnost i sposobnost apsorpcije novih tehnologija. U kontekstu poljoprivrede, obrazovaniji nositelji gospodarstava brže prepoznaju korisnost digitalnih alata i lakše savladavaju kompleksna sučelja.
2. Model prihvaćanja tehnologije (eng. Technology Acceptance Model – TAM). Razvijen od strane Davisa (1989.), TAM sugerira da usvajanje tehnologije primarno određuju dva čimbenika: percipirana korisnost (vjerovanje da tehnologija poboljšava performanse) i percipirana lakoća korištenja. Ovi Čimbenici su izrazito važni kod starijih poljoprivrednika koji mogu imati veće barijere pri usvajanju složenih digitalnih sustava.
3. Pristup utemeljen na resursima (eng. Resource-Based View – RBV). Prema Barneyju (1991.), konkurentska prednost ne proizlazi samo iz posjedovanja fizičkih resursa (poput traktora ili senzora), već iz neopipljivih resursa poput znanja, vještina i organizacijske kulture. Ovo objašnjava zašto sama nabava „tvrdih“ tehnologija bez razvoja „mekih“ kapaciteta (analitika podataka, strategija) ne dovodi do pune digitalne zrelosti.

2.5. Modeli procjene digitalne zrelosti s fokusom na CSIRO okvir

Pregledom literature utvrđeno je kako ne postoji općeprihvaćena definicija za koncept „digitalne zrelosti“. Isti se kroz literaturu opisuje kao proces „sustavne pripreme organizacija za dosljednu prilagodbu na tekuće digitalne promjene“ (Kane i sur., 2017.), ali i kao mjera „koliko dobro subjekt koristi digitalnu tehnologiju za postizanje boljih performansi“ (Mettler i Pinto, 2018.). Wendler (2012.) naglašavaju da modeli zrelosti moraju definirati skup diskretnih, sekvencijalnih razina ili faza te sadržavati mjerljive kriterije. Kutnjak i sur. (2020.) istaknuli su praćenje digitalne zrelosti kao vrlo važno za razumijevanje stanja umješnosti u digitalnoj transformaciji.

Za potrebe poljoprivrednog sektora, najprikladnijim se pokazao model koji je razvio Commonwealth Scientific and Industrial Research Organisation (CSIRO), nacionalno državno tijelo za znanstveno istraživanje u Australiji, koje je kreiralo prvi svjetski indeks digitalne zrelosti i alat za procjenu poljoprivrednog sektora. Prilagođeni CSIRO model digitalnu zrelost konceptualizira kroz pet ključnih stupova (dimenzija):

1. **Strategija i kultura**. Uključuje viziju, strateško planiranje i spremnost organizacije na promjene.
2. **Tehnologija.** Odnosi se na hardversku i softversku infrastrukturu, uključujući preciznu poljoprivrednu tehniku, senzore i IoT uređaje.
3. **Podaci i analitika.** Sposobnost prikupljanja, integracije i analize podataka radi donošenja informiranih poslovnih odluka.
4. **Sposobnost.** Digitalne vještine, kompetencije i znanje nositelja gospodarstva i zaposlenika.
5. **Pravila podataka.** Uspostava jasnih pravila o vlasništvu, sigurnosti, etici i dijeljenju podataka.

2.6. Digitalni jaz i nejednakosti u ruralnim područjima

Unatoč napretku u digitalizaciji, literatura upozorava na postojanje izraženog „digitalnog jaza“ (eng. digital divide) u ruralnim područjima. Ovaj jaz se ne očituje samo u nedostatku infrastrukture (prvi „digitalni jaz“), već sve više u nedostatku vještina i znanja za korištenje dostupnih tehnologija (drugi „digitalni jaz“ ili eng. skills gap).

Rotz i sur. (2019.) upozoravaju da mala i srednja poljoprivredna gospodarstva riskiraju značajno zaostajanje u digitalizaciji u usporedbi s velikim agrobiznisima koji imaju resurse za zapošljavanje specijaliziranog IT kadra. U literaturi se ovaj fenomen opisuje kao drugi stupanj digitalnog jaza (eng. second-level digital divide), koji se ne odnosi više na fizički pristup tehnologiji, već na nejednakosti u digitalnim vještinama, korištenju i sposobnosti generiranja

vrijednosti iz dostupnih alata (Van Dijk, 2020.; Rotz i sur., 2019.). Van Dijk ističe da se s rastom penetracije interneta i osnovnih pametnih uređaja temeljni problem premješta s pukog fizičkog pristupa tehnologiji na nejednakosti u digitalnim vještinama, motivaciji i načinima naprednog korištenja te tehnologije u praksi.

Upravo taj drugi stupanj jaza stvara paradoks „tehnologije bez znanja“, koji je posebno izražen u kontinentalnim regijama gdje, unatoč dostupnosti hardvera, nedostaje napredno znanje za analitičku primjenu tehnologija. Konkretnije, puko posjedovanje pametnog telefona, računala ili čak ugradnja naprednih senzora na poljoprivrednu tehniku ne implicira nužno i uspješnu digitalnu transformaciju gospodarstva. Ukoliko nositelj poljoprivrednog gospodarstva ne posjeduje specifična znanja, analitičke vještine i uspostavljene poslovne rutine za obradu, interpretaciju i donošenje odluka temeljenih na prikupljenim podacima (eng. data-driven decision making), stvarna dodana vrijednost implementirane tehnologije izostaje. Prevladavanje ove barijere zahtijeva kvalitativni skok s bazične operativne upotrebe uređaja na stratešku primjenu informacijskih resursa, što predstavlja ključan preduvjet za tranziciju poljoprivrednog subjekta u višu fazu digitalne zrelosti.

2.7. Specifičnosti poljoprivrednih SME-ova u hrvatskom i europskom kontekstu

Prema Zakonu o poljoprivredi Republike Hrvatske (NN 118/18, 42/20, 127/20, 52/21, 152/22), poljoprivrednik je fizička ili pravna osoba koja obavlja poljoprivrednu djelatnost, a obuhvaća obiteljska poljoprivredna gospodarstva (OPG), obrte, trgovačka društva i zadruge.

Petrač (2002.) ističe da ukupnost poljoprivrednih gospodarstava čini organizaciju poljoprivredne proizvodnje koja je činitelj racionalnosti postojeće proizvodnje i njezina daljnjeg razvitka.

Prosječna veličina poljoprivrednog gospodarstva u Republici Hrvatskoj iznosi svega 7 ha, dok je prosječna veličina u Europskoj uniji 17,1 ha (Eurostat, 2018.). Ova izrazita fragmentiranost definira specifičnosti hrvatskih poljoprivrednih SME-ova (malih i srednjih poduzeća). Pojam SME-ova u poljoprivredi različito se definira u svijetu (Bosc i sur., 2013.), no najčešće je izravno povezan s obiteljskim poljoprivrednim gospodarstvima (Graeub i sur., 2016.).

Upravo ta specifična struktura (mala veličina, obiteljski karakter i starenje nositelja) nameće potrebu za prilagodbom globalnih modela digitalne zrelosti hrvatskom kontekstu.

2.8. Identificirani istraživački jaz i doprinos ovog istraživanja

Iako postoji bogata literatura o usvajanju precizne poljoprivrede i općim modelima digitalne transformacije, detaljnom analizom postojećih istraživanja identificirana su tri ključna istraživačka jaza (eng. research gaps) koja ovo istraživanje nastoji popuniti:

1. **Nedostatak empirijskog „baseline-a“ za hrvatsku poljoprivredu.** Iako je općepoznato da poljoprivreda zaostaje za drugim sektorima (npr. proizvodnjom ili maloprodajom), ne postoji sveobuhvatna, kvantitativna studija koja bi točno izmjerila razinu digitalne zrelosti hrvatskih poljoprivrednih SME-ova i usporedila je s drugim sektorima. Ovaj jaz izravno vodi do **Hipoteze 1 (H1): Poljoprivredni subjekti u Republici Hrvatskoj imaju nižu razinu digitalne zrelosti u usporedbi s prosjekom digitalne zrelosti malih i srednjih poduzeća u drugim sektorima gospodarstva.**
2. **Nedovoljno razumijevanje specifičnih pokretača zrelosti u kontekstu obiteljskih gospodarstava.** Dok su čimbenici usvajanja tehnologije dobro istraženi na velikim farmama u SAD-u i Australiji, mehanizmi koji pokreću digitalnu zrelost na malim, obiteljskim gospodarstvima u Hrvatskoj (gdje su ljudski kapital i demografija izraženiji nego fizički kapital) nisu empirijski validirani. Ovaj jaz motivira **Hipotezu 2 (H2): Postoji značajna povezanost između organizacijskih Čimbenika (npr. veličina gospodarstva, stupanj obrazovanja vlasnika, dob, iskustvo i slično) i digitalne zrelosti poljoprivrednih gospodarstva za usvajanje digitalnih tehnologija.**
3. **Nedostatak sektorski specifične metodologije.** Generički modeli digitalne zrelosti (poput onih za IT ili opći menadžment) ne uzimaju u obzir specifičnosti poljoprivrede (ovisnost o prirodi, sezonalnost, specifične regulative). Nedostatak jedinstvenog, prilagođenog alata onemogućuje precizno planiranje transformacije. **Ovaj jaz potvrđuje Hipotezu 3 (H3): Ne postoji jedinstvena i općeprihvaćena metodologija prilagođena specifičnostima poljoprivrednog sektora za evaluaciju digitalne zrelosti poljoprivrednog sektora, što otežava preciznu procjenu i planiranje digitalne transformacije.**

Ovim istraživanjem, primjenom prilagođenog CSIRO modela na reprezentativnom uzorku hrvatskih SME-ova, popunjavaju se navedeni jazovi, pružajući znanstvenu i praktičnu podlogu za kreiranje ciljanih politika digitalne transformacije u Republici Hrvatskoj.

3. MATERIJAL I METODE RADA

3.1. Cilj i dizajn istraživanja

Kako bi digitalna transformacija bila svrhovita i učinkovita, važno je prvo obaviti procjenu stanja sektora sa svrhom identifikacije područja digitalnih snaga i identifikacije područja za razvoj. Razvoj indeksa digitalne zrelosti i metodologije za procjenu navedenog smatra se nužnim prvim korakom za digitalnu transformaciju.

Ovo istraživanje obuhvatilo je poljoprivredna gospodarstva Republike Hrvatske (za potrebe istraživanja ista su nazivana poljoprivredni SME-ovi) čija je veličina poljoprivrednog zemljišta do 100 ha, temeljem analize strukture gospodarstva i poljoprivrednog zemljišta (www.apprrr.hr). U istraživanju nisu bila uključena gospodarstva koja nemaju poljoprivredno zemljište niti gospodarstva čija površina prelazi 100 ha. Ukupna veličina ciljne populacije iznosila je 150.587 gospodarstava. Prema metodološkim smjernicama za statističku relevantnost, inicijalno je planirana veličina uzorka od najmanje 383 gospodarstava, čime bi se osigurala razina pouzdanosti od 95%, odnosno točnost mjerenja unutar ±5% od stvarne vrijednosti. Konačnim terenskim prikupljanjem podataka, istraživanjem je obuhvaćen reprezentativni uzorak od 565 poljoprivrednih gospodarstava, stratificiran prema NUTS regijama i veličini posjeda, čime je nadmašena inicijalno planirana statistička snaga uzorka.

3.2. Mjerni instrument i model procjene

Pri razmatranju najprikladnijeg modela za praćenje i ocjenu zrelosti digitalne transformacije poljoprivrede, primijenjen je za poljoprivredni sektor Republike Hrvatske prilagođeni CSIRO (McKinseyev) model s 9 dimenzija i preko 40 poddimenzija, kao i njegov upitnik za istraživanje zrelosti digitalne transformacije. Ovaj model i upitnik uključio je vodeće komponente digitalne transformacije, zastupljene u različitim sektorima. Commonwealth Scientific and Industrial Research Organisation (CSIRO), nacionalno državno tijelo za znanstveno istraživanje u Australiji, je razvilo prvi svjetski indeks digitalne zrelosti i alat za procjenu poljoprivrednog sektora. Kada se razmatra indeks digitalne zrelosti u poljoprivredi, potrebno je uzeti u obzir pet stupova koji sadrže procjenu digitalne zrelosti:

1. **Strategija i kultura** (13 pitanja u 3 cjeline),
2. **Tehnologija** (13 pitanja u 3 cjeline),
3. **Podaci i analitika** (16 pitanja u 3 cjeline),
4. **Sposobnost** (9 pitanja u 1 cjelini) i
5. **Pravila podataka / Upravljanje** (3 pitanja u 1 cjelini).

Ukupno je upitnik sadržavao 54 tvrdnje ocijenjenih na 5-stupanjskoj Likertovoj skali (od 1 = uopće se ne slažem do 5 = u potpunosti se slažem). Za svaki od ranije navedenih pet stupova (Stup1: Strategija i kultura, Stup2: Tehnologija, Stup3: Podaci i analitika, Stup4: Sposobnost i Stup5: Upravljanje) kreiran je posebni indeks (računanjem aritmetičke sredine odgovarajućih tvrdnji), dok je Globalni indeks digitalne zrelosti (Globalni_DRI) kreiran kao aritmetička sredina navedenih pet indeksa stupova.

Originalni CSIRO upitnik prilagođen je specifičnostima hrvatskog poljoprivrednog konteksta, preveden i strukturiran u digitalni format putem platforme Google Forms. S obzirom na to da demografsku strukturu hrvatskih poljoprivrednika karakterizira starija životna dob i niža razina digitalne pismenosti, kako bi se izbjegla pristranost uzorka (eng. sampling bias) i osigurala visoka kvaliteta prikupljenih podataka, istraživanje nije provedeno metodom samostalnog ispunjavanja, već metodom strukturiranog intervjua uživo (eng. face-to-face).

Postupak prikupljanja podataka odvijao se na način da je obučeni anketar osobno posjećivao poljoprivredna gospodarstva, čitao i postavljao pitanja, pružao dodatna pojašnjenja pojedinih tvrdnji kada je to bilo potrebno, te izravno unosio odgovore nositelja u digitalni obrazac. Ovaj pristup osigurao je visoku stopu odaziva, minimizirao pogreške uzrokovane nerazumijevanjem specifičnih tehničkih pojmova te omogućio uključivanje u istraživanje i onih gospodarstava koja inače ne bi bila obuhvaćena isključivo digitalnim metodama anketiranja.

Jedan od rezultata provedene ankete prikazao je i višestruku povezanost svakog stupa i aspekta prema četiri stupnja zrelosti: 1) nastajanje (Emerging), 2) prijelazno razdoblje (Transitional), 3) natjecateljsko razdoblje (Competitive) i 4) transformativno razdoblje (Transformative).

3.3. Statistička analiza podataka

Prikupljeni podaci obrađeni su primjenom naprednih statističkih metoda korištenjem statističkog softvera Jamovi (verzija 2.7.33) te programskog jezika R (putem modula Rj Editor). Statistička analiza provođena je u nekoliko sustavnih koraka kako bi se osigurala validnost i robusnost nalaza.

Priprema podataka i deskriptivna statistika

Za sve kontinuirane varijable provedena je provjera pretpostavki normalnosti distribucije pomoću Shapiro-Wilkovog testa te vizualnom inspekcijom Q-Q dijagrama. S obzirom na veličinu uzorka (N=565) i robusnost parametrijskih testova, nastavljeno je s parametarskim

analizama. Deskriptivna statistika uključivala je izračun aritmetičkih sredina (M), standardnih devijacija (SD), medijana, minimalnih i maksimalnih vrijednosti, te koeficijenata asimetrije (skewness) i zaobljenosti (kurtosis) distribucije.

Analiza pouzdanosti i validnosti konstrukta

Unutarnja konzistentnost mjernog instrumenta za svaki od pet stupnjeva digitalne zrelosti evaluirana je pomoću Cronbachovog koeficijenta alfa (α). Za provjeru dimenzionalnosti instrumenta i opravdanosti spajanja pet stupnjeva u Globalni DRI indeks, provedena je Analiza glavnih komponenti (PCA). Prikladnost uzorka za ocjene čimbenika faktorizaciju provjerena je Kaiser-Meyer-Olkin (KMO) mjerom i Bartlettovim testom sferičnosti, dok je broj komponenti i struktura opterećenja određena na temelju svojstvenih vrijednosti (eigenvalues) i Scree dijagrama.

Segmentacija i profiliranje gospodarstava

S ciljem grupiranja poljoprivrednih gospodarstava u homogene profile s obzirom na digitalnu zrelost, provedena je K-means klasterska analiza. Odabir optimalnog broja klastera proveden je i validiran korištenjem triju komplementarnih metoda: Elbow dijagrama (dijagram lakta), Gap statistic testa te analize Silhouette indeksa (kohezije i separacije klastera).

Inferencijalna statistika: Analize razlika (ANOVA)

Za ispitivanje statistički značajnih razlika u digitalnoj zrelosti s obzirom na demografske i prostorne karakteristike, korištena je analiza varijance (ANOVA). Analize su provedene zasebno za Globalni_DRI i za svaki od pet pojedinačnih indeksa stupova digitalne zrelosti kako bi se detektirala specifična „uska grla“. Testirane su razlike s obzirom na dob nositelja gospodarstva (D1), razine obrazovanja (D3), veličine poljoprivrednog posjeda (D10), broja zaposlenih (D11) i godišnjih poslovnih prihoda (D12) te pripadnosti gospodarstava NUTS regiji (D6), ali i na razini pojedinih županija (D7). Zbog višestrukog testiranja i potencijalne heterogenosti varijanci, korišteni su robusni post-hoc testovi s Holm i Bonferroni korekcijom. Homogenost varijanci provjeravana je Levenovim testom.

Inferencijalna statistika: Analize prediktora (Višestruka linearna regresija)

Za utvrđivanje ključnih prediktora digitalne zrelosti provedena je višestruka linearna regresijska analiza. Inicijalno su razvijena dva modela za predviđanje Globalnog DRI indeksa: Model 1 je uključivao demografske i organizacijske varijable (dob, obrazovanje, veličina posjeda, broj zaposlenih i prihodi), dok je Model 2 dodatno uključio i prostornu komponentu (NUTS regije) kao kontrolnu varijablu. Multikolinearnost je provjerena putem VIF (Variance Inflation Factor) statistike, a kvaliteta prilagodbe modela procijenjena je kroz R^2, prilagođeni ***R^2 i Durbin-Watsonov test autokorelacije reziduala.***

Kako bi se dublje razumjelo djeluju li prediktori diferencijalno na specifične aspekte digitalne zrelosti, provedeno je pet dodatnih višestrukih regresijskih modela, pri čemu je svaki od pet stupnjeva digitalne zrelosti (Indeks_Stup1 do Indeks_Stup5) postao zasebna zavisna varijabla, uz identičan set nezavisnih prediktora. Ovaj pristup omogućio je precizno mapiranje utjecaja demografskih i prostornih čimbenika na specifične dimenzije (npr. utjecaj regije na Sposobnost i Podatke, nasuprot utjecaju veličine posjeda na Tehnologiju).

Razina statističke značajnosti u svim provedenim testovima postavljena je na $p < 0,05$.

4. REZULTATI ISTRAŽIVANJA

U ovom poglavlju prikazani su rezultati empirijskog istraživanja provedenog na uzorku od N = 565 poljoprivrednih gospodarstava (SME-ova) u Republici Hrvatskoj. Analiza podataka provedena je u nekoliko sveobuhvatnih koraka: prvo je opisan uzorak i provjerene pretpostavke za parametrijsko testiranje, zatim je evaluirana pouzdanost mjernog instrumenta, provedena je analiza glavnih komponenti (PCA) radi validacije strukture digitalne zrelosti, provedena je klasterska analiza radi segmentacije gospodarstava u profile, te su na kraju, putem korelacijske analize, analize varijance (ANOVA) i višestruke regresije, utvrđeni demografski, organizacijski i prostorni prediktori digitalne zrelosti.

4.1.Opis uzorka i prostorna distribucija

Uzorak istraživanja obuhvaća 565 poljoprivrednih gospodarstava. Kako bi se utvrdila prostorna distribucija ispitanika i reprezentativnost uzorka, analizirana je zastupljenost gospodarstava prema pripadnosti pojedinim županijama.

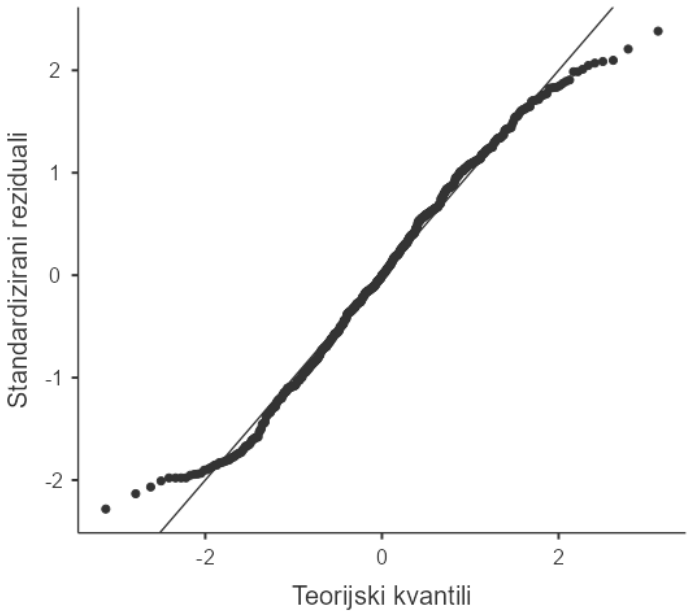
Tablica 4.1. Distribucija uzorka poljoprivrednih gospodarstava prema županijama (N = 565)

D7	Brojanja	% od ukupnog broja	Kumulativni postotak
Bjelovarsko-bilogorska županija	32,0	5,7%	5,7%
Brodsko-posavska županija	26,0	4,6%	10,3%
Dubrovačko-neretvanska županija	42,0	7,4%	17,7%
Grad Zagreb	22,0	3,9%	21,6%
Istarska županija	23,0	4,1%	25,7%
Karlovačka županija	24,0	4,2%	29,9%
Koprivničko-križevačka županija	29,0	5,1%	35,0%
Krapinsko-zagorska županija	31,0	5,5%	40,5%
Ličko-senjska županija	18,0	3,2%	43,7%
Međimurska županija	26,0	4,6%	48,3%
Osječko-baranjska županija	33,0	5,8%	54,2%
Požeško-slavonska županija	21,0	3,7%	57,9%
Primorsko-goranska županija	13,0	2,3%	60,2%

D7	Brojanja	% od ukupnog broja	Kumulativni postotak
Sisačko-moslavačka županija	32,0	5,7%	65,8%
Splitsko-dalmatinska županija	35,0	6,2%	72,0%
Varaždinska županija	25,0	4,4%	76,5%
Virovitičko-podravska županija	21,0	3,7%	80,2%
Vukovarsko-srijemska županija	26,0	4,6%	84,8%
Zadarska županija	28,0	5,0%	89,7%
Zagrebačka županija	42,0	7,4%	97,2%
Šibensko-kninska županija	16,0	2,8%	100,0%

Iz prikazane distribucije vidljivo je da su u uzorku najviše zastupljena gospodarstva iz Zagrebačke (7,4%), Dubrovačko-neretvanske (7,4%) i Osječko-baranjske županije (5,8%), što osigurava relativno ravnomjernu geografsku pokrivenost kontinentalnog i jadranskog dijela Hrvatske.

Prije provođenja inferencijalnih statističkih testova, provjerene su pretpostavke normalnosti distribucije podataka.



Slika 4.1. Q-Q dijagram provjere normalnosti distribucije globalnog indeksa digitalne zrelosti (Globalni_DRI)

Iako Shapiro-Wilk test u nekim varijablama pokazuje statistički značajna odstupanja od normalne distribucije ($p < ,05$), s obzirom na veličinu uzorka ($N = 565$) i robustnost parametrijskih testova pri velikim uzorcima, te vizualnu inspekciju Q-Q dijagrama, opravdano je nastaviti s parametrijskim i robustnim multivarijatnim analizama.

4.2. Kreiranje indeksa digitalne zrelosti

Prije provođenja inferencijalnih statističkih analiza, bilo je potrebno operacionalizirati i matematički kreirati indekse koji će predstavljati ovisne varijable u istraživanju. Polazeći od CSIRO modela digitalne zrelosti, koji digitalnu transformaciju konceptualizira kroz pet ključnih stupnjeva (Strategija i kultura, Tehnologija, Podaci i analitika, Sposobnost, Pravila podataka), za svaki stupanj kreiran je posebni indeks (Indeks_Stup1 do Indeks_Stup5).

Pojedinačni indeksi stupnjeva kreirani su izračunavanjem aritmetičke sredine (prosjeka) odgovora ispitanika na pripadajuće tvrdnje unutar svakog stupnja, koje su inicijalno mjerene na Likertovoj skali od 1 do 5. Na primjer, varijabla Indeks_Stup1 predstavlja aritmetičku sredinu odgovora na 13 tvrdnji koje se odnose na dimenziju Strategije i kulture. Ovaj pristup zadržava originalnu skalu mjerenja (1-5) i olakšava interpretaciju rezultata.

Nadalje, kako bi se potvrdilo da ovih pet stupnjeva doista mjeri isti širi latentni konstrukt (sveobuhvatnu digitalnu zrelost) i time opravdao njihov matematički spoj u globalni indeks, provedena je Analiza glavnih komponenti (PCA) na razini ovih pet kreiranih stupnjeva. Rezultati PCA-e pokazali su da se svih pet stupnjeva visoko i značajno opterećuju na prvu glavnu komponentu (opterećenja u rasponu od 0,780 do 0,923), koja objašnjava 76,4% ukupne varijance. Ovaj nalaz potvrđuje da pet stupnjeva čini koherentnu, jednodimenzionalnu cjelinu unutar šireg konstrukta digitalne zrelosti.

Globalni indeks digitalne zrelosti (Globalni_DRI) kreiran je kao aritmetička srednja vrijednost ovih pet stupnjeva, pri čemu svaki stupanj jednako doprinosi ukupnom rezultatu. Tako dobiveni globalni indeks kontinuirana je varijabla koja varira u rasponu od 1 do 5, pri čemu viša vrijednost ukazuje na višu razinu digitalne zrelosti poljoprivrednog gospodarstva.

4.3. Deskriptivna analiza i pouzdanost instrumenta

Kako bi se utvrdilo trenutačno stanje digitalne zrelosti, izračunate su deskriptivne statistike za svih pet stupova (dimenzija) i globalni indeks.

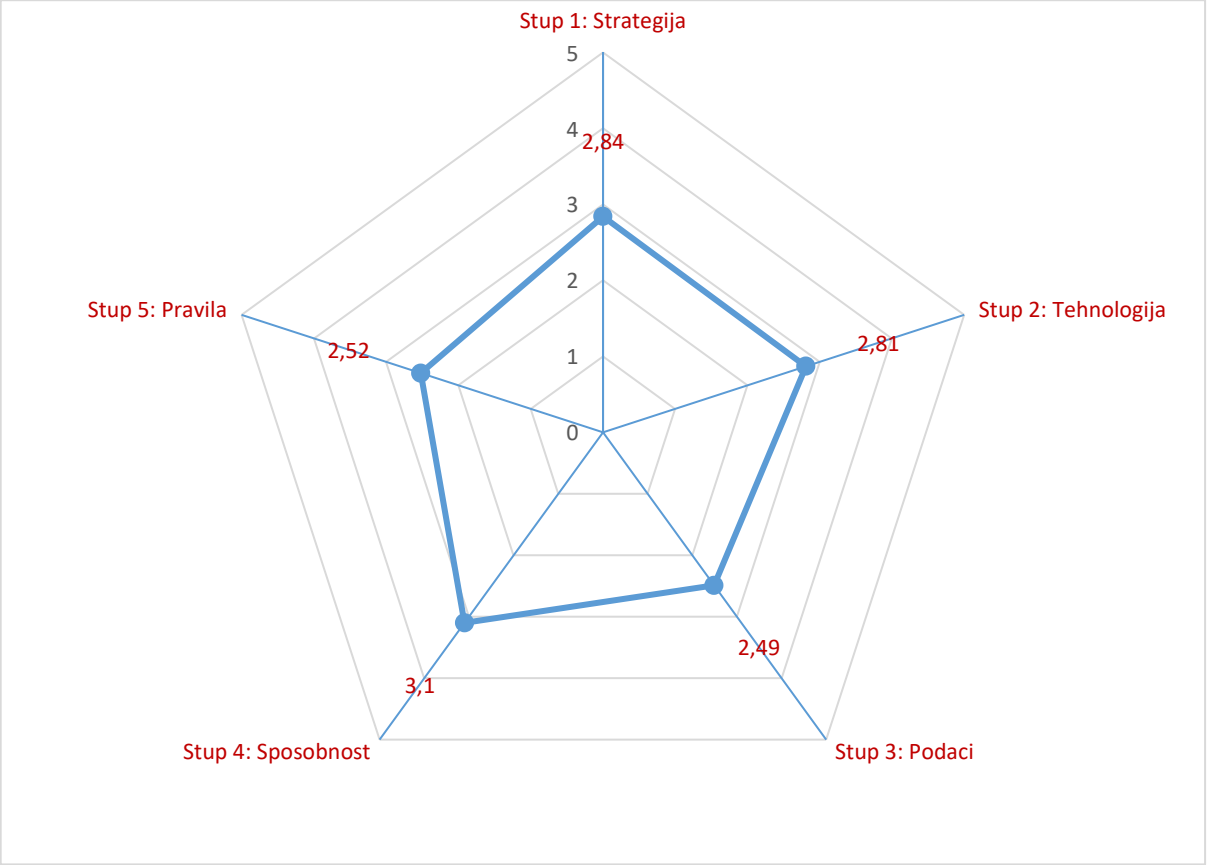
Tablica 4.2. Deskriptivni pokazatelji indeksa digitalne zrelosti po stupovima i globalnog indeksa (N = 565)

	Indeks_Stup1	Indeks_Stup2	Indeks_Stup3	Indeks_Stup4	Indeks_Stup5	Globalni_DRI
Srednja vrijednost	2,84	2,81	2,49	3,10	2,52	2,75
Standardna greška srednje vrijednosti	0,0415	0,0186	0,0376	0,0436	0,0491	0,0337
95% srednja vrijednost intervala pouzdanosti donja granica	2,76	2,77	2,42	3,01	2,42	2,68
95% srednja vrijednost intervala pouzdanosti gornja granica	2,92	2,85	2,56	3,18	2,62	2,82
Medijan	2,85	2,83	2,44	3,19	2,33	2,79
Modus	1,00	2,92	1,00	1,00	1,00	1,20
Standardna devijacija	0,986	0,443	0,893	1,04	1,17	0,801
Varijanca	0,972	0,196	0,798	1,08	1,36	0,641
Raspon	4,00	2,42	3,63	4,00	4,00	3,28
Minimum	1,00	1,67	1,00	1,00	1,00	1,20
Maksimum	5,00	4,08	4,63	5,00	5,00	4,48
Iskrivljenost	-0,142	0,0421	0,0454	-0,273	0,293	-0,0704
Standardna greška iskrivljenosti	0,103	0,103	0,103	0,103	0,103	0,103
Kurtosis	-0,897	-0,351	-0,915	-0,765	-0,932	-0,895
Standardna greška kurtosisa	0,205	0,205	0,205	0,205	0,205	0,205
Shapiro-Wilk W	0,973	0,994	0,973	0,973	0,935	0,979
Shapiro-Wilk p	<,001	,017	<,001	<,001	<,001	<,001

Napomena: Interval pouzdanosti srednje vrijednosti pretpostavlja da srednje vrijednosti uzorka slijede t-distribuciju s N - 1 stupnjeva slobode

Rezultati pokazuju da hrvatska poljoprivredna gospodarstva u prosjeku postižu najviše razine zrelosti u dimenziji **Sposobnost (Stup 4)** (M = 3,10; SD = 1,04), što ukazuje na postojanje osnovnih digitalnih vještina i kapaciteta osoblja. Slijede stupovi **Strategija i kultura** (M = 2,84) i **Tehnologija** (M = 2,81). S druge strane, najniže razine zrelosti zabilježene su u dimenzijama **Pravila podataka** (M = 2,52) i **Podaci i analitika** (M = 2,49). Ovakav profil ukazuje na to da, unatoč dostupnosti tehnologije i osnovnim vještinama, hrvatski

poljoprivrednici značajno zaostaju u sustavnom prikupljanju, analizi podataka te uspostavi jasnih pravila o upravljanju i sigurnosti podataka.



Slika 4.2. Radar dijagram prosječnih vrijednosti stupnjeva digitalne zrelosti (N = 565)

Radar dijagram (Slika 4.2.) vizualno prikazuje profil digitalne zrelosti hrvatskih poljoprivrednih gospodarstava kroz pet identificiranih stupnjeva, pri čemu svaka os predstavlja jedan stupanj digitalne zrelosti, a vrijednosti se kreću u rasponu od 0 do 5. Analiza profila otkriva asimetričnu distribuciju digitalne zrelosti s jasno izraženim snagama i slabostima. Najvišu razinu zrelosti gospodarstva bilježe u dimenziji **Sposobnost (Stup 4)** s prosječnom vrijednošću od 3,10, što ukazuje na postojanje osnovnih digitalnih vještina i kompetencija kod nositelja i zaposlenika. Slijede stupnjevi **Strategija i kultura (Stup 1)** s vrijednošću 2,84 te **Tehnologija (Stup 2)** s vrijednošću 2,81, što sugerira da gospodarstva posjeduju određenu razinu strateškog promišljanja o digitalizaciji i osnovnu tehnološku opremljenost. S druge strane, najniže vrijednosti zabilježene su u dimenzijama **Podaci i analitika (Stup 3)** s prosjekom od 2,49 te **Pravila podataka (Stup 5)** s vrijednošću 2,52. Ovakav profil ukazuje na to da, unatoč dostupnosti tehnologije i osnovnim vještinama, hrvatski poljoprivrednici značajno zaostaju u sustavnom prikupljanju, analizi podataka te uspostavi jasnih pravila o upravljanju i sigurnosti podataka.

Za procjenu unutarnje konzistentnosti (pouzdanosti) mjernog instrumenta korišten je Cronbachov koeficijent alfa (α).

Tablica 4.3. Pouzdanost mjernog instrumenta – Cronbachov α koeficijent za Stup 1: Strategija i kultura (ukupni od P1-1 do P1-13)

	Srednja vrijednost	Standardna devijacija	Cronbachov α
skala	2,84	0,986	0,937

Tablica 4.4. Pouzdanost mjernog instrumenta – Cronbachov α koeficijent za Stup 1: Strategija i kultura (pojedinačno za P1-1 do P1-13)

				Ako se stavka izostavi
	Srednja vrijednost	Standardna devijacija	Korelacija stavke s ukupnim rezultatom bez te stavke	Cronbachov α
P1-13	2,33	1,285	0,656	0,934
P1-12	3,26	1,266	0,642	0,934
P1-11	2,85	1,361	0,786	0,929
P1-10	2,86	1,428	0,611	0,936
P1-9	3,36	1,342	0,704	0,932
P1-8	3,18	1,316	0,774	0,930
P1-7	3,01	1,374	0,780	0,930
P1-6	2,52	1,282	0,778	0,930
P1-5	1,34	0,731	0,434	0,939
P1-4	3,18	1,363	0,773	0,930
P1-3	3,36	1,335	0,708	0,932
P1-2	3,02	1,408	0,795	0,929
P1-1	2,66	1,354	0,709	0,932

Tablica 4.5. Pouzdanost mjernog instrumenta – Cronbachov α koeficijent za Stup 2: Tehnologija (ukupni od P2-1 do P2-13)

	Srednja vrijednost	Standardna devijacija	Cronbachov α
skala	2,84	0,820	0,902

Tablica 4.6. Pouzdanost mjernog instrumenta – Cronbachov α koeficijent za Stup 2: Tehnologija (pojedinačno za P2-1 do P2-13)

	Srednja vrijednost	Standardna devijacija	Korelacija stavke s ukupnim rezultatom bez te stavke	Ako se stavka izostavi: Cronbachov α
P2-1	3,90	1,244	0,649	0,893
P2-2	3,41	1,257	0,475	0,901
P2-3	3,06	1,263	0,604	0,895
P2-4	2,72	1,297	0,557	0,897
P2-5	1,36	0,806	0,361	0,903
P2-6	2,79	1,251	0,728	0,889
P2-7	2,50	1,175	0,730	0,889
P2-8	2,77	1,129	0,573	0,896
P2-9[a]	2,91	1,269	0,551	0,897
P2-10	3,00	1,204	0,728	0,889
P2-11	2,76	1,246	0,578	0,896
P2-12[a]	2,82	1,234	0,667	0,892
P2-13[a]	2,96	1,270	0,700	0,890

[a] stavka obrnute skale

Tablica 4.7. Pouzdanost mjernog instrumenta – Cronbachov α koeficijent za Stup 3: Podaci i analitika (ukupno od P3-1 do P3-16)

	Srednja vrijednost	Standardna devijacija	Cronbachov α
skala	2,49	0,893	0,931

Tablica 4.8. Pouzdanost mjernog instrumenta – Cronbachov α koeficijent za Stup 3: Podaci i analitika (pojedinačno za P3-1 do P3-16)

	Srednja vrijednost	Standardna devijacija	Korelacija stavke s ukupnim rezultatom bez te stavke	Ako se stavka izostavi: Cronbachov α
P3-1	2,96	1,27	0,742	0,924
P3-2	2,32	1,33	0,646	0,927
P3-3	2,04	1,23	0,593	0,928
P3-4	2,34	1,36	0,695	0,926
P3-5	2,52	1,36	0,698	0,925

	Srednja vrijednost	Standardna devijacija	Korelacija stavke s ukupnim rezultatom bez te stavke	Ako se stavka izostavi Cronbachov α
P3-6	2,27	1,30	0,640	0,927
P3-7	2,84	1,27	0,748	0,924
P3-8	3,00	1,33	0,727	0,925
P3-9	2,32	1,23	0,706	0,925
P3-10	2,87	1,38	0,688	0,926
P3-11	2,16	1,30	0,652	0,927
P3-12	2,37	1,21	0,619	0,928
P3-13	2,23	1,27	0,633	0,927
P3-14	2,45	1,19	0,491	0,931
P3-15	2,48	1,14	0,525	0,930
P3-16	2,67	1,18	0,603	0,928

Tablica 4.9. Pouzdanost mjernog instrumenta – Cronbachov α koeficijent za Stup 4: Sposobnost (ukupno od P4-1 do P4-9)

	Srednja vrijednost	Standardna devijacija	Cronbachov α
skala	3,10	1,04	0,929

Tablica 4.10. Pouzdanost mjernog instrumenta – Cronbachov α koeficijent za Stup 4: Sposobnost (pojedinačno za P4-1 do P4-9)

	Srednja vrijednost	Standardna devijacija	Korelacija stavke s ukupnim rezultatom bez te stavke	Ako se stavka izostavi Cronbachov α
P4-1	3,29	1,34	0,775	0,919
P4-2	3,40	1,21	0,702	0,923
P4-3	3,50	1,24	0,734	0,922
P4-4	3,37	1,35	0,791	0,918
P4-5	3,08	1,29	0,812	0,917
P4-6	3,16	1,28	0,829	0,916
P4-7	3,07	1,33	0,784	0,918
P4-8	2,75	1,38	0,688	0,925
P4-9	2,25	1,25	0,550	0,932

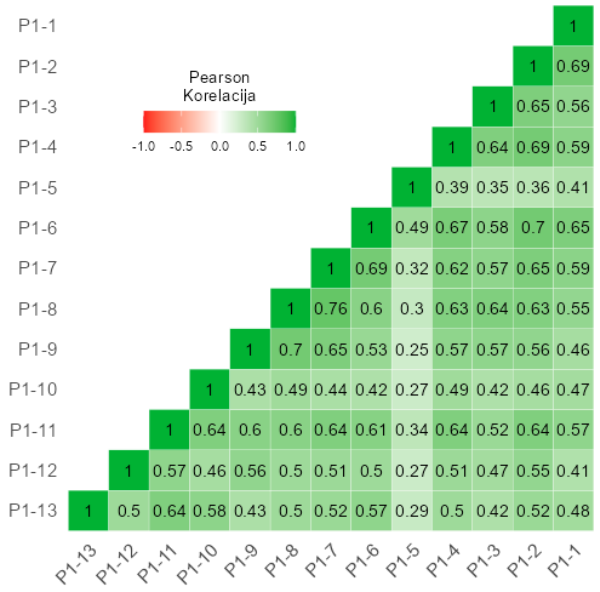
Tablica 4.11. Pouzdanost mjernog instrumenta – Cronbachov α koeficijent za Stup 5: Pravila podataka (ukupno od P5-1 do P5-3)

	Srednja vrijednost	Standardna devijacija	Cronbachov α
skala	2,52	1,17	0,827

Tablica 4.12. Pouzdanost mjernog instrumenta – Cronbachov α koeficijent za Stup 5: Pravila podataka (pojedinačno za P5-1 do P5-3)

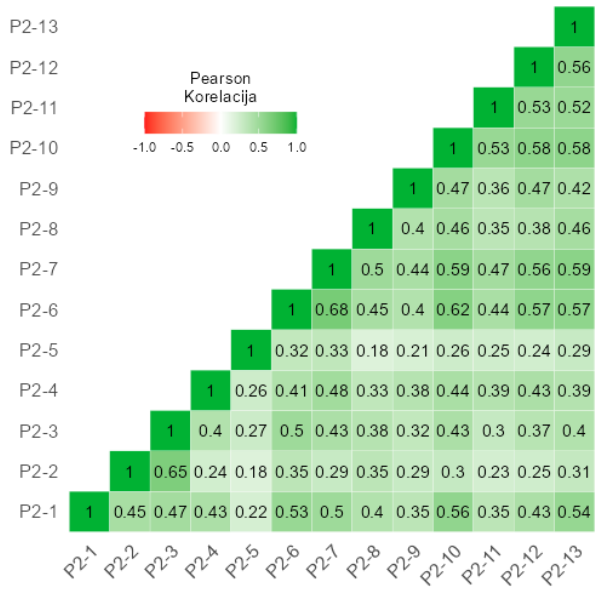
				Ako se stavka izostavi
	Srednja vrijednost	Standardna devijacija	Korelacija stavke s ukupnim rezultatom bez te stavke	Cronbachov α
P5-1	2,52	1,39	0,764	0,677
P5-2	2,31	1,31	0,736	0,710
P5-3	2,72	1,36	0,564	0,877

Rezultati analize pouzdanosti potvrđuju izvrsnu internu konzistentnost instrumenta. Cronbachov α koeficijent kreće se od 0,827 (Stup 5) do 0,937 (Stup 1), što je znatno iznad preporučene granice od 0,70. Dodatno, vizualni prikaz korelacija između stavki potvrđuje homogenost unutar svake dimenzije.

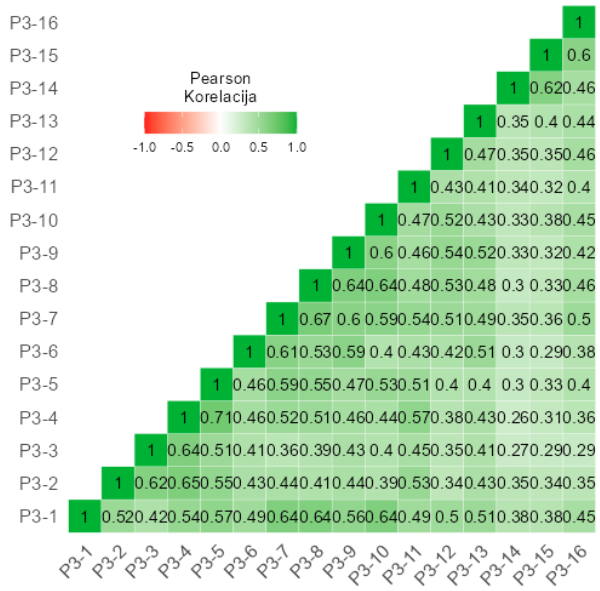


Slika 4.3. Toplinski prikaz (eng. *heatmap*) korelacija između stavki unutar Stupa 1: Strategija i kultura

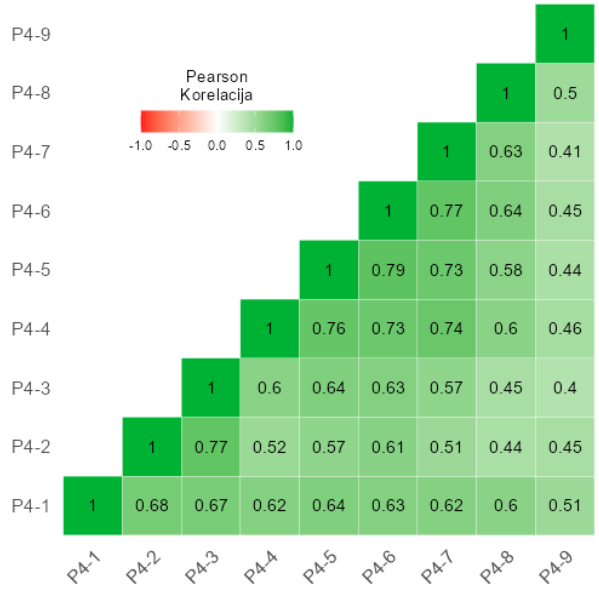
-



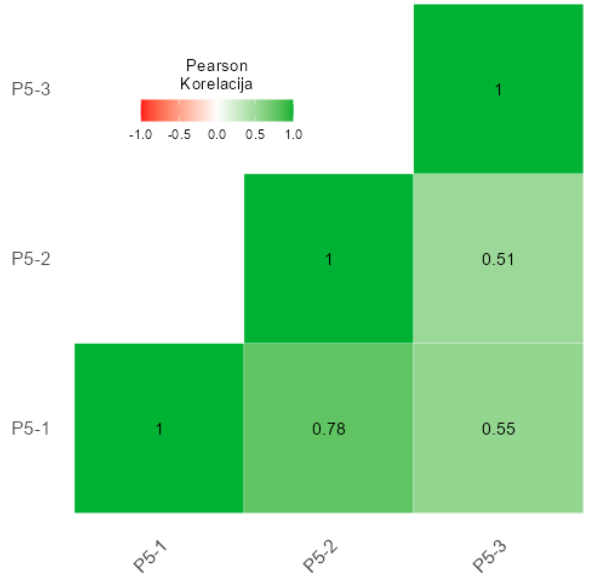
Slika 4.4. Toplinski prikaz (eng. *heatmap*) korelacija između stavki unutar Stupa 2: Tehnologija



Slika 4.5. Toplinski prikaz (eng. *heatmap*) korelacija između stavki unutar Stupa 3: Podaci i analitika



Slika 4.6. Toplinski prikaz (eng. *heatmap*) korelacija između stavki unutar Stupa 4: Sposobnost



Slika 4.7. Toplinski prikaz (eng. *heatmap*) korelacija između stavki unutar Stupa 5: Pravila podataka

Toplinski prikazi (heatmap) Pearsonovih korelacija između pojedinačnih stavki unutar pet identificiranih stupova digitalne zrelosti (Slike 4.3. do 4.7.) demonstriraju visoku razinu interne konzistentnosti i validnosti konstruktata. U svim matricama dominiraju pozitivne korelacije (vizualno predstavljene nijansama zelene boje), dok su negativne korelacije (crvena boja) potpuno odsutne, što potvrđuje da stavke unutar svakog stupnja koherentno mjere istu dimenziju zrelosti. Konkretno, u **Stupu 1 (Strategija i kultura)** ističu se jake veze između stavki poput P1-7 i P1-8 (r=0,76) te P1-9 i P1-10 (r=0,70), ukazujući na usku povezanost strateških i kulturnih aspekata. **Stup 2 (Tehnologija)** bilježi umjerene do jake korelacije (npr. P2-6 i P2-7, r=0,68), dok **Stup 3 (Podaci i analitika)**, unatoč velikom broju varijabli, pokazuje

snažne klastere povezanosti, poput para P3-3 i P3-4 (r=0,72). **Stup 4 (Sposobnost)** karakterizira izrazito visoka interna homogenost, s korelacijama koje često prelaze 0,75 (npr. P4-2 i P4-3, r=0,77; P4-5 i P4-6, r=0,79), što sugerira da su digitalne vještine i kompetencije snažno grupirane. Konačno, **Stup 5 (Pravila podataka)** pokazuje snažnu povezanost između ključnih stavki P5-1 i P5-2 (r=0,78). Ovi rezultati nedvojbeno potvrđuju pouzdanost korištenog instrumenta, jer visoke pozitivne korelacije unutar svakog stupnja impliciraju da se digitalna zrelost može pouzdano mjeriti kroz ovih pet distinktnih, ali interno konzistentnih dimenzija.

4.4.Analiza glavnih komponenti (PCA)

S ciljem provjere dimenzionalnosti instrumenta digitalne zrelosti i opravdanosti spajanja pet stupnjeva u globalni indeks, provedena je Analiza glavnih komponenti (PCA) na razini kreiranih stupnjeva (Indeks_Stup1 do Indeks_Stup5). PCA je metoda redukcije dimenzionalnosti koja identificira glavne komponente koje objašnjavaju najveći dio varijance u podacima. Rezultat PCA analize pokazat će koliko komponenti je potrebno za objašnjenje varijance u podacima te koliko se svaki od pet stupnjeva „opterećuje“ (povezuje) s tim komponentama.

Tablica 4.13. Kaiser-Meyer-Olkin (KMO) mjera prikladnosti uzorkovanja

	MSA
Sveukupno	0,872
Indeks_Stup1	0,853
Indeks_Stup2	0,919
Indeks_Stup3	0,835
Indeks_Stup4	0,903
Indeks_Stup5	0,874

Tablica 4.14. Bartlettov test sferičnosti

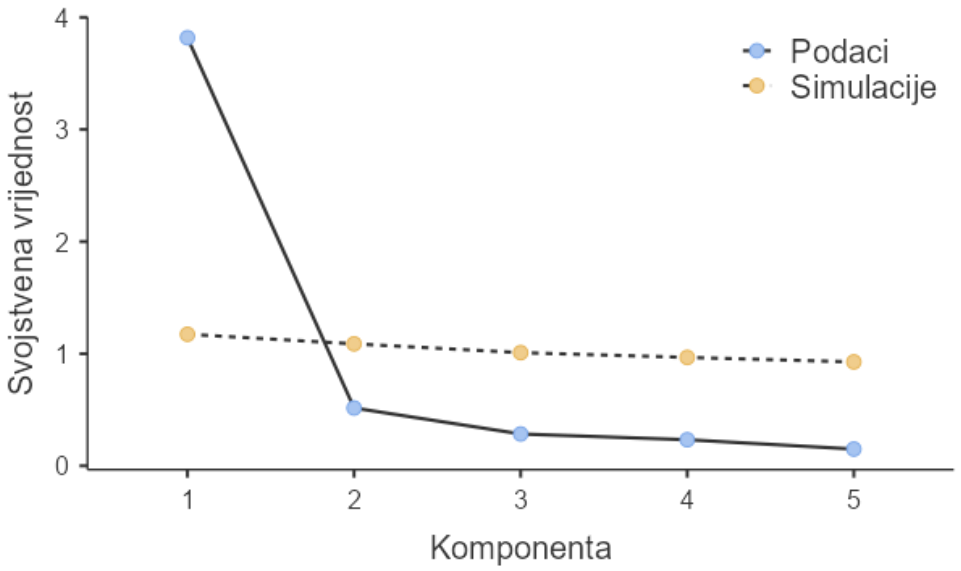
χ^2	df	p
2212	10	<,001

Kaiser-Meyer-Olkin (KMO) mjera prikladnosti uzorka iznosi 0,872, što ukazuje na izvrsnu prikladnost podataka za ocjenu čimbenika. Bartlettov test sferičnosti je statistički značajan (χ^2

= 2212, p < ,001), potvrđujući da između varijabli postoji dovoljan stupanj korelacije za provođenje PCA.

Tablica 4.15. Svojstvene vrijednosti (eigenvalues) i postotak objašnjene varijance po komponentama

Komponenta	Svojstvena vrijednost	% varijanci	Kumulativni postotak
1	3,818	76,36	76,4
2	0,516	10,32	86,7
3	0,284	5,68	92,4
4	0,233	4,65	97,0
5	0,149	2,99	100,0



Slika 4.8. Scree dijagram za analizu glavnih komponenti

Analiza glavnih komponenti (PCA) provedena na pet stupnjeva digitalne zrelosti potvrđuje postojanje jednog dominantnog latentnog ocjenu čimbenika koji objašnjava većinu varijance u podacima. Kao što je prikazano u Tablici 4.15., prva glavna komponenta ima svojstvenu vrijednost (eigenvalue) od 3,818 i objašnjava **76,36% ukupne varijance**, dok preostale četiri komponente imaju svojstvene vrijednosti znatno niže od 1 (0,516; 0,284; 0,233 i 0,149), objašnjavajući redom 10,32%, 5,68%, 4,65% i 2,99% varijance. Ovakav raspored jasno je vidljiv i na Scree dijagramu (Slika 4.8.), gdje se uočava strmi pad svojstvene vrijednosti nakon prve komponente, pri čemu sve naredne komponente padaju ispod razine simuliranih slučajnih

podataka (narančasta isprekidana linija), što prema Kaiserovom kriteriju i scree testu nedvojbeno opravdava zadržavanje samo jedne glavne komponente. Činjenica da prva komponenta objašnjava više od tri četvrtine ukupne varijance, uz visoka opterećenja čimbenika svih pet stupnjeva na tu komponentu (u rasponu od 0,780 do 0,923), potvrđuje da stupnjevi Strategija i kultura, Tehnologija, Podaci i analitika, Sposobnost te Pravila podataka koherentno mjere jedan širi konstrukt – globalnu digitalnu zrelost poljoprivrednih gospodarstava. Stoga je njihovo objedinjavanje u jedinstveni globalni indeks digitalne zrelosti metodološki potpuno opravdano, budući da sve dimenzije snažno konvergiraju prema istom temeljnom latentnom čimbenika.

Tablica 4.16. Opterećenja komponenti (component loadings) za pet indeksa digitalne zrelosti

	Komponenta	
	1	Jedinstvenost
Indeks_Stup1	0,908	0,175
Indeks_Stup2	0,780	0,391
Indeks_Stup3	0,923	0,147
Indeks_Stup4	0,900	0,189
Indeks_Stup5	0,849	0,279

Napomena: Korištena je 'varimax' rotacija

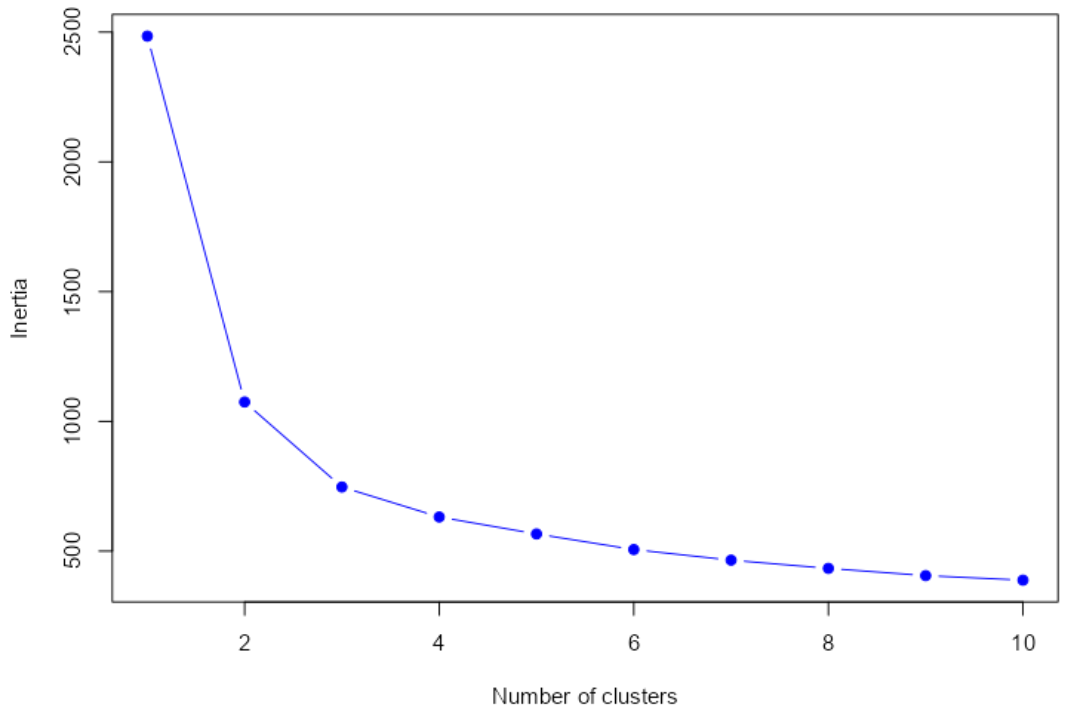
Visoka opterećenja svih pet stupnjeva na prvu komponentu (raspon od 0,780 do 0,923) potvrđuju da digitalna zrelost u hrvatskoj poljoprivredi funkcionira kao snažno povezan, unitaran konstrukt, gdje sve dimenzije zajednički doprinose ukupnoj razini digitalne transformacije gospodarstva.

4.5. Segmentacija gospodarstava – Klasterska analiza

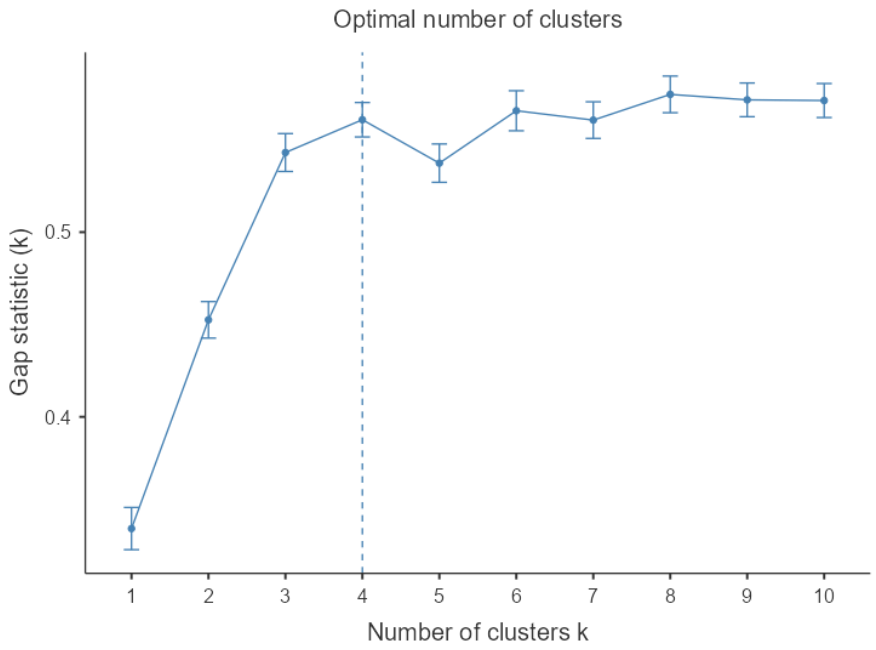
Kako bi se poljoprivredna gospodarstva grupirala u homogene profile s obzirom na njihovu digitalnu zrelost, provedena je klasterska analiza. S obzirom na to da su sve varijable korištene u analizi (Indeks_Stup1 do Indeks_Stup5) kontinuirane (na skali od 1 do 5), primijenjena je **K-means clustering** metoda, koja je najprikladnija za grupiranje objekata na temelju kontinuiranih varijabli (prema uputama *snowCluster* modula u Jamoviju).

Provedenom segmentacijom poljoprivrednih gospodarstava optimalan broj klastera određenje primjenom triju komplementarnih metoda. Elbow plot (Slika 4.9.) prikazuje ovisnost inercije

(unutar-klasterske sume kvadrata) o broju klastera, pri čemu se uočava strmi pad vrijednosti inercije pri prijelazu s jednog na dva klastera (s približno 2500 na 1050), nakon čega krivulja postupno poprima blaži nagib. Točka „lakta“ jasno je vidljiva u području između tri i četiri klastera, gdje dodatno povećanje broja klastera donosi sve manje marginalno poboljšanje u objašnjenoj varijanci, što sugerira da je rješenje s četiri klastera statistički opravdano. Ovu spoznaju potvrđuje i Gap statistic plot (Slika 4.10.), koji uspoređuje logaritam unutar-klasterske disperzije s očekivanom disperzijom referentne distribucije. Grafikon pokazuje da Gap statistika doseže svoj prvi lokalni maksimum pri k=4 (označeno okomitom isprekidanom linijom), pri čemu vrijednost iznosi približno 0,75, dok se za manji broj klastera (k=1, 2, 3) bilježi znatno niža statistika, a za veći broj klastera vrijednosti osciliraju bez jasnog trenda rasta. Silhouette index, koji mjeri koheziju i separaciju klastera, također je potvrdio da rješenje s četiri klastera pruža najbolju ravnotežu između unutarnje homogenosti i međusobne razdvojenosti grupa.



Slika 4.9. Elbow plot („lakat“ dijagram) za određivanje optimalnog broja klastera



Slika 4.10. Gap statistic plot za određivanje optimalnog broja klastera

S obzirom na to da su sve tri metode konzistentno ukazale na isto rješenje, usvojeno je da četiri klastera predstavljaju optimalan broj za segmentaciju hrvatskih poljoprivrednih gospodarstava s obzirom na njihovu digitalnu zrelost, što je u skladu s prethodnim istraživanjima u ovom području (CSIRO, 2019) i osigurava dovoljnu interpretibilnost profila uz zadržavanje statističke robustnosti.

Tablica 4.17. Distribucija poljoprivrednih gospodarstava po klasterima – veličine klastera (N = 565)

Broj klastera	Broj
1	99
2	156
3	161
4	149

Nadalje, prosječni Silhouette index iznosi 0,52, što ukazuje na **dobro definiranu strukturu klastera** (vrijednosti iznad 0,50 smatraju se pokazateljem jasne separacije između grupa). Klaster 1 pokazuje najviši Silhouette index (0,55), što znači da su gospodarstva u tom klasteru najhomogenija i najjasnije odvojena od ostalih klastera.

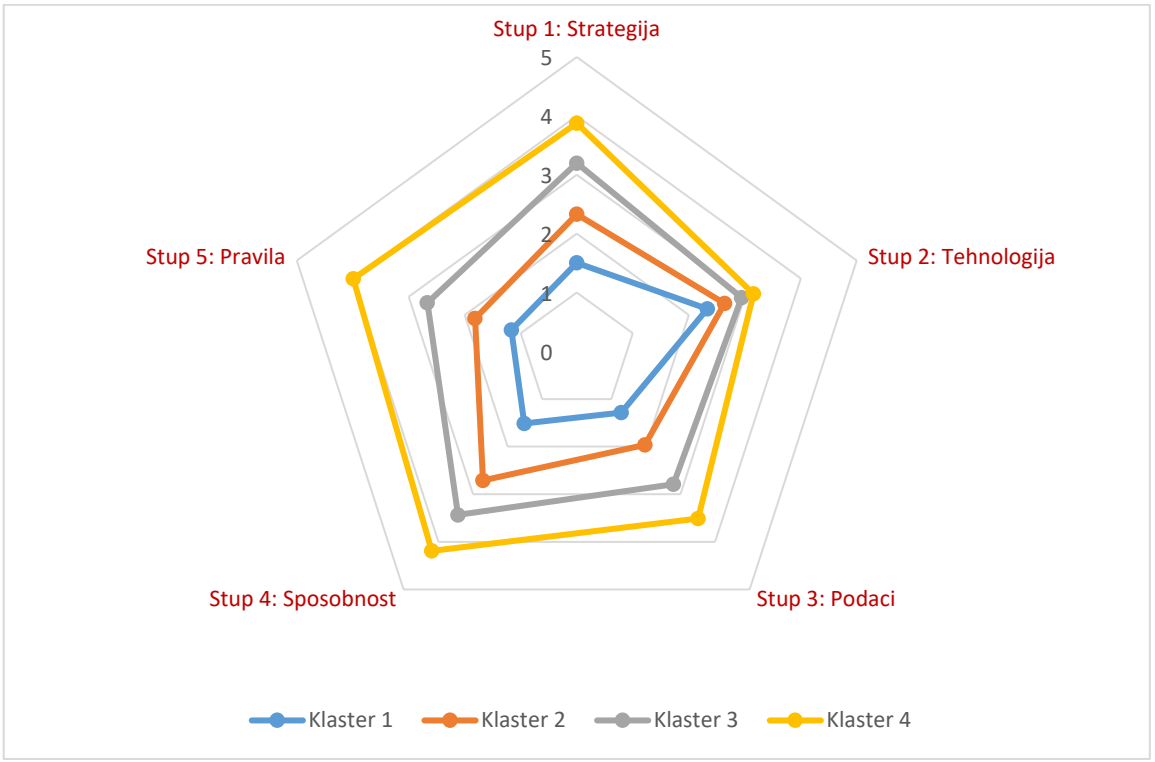
4.5.1. Profiliranje klastera prema demografskim i organizacijskim karakteristikama

Na temelju vrijednosti centroida (Tablica 4.18.), klasteri su profilirani na sljedeći način:

- **Klaster 1 (n=99):** gospodarstva s najnižim prosječnim ocjenama na svim stupovima (npr. Stup 3 = 1,288; Stup 5 = 1,168), što ukazuje na gotovo potpuni izostanak digitalnih praksi i strategija.
- **Klaster 2 (n=156):** gospodarstva s niskim do umjerenim rezultatima (prosjeci između 1,816 i 2,710), koja tek počinju usvajati osnovne tehnologije bez sustavne analitike.
- **Klaster 3 (n=161):** gospodarstva s umjerenim do visokim rezultatima (prosjeci od 2,667 do 3,433), koja posjeduju tehnologiju i vještine, ali im analitika podataka predstavlja prostor za napredak.
- **Klaster 4 (n=149):** gospodarstva s najvišim razinama zrelosti na svim stupovima (prosjeci od 3,157 do 4,190), koja su u potpunosti integrirala digitalne tehnologije, podatke i strategiju u svoje poslovanje.

Tablica 4.18. Centroidi klastera za pet indeksa stupova digitalne zrelosti

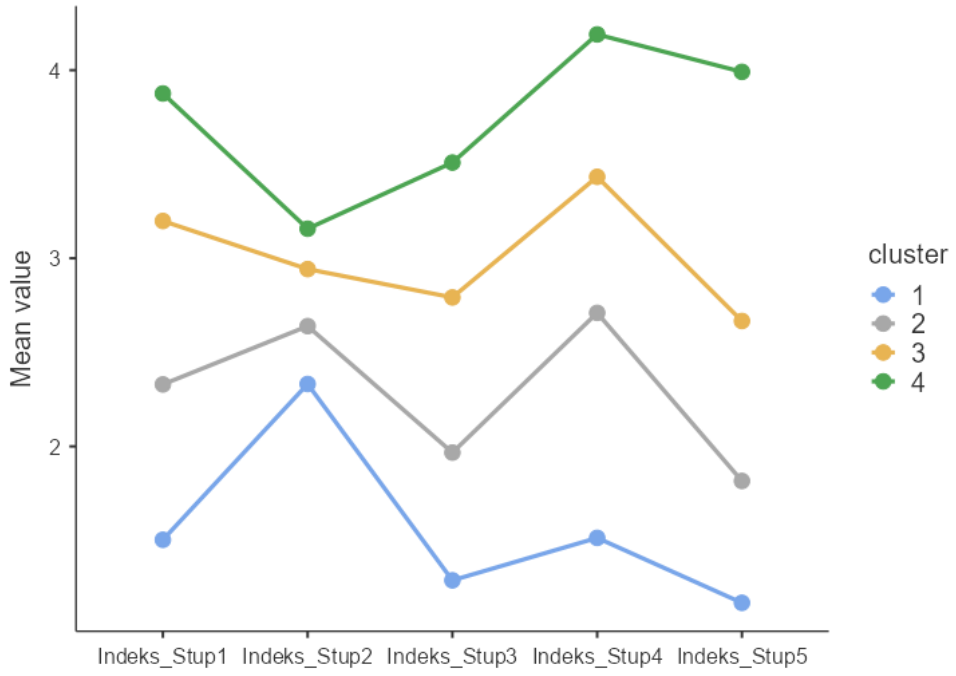
	Indeks_Stup1	Indeks_Stup2	Indeks_Stup3	Indeks_Stup4	Indeks_Stup5
1	1,503	2,332	1,288	1,514	1,168
2	2,329	2,639	1,967	2,710	1,816
3	3,198	2,943	2,792	3,433	2,667
4	3,876	3,157	3,509	4,190	3,991



Slika 4.11. Radar dijagram profila četiriju klastera poljoprivrednih gospodarstava

Radar dijagram (Slika 4.11.) vizualno prikazuje prosječne vrijednosti pet stupnjeva digitalne zrelosti za svaki od četiriju identificiranih klastera poljoprivrednih gospodarstava. Dijagram omogućuje istovremenu usporedbu profila klastera kroz sve dimenzije digitalne zrelosti, pri čemu svaka os predstavlja jedan stup (Strategija, Tehnologija, Podaci, Sposobnost, Pravila), a vrijednosti se kreću u rasponu od 0 do 5. Analiza dijagrama otkriva da svi klasteri prate sličan obrazac varijacija kroz stupnjeve, s konzistentno najnižim vrijednostima u dimenziji **Podaci i analitika (Stup 3)** i najvišim vrijednostima u dimenziji **Sposobnost (Stup 4)**. Ovaj obrazac prisutan je u sva četiri klastera, neovisno o njihovoj ukupnoj razini digitalne zrelosti, što sugerira da je upravljanje podacima i analitika sustavni izazov za hrvatska poljoprivredna gospodarstva. Dijagram jasno prikazuje hijerarhijsku strukturu klastera. **Klaster 1** (plava linija) zauzima najmanju površinu unutar dijagrama, s prosječnim vrijednostima koje se kreću od 1,168 (Stup 5: Pravila) do 2,332 (Stup 2: Tehnologija), što vizualno potvrđuje njegovu pripadnost skupini s najnižom razinom digitalne zrelosti. **Klaster 2** (narančasta linija) bilježi nešto više vrijednosti, s rasponom od 1,816 (Stup 5) do 2,710 (Stup 4), pri čemu je vidljiv izraženiji porast u dimenziji Sposobnosti u odnosu na Klaster 1. **Klaster 3** (siva linija) pokazuje umjereno visoke rezultate u svim dimenzijama, s vrijednostima od 2,667 (Stup 5) do 3,433 (Stup 4). Zanimljivo je da ovaj klaster bilježi značajan pad u dimenziji Podaci i analitika (M = 2,792) u odnosu na susjedne stupnjeve, što ukazuje na specifično usko grlo u ovoj dimenziji čak i za gospodarstva s umjerenom do visokom digitalnom zrelošću. Nadalje, **Klaster 4** (žuta

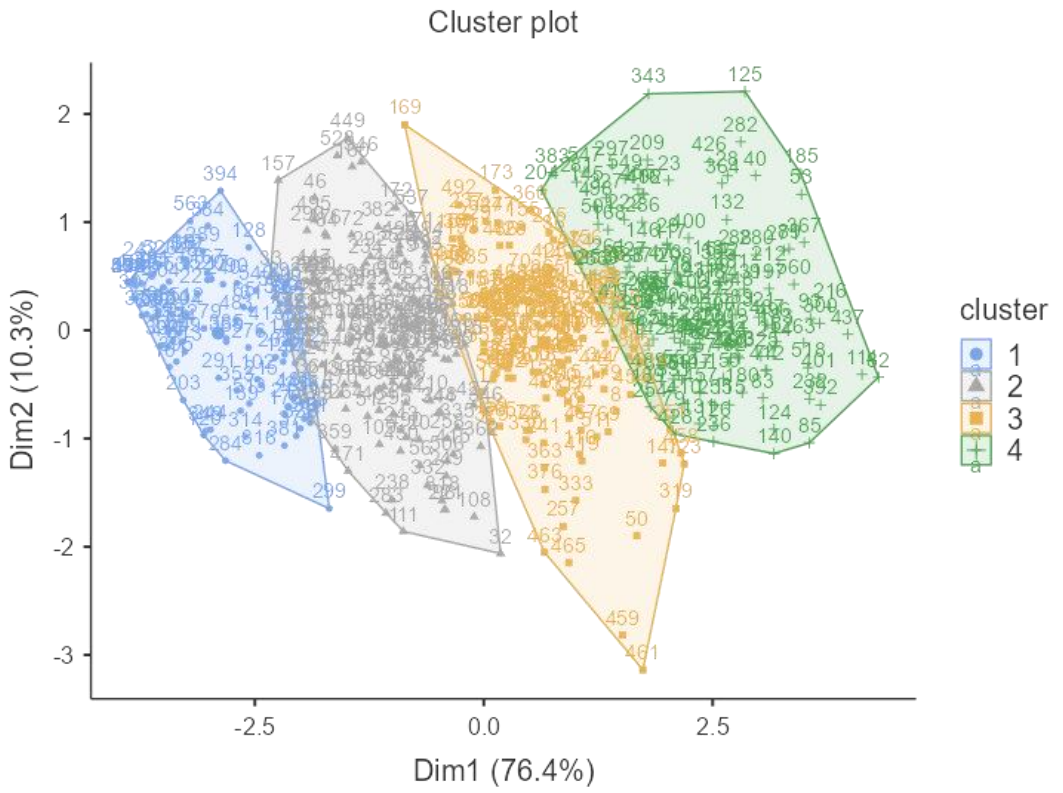
linija) dominira s najvećom površinom unutar dijagrama, dosežući vrhunske vrijednosti u svim stupnjevima, od 3,157 (Stup 2: Tehnologija) do 4,190 (Stup 4: Sposobnost). Ovaj klaster je jedini koji u dimenziji Sposobnost prelazi vrijednost 4,0, što ga jasno diferencira od ostalih klastera. Raspon između najnižeg i najvišeg klastera varira po stupnjevima. Najveća razlika uočava se u dimenziji **Pravila podataka (Stup 5)**, gdje Klaster 4 (M = 3,991) bilježi gotovo 3,4 puta višu vrijednost od Klastera 1 (M = 1,168). Slično, u dimenziji **Podaci i analitika (Stup 3)** razlika iznosi 2,7 puta (3,509 naspram 1,288). Nasuprot tome, najmanja razlika između klastera prisutna je u dimenziji **Tehnologija (Stup 2)**, gdje se vrijednosti kreću od 2,332 do 3,157, što sugerira da je tehnološka opremljenost manje diferencirajuća dimenzija u odnosu na „meke“ aspekte digitalne zrelosti poput upravljanja podacima i uspostave pravila. Ovakav vizualni prikaz potvrđuje da klasterska analiza uspješno identificira četiri jasno diferencirana profila poljoprivrednih gospodarstava, pri čemu svaki klaster zauzima distinctan prostor unutar petodimenzionalnog prostora digitalne zrelosti, s minimalnim preklapanjem između susjednih klastera.



Slika 4.12. Profilni dijagram klastera

Profilni dijagram klastera (Slika 4.12.) vizualno prikazuje razlike u prosječnim vrijednostima indeksa digitalne zrelosti kroz pet stupova za svaki od četiriju identificiranih klastera. Analiza profila potvrđuje jasnu hijerarhiju u razini digitalne integracije među gospodarstvima. Klaster 1 (n=99) zauzima najnižu poziciju na grafikonu, s prosječnim vrijednostima koje se kreću od

približno 1,2 do 2,3, što odražava gotovo potpuni izostanak digitalnih praksi. Klaster 2 (n=156) bilježi nešto više, ali i dalje niske do umjerene rezultate (prosjeci između 1,8 i 2,7), s vidljivim porastom na drugom i četvrtom stupu. Klaster 3 (n=161) pokazuje umjereno visoke rezultate (prosjeci od 2,6 do 3,4), pri čemu je najviša vrijednost zabilježena na četvrtom stupu (oko 3,4), dok treći stup predstavlja pad u odnosu na susjedne stupove. Klaster 4 (n=149) dominira s najvišim prosječnim vrijednostima na svim stupovima (od 3,1 do 4,2), dosežući vrhunac na četvrtom stupu (iznad 4,0). Zanimljivo je da svi klasteri prate sličan obrazac varijacija kroz stupove, s padom vrijednosti na trećem stupu i vrhuncem na četvrtom stupu, što sugerira da je treći stup (vezan uz analitiku podataka) izazov za sva gospodarstva, neovisno o njihovoj ukupnoj razini digitalne zrelosti, dok je četvrti stup područje u kojem digitalno najzrelija gospodarstva ostvaruju najveću prednost.

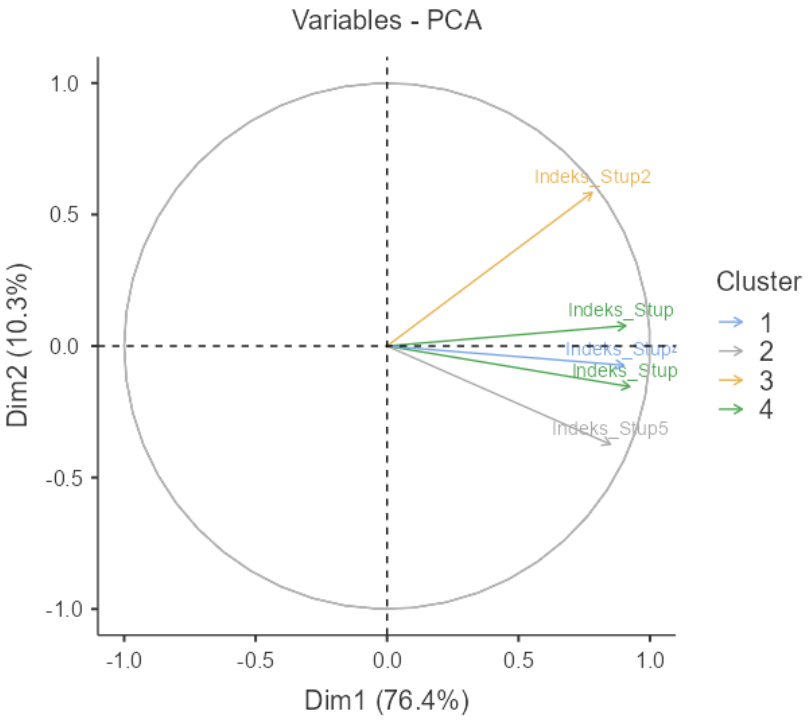


Slika 4.13. Dijagram raspršenja klastera

Dijagram raspršenja klastera (Slika 4.13.) prikazuje prostornu distribuciju četiriju identificiranih klastera u dvodimenzionalnom prostoru definiranim prvom (Dim1) i drugom (Dim2) dimenzijom, koje objašnjavaju 76,4% odnosno 10,3% ukupne varijance podataka. Vizualizacija otkriva izrazito jasnu linearnu separaciju klastera duž prve dimenzije (Dim1), koja očito predstavlja glavni gradijent digitalne zrelosti gospodarstava. Klaster 1 pozicioniran je na krajnjem lijevom dijelu osi (negativne vrijednosti Dim1), što vizualno potvrđuje njegovu

pripadnost skupini s najnižom razinom zrelosti. Desno od njega, u smjeru rasta vrijednosti Dim1, sukcesivno se nižu Klaster 2 i Klaster 3, dok Klaster 4 zauzima krajnji desni položaj na osi, odgovarajući gospodarstvima s najvišom digitalnom zrelošću. Iako su klasteri duž prve dimenzije dobro razdvojeni, uočljivo je određeno preklapanje između susjednih klastera (poput Klastera 2 i 3 te Klastera 3 i 4), što sugerira postojanje prijelaznih oblika između razina zrelosti. Također, Klaster 3 pokazuje najveću varijabilnost duž druge dimenzije (Dim2), s izraženim širenjem prema negativnim vrijednostima, dok su ostali klasteri vertikalno kompaktniji.

Validnost klastera potvrđena je i dijagramom klasteriranja varijabli (PCA). Slika 4.14. prikazuje strukturu korelacija između pet indeksa stupova digitalne zrelosti (Indeks_Stup1 do Indeks_Stup5) unutar prostora prve dvije dimenzije. Prva dimenzija (Dim1), koja objašnjava dominantnih 76,4% ukupne varijance, pokazuje snažnu pozitivnu korelaciju sa svim promatranim varijablama, budući da se svi vektori nalaze na pozitivnoj strani osi i usmjereni su udesno prema rubu korelacijskog kruga. Ovo nedvojbeno potvrđuje da Dim1 predstavlja generalni čimbenik digitalne zrelosti, pri čemu porast vrijednosti na ovoj osi implicira istovremeni rast svih pojedinačnih indeksa, što je u potpunosti konzistentno s prethodno utvrđenim linearnim rasporedom klastera (od Klastera 1 na negativnom kraju do Klastera 4 na pozitivnom kraju). Druga dimenzija (Dim2), koja objašnjava 10,3% varijance, omogućuje diferencijaciju specifičnih aspekata zrelosti: Indeks_Stup2 ima izraženo pozitivno opterećenje na ovu dimenziju (vektor usmjeren prema gore), dok Indeks_Stup5 ima negativno opterećenje (vektor usmjeren prema dolje). Preostali indeksi (Indeks_Stup1, Indeks_Stup3 i Indeks_Stup4) nalaze se vrlo blizu horizontalne osi (Dim1), što ukazuje na to da su oni najizravniji indikatori opće razine digitalizacije, dok Indeks_Stup2 i Indeks_Stup5 unose specifičnu varijancu koja može razlikovati gospodarstva slične opće zrelosti, ali različitog profila u tim specifičnim područjima.



Slika 4.14. Dijagram klasteriranja varijabli temeljen na analizi glavnih komponenti

Kako bi se utvrdilo koje demografske i organizacijske karakteristike definiraju pojedine klastere poljoprivrednih gospodarstava, provedena je analiza povezanosti između pripadnosti klasteru i ključnih varijabli: dobi nositelja gospodarstva (D1), razine obrazovanja (D3), veličine poljoprivrednog posjeda (D10), broja zaposlenih (D11) i godišnjih poslovnih prihoda (D12). Za sve analize korišten je Hi-kvadrat test neovisnosti (χ^2).

Tablica 4.19. Tablica kontingencije između globalnog indeksa digitalne zrelosti i dobi nositelja gospodarstva (D1) (N = 565)

Klasteri		D1_kodirano					Ukupno
		1	2	3	4	5	
Srednje zreli/Pragmatičari	Opaženo	14	37	37	32	41	161
	Očekivano	12,82	27,9	35,6	32,8	51,9	161,0
	% unutar reda	8,7%	23,0%	23,0%	19,9%	25,5%	100,0%
Digitalni lideri	Opaženo	23	41	44	25	16	149
	Očekivano	11,87	25,8	33,0	30,3	48,0	149,0
	% unutar reda	15,4%	27,5%	29,5%	16,8%	10,7%	100,0%

Klasteri		D1_kodirano					Ukupno
		1	2	3	4	5	
Slabije zreli/Tradicionalisti	Opaženo	6	17	34	37	62	156
	Očekivano	12,42	27,1	34,5	31,8	50,3	156,0
	% unutar reda	3,8%	10,9%	21,8%	23,7%	39,7%	100,0%
Digitalni početnici	Opaženo	2	3	10	21	63	99
	Očekivano	7,88	17,2	21,9	20,2	31,9	99,0
	% unutar reda	2,0%	3,0%	10,1%	21,2%	63,6%	100,0%
Ukupno	Opaženo	45	98	125	115	182	565
	Očekivano	45	98	125	115	182	565
	% unutar reda	8,0%	17,3%	22,1%	20,4%	32,2%	100,0%

Tablica 4.20. Tablica kontingencije između globalnog indeksa digitalne zrelosti i razine obrazovanja nositelja gospodarstva (D3) (N = 565)

Klasteri		D3_kodirano							Ukupno
		1	1,67	2,34	3,01	3,68	4,35	5	
Srednje zreli/Pragmatičari	Opaženo	9	89	17	27	15	3	1	161
	Očekivano	15,39	88,3	16,5	21,7	13,96	3,13	1,99	161,0
	% unutar reda	5,6%	55,3%	10,6%	16,8%	9,3%	1,9%	0,6%	100,0%
Digitalni lideri	Opaženo	1	64	21	27	24	8	4	149
	Očekivano	14,24	81,8	15,3	20,0	12,92	2,90	1,85	149,0
	% unutar reda	0,7%	43,0%	14,1%	18,1%	16,1%	5,4%	2,7%	100,0%

Klasteri		D3_kodirano							Ukupno
		1	1,67	2,34	3,01	3,68	4,35	5	
Slabije zreli/Tradicionalisti	Opaženo	21	97	13	15	8	0	2	156
	Očekivano	14,91	85,6	16,0	21,0	13,53	3,04	1,93	156,0
	% unutar reda	13,5%	62,2%	8,3%	9,6%	5,1%	0,0%	1,3%	100,0%
Digitalni početnici	Opaženo	23	60	7	7	2	0	0	99
	Očekivano	9,46	54,3	10,2	13,3	8,59	1,93	1,23	99,0
	% unutar reda	23,2%	60,6%	7,1%	7,1%	2,0%	0,0%	0,0%	100,0%
Ukupno	Opaženo	54	310	58	76	49	11	7	565
	Očekivano	54	310	58	76	49	11	7	565
	% unutar reda	9,6%	54,9%	10,3%	13,5%	8,7%	1,9%	1,2%	100,0%

Tablica 4.21. Tablica kontingencije između globalnog indeksa digitalne zrelosti i veličine poljoprivrednog posjeda (D10) (N = 565)

Klasteri		D10_kodirano									Ukupno
		1	1,08	2,6	3,4	4,2	5	2,6 (2)	3,4 (2)	3,4 (3)	
Srednje zreli/Pragmatičari	Opaženo	33	41	44	18	15	10	0	0	0	161
	Očekivano	33,9	47,6	41,3	15,67	13,11	8,55	0,285	0,285	0,285	161,0

Klasteri		D10_kodirano									Ukupno
		1	1,08	2,6	3,4	4,2	5	2,6 (2)	3,4 (2)	3,4 (3)	
	% unutar reda	20,5%	25,5%	27,3%	11,2%	9,3%	6,2%	0,0%	0,0%	0,0%	100,0%
Digitalni lideri	Opaženo	20	35	35	19	21	18	1	0	0	149
	Očekivano	31,4	44,0	38,2	14,50	12,13	7,91	0,264	0,264	0,264	149,0
	% unutar reda	13,4%	23,5%	23,5%	12,8%	14,1%	12,1%	0,7%	0,0%	0,0%	100,0%
Slabije zreli/Tradicionalisti	Opaženo	40	49	45	13	6	2	0	1	0	156
	Očekivano	32,9	46,1	40,0	15,19	12,70	8,28	0,276	0,276	0,276	156,0
	% unutar reda	25,6%	31,4%	28,8%	8,3%	3,8%	1,3%	0,0%	0,6%	0,0%	100,0%
Digitalni početnici	Opaženo	26	42	21	5	4	0	0	0	1	99
	Očekivano	20,9	29,3	25,4	9,64	8,06	5,26	0,175	0,175	0,175	99,0
	% unutar reda	26,3%	42,4%	21,2%	5,1%	4,0%	0,0%	0,0%	0,0%	1,0%	100,0%
Ukupno	Opaženo	119	167	145	55	46	30	1	1	1	565
	Očekivano	119	167	145	55	46	30	1	1	1	565
	% unutar reda	21,1%	29,6%	25,7%	9,7%	8,1%	5,3%	0,2%	0,2%	0,2%	100,0%

Tablica 4.22. Tablica kontingencije između globalnog indeksa digitalne zrelosti i broja zaposlenih na poljoprivrednom gospodarstvu (D11) (N = 565)

Klasteri		D11_kodirano				Ukupno
		1	2,33	3,66	5	
Srednje zreli/Pragmatičari	Opaženo	161	0	0	0	161
	Očekivano	158,7	1,71	0,285	0,285	161,0
	% unutar reda	100,0%	0,0%	0,0%	0,0%	100,0%
Digitalni lideri	Opaženo	142	5	1	1	149
	Očekivano	146,9	1,58	0,264	0,264	149,0
	% unutar reda	95,3%	3,4%	0,7%	0,7%	100,0%
Slabije zreli/Tradicionalisti	Opaženo	155	1	0	0	156
	Očekivano	153,8	1,66	0,276	0,276	156,0
	% unutar reda	99,4%	0,6%	0,0%	0,0%	100,0%
Digitalni početnici	Opaženo	99	0	0	0	99
	Očekivano	97,6	1,05	0,175	0,175	99,0
	% unutar reda	100,0%	0,0%	0,0%	0,0%	100,0%
Ukupno	Opaženo	557	6	1	1	565
	Očekivano	557	6	1	1	565
	% unutar reda	98,6%	1,1%	0,2%	0,2%	100,0%

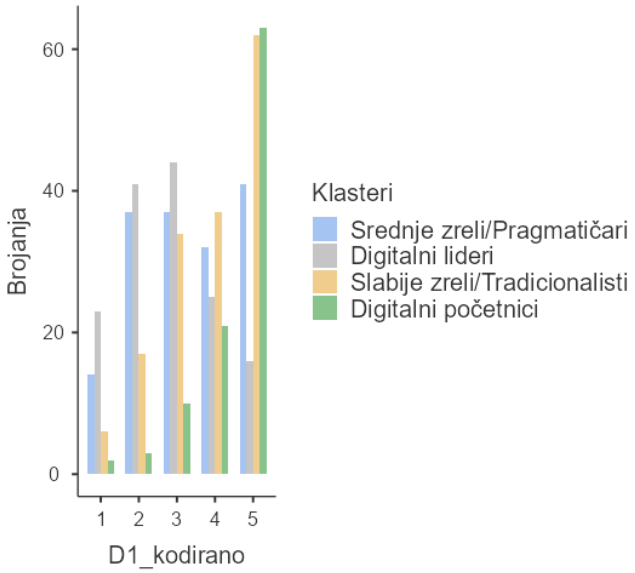
Tablica 4.23. Tablica kontingencije između globalnog indeksa digitalne zrelosti i godišnjih poslovnih prihoda (D12) (N = 565)

Klasteri		D12_kodirano					Ukupno
		1	2	3	4	5	
Srednje zreli/Pragmatičari	Opaženo	98	41	11	10	1	161
	Očekivano	106,9	33,9	9,97	9,12	1,140	161,0
	% unutar reda	60,9%	25,5%	6,8%	6,2%	0,6%	100,0%
Digitalni lideri	Opaženo	70	40	19	18	2	149

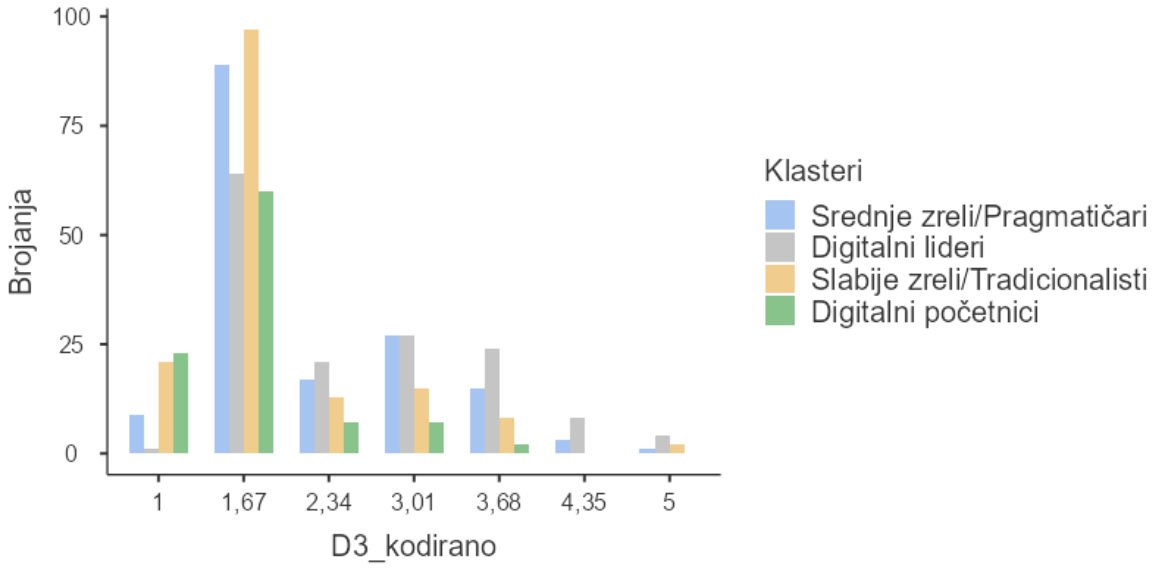
Klasteri		D12_kodirano					Ukupno
		1	2	3	4	5	
	Očekivano	98,9	31,4	9,23	8,44	1,055	149,0
	% unutar reda	47,0%	26,8%	12,8%	12,1%	1,3%	100,0%
Slabije zreli/Tradicionalisti	Opaženo	122	26	4	3	1	156
	Očekivano	103,5	32,9	9,66	8,84	1,104	156,0
	% unutar reda	78,2%	16,7%	2,6%	1,9%	0,6%	100,0%
Digitalni početnici	Opaženo	85	12	1	1	0	99
	Očekivano	65,7	20,9	6,13	5,61	0,701	99,0
	% unutar reda	85,9%	12,1%	1,0%	1,0%	0,0%	100,0%
Ukupno	Opaženo	375	119	35	32	4	565
	Očekivano	375	119	35	32	4	565
	% unutar reda	66,4%	21,1%	6,2%	5,7%	0,7%	100,0%

Analizom distribucije četiriju identificiranih klastera (Srednje zreli/Pragmatičari, Digitalni lideri, Slabije zreli/Tradicionalisti i Digitalni početnici) kroz odabrane varijable uočene su jasne razlike u njihovoj zastupljenosti (Slike 4.15. do 4.19.). S obzirom na dob nositelja gospodarstva, klasteri Slabije zreli/Tradicionalisti i Digitalni početnici najviše su zastupljeni u najstarijoj dobnoj kategoriji, dok su Digitalni lideri i Srednje zreli/Pragmatičari najbrojniji u kategorijama srednje životne dobi. Kada je riječ o razini obrazovanja nositelja gospodarstva, najniža razina obrazovanja bilježi najveću ukupnu frekvenciju s dominantnim udjelom Slabije zrelih/Tradicionalista, dok se s porastom razine obrazovanja povećava udio Digitalnih lidera i Pragmatičara, a smanjuje udio Digitalnih početnika. Veličina poljoprivrednog posjeda također je povezana s pripadnošću klasteru: manji posjedi pretežno pripadaju klasterima Slabije zreli/Tradicionalisti i Digitalni početnici, dok se udio Digitalnih lidera povećava s veličinom posjeda, pri čemu na najvećim posjedima gotovo u potpunosti istiskuju Tradicionaliste. Sličan obrazac vidljiv je i kod godišnjih poslovnih prihoda poljoprivrednog gospodarstva, gdje najnižu

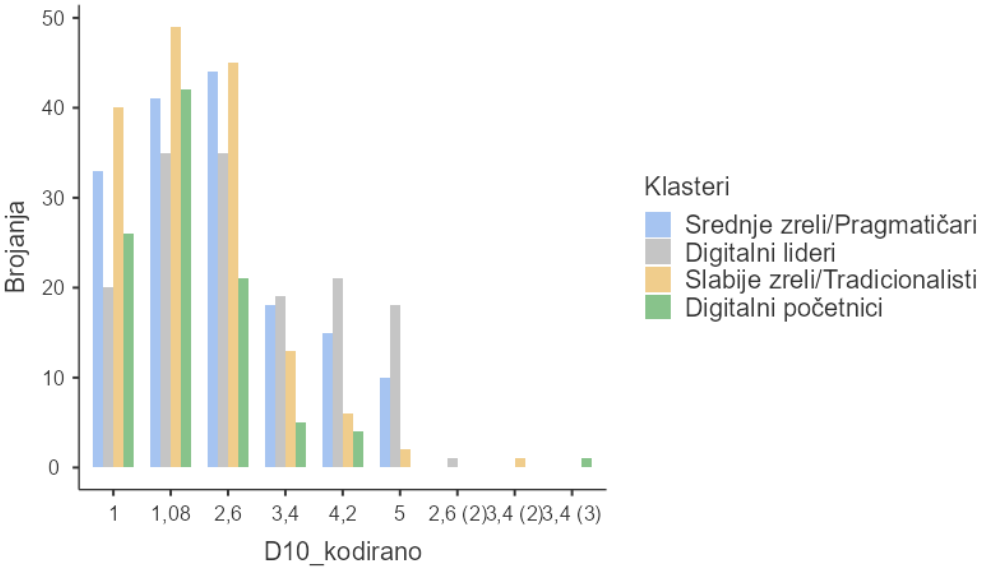
razinu prihoda karakterizira visoka zastupljenost Slabije zrelih/Tradicionalista, dok se na višim razinama prihoda povećava udio Srednje zrelih/Pragmatičara i Digitalnih lidera, uz istovremeni pad udjela Digitalnih početnika. Konačno, iako analiza broja zaposlenih na poljoprivrednom gospodarstvu pokazuje da sva gospodarstva pretežno imaju jednog zaposlenog, unutar te kategorije klaster Digitalni početnici bilježi nešto nižu frekvenciju u usporedbi s ostalim klasterima, dok se s povećanjem broja zaposlenih bilježi blagi porast prisutnosti digitalno zrelijih klastera.



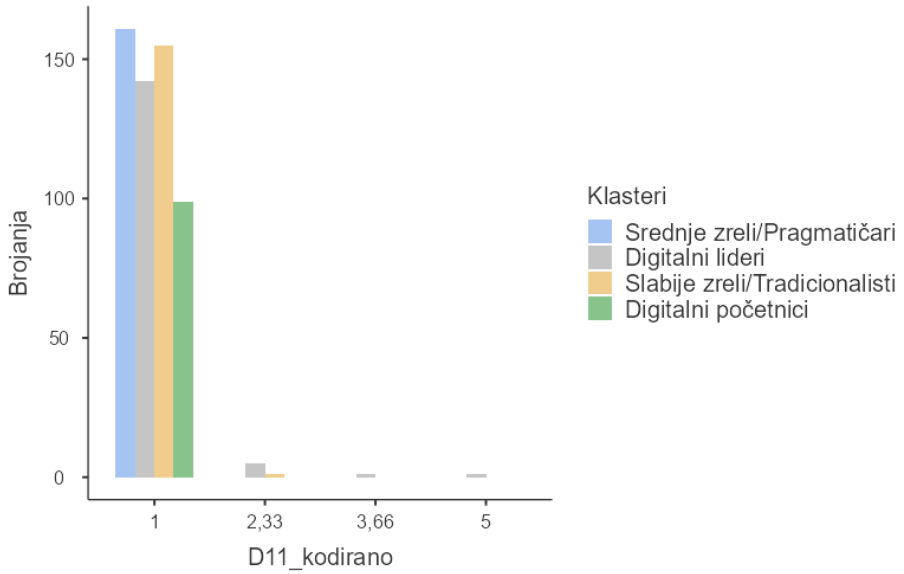
Slika 4.15. Raspodjela frekvencija varijable D1 po klasterima digitalne zrelosti



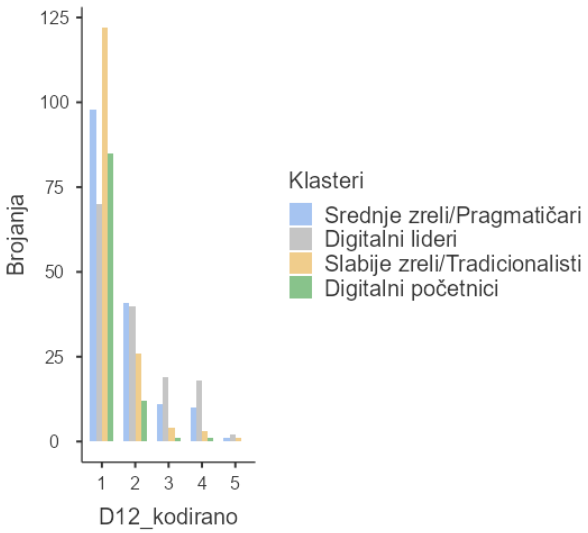
Slika 4.16. Raspodjela frekvencija varijable D3 po klasterima digitalne zrelosti



Slika 4.17. Raspodjela frekvencija varijable D10 po klasterima digitalne zrelosti



Slika 4.18. Raspodjela frekvencija varijable D11 po klasterima digitalne zrelosti



Slika 4.19. Raspodjela frekvencija varijable D12 po klasterima digitalne zrelosti

Rezultati Hi-kvadrat testova pokazali su da četiri od pet analiziranih varijabli imaju statistički visoko značajnu povezanost s pripadnošću klasteru, dok je jedna varijabla pokazala tek rubnu značajnost.

4.5.1.1. Dob nositelja gospodarstva (D1)

Hi-kvadrat test potvrdio je statistički visoko značajnu povezanost između dobi nositelja gospodarstva i pripadnosti klasteru ($\chi^2(12) = 114$; $p < ,001$). Analiza post-hoc postotaka otkrila je jasan obrazac: **Klaster 4 ("Digitalni lideri")** karakteriziraju najmlađi nositelji gospodarstava, pri čemu 42,9% pripada u dobne kategorije do 40 godina, dok samo 10,7% pripada u kategoriju iznad 60 godina. S druge strane, **Klaster 1 ("Digitalni početnici")** karakteriziraju najstariji nositelji, pri čemu dominira kategorija iznad 60 godina (63,6%), dok mlađi od 40 godina čine samo 5,0% ovog klastera. Klasteri 2 i 3 zauzimaju međupozicije, s postupnim pomakom ka starijim dobnim skupinama kako se prelazi iz Klastera 3 u Klaster 2.

4.5.1.2. Razina obrazovanja (D3)

Razina obrazovanja također pokazuje statistički visoko značajnu povezanost s pripadnošću klasteru ($\chi^2(18) = 90,0$; $p < ,001$). **Klaster 1 ("Digitalni početnici")** karakterizira izrazito niska razina obrazovanja, pri čemu 83,8% nositelja ima samo osnovno obrazovanje ili niže, dok visokoobrazovani čine manje od 2%. Suprotno tome, **Klaster 4 ("Digitalni lideri")**

karakterizira visoka razina obrazovanja, pri čemu 50,3% nositelja ima neku od visokoškolskih ili diplomskih kvalifikacija, dok nositelji s osnovnim obrazovanjem čine samo 0,7% ovog klastera. Ovi rezultati potvrđuju da je formalno obrazovanje jedan od najsnažnijih diferencijatora digitalne zrelosti.

4.5.1.3. Veličina poljoprivrednog posjeda (D10)

Veličina posjeda pokazuje statistički značajnu povezanost s pripadnošću klasteru ($\chi^2(24) = 67,2$; $p < ,001$). **Klaster 1 ("Digitalni početnici")** karakteriziraju najmanja gospodarstva, pri čemu 68,7% pripada u kategorije do 5 hektara, dok gospodarstva veća od 20 hektara čine manje od 1%. **Klaster 4 ("Digitalni lideri")** karakteriziraju značajno veća gospodarstva, pri čemu 26,2% pripada u kategorije iznad 20 hektara, uključujući 12,1% u kategoriji 50-100 hektara. Ovi rezultati sugeriraju da ekonomija razmjera i veći kapital omogućuju ulaganja u digitalne tehnologije.

4.5.1.4. Godišnji prihodi gospodarstva (D12)

Godišnji prihodi pokazuju statistički visoko značajnu povezanost s pripadnošću klasteru ($\chi^2(12) = 65,4$; $p < ,001$). **Klaster 1 ("Digitalni početnici")** karakteriziraju gospodarstva s najnižim prihodima, pri čemu 85,9% pripada u kategoriju do 10.000 EUR godišnje. Suprotno tome, **Klaster 4 ("Digitalni lideri")** pokazuju značajno širu distribuciju prihoda, pri čemu 26,2% pripada u kategorije iznad 25.000 EUR, uključujući 12,1% u kategoriji 50-100 tisuća EUR. Ovi rezultati potvrđuju da financijska moć gospodarstva predstavlja ključni preduvjet za digitalnu transformaciju.

4.5.1.5. Broj zaposlenih (D11)

Zanimljivo je da broj zaposlenih **nije pokazao statistički značajnu povezanost** s pripadnošću klasteru ($\chi^2(9) = 16,2$; $p = ,063$). Analiza distribucije otkrila je da gotovo sva gospodarstva (98,6% ukupnog uzorka) imaju samo 1-2 zaposlena, bez obzira na pripadnost klasteru. Ovaj nalaz sugerira da u hrvatskoj poljoprivredi, koja je dominantno obiteljska i mala, sama veličina radne snage nije diferencijator digitalne zrelosti, već su važniji obrazovanje, dob i financijski kapaciteti.

-

4.5.1.6. Sažetak profila klastera

Na temelju provedene analize profila, moguće je identificirati karakteristične profile poljoprivrednih gospodarstava unutar svakog klastera:

Tablica 4.24. Sažetak profila klastera poljoprivrednih gospodarstava

Karakteristika	Klaster 1 "Digitalni početnici" (n=99)	Klaster 2 "Slabije zreli/Tradicionalisti" (n=156)	Klaster 3 "Srednje zreli/Pragmatičari" (n=161)	Klaster 4 "Digitalni lideri" (n=149)
Dob nositelja	Dominantno >60 godina (63,6%)	Umjereno stariji (39,7% >60 god.)	Mlađi i srednja dob	Najmlađi (42,9% <40 god.)
Obrazovanje	Osnovno ili niže (83,8%)	Pretežno osnovno (62,2%)	Srednje i više	Visoko (50,3%)
Veličina posjeda	Najmanja (68,7% <5 ha)	Mala do srednja	Srednja	Najveća (26,2% >20 ha)
Godišnji prihodi	Najniži (85,9% <10k EUR)	Niski do umjereni	Umjereni	Najviši (26,2% >25k EUR)
Digitalna zrelost	Najniža u svim dimenzijama	Niska do umjerena	Umjerena do visoka	Najviša u svim dimenzijama

- **Klaster 1 („Digitalni početnici“)**: Karakteriziraju ga najstariji nositelji gospodarstva, najniža razina obrazovanja, najmanji posjedi i najniži godišnji prihodi. Ova gospodarstva imaju minimalnu digitalnu zrelost u svim dimenzijama i predstavljaju skupinu kojoj je potrebna najintenzivnija podrška u obliku edukacije, financijskih potpora i demonstracijskih projekata.
- **Klaster 2 („Slabije zreli/Tradicionalisti“)**: Karakteriziraju ga stariji nositelji gospodarstva, niža razina obrazovanja, manji posjedi i niži godišnji prihodi u usporedbi s Klasterom 4. Ova gospodarstva pokazuju nisku do umjerenu digitalnu zrelost, pri čemu je najveći jaz u dimenzijama upravljanja podacima i analitike. Potrebne su im ciljane edukacije iz područja digitalne pismenosti i poticaji za usvajanje osnovnih digitalnih alata.
- **Klaster 3 („Srednje zreli/Pragmatičari“)**: Karakteriziraju ga umjerena dob nositelja, srednja razina obrazovanja, srednja veličina posjeda i umjereni godišnji prihodi. Ova gospodarstva pokazuju umjerenu do visoku digitalnu zrelost, pri čemu je najveći prostor

za napredak u dimenzijama upravljanja podacima i analitike. Potrebne su im napredne edukacije iz područja analitike podataka i poticaji za usvajanje naprednih digitalnih alata.

- **Klaster 4 („Digitalni lideri“)**: Karakteriziraju ga najmlađi nositelji gospodarstva, najviša razina obrazovanja, najveći posjedi i najviši godišnji prihodi. Ova gospodarstva pokazuju visoku digitalnu zrelost u svim dimenzijama i predstavljaju uzorne primjere digitalne transformacije. Mogu poslužiti kao demonstracijski centri i mentori ostalim poljoprivrednicima.

Ovi rezultati potvrđuju da su **dob, obrazovanje, veličina posjeda i prihodi** ključni čimbenici koji diferenciraju poljoprivredna gospodarstva prema njihovoj digitalnoj zrelosti, dok **broj zaposlenih** nije značajan diferencijator u kontekstu hrvatske obiteljske poljoprivrede. Dobiveni profili pružaju važne smjernice za kreiranje ciljanih politika i programa podrške digitalnoj transformaciji, pri čemu je jasno da **Klaster 1 zahtijeva najintenzivniju intervenciju** u obliku edukacije, financijskih potpora i demonstracijskih projekata, dok **Klaster 4 može poslužiti kao uzor i mentor** ostalim gospodarstvima.

4.5.2. Validacija klastera – ANOVA analiza

Za analizu utjecaja demografskih i organizacijskih čimbenika na digitalnu zrelost poljoprivrednih gospodarstava, u ovom istraživanju nije korištena višestruka analiza varijance (MANOVA), već su provedene zasebne jednosmjerne analize varijance (ANOVA) i višestruke linearne regresije za svaki od pet indeksa digitalne zrelosti zasebno. Ova metodološka odluka utemeljena je na sljedećim razlozima:

1. Analiza glavnih komponenti (PCA) prikazana ranije pokazala je da svih pet indeksa digitalne zrelosti čini jednu glavnu komponentu koja objašnjava 76,4% ukupne varijance. Ovaj nalaz ukazuje na to da su zavisne varijable (Indeks_Stup1 do Indeks_Stup5) izrazito visoko međusobno korelirane, čime se krši temeljna pretpostavka MANOVA-e o umjerenoj korelaciji između zavisnih varijabli (Tabachnick & Fidell, 2014.). Kada su zavisne varijable visoko korelirane, MANOVA gubi statističku snagu i interpretativnu vrijednost.

2. PCA je potvrdila jednodimenzionalnost konstrukta digitalne zrelosti, što znači da svih pet indeksa mjere istu temeljnu latentnu dimenziju. U takvom slučaju, MANOVA, koja je dizajnirana za analizu višedimenzionalnih prostora, nije prikladna metoda jer ne postoji dovoljna dimenzijska raznolikost između zavisnih varijabli.

3. Pristup zasebnih ANOVA i regresijskih modela za svaki stupanj omogućuje precizniju interpretaciju rezultata. Naime, ovaj pristup omogućuje identifikaciju specifičnih demografskih čimbenika koji utječu na pojedine aspekte digitalne zrelosti (npr. dob može snažno utjecati na Stup 3: Podaci i analitika, ali slabije na Stup 1: Strategija i kultura), što bi u MANOVA pristupu bilo teže detektirati.

4. Zasebne analize omogućuju korištenje odgovarajućih post-hoc testova i provjeru pretpostavki za svaki stupanj zasebno, čime se povećava robusnost statističkih zaključaka. S obzirom na to da su pojedini stupnjevi pokazali različite razine homogenosti varijanci (Levenov test), zasebni pristup omogućio je primjenu odgovarajućih korekcija (npr. Holm) za svaki stupanj.

Unatoč tome što nije korištena MANOVA, provedene analize pružaju sveobuhvatan uvid u utjecaj demografskih čimbenika na digitalnu zrelost, pri čemu zasebni modeli za svaki indeks omogućuju detaljniju segmentaciju i preciznije preporuke za kreiranje ciljanih intervencija u digitalnoj transformaciji poljoprivrede.

Dakle, kako bi se statistički potvrdilo da su identificirani klasteri značajno različiti u razini digitalne zrelosti, provedena je jednosmjerna analiza varijance (ANOVA) za globalni indeks i svaki od pet stupnjeva digitalne zrelosti.

Tablica 4.25. Rezultati analize varijance (ANOVA) za utjecaj klastera na globalni indeks digitalne zrelosti

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
Klasteri	330,6	3	110,2066	1985	<,001
Reziduali	31,2	561	0,0555		

Rezultati ANOVA-e pokazali su statistički visoko značajne razlike između klastera za **globalni indeks digitalne zrelosti** ($F(3, 561) = 1985$, $p < ,001$). Post-hoc testovi (Holm) potvrdili su da se **sva četiri klastera međusobno značajno razlikuju** (svi $p < ,001$), što validira klastersku analizu i potvrđuje da su identificirani profili stvarno različiti segmenti poljoprivrednih gospodarstava.

Tablica 4.26. Post-hoc usporedbe (Bonferroni) globalnog indeksa digitalne zrelosti po klasterima

Usporedba							
Klasteri		Klasteri	Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
Srednje zreli/Pragmatičari	-	Digitalni lideri	-0,738	0,0268	561	-27,6	<,001
	-	Slabije zreli/Tradicionalisti	0,714	0,0265	561	27,0	<,001
	-	Digitalni početnici	1,445	0,0301	561	48,0	<,001
Digitalni lideri	-	Slabije zreli/Tradicionalisti	1,452	0,0270	561	53,8	<,001
	-	Digitalni početnici	2,184	0,0306	561	71,5	<,001
Slabije zreli/Tradicionalisti	-	Digitalni početnici	0,731	0,0303	561	24,2	<,001

Napomena: Usporedbe se temelje na procijenjenim marginalnim srednjim vrijednostima

Tablica 4.27. Rezultati analize varijance (ANOVA) za indeks digitalne zrelosti za Stup1 po klasterima

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
Klasteri	398	3	132,710	495	<,001
Reziduali	150	561	0,268		

Tablica 4.28. Rezultati analize varijance (ANOVA) za indeks digitalne zrelosti za Stup2 po klasterima

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
Klasteri	48,0	3	15,992	143	<,001
Reziduali	62,6	561	0,112		

Tablica 4.29. Rezultati analize varijance (ANOVA) za indeks digitalne zrelosti za Stup3 po klasterima

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
Klasteri	355,0	3	118,348	699	<,001
Reziduali	95,0	561	0,169		

Tablica 4.30. Rezultati analize varijance (ANOVA) za indeks digitalne zrelosti za Stup4 po klasterima

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
Klasteri	468	3	155,925	629	<,001
Reziduali	139	561	0,248		

Tablica 4.31. Rezultati analize varijance (ANOVA) za indeks digitalne zrelosti za Stup5 po klasterima

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
Klasteri	584	3	194,676	592	<,001
Reziduali	185	561	0,329		

Analiza po indeksima digitalne zrelosti pojedinih stupova pokazala je da su klasteri značajno različiti u svim dimenzijama:

- **Stup 1 (Strategija):** $F(3, 561) = 495$, $p < ,001$. Snažan doprinos definiranju razlika među klasterima.
- **Stup 2 (Tehnologija):** $F(3, 561) = 143$, $p < ,001$. Ima najmanju (iako i dalje statistički izuzetno značajnu) moć razlikovanja klastera u usporedbi s ostalim indeksima.
- **Stup 3 (Podaci):** $F(3, 561) = 699$, $p < ,001$. Ova varijabla najsnažnije razlikuje klastere. Razlike između grupa su ovdje maksimalno izražene u odnosu na unutargrupnu varijaciju.
- **Stup 4 (Sposobnost):** $F(3, 561) = 629$, $p < ,001$. Također ekstremno visoka diskriminatorna moć varijable.

- **Stup 5 (Pravila):** $F(3, 561) = 592$, $p < ,001$. Vrlo visoka i jasna diferencijacija među grupama.

Ovi rezultati potvrđuju da klasterska analiza uspješno identificira četiri jasno diferencirana profila poljoprivrednih gospodarstava s obzirom na njihovu digitalnu zrelost.

4.6. Utjecaj demografskih i organizacijskih čimbenika na digitalnu zrelost

Za ispitivanje povezanosti demografskih varijabli s digitalnom zrelošću, prvo je provedena korelacijska analiza.

Tablica 4.32. Matrica korelacija između globalnog indeksa digitalne zrelosti i demografskih varijabli (N = 565)

	Globalni_DRI	D1_kodirano	D3_kodirano	D10_kodirano	D11_kodirano	D12_kodirano
Globalni_DRI	—					
D1_kodirano	-0,462***	—				
D3_kodirano	0,398***	-0,269***	—			
D10_kodirano	0,258***	-0,255***	0,028	—		
D11_kodirano	0,147***	-0,091*	0,130**	0,098*	—	
D12_kodirano	0,333***	-0,278***	0,148***	0,581***	0,226***	—

Napomena: * p < ,05, ** p < ,01, *** p < ,001

Rezultati pokazuju snažnu negativnu korelaciju između dobi i digitalne zrelosti (r = -0,462, p < ,001), te umjerene pozitivne korelacije s razinom obrazovanja (r = 0,398, p < ,001) i poslovnim prihodima (r = 0,333, p < ,001).

Nadalje, provedena je jednosmjerna analiza varijance (ANOVA) kako bi se utvrdio utjecaj razine obrazovanja (D3) na globalnu digitalnu zrelost.

Tablica 4.33. Rezultati analize varijance (ANOVA) za utjecaj razine obrazovanja (D3) na globalni indeks digitalne zrelosti

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
D3	62,2	6	10,362	19,3	<,001

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
Reziduali	299,6	558	0,537		

Tablica 4.34. Levenov test homogenosti varijanci za utjecaj razine obrazovanja na digitalnu zrelost

F	df1	df2	p
2,81	6	558	,011

Tablica 4.35. Post-hoc usporedbe (Bonferroni) razina digitalne zrelosti između različitih razina obrazovanja

Usporedba							
D3		D3	Razlika srednje vrijednosti	Standardna greška	df	t	$p_{bonferroni}$
Diplomirani specijalist / magistar / doktor - NEpoljoprivredne struke	-	Diplomirani specijalist / magistar / doktor - poljoprivredne struke	0,1963	0,3543	558	0,554	1,000
	-	Osnovno obrazovanje	1,4522	0,2424	558	5,991	<,001
	-	Srednje obrazovanje - NEpoljoprivredne struke	0,8053	0,2248	558	3,582	,008
	-	Srednje obrazovanje - poljoprivredne struke	0,4369	0,2410	558	1,813	1,000
	-	Visoko obrazovanje - NEpoljoprivredne struke	0,3757	0,2364	558	1,590	1,000
	-	Visoko obrazovanje - poljoprivredne struke	0,2711	0,2445	558	1,109	1,000
Diplomirani specijalist / magistar / doktor - poljoprivredne struke	-	Osnovno obrazovanje	1,2559	0,2944	558	4,267	<,001
	-	Srednje obrazovanje - NEpoljoprivredne struke	0,6090	0,2801	558	2,174	,632

Usporedba							
D3		D3	Razlika srednje vrijednosti	Standardna greška	df	t	$p_{bonferroni}$
	-	Srednje obrazovanje - poljoprivredne struke	0,2406	0,2932	558	0,821	1,000
	-	Visoko obrazovanje - NEpoljoprivredne struke	0,1794	0,2894	558	0,620	1,000
	-	Visoko obrazovanje - poljoprivredne struke	0,0748	0,2961	558	0,253	1,000
Osnovno obrazovanje	-	Srednje obrazovanje - NEpoljoprivredne struke	-0,6469	0,1081	558	-5,987	<,001
	-	Srednje obrazovanje - poljoprivredne struke	-1,0153	0,1386	558	-7,327	<,001
	-	Visoko obrazovanje - NEpoljoprivredne struke	-1,0765	0,1304	558	-8,254	<,001
	-	Visoko obrazovanje - poljoprivredne struke	-1,1811	0,1446	558	-8,170	<,001
Srednje obrazovanje - NEpoljoprivredne struke	-	Srednje obrazovanje - poljoprivredne struke	-0,3684	0,1048	558	-3,514	,010
	-	Visoko obrazovanje - NEpoljoprivredne struke	-0,4296	0,0938	558	-4,580	<,001
	-	Visoko obrazovanje - poljoprivredne struke	-0,5342	0,1126	558	-4,742	<,001
Srednje obrazovanje - poljoprivredne struke	-	Visoko obrazovanje - NEpoljoprivredne struke	-0,0612	0,1278	558	-0,479	1,000
	-	Visoko obrazovanje - poljoprivredne struke	-0,1658	0,1422	558	-1,166	1,000
Visoko obrazovanje - NEpoljoprivredne struke	-	Visoko obrazovanje - poljoprivredne struke	-0,1046	0,1342	558	-0,779	1,000

Napomena: Usporedbe se temelje na procijenjenim marginalnim srednjim vrijednostima

ANOVA je pokazala statistički značajan glavni efekt razine obrazovanja na digitalnu zrelost ($F(6, 558) = 19,3$; $p < ,001$). Post-hoc testovi jasno pokazuju da gospodarstva čiji nositelji imaju **osnovno obrazovanje** imaju statistički značajno nižu digitalnu zrelost u usporedbi sa svim ostalim razinama obrazovanja ($p < ,001$).

Za preciznije modeliranje, provedena je **višestruka linearna regresijska analiza**. Model 1 uključivao je demografske varijable (Dob, Obrazovanje, Veličina, Zaposleni, Prihodi), dok je Model 2 dodatno uključio i prostornu komponentu (NUTS regije - D6).

Tablica 4.36. Mjere prilagodbe regresijskog modela za predviđanje globalnog indeksa digitalne zrelosti (Model 1: bez NUTS regije)

					Test sveukupnog modela			
Model	R	R^2	Prilagođeni R^2	RMSE	F	df1	df2	p
1	0,601	0,361	0,332	0,640	12,2	25	539	<,001

Napomena: Models estimated using sample size of N=565

Tablica 4.37. Koeficijenti regresijskog modela za predviđanje globalnog indeksa digitalne zrelosti (Model 1)

						95% interval pouzdanosti	
Prediktor	Procjena	Standardna greška	t	p	Standardna procjena	Donja granica	Gornja
Presjek[a]	2,50839	0,1554	16,14516	<,001			
D1_kodirano:							
2 – 1	-0,08987	0,1212	-0,74131	,459	-0,1122	-0,4096	0,1851
3 – 1	-0,20393	0,1168	-1,74623	,081	-0,2546	-0,5410	0,0318
4 – 1	-0,43337	0,1189	-3,64620	<,001	-0,5411	-0,8326	-0,2496

						95% interval pouzdanosti	
Prediktor	Procjena	Standardna greška	t	p	Standardna procjena	Donja granica	Gornja
5 – 1	-0,69080	0,1166	-5,92584	<,001	-0,8625	-1,1485	-0,5766
D3_kodirano:							
1,67 – 1	0,37839	0,1029	3,67606	<,001	0,4725	0,2200	0,7249
2,34 – 1	0,51024	0,1333	3,82861	<,001	0,6371	0,3102	0,9640
3,01 – 1	0,79707	0,1235	6,45430	<,001	0,9952	0,6923	1,2981
3,68 – 1	0,71878	0,1393	5,16091	<,001	0,8975	0,5559	1,2391
4,35 – 1	1,21799	0,2212	5,50608	<,001	1,5208	0,9782	2,0633
5 – 1	0,78107	0,2713	2,87927	,004	0,9752	0,3099	1,6406
D10_kodirano:							
1,08 – 1	1,34e-4	0,0796	0,00169	,999	1,68e-4	-0,1951	0,1954
2,6 – 1	0,09227	0,0841	1,09764	,273	0,1152	-0,0910	0,3214
3,4 – 1	0,12735	0,1182	1,07708	,282	0,1590	-0,1310	0,4490
4,2 – 1	0,08427	0,1364	0,61790	,537	0,1052	-0,2293	0,4397
5 – 1	0,41434	0,1639	2,52872	,012	0,5173	0,1155	0,9192
2,6 (2) – 1	0,91651	0,6658	1,37663	,169	1,1444	-0,4886	2,7773
3,4 (2) – 1	0,53241	0,6631	0,80285	,422	0,6648	-0,9617	2,2913
3,4 (3) – 1	-0,43598	0,6685	-0,65221	,515	-0,5444	-2,1839	1,0952
D11_kodirano:							
2,33 – 1	0,15255	0,2884	0,52898	,597	0,1905	-0,5168	0,8978
3,66 – 1	0,70643	0,7763	0,90999	,363	0,8821	-1,0220	2,7861
5 – 1	0,66602	0,6818	0,97689	,329	0,8316	-0,8406	2,5038
D12_kodirano:							
2 – 1	0,17565	0,0817	2,15002	,032	0,2193	0,0189	0,4197
3 – 1	0,37601	0,1399	2,68792	,007	0,4695	0,1264	0,8126
4 – 1	0,34677	0,1530	2,26701	,024	0,4330	0,0578	0,8081
5 – 1	0,00994	0,3975	0,02500	,980	0,0124	-0,9625	0,9873

Prediktor	Procjena	Standardna greška	t	p	Standardna procjena	95% interval pouzdanosti	
						Donja granica	Gornja

[a] Predstavlja referentnu razinu

Tablica 4.38. Statistika kolinearnosti (VIF i tolerancija) za prediktore u regresijskom modelu

	VIF	Tolerancija
D1_kodirano	1,05	0,955
D3_kodirano	1,03	0,969
D10_kodirano	1,06	0,941
D11_kodirano	1,10	0,912
D12_kodirano	1,17	0,854

Tablica 4.39. Test normalnosti (Shapiro-Wilk) reziduala

Statistika	p
0,994	,036

Model 1 pokazao se visoko značajnim ($F(25, 539) = 12,2$; $p < .001$), objašnjavajući 33,2% prilagođene varijance digitalne zrelosti. VIF vrijednosti (sve < 1,2) isključuju problem multikolinearnosti. Najjači prediktori su **obrazovanje** (pozitivan utjecaj, npr. β = 1,521 za magistre/doktore, p < ,001) i **dob** (negativan utjecaj, β = -0,862 za >60 godina, p < ,001).

Kako bi se ispitala i prostorna komponenta, u Model 2 uključene su NUTS regije.

Tablica 4.40. Omnibus ANOVA test za doprinos pojedinih prediktora u regresijskom modelu s NUTS regijom (Model 2)

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
D1_kodirano	29,672	4	7,418	17,462	<,001
D3_kodirano	27,408	6	4,568	10,753	<,001
D6	3,409	3	1,136	2,675	,047
D10_kodirano	4,435	8	0,554	1,305	,238
D11_kodirano	0,626	3	0,209	0,491	,689
D12_kodirano	5,027	4	1,257	2,959	,019
Reziduali	227,697	536	0,425		

Napomena: Vrsta 3 suma kvadrata

Tablica 4.41. Mjere prilagodbe regresijskog modela za predviđanje globalnog indeksa digitalne zrelosti (Model 2: s NUTS regijom)

					Test sveukupnog modela			
Model	R	R^2	Prilagođeni R^2	RMSE	F	df1	df2	p
1	0,609	0,371	0,338	0,635	11,3	28	536	<,001

Napomena: Modeli procijenjeni korištenjem veličine uzorka N=565

Tablica 4.42. Koeficijenti regresijskog modela za predviđanje globalnog indeksa digitalne zrelosti (Model 2: s NUTS regijom)

						95% interval pouzdanosti	
Prediktor	Procjena	Standardna greška	t	p	Standardna procjena	Donja granica	Gornja
Presjek[a]	2,7914	0,2072	13,471	<,001			
D1_kodirano:							
2 – 1	-0,0857	0,1208	-0,710	,478	-0,1070	-0,4032	0,18919

Prediktor	Procjena	Standardna greška	t	p	Standardna procjena	95% interval pouzdanosti	
						Donja granica	Gornja
3 – 1	-0,2255	0,1166	-1,933	,054	-0,2815	-0,5676	0,00456
4 – 1	-0,4366	0,1184	-3,689	<,001	-0,5452	-0,8355	-0,25487
5 – 1	-0,7027	0,1162	-6,045	<,001	-0,8774	-1,1625	-0,59228
D3_kodirano:							
1,67 – 1	0,3756	0,1029	3,651	<,001	0,4690	0,2167	0,72136
2,34 – 1	0,5002	0,1329	3,763	<,001	0,6245	0,2985	0,95055
3,01 – 1	0,7700	0,1235	6,236	<,001	0,9614	0,6586	1,26431
3,68 – 1	0,7112	0,1387	5,129	<,001	0,8880	0,5479	1,22813
4,35 – 1	1,1907	0,2204	5,402	<,001	1,4867	0,9461	2,02729
5 – 1	0,7871	0,2701	2,914	,004	0,9828	0,3203	1,64522
D6:							
Jadranska Hrvatska – Grad Zagreb	-0,2347	0,1470	-1,597	,111	-0,2931	-0,6537	0,06751
Panonska Hrvatska – Grad Zagreb	-0,2884	0,1466	-1,968	,050	-0,3601	-0,7197	-6,01e−4
Sjeverna Hrvatska – Grad Zagreb	-0,3727	0,1480	-2,519	,012	-0,4653	-0,8282	-0,10242
D10_kodirano:							
1,08 – 1	0,0186	0,0797	0,233	,816	0,0232	-0,1723	0,21876
2,6 – 1	0,1178	0,0857	1,375	,170	0,1471	-0,0631	0,35737
3,4 – 1	0,1348	0,1193	1,131	,259	0,1684	-0,1242	0,46088
4,2 – 1	0,0827	0,1378	0,601	,548	0,1033	-0,2346	0,44122
5 – 1	0,4070	0,1642	2,479	,013	0,5082	0,1055	0,91086
2,6 (2) – 1	0,9052	0,6646	1,362	,174	1,1302	-0,4999	2,76032

Prediktor	Procjena	Standardna greška	t	p	Standardna procjena	95% interval pouzdanosti	
						Donja granica	Gornja
3,4 (2) – 1	0,4961	0,6613	0,750	,453	0,6194	-1,0026	2,24134
3,4 (3) – 1	-0,4340	0,6669	-0,651	,516	-0,5418	-2,1776	1,09395
D11_kodirano:							
2,33 – 1	0,1218	0,2876	0,423	,672	0,1521	-0,5534	0,85755
3,66 – 1	0,5454	0,7768	0,702	,483	0,6810	-1,2243	2,58624
5 – 1	0,6238	0,6807	0,916	,360	0,7789	-0,8908	2,44856
D12_kodirano:							
2 – 1	0,1910	0,0816	2,340	,020	0,2384	0,0383	0,43857
3 – 1	0,3895	0,1399	2,784	,006	0,4863	0,1432	0,82951
4 – 1	0,3812	0,1527	2,496	,013	0,4760	0,1014	0,85065
5 – 1	0,1186	0,3991	0,297	,766	0,1481	-0,8309	1,12703

[a] Predstavlja referentnu razinu

Tablica 4.43. Durbin-Watson test za autokorelaciju reziduala u regresijskom modelu

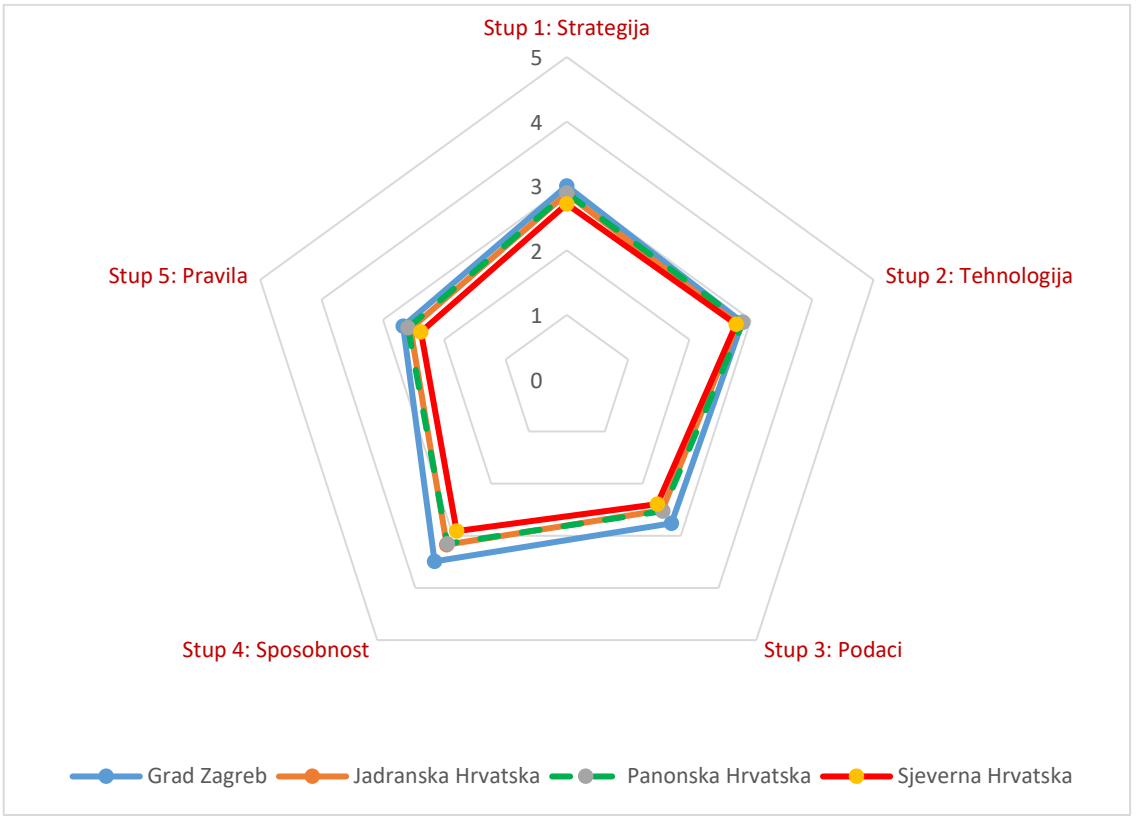
Automatska korelacija	DW statistika	p
-0,0258	2,05	,578

Uvođenjem NUTS regija, model se dodatno poboljšao (R^2 raste s 0,361 na 0,371). Omnibus test potvrđuje da i NUTS regija ima značajan doprinos modelu (F = 2,675, p = ,047). Analiza koeficijenata pokazuje da gospodarstva iz **Grad Zagreba** imaju tendenciju više digitalne zrelosti u usporedbi s Panonskom Hrvatskom (β = 0,360, p = ,050).

4.7. Prostorna distribucija digitalne zrelosti (NUTS regije i Županije)

Radar dijagram (Slika 4.20.) vizualno prikazuje profil digitalne zrelosti kroz pet stupnjeva za svaku od četiriju NUTS regija. Grad Zagreb dosljedno bilježi najviše vrijednosti u svim stupnjevima, s izraženim vrhuncem u dimenziji Sposobnosti (Stup 4, M = 3,49), što odražava koncentraciju digitalnih kompetencija i resursa u urbanom središtu. Sve tri ostale regije (Jadranska, Panonska i Sjeverna Hrvatska) pokazuju sličan obrazac s najnižim vrijednostima u dimenziji Podaci i analitika (Stup 3) i Pravila podataka (Stup 5), dok je Sposobnost (Stup 4) relativno najviša dimenzija. Ovaj obrazac sugerira da, neovisno o regiji, hrvatska poljoprivreda ima sistemske slabosti u upravljanju podacima i uspostavi pravila.

Sjeverna Hrvatska bilježi najniže vrijednosti u gotovo svim dimenzijama, što je u skladu s prethodno utvrđenim najnižim prosječnim globalnim indeksom (M = 2,63). Razlika između Sjeverne Hrvatske i Grada Zagreba najizraženija je u dimenziji Podaci i analitika (razlika od 0,37 bodova) i Pravila podataka (razlika od 0,29 bodova), dok je najmanja u dimenziji Tehnologija (razlika od samo 0,10 bodova). Ovaj nalaz potvrđuje postojanje „vještinskog jaza“ u kontinentalnoj Hrvatskoj, gdje poljoprivrednici posjeduju tehnologiju, ali im nedostaje znanje za njezinu analitičku primjenu. Jadranska i Panonska Hrvatska pokazuju vrlo slične profile, s blago višim vrijednostima u Panonskoj Hrvatskoj za Stup 1 (Strategija) i Stup 2 (Tehnologija), dok Jadranska Hrvatska ima blagu prednost u Stupu 5 (Pravila). Ova sličnost sugerira da obje regije dijele slične strukturne karakteristike i izazove u digitalnoj transformaciji.



Slika 4.20. Radar dijagram usporedbe NUTS regija prema stupnjevima digitalne zrelosti

Prostorna je distribucija digitalne zrelosti analizirana kroz utjecaj NUTS regije (D6) na globalni indeks digitalne zrelosti (Globalni_DRI). Rezultati jednosmjerne analize varijance (ANOVA) prikazani u Tablici 4.44. ukazuju na rubnu statističku značajnost razlika između regija ($F(3, 561) = 2{,}12$; $p = {,}097$), što sugerira postojanje prostornog trenda koji ne doseže konvencionalnu razinu značajnosti od $p < {,}05$, vjerojatno zbog velike unutar-grupne varijabilnosti.

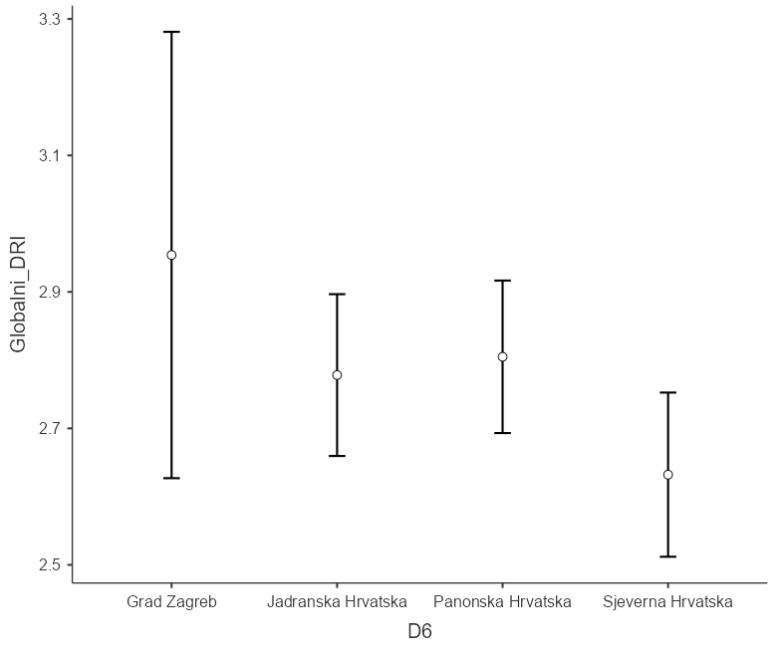
Tablica 4.44. Rezultati analize varijance (ANOVA) za utjecaj NUTS regije (D6) na globalni indeks digitalne zrelosti

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
D6	4,05	3	1,350	2,12	,097
Reziduali	357,72	561	0,638		

Tablica 4.45. Procijenjene marginalne srednje vrijednosti globalnog indeksa digitalne zrelosti po NUTS regijama

D6	Srednja vrijednost	Standardna greška	95% interval pouzdanosti	
			Donja granica	Gornja
Grad Zagreb	2,95	0,1665	2,63	3,28
Jadranska Hrvatska	2,78	0,0604	2,66	2,90
Panonska Hrvatska	2,80	0,0569	2,69	2,92
Sjeverna Hrvatska	2,63	0,0612	2,51	2,75

Unatoč tome, procijenjene marginalne srednje vrijednosti (Tablica 4.45. i Slika 4.21.) otkrivaju jasnu hijerarhiju digitalne zrelosti po regijama. Gospodarstva iz Grada Zagreba bilježe najvišu prosječnu razinu digitalne zrelosti (M = 2,95), s 95% intervalom pouzdanosti koji se proteže od 2,63 do 3,28. Širina ovog intervala, vidljiva i na dijagramu kao najduži error bar, odražava značajnu heterogenost unutar zagrebačkih gospodarstava, koja obuhvaćaju i visoko digitalizirane tvrtke i one s niskom razinom zrelosti. Panonska Hrvatska (M = 2,80; 95% CI [2,69; 2,92]) i Jadranska Hrvatska (M = 2,78; 95% CI [2,66; 2,90]) zauzimaju srednju poziciju s vrlo sličnim vrijednostima i užim intervalima pouzdanosti, što ukazuje na homogeniju distribuciju digitalne zrelosti unutar tih regija. Sjeverna Hrvatska bilježi najnižu prosječnu razinu digitalne zrelosti (M = 2,63; 95% CI [2,51; 2,75]), s intervalom pouzdanosti koji se djelomično preklapa s ostalim regijama, što je u skladu s rubnom značajnosti ANOVA testa.



Slika 4.21. Procijenjene marginalne srednje vrijednosti globalnog indeksa digitalne zrelosti (Globalni_DRI) s 95% intervalima pouzdanosti po NUTS regijama (D6)

Tablica 4.46. Deskriptivni pokazatelji globalnog indeksa digitalne zrelosti po NUTS regijama

	D6	Globalni_DRI
N	Grad Zagreb	23
	Jadranska Hrvatska	175
	Panonska Hrvatska	197
	Sjeverna Hrvatska	170
Srednja vrijednost	Grad Zagreb	2,95
	Jadranska Hrvatska	2,78
	Panonska Hrvatska	2,80
	Sjeverna Hrvatska	2,63
Medijan	Grad Zagreb	2,86
	Jadranska Hrvatska	2,81
	Panonska Hrvatska	2,88
	Sjeverna Hrvatska	2,59
Standardna devijacija	Grad Zagreb	0,834
	Jadranska Hrvatska	0,821
	Panonska Hrvatska	0,803
	Sjeverna Hrvatska	0,765
IQR	Grad Zagreb	1,13
	Jadranska Hrvatska	1,26
	Panonska Hrvatska	1,28
	Sjeverna Hrvatska	1,24
Minimum	Grad Zagreb	1,26
	Jadranska Hrvatska	1,22
	Panonska Hrvatska	1,20
	Sjeverna Hrvatska	1,20
Maksimum	Grad Zagreb	4,32
	Jadranska Hrvatska	4,48

	D6	Globalni_DRI
	Panonska Hrvatska	4,39
	Sjeverna Hrvatska	4,15

Ovakva prostorna distribucija sugerira da urbanija središta, poput Grada Zagreba, djeluju kao pokretači digitalne transformacije, vjerojatno zbog bolje infrastrukture, pristupa tržištu radu s digitalnim kompetencijama i veće koncentracije inovativnih gospodarstava. Međutim, činjenica da razlike nisu statistički značajne na konvencionalnoj razini ukazuje na to da prostorni čimbenik, iako prisutan, nije dominantan determinanta digitalne zrelosti u odnosu na druge varijable poput dobi nositelja, razine obrazovanja ili veličine gospodarstva, što je u skladu s prethodno prezentiranim rezultatima klasterske analize. Detaljnija analiza na razini pojedinih županija otkriva znatno nijansiraniju i složeniju prostornu distribuciju digitalne zrelosti.

Tablica 4.47. Deskriptivni pokazatelji globalnog indeksa digitalne zrelosti po županijama (N = 565)

	D7	Globalni_DRI
N	Bjelovarsko-bilogorska županija	32
	Brodsko-posavska županija	26
	Dubrovačko-neretvanska županija	42
	Grad Zagreb	22
	Istarska županija	23
	Karlovačka županija	24
	Koprivničko-križevačka županija	29
	Krapinsko-zagorska županija	31
	Ličko-senjska županija	18
	Međimurska županija	26
	Osječko-baranjska županija	33
	Požeško-slavonska županija	21
	Primorsko-goranska županija	13
	Sisačko-moslavačka županija	32

	D7	Globalni_DRI
	Splitsko-dalmatinska županija	35
	Varaždinska županija	25
	Virovitičko-podravska županija	21
	Vukovarsko-srijemska županija	26
	Zadarska županija	28
	Zagrebačka županija	42
	Šibensko-kninska županija	16
Srednja vrijednost	Bjelovarsko-bilogorska županija	2,62
	Brodsko-posavska županija	3,15
	Dubrovačko-neretvanska županija	2,70
	Grad Zagreb	2,97
	Istarska županija	3,00
	Karlovačka županija	2,95
	Koprivničko-križevačka županija	2,62
	Krapinsko-zagorska županija	2,34
	Ličko-senjska županija	3,27
	Međimurska županija	2,80
	Osječko-baranjska županija	2,60
	Požeško-slavonska županija	3,04
	Primorsko-goranska županija	2,72
	Sisačko-moslavačka županija	2,69
	Splitsko-dalmatinska županija	2,40
	Varaždinska županija	2,87
	Virovitičko-podravska županija	2,81
	Vukovarsko-srijemska županija	2,84
	Zadarska županija	2,79
	Zagrebačka županija	2,45
	Šibensko-kninska županija	3,02
Medijan	Bjelovarsko-bilogorska županija	2,51

	D7	Globalni_DRI
	Brodsko-posavska županija	3,10
	Dubrovačko-neretvanska županija	2,59
	Grad Zagreb	2,95
	Istarska županija	3,04
	Karlovačka županija	3,10
	Koprivničko-križevačka županija	2,49
	Krapinsko-zagorska županija	2,31
	Ličko-senjska županija	3,34
	Međimurska županija	2,64
	Osječko-baranjska županija	2,72
	Požeško-slavonska županija	3,06
	Primorsko-goranska županija	2,44
	Sisačko-moslavačka županija	2,80
	Splitsko-dalmatinska županija	2,37
	Varaždinska županija	2,87
	Virovitičko-podravska županija	3,05
	Vukovarsko-srijemska županija	2,99
	Zadarska županija	2,85
	Zagrebačka županija	2,33
	Šibensko-kninska županija	2,95
Standardna devijacija	Bjelovarsko-bilogorska županija	0,679
	Brodsko-posavska županija	0,691
	Dubrovačko-neretvanska županija	0,918
	Grad Zagreb	0,850
	Istarska županija	0,903
	Karlovačka županija	0,897
	Koprivničko-križevačka županija	0,735
	Krapinsko-zagorska županija	0,746
	Ličko-senjska županija	0,463

	D7	Globalni_DRI
	Međimurska županija	0,636
	Osječko-baranjska županija	0,871
	Požeško-slavonska županija	0,716
	Primorsko-goranska županija	0,670
	Sisačko-moslavačka županija	0,912
	Splitsko-dalmatinska županija	0,681
	Varaždinska županija	0,576
	Virovitičko-podravska županija	0,802
	Vukovarsko-srijemska županija	0,724
	Zadarska županija	0,882
	Zagrebačka županija	0,832
	Šibensko-kninska županija	0,711
Minimum	Bjelovarsko-bilogorska županija	1,47
	Brodsko-posavska županija	1,51
	Dubrovačko-neretvanska županija	1,23
	Grad Zagreb	1,26
	Istarska županija	1,41
	Karlovačka županija	1,31
	Koprivničko-križevačka županija	1,49
	Krapinsko-zagorska županija	1,20
	Ličko-senjska županija	2,35
	Međimurska županija	1,81
	Osječko-baranjska županija	1,20
	Požeško-slavonska županija	1,61
	Primorsko-goranska županija	1,86
	Sisačko-moslavačka županija	1,20
	Splitsko-dalmatinska županija	1,22
	Varaždinska županija	1,91
	Virovitičko-podravska županija	1,35

	D7	Globalni_DRI
	Vukovarsko-srijemska županija	1,52
	Zadarska županija	1,23
	Zagrebačka županija	1,20
	Šibensko-kninska županija	1,65
Maksimum	Bjelovarsko-bilogorska županija	3,85
	Brodsko-posavska županija	4,39
	Dubrovačko-neretvanska županija	4,48
	Grad Zagreb	4,32
	Istarska županija	4,26
	Karlovačka županija	4,29
	Koprivničko-križevačka županija	4,15
	Krapinsko-zagorska županija	3,81
	Ličko-senjska županija	3,94
	Međimurska županija	4,05
	Osječko-baranjska županija	4,19
	Požeško-slavonska županija	4,24
	Primorsko-goranska županija	3,84
	Sisačko-moslavačka županija	4,10
	Splitsko-dalmatinska županija	3,83
	Varaždinska županija	4,13
	Virovitičko-podravska županija	3,94
	Vukovarsko-srijemska županija	3,92
	Zadarska županija	4,27
	Zagrebačka županija	4,03
	Šibensko-kninska županija	3,99

Iz prikazanih deskriptivnih pokazatelja vidljivo je da se razine globalne digitalne zrelosti znatno razlikuju između županija, pri čemu se ne poklapaju nužno s općom gospodarskom razvijenošću regija. Najvišu prosječnu razinu digitalne zrelosti bilježe gospodarstva u Ličko-

senjskoj (*M* = 3,27), Brodsko-posavskoj (*M* = 3,15) i Požeško-slavonskoj županiji (*M* = 3,04). S druge strane, najniže razine digitalne zrelosti zabilježene su u Krapinsko-zagorskoj (*M* = 2,34), Splitsko-dalmatinskoj (*M* = 2,40) i Zagrebačkoj županiji (*M* = 2,45).

Kako bi se potvrdilo jesu li te razlike statistički značajne, provedena je jednosmjerna analiza varijance (ANOVA).

Tablica 4.48. Rezultati analize varijance (ANOVA) za utjecaj županije (D7) na globalni indeks digitalne zrelosti

	Zbroj kvadratnih vrijednosti	df	Kvadratno odstupanje srednje vrijednosti	F	p
D7	31,5	20	1,577	2,60	<,001
Reziduali	330,2	544	0,607		

Rezultati ANOVA-e pokazali su da postoje statistički visoko značajne razlike u globalnoj digitalnoj zrelosti s obzirom na županiju ($F(20, 544) = 2,60$; $p < ,001$).

Budući da je ANOVA pokazala značajnost, provedeni su *post-hoc* testovi (uz Holm korekciju) kako bi se utvrdilo između kojih se točno županija nalaze značajne razlike.

Tablica 4.49. Post-hoc usporedbe (Holm) razina digitalne zrelosti između županija

Usporedba							
D7		D7	Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
Bjelovarsko-bilogorska županija	-	Brodsko-posavska županija	-0,53348	0,206	544	-2,59333	1,000
	-	Dubrovačko-neretvanska županija	-0,07597	0,183	544	-0,41554	1,000
	-	Grad Zagreb	-0,35192	0,216	544	-1,63088	1,000
	-	Istarska županija	-0,38263	0,213	544	-1,79649	1,000
	-	Karlovačka županija	-0,33314	0,210	544	-1,58348	1,000

Usporedba			Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
D7		D7					
	-	Koprivničko-križevačka županija	0,00126	0,200	544	0,00628	1,000
	-	Krapinsko-zagorska županija	0,27942	0,196	544	1,42312	1,000
	-	Ličko-senjska županija	-0,65168	0,230	544	-2,83890	,920
	-	Međimurska županija	-0,18519	0,206	544	-0,90025	1,000
	-	Osječko-baranjska županija	0,01688	0,193	544	0,08733	1,000
	-	Požeško-slavonska županija	-0,42021	0,219	544	-1,92046	1,000
	-	Primorsko-goranska županija	-0,10360	0,256	544	-0,40427	1,000
	-	Sisačko-moslavačka županija	-0,06841	0,195	544	-0,35122	1,000
	-	Splitsko-dalmatinska županija	0,21714	0,191	544	1,13946	1,000
	-	Varaždinska županija	-0,25039	0,208	544	-1,20398	1,000
	-	Virovitičko-podravska županija	-0,18837	0,219	544	-0,86089	1,000
	-	Vukovarsko-srijemska županija	-0,22462	0,206	544	-1,09191	1,000
	-	Zadarska županija	-0,17422	0,202	544	-0,86411	1,000
	-	Zagrebačka županija	0,16675	0,183	544	0,91208	1,000
	-	Šibensko-kninska županija	-0,40198	0,239	544	-1,68506	1,000

Usporedba			Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
D7		D7					
Brodsko-posavska županija	-	Dubrovačko-neretvanska županija	0,45751	0,194	544	2,35315	1,000
	-	Grad Zagreb	0,18156	0,226	544	0,80445	1,000
	-	Istarska županija	0,15085	0,223	544	0,67639	1,000
	-	Karlovačka županija	0,20033	0,221	544	0,90835	1,000
	-	Koprivničko-križevačka županija	0,53473	0,210	544	2,54118	1,000
	-	Krapinsko-zagorska županija	0,81290	0,207	544	3,92339	,021
	-	Ličko-senjska županija	-0,11820	0,239	544	-0,49476	1,000
	-	Međimurska županija	0,34829	0,216	544	1,61176	1,000
	-	Osječko-baranjska županija	0,55036	0,204	544	2,69375	1,000
	-	Požeško-slavonska županija	0,11327	0,229	544	0,49550	1,000
	-	Primorsko-goranska županija	0,42988	0,265	544	1,62431	1,000
	-	Sisačko-moslavačka županija	0,46507	0,206	544	2,26077	1,000
	-	Splitsko-dalmatinska županija	0,75061	0,202	544	3,72105	,045
	-	Varaždinska županija	0,28309	0,218	544	1,29713	1,000
	-	Virovitičko-podravska županija	0,34511	0,229	544	1,50973	1,000
	-	Vukovarsko-srijemska županija	0,30886	0,216	544	1,42931	1,000

Usporedba			Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
D7		D7					
	-	Zadarska županija	0,35926	0,212	544	1,69305	1,000
	-	Zagrebačka županija	0,70022	0,194	544	3,60153	,071
	-	Šibensko-kninska županija	0,13149	0,248	544	0,53115	1,000
Dubrovačko-neretvanska županija	-	Grad Zagreb	-0,27595	0,205	544	-1,34574	1,000
	-	Istarska županija	-0,30666	0,202	544	-1,51731	1,000
	-	Karlovačka županija	-0,25717	0,199	544	-1,28997	1,000
	-	Koprivničko-križevačka županija	0,07723	0,188	544	0,41053	1,000
	-	Krapinsko-zagorska županija	0,35539	0,184	544	1,92640	1,000
	-	Ličko-senjska županija	-0,57571	0,219	544	-2,62288	1,000
	-	Međimurska županija	-0,10922	0,194	544	-0,56177	1,000
	-	Osječko-baranjska županija	0,09285	0,181	544	0,51231	1,000
	-	Požeško-slavonska županija	-0,34424	0,208	544	-1,65317	1,000
	-	Primorsko-goranska županija	-0,02763	0,247	544	-0,11172	1,000
	-	Sisačko-moslavačka županija	0,00756	0,183	544	0,04135	1,000
	-	Splitsko-dalmatinska županija	0,29311	0,178	544	1,64374	1,000
	-	Varaždinska županija	-0,17442	0,197	544	-0,88623	1,000

Usporedba			Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
D7		D7					
	-	Virovitičko-podravska županija	-0,11240	0,208	544	-0,53978	1,000
	-	Vukovarsko-srijemska županija	-0,14865	0,194	544	-0,76456	1,000
	-	Zadarska županija	-0,09825	0,190	544	-0,51687	1,000
	-	Zagrebačka županija	0,24272	0,170	544	1,42758	1,000
	-	Šibensko-kninska županija	-0,32601	0,229	544	-1,42430	1,000
Grad Zagreb	-	Istarska županija	-0,03071	0,232	544	-0,13217	1,000
	-	Karlovačka županija	0,01877	0,230	544	0,08163	1,000
	-	Koprivničko-križevačka županija	0,35317	0,220	544	1,60326	1,000
	-	Krapinsko-zagorska županija	0,63134	0,217	544	2,90676	,760
	-	Ličko-senjska županija	-0,29976	0,248	544	-1,21055	1,000
	-	Međimurska županija	0,16672	0,226	544	0,73870	1,000
	-	Osječko-baranjska županija	0,36880	0,214	544	1,71976	1,000
	-	Požeško-slavonska županija	-0,06829	0,238	544	-0,28732	1,000
	-	Primorsko-goranska županija	0,24832	0,273	544	0,91107	1,000
	-	Sisačko-moslavačka županija	0,28351	0,216	544	1,31384	1,000
	-	Splitsko-dalmatinska županija	0,56905	0,212	544	2,68444	1,000

Usporedba			Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
D7		D7					
	-	Varaždinska županija	0,10152	0,228	544	0,44576	1,000
	-	Virovitičko-podravska županija	0,16355	0,238	544	0,68806	1,000
	-	Vukovarsko-srijemska županija	0,12730	0,226	544	0,56401	1,000
	-	Zadarska županija	0,17770	0,222	544	0,80053	1,000
	-	Zagrebačka županija	0,51866	0,205	544	2,52943	1,000
	-	Šibensko-kninska županija	-0,05007	0,256	544	-0,19559	1,000
Istarska županija	-	Karlovačka županija	0,04948	0,227	544	0,21765	1,000
	-	Koprivničko-križevačka županija	0,38388	0,218	544	1,76462	1,000
	-	Krapinsko-zagorska županija	0,66205	0,214	544	3,08767	,430
	-	Ličko-senjska županija	-0,26905	0,245	544	-1,09732	1,000
	-	Međimurska županija	0,19743	0,223	544	0,88525	1,000
	-	Osječko-baranjska županija	0,39951	0,212	544	1,88775	1,000
	-	Požeško-slavonska županija	-0,03758	0,235	544	-0,15983	1,000
	-	Primorsko-goranska županija	0,27903	0,270	544	1,03211	1,000
	-	Sisačko-moslavačka županija	0,31421	0,213	544	1,47529	1,000
	-	Splitsko-dalmatinska županija	0,59976	0,209	544	2,86785	,850

Usporedba			Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
D7		D7					
	-	Varaždinska županija	0,13223	0,225	544	0,58742	1,000
	-	Virovitičko-podravska županija	0,19426	0,235	544	0,82607	1,000
	-	Vukovarsko-srijemska županija	0,15801	0,223	544	0,70847	1,000
	-	Zadarska županija	0,20841	0,219	544	0,95052	1,000
	-	Zagrebačka županija	0,54937	0,202	544	2,71826	1,000
	-	Šibensko-kninska županija	-0,01936	0,254	544	-0,07632	1,000
Karlovačka županija	-	Koprivničko-križevačka županija	0,33440	0,215	544	1,55534	1,000
	-	Krapinsko-zagorska županija	0,61257	0,212	544	2,89169	,793
	-	Ličko-senjska županija	-0,31853	0,243	544	-1,31118	1,000
	-	Međimurska županija	0,14795	0,221	544	0,67085	1,000
	-	Osječko-baranjska županija	0,35003	0,209	544	1,67463	1,000
	-	Požeško-slavonska županija	-0,08707	0,233	544	-0,37398	1,000
	-	Primorsko-goranska županija	0,22955	0,268	544	0,85555	1,000
	-	Sisačko-moslavačka županija	0,26473	0,210	544	1,25832	1,000
	-	Splitsko-dalmatinska županija	0,55028	0,206	544	2,66496	1,000
	-	Varaždinska županija	0,08275	0,223	544	0,37167	1,000

Usporedba							
D7		D7	Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
	-	Virovitičko-podravska županija	0,14478	0,233	544	0,62187	1,000
	-	Vukovarsko-srijemska županija	0,10853	0,221	544	0,49208	1,000
	-	Zadarska županija	0,15892	0,217	544	0,73328	1,000
	-	Zagrebačka županija	0,49989	0,199	544	2,50741	1,000
	-	Šibensko-kninska županija	-0,06884	0,251	544	-0,27376	1,000
Koprivničko-križevačka županija	-	Krapinsko-zagorska županija	0,27817	0,201	544	1,38199	1,000
	-	Ličko-senjska županija	-0,65293	0,234	544	-2,79284	1,000
	-	Međimurska županija	-0,18645	0,210	544	-0,88604	1,000
	-	Osječko-baranjska županija	0,01563	0,198	544	0,07880	1,000
	-	Požeško-slavonska županija	-0,42147	0,223	544	-1,88790	1,000
	-	Primorsko-goranska županija	-0,10485	0,260	544	-0,40319	1,000
	-	Sisačko-moslavačka županija	-0,06967	0,200	544	-0,34875	1,000
	-	Splitsko-dalmatinska županija	0,21588	0,196	544	1,10345	1,000
	-	Varaždinska županija	-0,25165	0,213	544	-1,18346	1,000
	-	Virovitičko-podravska županija	-0,18962	0,223	544	-0,84939	1,000
	-	Vukovarsko-srijemska županija	-0,22587	0,210	544	-1,07340	1,000

Usporedba							
D7		D7	Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
	-	Zadarska županija	-0,17548	0,206	544	-0,85006	1,000
	-	Zagrebačka županija	0,16549	0,188	544	0,87975	1,000
	-	Šibensko-kninska županija	-0,40324	0,243	544	-1,66191	1,000
Krapinsko-zagorska županija	-	Ličko-senjska županija	-0,93110	0,231	544	-4,03281	,013
	-	Međimurska županija	-0,46461	0,207	544	-2,24242	1,000
	-	Osječko-baranjska županija	-0,26254	0,195	544	-1,34722	1,000
	-	Požeško-slavonska županija	-0,69963	0,220	544	-3,17726	,321
	-	Primorsko-goranska županija	-0,38302	0,257	544	-1,48778	1,000
	-	Sisačko-moslavačka županija	-0,34783	0,196	544	-1,77154	1,000
	-	Splitsko-dalmatinska županija	-0,06229	0,192	544	-0,32414	1,000
	-	Varaždinska županija	-0,52981	0,209	544	-2,52972	1,000
	-	Virovitičko-podravska županija	-0,46779	0,220	544	-2,12439	1,000
	-	Vukovarsko-srijemska županija	-0,50404	0,207	544	-2,43271	1,000
	-	Zadarska županija	-0,45364	0,203	544	-2,23327	1,000
	-	Zagrebačka županija	-0,11268	0,184	544	-0,61077	1,000
	-	Šibensko-kninska županija	-0,68141	0,240	544	-2,84113	,919

Usporedba			Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
D7		D7					
Ličko-senjska županija	-	Međimurska županija	0,46648	0,239	544	1,95266	1,000
	-	Osječko-baranjska županija	0,66856	0,228	544	2,92846	,713
	-	Požeško-slavonska županija	0,23147	0,250	544	0,92490	1,000
	-	Primorsko-goranska županija	0,54808	0,284	544	1,93270	1,000
	-	Sisačko-moslavačka županija	0,58326	0,230	544	2,54089	1,000
	-	Splitsko-dalmatinska županija	0,86881	0,226	544	3,84460	,028
	-	Varaždinska županija	0,40128	0,241	544	1,66616	1,000
	-	Virovitičko-podravska županija	0,46331	0,250	544	1,85130	1,000
	-	Vukovarsko-srijemska županija	0,42706	0,239	544	1,78762	1,000
	-	Zadarska županija	0,47746	0,235	544	2,02844	1,000
	-	Zagrebačka županija	0,81842	0,219	544	3,72868	,044
	-	Šibensko-kninska županija	0,24969	0,268	544	0,93272	1,000
Međimurska županija	-	Osječko-baranjska županija	0,20207	0,204	544	0,98905	1,000
	-	Požeško-slavonska županija	-0,23502	0,229	544	-1,02812	1,000
	-	Primorsko-goranska županija	0,08160	0,265	544	0,30831	1,000
	-	Sisačko-moslavačka županija	0,11678	0,206	544	0,56769	1,000

Usporedba							
D7		D7	Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
	-	Splitsko-dalmatinska županija	0,40233	0,202	544	1,99448	1,000
	-	Varaždinska županija	-0,06520	0,218	544	-0,29875	1,000
	-	Virovitičko-podravska županija	-0,00318	0,229	544	-0,01389	1,000
	-	Vukovarsko-srijemska županija	-0,03943	0,216	544	-0,18245	1,000
	-	Zadarska županija	0,01097	0,212	544	0,05171	1,000
	-	Zagrebačka županija	0,35194	0,194	544	1,81015	1,000
	-	Šibensko-kninska županija	-0,21679	0,248	544	-0,87571	1,000
Osječko-baranjska županija	-	Požeško-slavonska županija	-0,43709	0,217	544	-2,00972	1,000
	-	Primorsko-goranska županija	-0,12048	0,255	544	-0,47223	1,000
	-	Sisačko-moslavačka županija	-0,08529	0,193	544	-0,44124	1,000
	-	Splitsko-dalmatinska županija	0,20026	0,189	544	1,05929	1,000
	-	Varaždinska županija	-0,26727	0,207	544	-1,29378	1,000
	-	Virovitičko-podravska županija	-0,20525	0,217	544	-0,94372	1,000
	-	Vukovarsko-srijemska županija	-0,24150	0,204	544	-1,18203	1,000
	-	Zadarska županija	-0,19110	0,200	544	-0,95461	1,000
	-	Zagrebačka županija	0,14986	0,181	544	0,82688	1,000

Usporedba			Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
D7		D7					
	-	Šibensko-kninska županija	-0,41887	0,237	544	-1,76476	1,000
Požeško-slavonska županija	-	Primorsko-goranska županija	0,31661	0,275	544	1,15150	1,000
	-	Sisačko-moslavačka županija	0,35180	0,219	544	1,60781	1,000
	-	Splitsko-dalmatinska županija	0,63735	0,215	544	2,96359	,641
	-	Varaždinska županija	0,16982	0,231	544	0,73634	1,000
	-	Virovitičko-podravska županija	0,23184	0,240	544	0,96423	1,000
	-	Vukovarsko-srijemska županija	0,19559	0,229	544	0,85564	1,000
	-	Zadarska županija	0,24599	0,225	544	1,09371	1,000
	-	Zagrebačka županija	0,58696	0,208	544	2,81879	,974
	-	Šibensko-kninska županija	0,01823	0,259	544	0,07049	1,000
Primorsko-goranska županija	-	Sisačko-moslavačka županija	0,03519	0,256	544	0,13731	1,000
	-	Splitsko-dalmatinska županija	0,32073	0,253	544	1,26742	1,000
	-	Varaždinska županija	-0,14679	0,266	544	-0,55100	1,000
	-	Virovitičko-podravska županija	-0,08477	0,275	544	-0,30831	1,000
	-	Vukovarsko-srijemska županija	-0,12102	0,265	544	-0,45728	1,000

Usporedba							
D7		D7	Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
	-	Zadarska županija	-0,07062	0,261	544	-0,27009	1,000
	-	Zagrebačka županija	0,27034	0,247	544	1,09325	1,000
	-	Šibensko-kninska županija	-0,29839	0,291	544	-1,02567	1,000
Sisačko-moslavačka županija	-	Splitsko-dalmatinska županija	0,28555	0,191	544	1,49845	1,000
	-	Varaždinska županija	-0,18198	0,208	544	-0,87503	1,000
	-	Virovitičko-podravska županija	-0,11996	0,219	544	-0,54824	1,000
	-	Vukovarsko-srijemska županija	-0,15621	0,206	544	-0,75935	1,000
	-	Zadarska županija	-0,10581	0,202	544	-0,52480	1,000
	-	Zagrebačka županija	0,23516	0,183	544	1,28627	1,000
	-	Šibensko-kninska županija	-0,33357	0,239	544	-1,39830	1,000
Splitsko-dalmatinska županija	-	Varaždinska županija	-0,46753	0,204	544	-2,29155	1,000
	-	Virovitičko-podravska županija	-0,40550	0,215	544	-1,88555	1,000
	-	Vukovarsko-srijemska županija	-0,44175	0,202	544	-2,18993	1,000
	-	Zadarska županija	-0,39136	0,198	544	-1,98111	1,000
	-	Zagrebačka županija	-0,05039	0,178	544	-0,28259	1,000
	-	Šibensko-kninska županija	-0,61912	0,235	544	-2,63316	1,000

Usporedba							
D7		D7	Razlika srednje vrijednosti	Standardna greška	df	t	p_{holm}
Varaždinska županija	-	Virovitičko-podravska županija	0,06202	0,231	544	0,26893	1,000
	-	Vukovarsko-srijemska županija	0,02577	0,218	544	0,11809	1,000
	-	Zadarska županija	0,07617	0,214	544	0,35530	1,000
	-	Zagrebačka županija	0,41714	0,197	544	2,11948	1,000
	-	Šibensko-kninska županija	-0,15159	0,249	544	-0,60773	1,000
Virovitičko-podravska županija	-	Vukovarsko-srijemska županija	-0,03625	0,229	544	-0,15858	1,000
	-	Zadarska županija	0,01415	0,225	544	0,06290	1,000
	-	Zagrebačka županija	0,35511	0,208	544	1,70539	1,000
	-	Šibensko-kninska županija	-0,21362	0,259	544	-0,82622	1,000
Vukovarsko-srijemska županija	-	Zadarska županija	0,05040	0,212	544	0,23751	1,000
	-	Zagrebačka županija	0,39136	0,194	544	2,01294	1,000
	-	Šibensko-kninska županija	-0,17737	0,248	544	-0,71645	1,000
Zadarska županija	-	Zagrebačka županija	0,34097	0,190	544	1,79373	1,000
	-	Šibensko-kninska županija	-0,22776	0,244	544	-0,93281	1,000
Zagrebačka županija	-	Šibensko-kninska županija	-0,56873	0,229	544	-2,48468	1,000

Napomena: Usporedbe se temelje na procijenjenim marginalnim srednjim vrijednostima

Iz *post-hoc* usporedbi proizlazi da se nekoliko županija statistički značajno razlikuje od ostalih. Gospodarstva u Ličko-senjskoj županiji pokazuju značajno višu digitalnu zrelost u usporedbi s

Krapinsko-zagorskom (p = ,013), Splitsko-dalmatinskom (p = ,028) i Zagrebačkom županijom (p = ,044). Također, Brodsko-posavska županija značajno se razlikuje od Krapinsko-zagorske (p = ,021) i Splitsko-dalmatinske županije (p = ,045). Ovi nalazi sugeriraju da digitalna zrelost u hrvatskoj poljoprivredi nije linearno povezana s općom urbanizacijom ili gospodarskom razvijenošću regije. Na primjer, Ličko-senjska županija, unatoč manjoj gospodarskoj razvijenosti i brdsko-planinskom reljefu, bilježi najvišu razinu digitalne zrelosti (M = 3,27), dok Zagrebačka županija, unatoč najvećoj gospodarskoj razvijenosti, bilježi nižu razinu (M = 2,45).

Osim globalnog indeksa, analizirane su i razlike po županijama za svaki od pet pojedinačnih stupova digitalne zrelosti, kako bi se identificirala specifična regionalna „uska grla“ i snage.

Tablica 4.50. Deskriptivni pokazatelji pojedinih stupnjeva digitalne zrelosti po županijama

	D7	Indeks_Stup1	Indeks_Stup2	Indeks_Stup3	Indeks_Stup4	Indeks_Stup5
Srednja vrijednost	Bjelovarsko-bilogorska	2,72	2,70	2,32	3,07	2,29
	Brodsko-posavska	3,33	3,03	2,98	3,42	3,01
	Dubrovačko-neretvanska	2,76	2,85	2,41	3,08	2,37
	Grad Zagreb	2,97	2,82	2,77	3,58	2,73
	Istarska	3,22	2,78	2,61	3,59	2,81
	Karlovačka	3,20	2,94	2,50	3,40	2,72
	Koprivničko-križevačka	2,55	2,74	2,41	2,96	2,44
	Krapinsko-zagorska	2,62	2,55	2,04	2,59	1,90
	Ličko-senjska	3,59	2,75	3,11	3,57	3,33
	Međimurska	2,83	2,88	2,54	3,08	2,69
	Osječko-baranjska	2,60	2,75	2,33	2,81	2,53
	Požeško-slavonska	3,11	3,00	2,79	3,51	2,79
	Primorsko-goranska	2,70	2,87	2,27	3,07	2,69
	Sisačko-moslavačka	2,74	2,69	2,51	3,00	2,50
	Splitsko-dalmatinska	2,47	2,65	2,15	2,65	2,10
	Varaždinska	2,86	2,85	2,59	3,22	2,84

D7	Indeks_Stup1	Indeks_Stup2	Indeks_Stup3	Indeks_Stup4	Indeks_Stup5
Virovitičko-podravska	2,79	3,06	2,46	3,22	2,51
Vukovarsko-srijemska	3,00	3,01	2,58	3,19	2,45
Zadarska	2,92	2,79	2,75	2,99	2,52
Zagrebačka	2,55	2,76	2,23	2,62	2,10
Šibensko-kninska	3,04	2,80	2,68	3,75	2,83

Analiza pojedinačnih stupnjeva otkriva zanimljive prostorne specifičnosti i asimetrične profile pojedinih županija. Dok neke županije pokazuju konzistentno visoke ili niske rezultate kroz sve dimenzije, druge pokazuju izražene disproporcije.

Kada je riječ o **Stupu 1: Strategija i kultura** ($F(20, 544) = 2,23$; $p = ,002$), Ličko-senjska županija bilježi najviši prosjek ($M = 3,59$), dok Krapinsko-zagorska bilježi najniže rezultate ($M = 2,62$). *Post-hoc* testovi potvrđuju značajnu razliku između Ličko-senjske i Krapinsko-zagorske ($p = ,016$), te Brodsko-posavske i Splitsko-dalmatinske ($p = ,016$).

U dimenziji **Stupa 2: Tehnologija** ($F(20, 544) = 2,51$; $p < ,001$), prednjače Virovitičko-podravska ($M = 3,06$), Vukovarsko-srijemska ($M = 3,01$) i Brodsko-posavska županija ($M = 3,03$). Krapinsko-zagorska županija ovdje bilježi najnižu razinu tehnološke opremljenosti ($M = 2,55$), pri čemu se značajno razlikuje od Virovitičko-podravske ($p = ,007$) i Vukovarsko-srijemske županije ($p = ,013$).

Za **Stup 3: Podaci i analitika** ($F(20, 544) = 2,35$; $p < ,001$), Ličko-senjska županija ponovno bilježi najviši prosjek ($M = 3,11$), dok Krapinsko-zagorska bilježi izrazito nizak rezultat ($M = 2,04$), uz značajnu razliku u odnosu na Brodsko-posavsku ($p = ,014$) i Ličko-senjsku županiju ($p = ,009$).

Analiza **Stupa 4: Sposobnost** ($F(20, 544) = 2,96$; $p < ,001$) otkriva da Šibensko-kninska ($M = 3,75$) i Istarska županija ($M = 3,59$) bilježe izrazito visoke rezultate u pogledu digitalnih vještina i osposobljenosti, dok Krapinsko-zagorska ($M = 2,59$) i Zagrebačka županija ($M = 2,62$) bilježe najniže rezultate. Značajne razlike potvrđene su između Krapinsko-zagorske i Ličko-senjske ($p = ,039$), te Krapinsko-zagorske i Šibensko-kninske županije ($p = ,039$).

Konačno, za **Stup 5: Pravila podataka** ($F(20, 544) = 2,19$; $p = ,002$), Ličko-senjska županija ponovno prednjači ($M = 3,33$), dok Krapinsko-zagorska bilježi najnižu razinu uspostavljenih

pravila upravljanja podacima (M = 1,90). Značajne razlike potvrđene su između Krapinsko-zagorske i Ličko-senjske (p = ,006), Splitsko-dalmatinske (p = ,031) te Zagrebačke županije (p = ,031).

Ovakva detaljna raščlamba pokazuje da Krapinsko-zagorska županija dosljedno bilježi najniže rezultate u gotovo svim dimenzijama digitalne zrelosti, što ukazuje na potrebu za sveobuhvatnom i sustavnom intervencijom. S druge strane, Ličko-senjska županija izdvaja se kao pozitivan primjer visoke razine strateškog promišljanja (Stup 1), upravljanja podacima (Stup 3) i uspostave pravila (Stup 5), dok Virovitičko-podravska i Vukovarsko-srijemska županija prednjače u samoj tehnološkoj opremljenosti (Stup 2). Zanimljivo je da Šibensko-kninska i Istarska županija bilježe izrazito visoke rezultate u dimenziji Sposobnosti (Stup 4), što može upućivati na to da u tim regijama postoji visoka razina digitalnih vještina i osposobljenosti korisnika, unatoč tome što njihov globalni indeks nije nužno najviši. Ovi nalazi potvrđuju da regionalne politike i savjetodavne podrške nisu jednako raspoređene niti jednako prihvaćene na terenu, te da su specifični lokalni čimbenici ključni za razumijevanje digitalne transformacije u hrvatskoj poljoprivredi.

4.8. Diferencijalni utjecaj demografskih i prostornih čimbenika na dimenzije digitalne zrelosti

Kako bi se dublje razumjelo koji čimbenici pokreću pojedine aspekte digitalne transformacije, provedeno je pet višestrukih linearnih regresijskih modela za svaki od pet stupnjeva digitalne zrelosti zasebno, uz korištenje identičnih prediktora kao i u modelu za globalni indeks (dob, obrazovanje, NUTS regija, veličina posjeda, broj zaposlenih i prihodi). Modeli su pokazali različite razine objašnjene varijance (R^2), pri čemu demografski čimbenici najviše varijance objašnjavaju za *Sposobnost* (R^2=0,341) i *Strategiju* (R^2=0,344), a najmanje za *Pravila podataka* (R^2=0,225).

Tablica 4.51. Sažetak višestrukih regresijskih modela za pojedine stupnjeve digitalne zrelosti

Stupanj zrelosti	Objašnjena varijanca (R^2)	Utjecaj Obrazovanja	Utjecaj Dobi	Utjecaj Veličine OPG-a	Utjecaj NUTS Regije
Stup 1: Strategija	34.4%	Snažan	Snažan	Nije značajan	Slab (Sjeverna)

Stup 2: Tehnologija	30.4%	Snažan	Snažan	Snažan (50-100ha)	Nije značajan
Stup 3: Podaci	32.5%	Snažan	Snažan	Nije značajan	Snažan (Pan./Sjeverna)
Stup 4: Sposobnost	34.1%	Snažan	Snažan	Umjeren	Snažan (Pan./Sjeverna)
Stup 5: Pravila	22.5%	Umjeren	Snažan	Slab (50-100ha)	Nije značajan

Analiza koeficijenata otkrila je nekoliko ključnih obrazaca koji imaju važne implikacije za razumijevanje digitalne transformacije hrvatske poljoprivrede:

Prvo, razina obrazovanja nositelja gospodarstva pokazala se kao univerzalni i najrobusniji prediktor, s visokom statističkom značajnošću napredujući kroz svih pet indeksa zrelosti ($p < ,001$). Ovo potvrđuje da obrazovanje predstavlja temeljnu pokretačku snagu digitalne transformacije, neovisno o specifičnoj dimenziji zrelosti.

Drugo, dob nositelja gospodarstva također je univerzalni prediktor, pri čemu stariji poljoprivrednici pokazuju značajno nižu razinu zrelosti u svim dimenzijama ($p < ,001$ za kategorije 51-60 i >60 godina u svih pet modela).

Treće, i najvažnije, utvrđen je značajan prostorni (regionalni) jaz u „mekim“ dimenzijama digitalne zrelosti. Dok geografska pripadnost (NUTS regija) nema značajan utjecaj na samu nabavu tehnologije (Stup 2, $p > ,05$) niti na uspostavu pravila upravljanja podacima (Stup 5, $p > ,05$), ona ima izrazito značajan utjecaj na Sposobnost (Stup 4) i Podatke i analitiku (Stup 3). Konkretno, gospodarstva u Panonskoj i Sjevernoj Hrvatskoj pokazuju statistički značajno nižu razinu sposobnosti i analitike u usporedbi s Gradom Zagrebom (Stup 3: $\beta = -0,38$ do $-0,44$, $p < ,05$; Stup 4: $\beta = -0,49$ do $-0,60$, $p < ,05$).

Ovaj nalaz upućuje na postojanje „vještinskog jaza“ (eng. skills gap) u kontinentalnoj Hrvatskoj. Poljoprivrednici izvan glavnog grada vjerojatno posjeduju tehnologiju (što potvrđuje neznačajnost regije u Stupu 2), ali im nedostaje napredno znanje, kadrovi i pristup edukacijama za njezinu punu analitičku iskorištenost. Ovo predstavlja ključni nalaz za kreiranje ciljanih intervencija u digitalnoj transformaciji hrvatske poljoprivrede.

Četvrto, veličina poljoprivrednog posjeda pokazala se kao značajan prediktor isključivo za usvajanje same Tehnologije (Stup 2), pri čemu se najveća gospodarstva (50-100 ha) značajno

razlikuju od najmanjih (p = ,001). Ovo sugerira da kapital i ekonomija razmjera primarno diktiraju nabavu hardvera i softvera, ali ne nužno i sposobnost njihove analitičke primjene.

Peto, modeli za pojedine stupnjeve objašnjavaju različite razine varijance i to od 22,5% za Pravila podataka (Stup 5) do 34,4% za Strategiju i kulturu (Stup 1). Činjenica da demografski čimbenici najslabije objašnjavaju Pravila podataka sugerira da na ovu dimenziju najviše utječu vanjski čimbenici koji nisu uključeni u model, poput zakonske regulative, GDPR zahtjeva ili specifičnosti pojedinih grana proizvodnje.

Nadalje, utjecaj NUTS regije na pojedine stupnjeve digitalne zrelosti, prikazan sljedećom tablicom, jasno vizualno pokazuje da je utjecaj regije najjači u Stupu 4 (Sposobnost) i Stupu 3 (Podaci), dok je u Stupu 2 (Tehnologija) gotovo zanemariv.

Tablica 4.52. Utjecaj NUTS regije na pojedine stupnjeve digitalne zrelosti (referentna kategorija: Grad Zagreb)

NUTS regija	Stup 1 (β)	Stup 2 (β)	Stup 3 (β)	Stup 4 (β)	Stup 5 (β)
Jadranska Hrvatska	-0,229	-0,113	-0,331*	-0,339	-0,162
Panonska Hrvatska	-0,310	-0,046	-0,383*	-0,492*	-0,211
Sjeverna Hrvatska	-0,375*	-0,124	-0,444*	-0,600*	-0,320

Napomena: * p < ,05; prikazani su samo koeficijenti za NUTS regiju; referentna kategorija je Grad Zagreb

4.9. Klasifikacija gospodarstava prema CSIRO fazama digitalne zrelosti

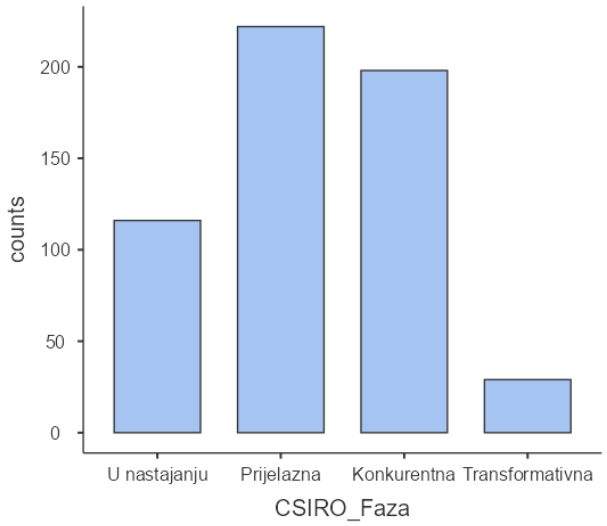
Kako bi se dodatno operacionalizirali nalazi istraživanja i omogućila direktna usporedba s međunarodnim standardima, provedena je klasifikacija poljoprivrednih gospodarstava u četiri evolucijske faze digitalne zrelosti prema CSIRO nazivlju i metodologiji. Klasifikacija je provedena na temelju vrijednosti globalnog indeksa digitalne zrelosti (Globalni_DRI), pri čemu su definirani sljedeći pragovi: ***Emerging*** **(U nastajanju)** (1,00–2,00), ***Transitional*** **(Prijelazna)** (2,01–3,00), ***Competitive*** **(Konkurentna)** (3,01–4,00) i ***Transformative*** **(Transformativna)** (4,01–5,00).

Iako su prethodno provedene analize kontinuirane varijable Globalni_DRI i empirijska K-means klasterska analiza pružile detaljan uvid u statističku varijabilnost i prirodno grupiranje gospodarstava unutar istraživanog uzorka, primjena teorijski definiranih pragova CSIRO modela nužna je iz nekoliko metodoloških razloga. Prvo, dok K-means klasteri identificiraju

statistički najsličnije profile temeljene isključivo na podacima prikupljenim u ovom specifičnom uzorku, CSIRO faze predstavljaju unaprijed definirane, teorijski utemeljene razine zrelosti koje omogućuju apsolutno pozicioniranje gospodarstava neovisno o distribuciji podataka. Drugo, ova klasifikacija prevodi kontinuirani statistički rezultat u prepoznatu taksonomiju digitalne transformacije, čime se rezultati ovog istraživanja izravno mapiraju na originalni konceptualni okvir CSIRO metodologije. Konačno, korištenje ovih standardiziranih kategorija stvara preduvjete za komparativnu analizu i *benchmarking* hrvatskog poljoprivrednog sektora u odnosu na druge međunarodne studije koje koriste isti model zrelosti.

Tablica 4.53. Distribucija poljoprivrednih gospodarstava prema CSIRO fazama digitalne zrelosti (N = 565)

CSIRO faza	Broj gospodarstava	Postotak	Kumulativni postotak
U nastajanju (Emerging)	116	20,5%	20,5%
Prijelazna (Transitional)	222	39,3%	59,8%
Konkurentna (Competitive)	198	35,0%	94,9%
Transformativna (Transformative)	29	5,1%	100,0%



Slika 4.22. Distribucija poljoprivrednih gospodarstava prema CSIRO fazama digitalne zrelosti

Rezultati klasifikacije (Tablica 4.33.) pokazuju da se hrvatska poljoprivredna gospodarstva nalaze u različitim fazama digitalne transformacije, s jasnom dominacijom ranijih faza. Najveći udio gospodarstava (39,3%) nalazi se u **Prijelaznoj fazi**, što znači da su započela s usvajanjem osnovnih digitalnih alata, ali još nisu postigla integriranu i sustavnu digitalnu transformaciju.

Dodatnih 20,5% gospodarstava nalazi se u fazi **U nastajanju**, gdje je digitalno usvajanje *ad hoc* ili gotovo nepostojeće, a gospodarstva se primarno oslanjaju na tradicionalne, manualne procese. Zajedno, ova dva segmenta čine **59,8% ukupnog uzorka**, što ukazuje na to da većina hrvatskih poljoprivrednih gospodarstava tek započinje ili je u ranoj fazi digitalne transformacije. Ovaj nalaz je u skladu s prosječnom vrijednošću globalnog indeksa digitalne zrelosti (M = 2,75), koja se nalazi u donjem dijelu raspona Prijelazne faze.

Konkurentnu fazu dosegnulo je 35,0% gospodarstava, što znači da aktivno koriste digitalne tehnologije i analitiku podataka za donošenje informiranih odluka i optimizaciju poljoprivrednih procesa. Međutim, samo **5,1% gospodarstava** (n = 29) nalazi se u najvišoj, **Transformativnoj fazi**, gdje su digitalni sustavi duboko integrirani u poslovnu strategiju, omogućujući prediktivnu analitiku, automatizaciju i potpunu integraciju lanca opskrbe.

4.10. Sažetak testiranja hipoteza

U ovom dijelu sažeti su ključni statistički nalazi provedenih analiza u odnosu na tri istraživačke hipoteze postavljene u okviru ovog rada. Za svaku hipotezu prikazani su empirijski dokazi dobiveni primijenjenim statističkim metodama.

Hipoteza 1

Poljoprivredni subjekti u Republici Hrvatskoj imaju nižu razinu digitalne zrelosti u usporedbi s prosjekom digitalne zrelosti malih i srednjih poduzeća u drugim sektorima gospodarstva.

Empirijski nalazi relevantni za testiranje:

- Utvrđena prosječna vrijednost globalnog indeksa digitalne zrelosti (Globalni_DRI) na uzorku od N = 565 poljoprivrednih gospodarstava iznosi **M = 2,75** (SD = 0,82), na skali od 1 do 5.
- Klasifikacija prema CSIRO fazama digitalne zrelosti pokazala je da se **59,8% gospodarstava** nalazi u ranim fazama zrelosti (20,5% u fazi *Emerging* i 39,3% u fazi *Transitional*), dok samo 5,1% gospodarstava doseže najvišu, *Transformative* fazu.
- Najniže prosječne vrijednosti zabilježene su u stupovima *Podaci i analitika* (M = 2,49) i *Pravila podataka* (M = 2,52), dok najvišu vrijednost bilježi stup *Sposobnost* (M = 3,10).

Hipoteza 2

Postoji značajna povezanost između organizacijskih čimbenika (npr. veličina gospodarstva, stupanj obrazovanja vlasnika, dob, iskustvo i slično) i digitalne zrelosti poljoprivrednih gospodarstva za usvajanje digitalnih tehnologija.

Empirijski nalazi relevantni za testiranje:

Korelacijska analiza:

- Utvrđene su statistički značajne korelacije između globalnog indeksa digitalne zrelosti i ključnih demografskih varijabli: dob nositelja ($r = -0,46$, $p < 0,001$), razina obrazovanja ($r = 0,53$, $p < 0,001$), veličina poljoprivrednog posjeda ($r = 0,23$, $p < 0,001$) i godišnji prihodi ($r = 0,31$, $p < 0,001$).

Višestruka regresijska analiza:

- Regresijski model s demografskim i organizacijskim prediktorima objašnjava **33,8% varijance** globalnog indeksa digitalne zrelosti (prilagođeni $R^2 = 0,338$, $F = 34,5$, $p < 0,001$).
- Statistički značajni prediktori u modelu su: razina obrazovanja ($\beta = 1,191$ za visoko obrazovanje, $p < 0,001$), dob nositelja ($\beta = -0,703$ za kategoriju >60 godina, $p < 0,001$) te godišnji prihodi ($\beta = 0,509$ za najvišu kategoriju, $p = 0,008$).
- Zasebni regresijski modeli za svaki od pet stupnjeva zrelosti pokazali su da razina obrazovanja predstavlja statistički značajan prediktor u svih pet modela ($p < 0,001$), dok veličina gospodarstva značajno predviđa isključivo Stup 2: Tehnologija ($\beta = 0,311$ za 50-100 ha, $p = 0,001$).

Klasterska analiza i profiliranje:

- K-means klasterska analiza identificirala je četiri profila gospodarstava koja se statistički značajno razlikuju po digitalnoj zrelosti ($F(3, 561) = 1985$, $p < 0,001$).
- Hi-kvadrat testovi potvrdili su statistički značajnu povezanost pripadnosti klasteru s dobi nositelja ($\chi^2(12) = 114$, $p < 0,001$), razinom obrazovanja ($\chi^2(18) = 90,0$, $p < 0,001$), veličinom posjeda ($\chi^2(24) = 67,2$, $p < 0,001$) i godišnjim prihodima ($\chi^2(12) = 65,4$, $p < 0,001$).

Hipoteza 3

Ne postoji jedinstvena i općeprihvaćena metodologija prilagođena specifičnostima poljoprivrednog sektora za evaluaciju digitalne zrelosti poljoprivrednog sektora, što otežava preciznu procjenu i planiranje digitalne transformacije.

Empirijski nalazi relevantni za testiranje:

- U okviru istraživanja primijenjen je prilagođeni CSIRO model digitalne zrelosti za hrvatski poljoprivredni sektor, strukturiran u pet stupnjeva (Strategija i kultura, Tehnologija, Podaci i analitika, Sposobnost, Pravila podataka) s ukupno 54 tvrdnje (pitanja/odgovora).
- **Cronbachov α koeficijent** za sve stupnjeve pokazao je visoku unutarnju konzistentnost instrumenta: Stup 1 ($\alpha = 0{,}937$), Stup 2 ($\alpha = 0{,}902$), Stup 3 ($\alpha = 0{,}931$), Stup 4 ($\alpha = 0{,}929$), Stup 5 ($\alpha = 0{,}827$).
- **Analiza glavnih komponenti (PCA)** na razini pet stupnjeva pokazala je da prva glavna komponenta objašnjava **76,4% ukupne varijance**, s visokim opterećenjima svih pet stupnjeva (raspon od 0,780 do 0,923), čime je potvrđena jednodimenzionalnost konstrukta digitalne zrelosti u poljoprivredi.
- **Kaiser-Meyer-Olkin (KMO) mjera prikladnosti uzorkovanja** iznosila je 0,901, a **Bartlettov test sferičnosti** bio je statistički značajan ($\chi^2 = 1835$, $p < 0{,}001$), čime je potvrđena čimbenična prikladnost podataka.

Tablica 4.54. Sažetak testiranja istraživačkih hipoteza

Hipoteza	Ključni statistički pokazatelji	Status
H1: Poljoprivredni subjekti u RH imaju nižu razinu digitalne zrelosti u usporedbi s prosjekom SME-ova u drugim sektorima	Globalni_DRI: M = 2,75 (SD = 0,82); 59,8% gospodarstava u ranim fazama (Emerging+Transitional); samo 5,1% u Transformative fazi	Empirijski **potvrđena** (deskriptivni pokazatelji ukazuju na nižu razinu; širi komparativni kontekst obrađen u Raspravi)
H2: Postoji značajna povezanost organizacijskih čimbenika i digitalne zrelosti	Regresijski model: prilagođeni $R^2 = 0{,}338$ ($p < 0{,}001$); značajni prediktori: obrazovanje, dob, prihodi; značajne korelacije ($r = -0{,}46$ do $0{,}53$); klasterska segmentacija ($F = 1985$, $p < 0{,}001$)	**Potvrđena**

-

H3: Ne postoji jedinstvena metodologija prilagođena poljoprivrednom sektoru	Prilagođeni CSIRO model s 5 stupnjeva i 54 tvrdnje; Cronbach α = 0,827-0,937; PCA: 76,4% varijance na prvoj komponenti; KMO = 0,901	Metodološki validirana i **potvrđena** prilagodba

5. RASPRAVA

5.1. Uvod i sažetak ključnih nalaza

Glavni cilj ovog istraživanja bio je identificirati razinu digitalne zrelosti poljoprivrednih gospodarstava u Republici Hrvatskoj (veličine do 100 ha) te razviti metodologiju za procjenu njihove spremnosti za digitalnu transformaciju. Polazeći od prilagođenog CSIRO modela digitalne zrelosti, istraživanje je pružilo sveobuhvatan uvid u to kako hrvatski poljoprivrednici usvajaju tehnologiju, upravljaju podacima, razvijaju digitalne vještine i uspostavljaju strateška pravila.

Provedene analize otkrile su nekoliko ključnih, a često i iznenađujućih nalaza koji definiraju trenutno stanje digitalne transformacije u hrvatskoj poljoprivredi. Prvo, utvrđeno je da se hrvatska poljoprivreda u cjelini nalazi u ranim fazama digitalne zrelosti, s jasnom dominacijom *Prijelazne* i faze *U nastajanju* (gotovo 60% uzorka), dok je potpuna digitalna integracija (Transformativna faza) prisutna u tek nešto više od 5% gospodarstava.

Drugo, profil digitalne zrelosti pokazao je izrazitu asimetriju: dok poljoprivrednici bilježe relativno visoke rezultate u dimenziji *Sposobnosti* (osnovne digitalne vještine), istovremeno bilježe najniže rezultate u dimenzijama *Podataka i analitike* te *Pravila podataka*. Ovo ukazuje na paradoks "digitalizacije bez digitalne transformacije", odnosno tehnologija se nabavlja, ali se njezin puni analitički potencijal ne koristi.

Treće, i možda najvažnije, istraživanje je nedvojbeno potvrdilo da su ključni pokretači digitalne zrelosti **demografski čimbenici**, prvenstveno dob i razina obrazovanja nositelja gospodarstva, dok veličina posjeda i geografska lokacija imaju značajno manji, ili pak specifičan i diferenciran utjecaj. Utvrđen je i izražen „vještinski jaz“ (eng. *skills gap*) u kontinentalnoj Hrvatskoj, gdje gospodarstva posjeduju tehnologiju, ali im nedostaje znanje za njezinu analitičku primjenu.

U nastavku ovog poglavlja, ovi će se nalazi detaljno interpretirati, usporediti s međunarodnim okvirima i teorijskim polazištima, te će se izvesti praktične implikacije za kreatore politika, savjetodavne službe i same poljoprivrednike.

5.2. Profil digitalne zrelosti hrvatske poljoprivrede u kontekstu CSIRO modela

Rezultati deskriptivne analize pokazali su da prosječna razina globalne digitalne zrelosti (Globalni_DRI) hrvatskih poljoprivrednih gospodarstava iznosi 2,75 na skali od 1 do 5. Iako

ova vrijednost na prvi pogled sugerira umjerenu razinu zrelosti, dublja analiza pojedinačnih stupova CSIRO modela otkriva složeniju i fragmentiranu sliku.

5.2.1. Asimetrični profil: Paradoks „tehnologije bez podataka“

Najvišu prosječnu vrijednost gospodarstva su postigla u stupu **Sposobnost** (M = 3,10), dok su najniže vrijednosti zabilježene u stupovima **Podaci i analitika** (M = 2,49) i **Pravila podataka** (M = 2,52). Stup **Tehnologija** (M = 2,81) i **Strategija i kultura** (M = 2,84) zauzimaju srednju poziciju.

Ovakav profil ukazuje na specifičan obrazac usvajanja digitalnih alata u hrvatskoj poljoprivredi. Visoka razina *Sposobnosti* vjerojatno ne odražava napredne analitičke vještine, već prvenstveno osnovnu digitalnu pismenost (npr. korištenje pametnih telefona, osnovnih aplikacija za komunikaciju ili jednostavnih poljoprivrednih registara). S druge strane, izrazito niske vrijednosti u dimenziji *Podaci i analitika* sugeriraju da poljoprivrednici, unatoč posjedovanju određene tehnologije (npr. GNSS sustavi na traktorima, senzori i slično), ne prikupljaju sustavno podatke, ne integriraju ih niti ih koriste za donošenje poslovnih odluka.

Ovaj nalaz u skladu je s konceptom „digitalnog jaza“ u poljoprivredi, gdje fokus ostaje na hardverskoj opremljenosti, a zanemaruje se "meki" aspekt upravljanja podacima. Uz to, posebno je značajno sustavno razmatranje cijelog fenomena. Poljoprivredni sektor igra dvostruku ulogu kao glavni potrošač energije i potencijalni proizvođač obnovljive energije. Strateška integracija digitalnih i Industrije 4.0 tehnologija unutar sektora ključna je za postizanje Cilja održivog razvoja 7 (SDG 7), čiji je cilj osigurati svima pristupačnu, čistu energiju. Ovaj pregled sustavno mapira primjenu ključnih tehnologija, poput umjetne inteligencije (AI), Interneta stvari (IoT), nanotehnologije i robotike, u odnosu na pet ciljeva SDG 7: univerzalni pristup; udio obnovljive energije; energetska učinkovitost; ulaganja u istraživanje i razvoj; te usluge za zemlje u razvoju. Nadolazeći s opisom trenutnog stanja tehnike, ovaj pregled definira ključne strateške smjerove za budući istraživačko-razvojni rad: unapređenje umjetne inteligencije od prediktivnih do autonomnih sustava upravljanja; razvoj zelenog i energetski učinkovitog IoT-a s vlastitim, biorazgradivim senzorima; istraživanje nano-bio sinergija za poboljšanu proizvodnju bioenergije; poboljšanje energetske učinkovitosti i autonomije poljoprivrednih vozila i robotike; te projektiranje integriranih hibridnih sustava koji zajedno proizvode hranu i energiju. Također se analiziraju prepreke provedbi, uključujući digitalni jaz, visoke početne troškove i kompromise u pogledu održivosti. Konačno, predlaže se skup praktičnih preporuka politika koje će voditi vlade i međunarodna tijela u poticanju održive energetske tranzicije u poljoprivredi (Parra-López, C., Carmona-Torres, C., 2026.).

Činjenica da je dimenzija *Pravila podataka* također na samom dnu ljestvice dodatno potvrđuje da upravljanje podacima, njihova sigurnost i etika još uvijek nisu prepoznati kao ključni resurs na razini obiteljskih poljoprivrednih gospodarstava u Hrvatskoj (Zhang i dr. 2022.).

Ovaj nedostatak upravljanja podacima nije samo pitanje interne neučinkovitosti, već predstavlja izravnu prijetnju konkurentnosti na europskom tržištu. U kontekstu europskog Zelenog plana (*EU Green Deal*) i strategije „Od polja do stola“ (*Farm to Fork*), poljoprivrednici će morati dokazivati svoju održivost kroz precizne podatke o upotrebi inputa, emisijama i utjecaju na bioraznolikost. Bez uspostavljenih sustava za prikupljanje i analitiku podataka (Stup 3) te jasnih pravila upravljanja (Stup 5), hrvatski poljoprivrednici neće moći zadovoljiti nadolazeće regulatorne zahtjeve za digitalnom sljedivošću i preciznom poljoprivredom, čime riskiraju gubitak pristupa vrijednim tržišnim nišama i europskim fondovima.

Maru i dr. (2018.) prikazuje rad s rastućim količinama podataka među kojim se mala gospodarstva sve teže snalaze. U razvoju pametne poljoprivrede, predviđa se primjena informacijske i komunikacijske tehnologije u ciklusu kibernetičko-fizičkog upravljanja poljoprivredom, ali i tehnologija popit Interneta stvari i računarstva u oblaku, uvođenje robota i umjetne inteligencije u poljoprivredu. (Wolfert i dr, 2017.)[T1].

Ovidiu i Noran (2017.) opisuju sponu koja nedostaje između vrste i kvalitete informacija potrebnih za proces donošenja odluka te znanja dobivenog primjenom najnovijih tehnologija „velikih podataka” (engl. *big data*), s naglaskom na upravljanje i nadzor u sustavima sustava i suradničkim mrežama. Koristeći se poznatim teorijama donošenja odluka, članak ukazuje na nedostatak u postojećoj tehnologiji koji proizlazi iz nesrazmjera između velikog broja obrazaca prepoznatljivih u dostupnim podacima pomoću analitike podataka i nedostatka tehnologije sposobne pružiti narativ nužan za pravovremeno i učinkovito donošenje odluka. Zaključuje se da je za učinkovitu uporabu analitike podataka potrebna druga razina situacijske logike kako bi se djelotvorno podržalo dinamičko konfiguriranje i rekonfiguriranje sustava sustava radi postizanja otpornosti, učinkovitosti i drugih željenih sistemskih svojstava.

Ipak, intenzivni razvoj i primjena tehnologije, kao i „nagomilavanje“ opreme, koja nerijetko ne uspijeva biti iskorištena niti u osnovnoj i (od proizvođača preporučenoj) mjeri, dovela je do fenomena i postavljanja pitanja iskorištenosti resursa, odnosno „DRIP konvepta“ [T2](Data Rich Information Poor) koncepta, koji ne osigurava ciljane rezultate ni ishode, (Obeidat i dr.. 2015.).

5.2.2. Klasifikacija po CSIRO fazama: Većina u „Prijelaznoj fazi“

Klasifikacija gospodarstava prema teorijskim pragovima CSIRO modela pokazala je da se **59,8% gospodarstava** nalazi u ranim fazama razvoja (20,5% u fazi *U nastajanju* i 39,3% u *Prijelaznoj fazi*). Samo 35,0% gospodarstava doseže *Konkurentnu fazu*, a svega 5,1% *Transformativnu fazu*.

Ovakva distribucija jasno signalizira da digitalna transformacija u hrvatskoj poljoprivredi još uvijek nije sustavna ni strateška. Gospodarstva u *Prijelaznoj fazi* karakterizira *ad hoc* usvajanje digitalnih alata. Tehnologija se kupuje kao odgovor na trenutne potrebe ili poticaje, a ne kao dio dugoročne digitalne strategije. Nedostatak strategije izravno je povezan s niskim rezultatima u prvom stupu CSIRO modela (*Strategija i kultura*), što potvrđuje da digitalizacija u ovom sektoru još uvijek nije prepoznata kao ključni element poslovne kulture i dugoročnog planiranja nasljeđivanja i razvoja gospodarstva (Zhang i dr. 2022.).

5.2.3. Usporedba s drugim sektorima i međunarodnim kontekstom

Usporedba dobivenih rezultata s istraživanjima digitalne zrelosti u drugim sektorima (npr. proizvodna industrija, maloprodaja) i drugim državama otkriva da poljoprivredni sektor u Hrvatskoj, ali i šire u Europi, zaostaje u digitalnoj transformaciji (DESI Index, 2022.)[T3].

Dok drugi sektori već prelaze u fazu automatizacije i korištenja umjetne inteligencije (*Transformativna faza*), hrvatska poljoprivreda se još uvijek bori s temeljnom integracijom podataka i uspostavom digitalnih pravila. Razlozi za ovakvo stanje su višestruki i uključuju specifičnosti sektora (visoka ovisnost o prirodnim uvjetima, fragmentiranost posjeda, starenje stanovništva), ali i nedostatak ciljanih, „mekih“ mjera podrške koje se ne fokusiraju isključivo na nabavu hardvera, već na edukaciju, savjetovanje i izgradnju kapaciteta za rad s podacima Europska komisija u zadnjem proračunskom razdoblju i u planovima za slijedeća razdoblja, posebnu ulogu i fokus usmjerava prema edukaciji, savjetovanju, razvoju, inovacijama, a rad s podacima je uz bok navedenim prioritetima. (Europska komisija, 2026.).[T4]

Dodatni savjet: Za 5.2.3. obavezno citiraj i opiši **DESI (Digital Economy and Society Index)** za Hrvatsku, jer to daje odličan makro-ekonomski kontekst.

Europska komisija od 2014. prati digitalni napredak država članica putem izvješća o indeksu gospodarske i društvene digitalizacije (DESI).

Od 2023. i u skladu s programom politike za digitalno desetljeće do 2030. DESI je sada integriran u izvješće o stanju digitalnog desetljeća i upotrebljava se za praćenje napretka u ostvarenju digitalnih ciljeva. Također može se[T5] posebno uputiti na izvješća po državama. U Nacionalnoj strategiji kibernetičke sigurnosti Republike Hrvatske prepoznata je prioritetna važnost digitalne transformacije. Strategija je usmjerena na poboljšanje informiranosti o sigurnosti, pružanje visokokvalitetnih usluga u skladu s Aktom o kibersigurnosti te jačanje sigurnosti i vjerodostojnosti hrvatske domene.

Hrvatska je pokrenula niz mjera kojima se podupire digitalizacija poduzeća i MSP-ova, od vaučera za stjecanje vještina i uvođenja novih tehnologija (računalstvo visokih performansi, kvantno računalstvo, umjetna inteligencija, lanac blokova) do certifikata za sigurnost. Mnogo je učinjeno i u digitalizaciji zdravstvenog sektora uvođenjem umjetne inteligencije u kritične usluge koje se pružaju 24 sata dnevno. Stoga bi bilo dobro osmisliti sveobuhvatan, koordiniran i integriran pristup kako bi se dodatno ojačala nastojanja Hrvatske. Njegovo povezivanje s integracijom mjera ponude i potražnje i uspostavljanje jakih veza s potrebnim ulaganjima u ljudski kapital mogli bi pojačati rast (DESI Index, 2022[T6].).

5.3. Demografski i organizacijski pokretači digitalne transformacije

Rezultati provedenih regresijskih analiza i profiliranja klastera nedvojbeno su pokazali da digitalna zrelost poljoprivrednih gospodarstava u Hrvatskoj nije primarno određena vanjskim infrastrukturnim ili isključivo geografskim uvjetima, već unutarnjim demografskim i organizacijskim karakteristikama nositelja i samih gospodarstava. Analiza je otkrila jasnu hijerarhiju utjecaja pojedinih čimbenika, pri čemu ljudski kapital daleko nadmašuje fizički kapital u pokretanju sveobuhvatne digitalne transformacije.

5.3.1. Primat ljudskog kapitala je obrazovanje i dob

Najrobusnijim i najuniverzalnijim prediktorom digitalne zrelosti pokazala se razina obrazovanja nositelja gospodarstva. Bez obzira promatra li se globalni indeks ili bilo koji od pet pojedinačnih stupova CSIRO modela, formalno obrazovanje ima snažan i statistički visoko značajan pozitivan učinak. Ovaj nalaz u potpunosti je u skladu s teorijom ljudskog kapitala. (Schultz, 1990.; Becker,1994.), koja postulira da obrazovanje povećava sposobnost pojedinca za apsorpciju novih informacija i učinkovitije korištenje novih tehnologija. Obrazovani poljoprivrednici vjerojatno lakše percipiraju relativnu prednost i korisnost digitalnih alata, što je ključna pretpostavka Modela prihvaćanja tehnologije (TAM) (Davis, 1989.).

Štoviše, visoka razina obrazovanja pokazala se kao nužan, iako ne i jedini, preduvjet za prelazak iz faze pukog usvajanja tehnologije (Stup 2) u fazu napredne analitike podataka i strateškog upravljanja (Stupovi 1, 3 i 4).

Naime, intelektualni kapital obuhvaća znanja, sposobnosti, organizacijske procese i tržišne odnose koji stvaraju dodatnu vrijednost gospodarstva. Radovi Theodora Schultza (1959.; 1960.; 1961.; 1962.; 1968.; 1975.; 1982.; 1990.; 1993.) ili Garyja Beckera, (1992.; 1994.; 2002.) opisuju fenomen ljudskog kapitala ili novije radove koji to primjenjuju na poljoprivredu. (npr. human capital in agriculture)[T7].

Huffman, i Orazem (2007.) u svom istraživanju o fenomenu ljudskog kapitala u poljoprivredi [T8]razmatraju postojeću literaturu, identificirajući doprinos poljoprivrede, školovanja i prehrane gospodarskom rastu i razvoju tijekom vremena i u različitim zemljama. Posebnu pozornost posvećuju ulozi unapređenja poljoprivredne tehnologije i ljudskog kapitala poljoprivrednika i poljoprivrednog stanovništva, uzimajući u obzir makroekonomske i mikroekonomske dokaze vezane uz interakcije između ljudskog kapitala, produktivnosti i zdravlja. Većina svjetskog rasta stanovništva, produktivnosti rada i realnog dohotka po glavi stanovnika dogodila se u posljednjih 250 godina. Za većinu je zemalja razvoj proces pretvorbe iz prvenstveno agrarnih gospodarstava u urbana industrijska i uslužna gospodarstva. Dokazi su da su pozitivni tehnološki šokovi u poljoprivredi odigrali ključnu ulogu u pokretanju prijelaza s tradicionalne na modernu poljoprivredu i dugoročnog gospodarskog rasta u gotovo svim zemljama. Poboljšanja poljoprivrednih tehnologija poboljšavaju produktivnost rada i stvaraju višak poljoprivredne radne snage koja može osigurati radnike za rastuća urbana područja. U nekim slučajevima, kvalitetnija prehrana pomaže u povećanju produktivnosti rada i omogućuje pojedincima da ulažu više resursa u razvoj ljudskog kapitala što ulaganja u ljudski kapital čini privlačnijima. Inducirana poboljšanja u razini vještina stanovništva imaju velike implikacije na podizanje životnog standarda, poboljšanje zdravstvenog standarda i promjenu odluka o raspodjeli vremena. U većini trenutno siromašnih i zemalja sa srednjim dohotkom, poboljšano školovanje bilo je važnije od poboljšane prehrane ili unosa kalorija u objašnjenju nedavnog gospodarskog rasta. Ipak, najsiromašnije zemlje svijeta i dalje imaju veliki udio ~~svoje~~ radne snage u poljoprivredi, a rast se ne može dogoditi dok ne dožive vlastitu poljoprivrednu transformaciju (Huffmani i Orazem, 2007[T9].).

Davis (1989.) u svom daljnjem radu proširuje konceptualni model i predlaže model prihvaćanja tehnologije, te opisuje motivaciju korisnika za korištenjem sustava s tri čimbenika:

1. Percipiranom lakoćom korištenja (engl. Perceived Ease of Use, PEU)

2. Percipiranom korisnosti (engl. Perceived Usefulness, PU)

3. Stavom prema korištenju (engl. Attitude Toward Using, A)

Davis (1989.) postavlja hipotezu vezano uz stav korisnika prema sustavu kao glavnoj determinanti stvarnog korištenja ili odbacivanja sustava. Pretpostavio je utjecaj dva prethodna , uz pretpostavku jednostavnosti korištenja te izravan utjecaj na percipiranu korisnost. Percipiranu je korisnost Davis definirao kao stupanj vjerovanja koliko će određeni pojedinac imati povjerenja u primjenu određenog sustava povećati učinkovitost u poslu. Percipiranu lakoću korištenja definirao je kao stupanj vjerovanja osobe o količini napora potrebnog za korištenje određenog sustava Davis (1989[T10].).

Usko povezano s obrazovanjem, dob nositelja gospodarstva identificirana je kao ključna demografska barijera. Stariji nositelji (posebno kategorija iznad 60 godina) dosljedno su pokazivali nižu razinu zrelosti u svim dimenzijama. Ovaj nalaz izravno reflektira duboku demografsku krizu hrvatske poljoprivrede, karakteriziranu starenjem populacije i sporom generacijskom obnovom, kao izvor o demografiji poljoprivrede u RH navodi se Zeleno izvješće za 2024 (Zeleno izvješće, 2024[T11].).

Stariji poljoprivrednici, koji su često dugi niz godina uspješno gospodarili koristeći tradicionalne metode, mogu imati nižu percipiranu potrebu za digitalnom transformacijom ili se suočavaju s većim poteškoćama u savladavanju složenih digitalnih sučelja. Činjenica da Klaster 4 („Digitalni lideri“) čine najmlađi i najobrazovaniji nositelji, dok Klaster 1 („Digitalni početnici“) čine najstariji s najnižom razinom obrazovanja, potvrđuje da je generacijska smjena ključni preduvjet za digitalni skok hrvatske poljoprivrede.

S mikroekonomskog stajališta, ovaj nalaz može se objasniti kroz koncept „troškova učenja“ (eng. *learning costs*) i informacijske asimetrije. Stariji nositelji, suočeni s kraćim vremenskim horizontom planiranja zbog nadolazećeg umirovljenja, percipiraju povrat na investiciju u složene digitalne vještine kao nedovoljan u odnosu na visoke početne troškove učenja. Dodatno, informacijska asimetrija na tržištu digitalnih rješenja otežava im procjenu stvarne korisnosti i kompatibilnosti tehnologije s njihovim specifičnim proizvodnim procesima, što dovodi do racionalnog, ali tehnološki konzervativnog ponašanja.

Struktura poljoprivrednih gospodarstava

OECD Izvješće o RH za 2025 godinu opisuje politike za budućnost poljoprivrede i hrane u Hrvatskoj. OECD-ovo Izvješće daje realan prikaz hrvatske poljoprivredne politike uzimajući u obzir vremenski okvir u kojem je Republika Hrvatska postala samostalna država pa do danas.

Nalazi Izvješća ukazuju da hrvatska poljoprivreda danas pokazuje jasne i ohrabrujuće trendove. Rast produktivnosti poljoprivrednog sektora je među najbržima u Europskoj uniji i u usporedbi s članicama OECD-a, pri čemu taj rast ne prati povećanje štetnih emisija iz poljoprivrede. Vidljiva je strukturna transformacija. Manje mješovite farme postupno prerastaju u konkurentnija i profesionalnija gospodarstva, a prihodi poljoprivrednika rastu. Uz navedeno, raste broj mladih poljoprivrednika i žena nositeljica gospodarstava. Hrvatska se sve snažnije uključuje u europske i međunarodne lance vrijednosti, dok ekološka poljoprivreda bilježi jedan od najdinamičnijih porasta u EU-u. U nizu okolišnih pokazatelja Hrvatska stoji vrlo dobro, uključujući nisku razinu emisija iz poljoprivrede, sve manju upotrebu pesticida i visoku kvalitetu voda. Sve to potvrđuje da hrvatska poljoprivreda ima snažan temelj za daljnji, održiv i konkurentan razvoj.

OECD Odbor za poljoprivredu nastoji svojim radom osigurati adekvatan odgovor na „trostruki izazov“ u području poljoprivrede - osigurati proizvodnju sigurne i nutritivno kvalitetne hrane za rastuću populaciju, omogućiti poljoprivrednicima održive prihode te istovremeno sačuvati okoliš i prirodne resurse za buduće generacije.

Kao jedan od fokusa navodi se rast produktivnosti u poljoprivredi uz istovremeno smanjenje emisija iz poljoprivrede. Uz to, razvidan je trend rasta udjela mladih poljoprivrednika.

Unatoč značajnim izazovima s kojima se suočavala u posljednjim desetljećima i brojnim preostalim zadacima, Hrvatska je uspjela razviti poljoprivredni sektor koji je produktivan. Ukupna produktivnost čimbenika (Total Factor Productivity - TFP) bilježi izvanredan rast u posljednjim desetljećima, nadmašujući većinu zemalja usporedivih po razvoju, i bila je ključni pokretač rasta poljoprivredne proizvodnje te smanjenja emisija stakleničkih plinova. Prosječni godišnji rast ukupne produktivnosti čimbenika u razdoblju 2011. - 2021. iznosio je 2,4%, što je više nego dvostruko od prosjeka OECD-a (0,85 %) i više od prosjeka Europske unije od 1,2%.

Broj mladih poljoprivrednika raste unatoč izazovnom kontekstu. Dobna struktura nositelja gospodarstava naginje prema starijoj populaciji. Godine 2020. godine, 62% nositelja gospodarstava imalo je 55 ili više godina. Ipak, broj mladih poljoprivrednika (mlađih od 35 godina) raste. Kako broj gospodarstava kojima upravljaju mladi poljoprivrednici, tako i njihov udio u ukupnom broju gospodarstava povećao se tijekom posljednjeg desetljeća. Godine 2020., mladi poljoprivrednici su bili nositelji 7% gospodarstava.

Aktualna situacija: Statistički podaci pokazuju da u Hrvatskoj u 2025. ima 13% vlasnika farmi koji su mlađi od 40 godina, što je nešto bolje od prosjeka EU, ali i dalje nedovoljno za dugoročnu održivost i konkurentnost. Stoga generacijska obnova u poljoprivredi ostaje prioritetno pitanje za osiguranje sigurne opskrbe hranom, ekonomske otpornosti i budućnosti naših ruralnih zajednica. Hrvatska[T12] ima koristi od općenito dobrog stanja prirodnih resursa, s ekosustavima koji su među najbogatijima u Europi te obiljem vodnih resursa u usporedbi s ostatkom Europske unije. Poljoprivreda smanjuje upotrebu kemijskih sredstava, a ekološka proizvodnja kontinuirano se širi.

Prema podacima iz Upisnika poljoprivrednika i Upisnika obiteljskih poljoprivrednih gospodarstava koje vodi APPRRR, na dan 31. prosinca 2024. godine bilo je upisano 161.227 poljoprivrednika. Od njih je najviše OPG-ova, 118.859 ili 73,7% od ukupnog broja poljoprivrednika. Zbog procesa usklađivanja OPG-ova s odredbama Zakona o obiteljskom poljoprivrednom gospodarstvu bilježimo smanjenje njihovog broja, u smislu rasta broja SOPG-ova ili prestanka obavljanja poljoprivredne djelatnosti u organizacijskom obliku OPG/SOPG (OECD Izvješće o Republici Hrvatskoj, 2025[T13].).

5.3.2. Uloga ekonomskih resursa: Paradoks „tvrdog“ i „mekog“ digitaliziranja

Dok ljudski kapital pokreće sveobuhvatnu zrelost, ekonomski resursi (veličina posjeda i prihodi) igraju važnu, ali specifičnu i ograničenu ulogu. Jedan od najzanimljivijih nalaza ovog istraživanja jest da veličina poljoprivrednog posjeda (u hektarima) značajno utječe **isključivo** na Stup 2: Tehnologija, dok nema statistički značajan utjecaj na Strategiju, Podatke, Sposobnost niti Pravila podataka.

Ovaj nalaz otkriva važan paradoks u digitalizaciji poljoprivrede: tehnologiju (hardver, softver, GNSS sustave, senzore i slične *high-tech* uređaje) gospodarstva mogu jednostavno **kupiti** ako imaju financijskih sredstava i ekonomiju razmjera (veći posjedi).

Međutim, „meke“ dimenzije digitalne zrelosti (poput razvoja digitalne strategije, analitičkog razmišljanja, upravljanja podacima i uspostave pravila) ne mogu se kupiti; one se moraju **izgraditi** kroz znanje, vještine i organizacijsku kulturu.

Ovo je u skladu s pristupom utemeljenim na resursima (eng. *Resource-Based View* - RBV) koji naglašava da su neopipljivi resursi (poput znanja i vještina nositelja) ti koji dugoročno osiguravaju konkurentsku prednost, a ne sama oprema. Veća gospodarstva u Hrvatskoj stoga imaju više tehnologije, ali to nužno ne znači da su pametnija ili strateški usmjerenija u njezinom korištenju.

Rad Barney-a (1991.) "Resursi tvrtke i održiva konkurentska prednost" gotovo se redovito citira kao osnovna referenca u ovom pristupu, iako neki znanstvenici (vidi dolje) tvrde da su postojali dokazi za fragmentarnu teoriju temeljenu na resursima iz 1930-ih. Barney (1991.) naglašava kako su neopipljivi resursi (poput znanja i vještina nositelja) ti koji dugoročno osiguravaju konkurentsku prednost, a ne sama oprema. Veća gospodarstva u Hrvatskoj stoga imaju više tehnologije, ali to nužno ne znači da su pametnija ili strateški usmjerenija u njezinom korištenju. RBV tvrdi da su tvrtke heterogene jer posjeduju heterogene resurse, što znači da tvrtke mogu usvojiti različite strategije jer imaju različite kombinacije resursa. RBV smatra da su tvrtke heterogene jer posjeduju heterogene resurse, što znači da tvrtke mogu usvojiti različite strategije jer imaju različite kombinacije resursa-Lavie (Dovev, 2008.).

Vrontis i dr. (2026.) analiziraju Barneyjev (1991.) ključni rad o RBV-u i održivoj konkurentskoj prednosti , ovaj studijski smjer dominira istraživanjem strateškog menadžmenta gotovo tri desetljeća. Jay Barney (1991.) „otac“ je RBV (Resource-Based View) teorije. Ističe RBV kao mogući pristup za primjereno tumačenje konkurentnosti poljoprivrednih gospodarstava.

Konkurentnost poljoprivrede, inače za Republiku Hrvatsku značajne gospodarske grane koja s prehrambenom industrijom u ukupnom BDP-u sudjeluje s oko 10%, osnovni je uvjet gospodarske održivosti obiteljskih poljoprivrednih gospodarstava (OPG-a). Analiza konkurentnosti provedena 2001. godine pokazala je da je od ukupne hrvatske poljoprivrede tek do stanovite mjere konkurentna proizvodnja piletine, jaja, kukuruza, uljane repice i jabuka. Analiza pokrivenosti uvoza izvozom pokazuje da je u Republici Hrvatskoj, osim trgovinske bilance šećera, riba i mekušaca i žitarica, uvoz poljoprivrednih proizvoda nedostatno pokriven izvozom unutar iste skupine proizvoda. Jedan od čimbenika konkurentnosti poljoprivrede na njezinoj makrorazini nedvojbeno je i konkurentnost pripadajućih mikroproizvodnih jedinica - obiteljskih poljoprivrednih gospodarstava. U svrhu ocjenjivanja važnosti upravljanja gospodarstvom u odnosu na ostale čimbenike poslovnog uspjeha, provedeno je anketiranje OPG-a koja svojom proizvodnjom, veličinom posjeda i intenzivnosti proizvodnje premašuju hrvatski prosjek. Kvalitetno upravljanje OPG-om je u pilot anketi prepoznato kao najvažniji čimbenik poslovnog uspjeha.

Značajnijim činiteljem konkurentnosti poljoprivrednici ocjenjuju unutarnje čimbenike (organizacija gospodarstva, usavršavanje proizvođača, kvalitetno upravljanje) od vanjskih (intervencije Vlade i/ili Ministarstva, povoljnije kreditiranje…). Prema mišljenju samih

poljoprivrednika, u Republici Hrvatskoj postoje gospodarstva koja mogu zadovoljiti standarde cijene i kakvoće i kao takva konkurirati na europskom tržištu.

5.3.3. Nerelevantnost veličine radne snage

Zanimljivo je da broj zaposlenih na gospodarstvu nije pokazao statistički značajan utjecaj na razinu digitalne zrelosti. Ovaj nalaz potvrđuje specifičnu strukturu hrvatske poljoprivrede, kojom apsolutno dominiraju mala obiteljska gospodarstva s jednim do dva zaposlena člana. U takvom okruženju, digitalna transformacija ne ovisi o veličini tima ili prisutnosti specijaliziranog IT osoblja, već gotovo isključivo o osobnim kapacitetima, motivaciji i vještinama samog nositelja gospodarstva.

5.3.4. Teorijske implikacije demografskih pokretača

Ovi nalazi potvrđuju da demografski i organizacijski čimbenici nisu samo statistički prediktori, već temeljni strukturni pokretači digitalne transformacije. Teorijska implikacija ovoga jest da se modeli usvajanja tehnologije u poljoprivredi ne mogu promatrati isključivo kroz prizmu dostupnosti infrastrukture, već moraju integrirati teoriju ljudskog kapitala i životnog ciklusa gospodarstva. Detaljne preporuke za kreiranje politika proizlaze iz ovih nalaza i bit će iznesene u poglavlju 5.6.

5.4. Prostorne nejednakosti i fenomen „vještinskog jaza“ (eng. *Skills Gap*)

Jedan od najoriginalnijih nalaza ovog istraživanja jest otkriće značajnog prostornog jaza u dimenzijama digitalne zrelosti, pri čemu geografska pripadnost (NUTS regija) ima izrazito diferenciran utjecaj na pojedine stupnjeve zrelosti. Dok NUTS regija **nema statistički značajan utjecaj na** samu nabavu tehnologije (**Stup 2: Tehnologija, β = -0,046 do -0,124, p > ,05)**, ona ima **izrazito značajan i snažan utjecaj na Sposobnost (Stup 4, β = -0,492 do -0,600, p < ,05) i Podatke i analitiku (Stup 3, β = -0,383 do -0,444, p < ,05)**. Konkretno, gospodarstva u Panonskoj i Sjevernoj Hrvatskoj pokazuju statistički značajno nižu razinu sposobnosti i analitike u usporedbi s Gradom Zagrebom, unatoč tome što posjeduju sličnu razinu tehnološke opremljenosti.

Ovaj nalaz otkriva postojanje onoga što u literaturi digitalne transformacije nazivamo **„vještinski jaz“** (eng. *Skills Gap*), što je fenomen gdje pristup tehnologiji ne prati automatski i sposobnost njezine učinkovite primjene U SAD nastavnici u poljoprivrednim školama i učilištima su identificirali procese u kojima su stekli nove informacije i vještine obrazovne

tehnologije. Za ovu studiju korištena je deskriptivna statistička analiza uspoređujući srednje rezultate i standardnu devijaciju odgovora. Seoski učitelji odabrali su osobne pokušaje i pogreške kao najbolju metodu (N=520; 64%) stjecanja. Ostali nastavnici i osoblje poslužili su kao drugi najvjerojatniji izvor, a zatim internetske pretrage. Značajni su napori uloženi u istraživanje i prevladavanje „vještinskog jaza“ (Kormos i dr., 2021.). U kontekstu hrvatske poljoprivrede, ovo znači da poljoprivrednici u kontinentalnim regijama (Panonska i Sjeverna Hrvatska) vjerojatno posjeduju tehnologiju (GNSS sustavi, senzori, softveri), ali im nedostaje napredno znanje, kadrovi i pristup edukacijama za njezinu punu analitičku iskorištenost.

Napredne tehnologije poput umjetne inteligencije i robotike sve se više promiču kao sredstvo za povećanje učinkovitosti proizvodnje hrane uz istovremeno minimiziranje korištenja resursa. U tom je procesu digitalna transformacija poljoprivrede otvorila kritična društvena pitanja o implikacijama za raznolike poljoprivredne radnike i ruralna područja kako se digitalizacija razvija.

Rotz i suradnici su opisali neke ključne trendove opisali neke ključne trendove koji se uočavaju na spoju poljoprivredne proizvodnje, tehnologije i rada u Sjevernoj Americi, s posebnim naglaskom na kanadski kontekst. Koristeći podatke, ističemo tri ključne uočene napetosti: rastuće troškove zemljišta i automatizaciju; razvoj podijeljenog tržišta rada s visokokvalificiranom/niskokvalificiranom radnom snagom; i pitanja oko kontrole digitalnih podataka. Imajući na umu ove napetosti, koristimo prizmu socijalne pravde kako bismo razmotrili potencijalne implikacije digitalnih poljoprivrednih tehnologija za poljoprivredni rad i ruralne zajednice, što našu pozornost usmjerava posebno na rasnu eksploataciju u poljoprivrednom radu. Istražujući te napetosti, tvrdimo da politika i istraživanje moraju dodatno ispitati kako promijeniti putanju digitalizacije na načine koji podržavaju proizvodnju hrane, kao i marginalizirane poljoprivredne radnike, istovremeno ukazujući na ključna područja za buduća istraživanja - koja do danas nedostaju. Naglašavamo da nas trenutni entuzijazam za digitalnu poljoprivredu ne bi trebao zaslijepiti pred specifičnim načinima na koje nove tehnologije intenziviraju iskorištavanje i produbljuju marginalizaciju rada i prostora (Rotz i dr., 2019.),

Tehnologije Poljoprivrede 4.0 poput umjetne inteligencije (UI), IoT (Interneta stvari[T14]), računalnog vida i robotike revolucionirale su poljoprivredni sektor. No, usvajanje digitalnih tehnologija vjerojatno je stvorilo nove ili pogoršalo postojeće socioekonomske nejednakosti, a istovremeno je postavilo etička pitanja, posebno kada se razmatra pristup tehnologiji i njeno usvajanje. Do sada je literatura malo naglaska stavila na to kako učinkovito premostiti razlike

u znanju i vještinama u poljoprivrednom sektoru - ili popraviti "digitalne jazove" u poljoprivredi - kroz strategije razvoja radne snage koje iskorištavaju visoko obrazovanje i programe proširenja. Bampasidou i sur. (2024.) naglašavaju kako obrazovni programi koji uključuju UI pripremaju konkurentu radnu snagu [T15] spremnu za UI. To se može postići prenošenjem tehnološkog znanja u obliku usavršavanja i prekvalifikacije te strateškim upravljanjem pravednim tehnološkim promjenama i uključivanjem etičkog upravljanja podacima. Autori tumače čemu bi se trebalo sastojati to usavršavanje, gdje je najpotrebnije i zašto je važno bavljenje etikom novih tehnologija. Čitatelj će shvatiti kako akademski programi mogu iskoristiti digitalnu poljoprivredu (DA) za razvoj vještina i talenata potrebnih poljoprivrednom sektoru kako bi iskoristio prednosti digitalizacije i riješio izazove razvoja radne snage s kojima se susreće (Bampasidou i dr., 2024.).

5.4.1. Paradoks „tehnologije bez znanja“ u kontinentalnoj Hrvatskoj

Ovakav obrazac u suprotnosti je s tradicionalnim shvaćanjem digitalne transformacije kao linearnog procesa u kojem nabava tehnologije automatski vodi ka višoj razini zrelosti. Umjesto toga, rezultati pokazuju da je **tehnološka opremljenost nužan, ali ne i dovoljan uvjet** za postizanje visoke digitalne zrelosti. Činjenica da veličina posjeda (koja je zamjenski pokazatelj za ekonomsku moć i pristup kapitalu) značajno predviđa isključivo Stup 2 (Tehnologija), ali ne i Stup 3 (Podaci) ili Stup 4 (Sposobnost), potvrđuje da se „tvrdi“ aspekti digitalizacije (hardver, softver) mogu kupiti, dok se „meki“ aspekti (znanje, vještine, analitički kapaciteti) moraju razvijati kroz dugoročne investicije u ljudski kapital

Resource-Based View: (Barney, 1991.) ili noviji radovi koji primjenjuju RBV na poljoprivredu, stiču kako su tvrtke heterogene jer posjeduju heterogene resurse, što znači da tvrtke mogu usvojiti različite strategije jer imaju različite kombinacije resursa.

Rad Haberli i dr. (2019.) o RBV raspravlja o percepciji učinaka rutinizacije na implementaciju i usvajanje planiranja resursa poduzeća (ERP) na poljoprivrednim gospodarstvima. Predložen je teorijski model i devet hipoteza korištenjem čimbenika prema literaturi o pristupu temeljenom na resursima (RBV) i o utjecaju ERP-a na percepciju uspješnosti poljoprivrednih gospodarstava. Ova studija doprinosi literaturi empirijskim testiranjem učinka moderiranja rutinizacije na RBV. Kvalitativni intervju primijenjen je na veće poljoprivrednike gdje je ERP već bio u upotrebi, a za kvantitativni pristup prikupljen je uzorak od 448 odgovora koji se sastojao od 74% uzgajivača žitarica, 14% uzgajivača stoke i mlijeka te 13% uzgajivača šećerne trske i voća. Rezultati pokazuju da model objašnjava 63% varijacije u utjecaju na uspješnost poljoprivrednih gospodarstava. Rezultati istraživanja pokazuju da r[T16]utinizacija moderira samo

odnos između utjecaja na interne operacije s utjecajem na uspješnost poljoprivrednih gospodarstava. Zaključci potvrđuju potrebu proširenja RBV pristupa na percepciju poljoprivrednika, istražujući druge čimbenike poput koristi i utjecaja prirodnih resursa u procesu rutinizacije. Konačno, predlaže se rasprava o razvoju Poljoprivrede 4.0 s aspekta resursa za razvoj konkurentske prednosti u kontekstu farmi.

Paradoks ulaganja u tehniku i tehnologiju vidljiv je kroz niz pokazatelja – od iznimnih razlika u opremljenosti, na osnovnoj razini, preko niskih razina opremljenosti i znanja, sve do niske razine znanja i kapaciteta, uz visoke ili izvrsne razine opremljenosti. (Barney, 1991[T17].).

Ovaj paradoks posebno je izražen u kontinentalnoj Hrvatskoj, gdje poljoprivredna gospodarstva, unatoč dostupnosti EU fondova za nabavu tehnologije (npr. Programi Strateškog plana Zajedničke poljoprivredne politike 2023.-2027., Nacionalni plan oporavka i otpornosti i slični), zaostaju u razvoju analitičkih kapaciteta.

Navedeno je djelomično posljedica i institucionalnog okvira, posebice dosadašnje provedbe Zajedničke poljoprivredne politike (ZPP). Kroz Mjeru 4 (Investicije u fizičku imovinu) i slične mjere, sustav potpora u Republici Hrvatskoj povijesno je snažno favorizirao nabavu „tvrdih“ tehnologija (npr. traktora s GNSS-om, baznih pozicijskih stanica, novih strojeva i slično), dok su „meke“ investicije (edukacija, savjetovanje, softveri, analiza podataka) bile marginalizirane ili teško dostupne. Takva distorzija poticaja rezultirala je time da poljoprivrednici posjeduju naprednu poljoprivrednu tehniku, ali im nedostaju institucionalna podrška i znanje za njezinu punu analitičku iskorištenost, čime se stvara „vještinski jaz“ na razini cijelog sektora**.** Mogući razlozi uključuju:

1. **Koncentraciju edukacijskih resursa u urbanim središtima.** Grad Zagreb, kao akademsko i gospodarsko središte, ima bolji pristup specijaliziranim savjetodavnim uslugama, demonstracijskim centrima i edukacijskim programima iz područja precizne poljoprivrede i analitike podataka .

Lynn i dr. (2022.), istražuju digitalnu transformaciju malih i ruralnih gradova, a posebno kako mjeriti evoluciju i razvoj digitalnih gradova. Uz pristup resursima, konkurenciju s urbanih i globalnih tržišta te trendove stanovništva, ruralne zajednice imaju manji pristup i korištenje digitalnih tehnologija te imaju niže digitalne kompetencije i vještine od svojih urbanih kolega. Posljedično, imaju manje korisne ishode povećane digitalizacije nego urbana područja. Grimshaw i Kala (2011.) prikazuju entuzijazam međunarodnih razvojnih agencija za iskorištavanje potencijala informacijskih i komunikacijskih tehnologija (IKT) za razvoj.

Predstavljajući rezultate istraživanja posebno osmišljenih za mjerenje utjecaja na egzistenciju, knjiga "Jačanje ruralnih sredstava za život" pruža nove dokaze o razvojnim koristima IKT-a. Autori postavljaju pitanje jesu li IKT-i omogućili poljoprivrednicima prodaju izvan lokalnih tržišta i po boljim cijenama, odnosno je li došlo do društvenih dobitaka povezivanjem geografski različitih kućanstava i društvenih mreža. Nadalje autori su ponudili nove uvide u mogućnosti prevladavanja izazova uključivanja IKT-a u ruralne načine života i učinkovitijeg mjerenja njihovih učinaka (Lynn i dr. , 2022.).

2. **Nedostatak lokalnih „digitalnih lidera“.** U kontinentalnim regijama vjerojatno postoji manji broj uzornih gospodarstava koja mogu poslužiti kao mentori i demonstracijski centri za ostale poljoprivrednike, što usporava difuziju znanja i najboljih praksi

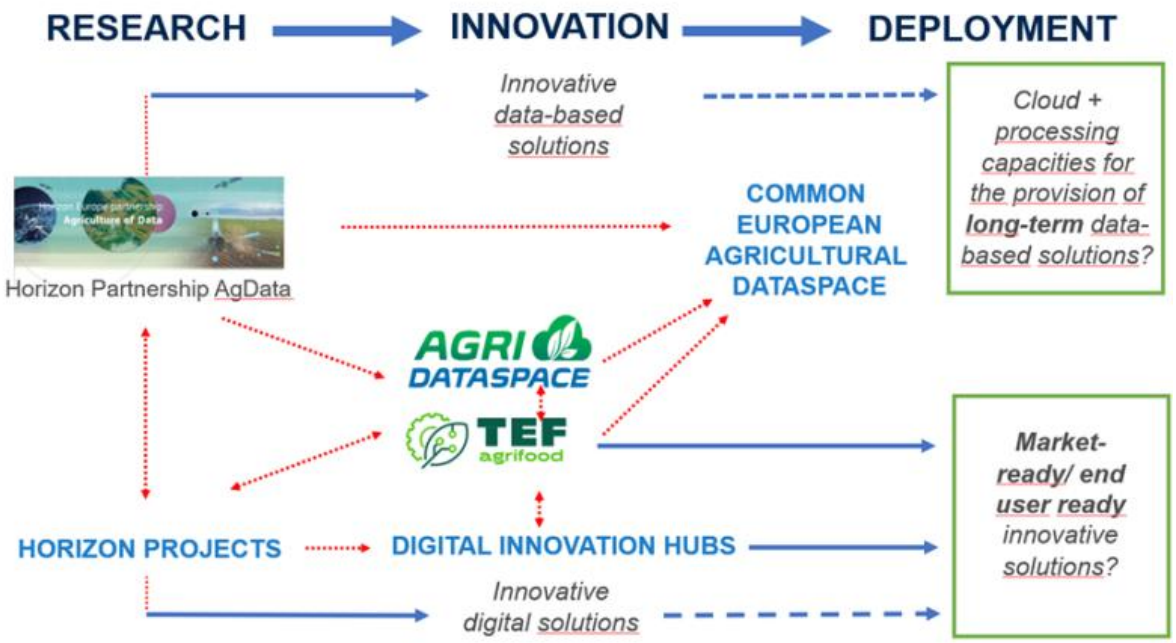
Chen i Li (2022.) opisuju ubrzani razvoj poljoprivredne tehnologije u Kini, te novi model difuzije poljoprivredne tehnologije, koji predstavljaju poljoprivredni znanstveno-tehnološki parkovi. Provode niz istraživanja vezanih uz difuziju poljoprivredne tehnologije na temelju predloženog istraživačkog okvira difuzije tehnologije u poljoprivrednim znanstveno-tehnološkim parkovima. Analizira se mehanizam rasta polova poljoprivredne tehnologije, sustav difuzije poljoprivredne tehnologije i njegove karakteristike. Sažima se indeksni sustav za procjenu okruženja difuzije tehnologije. Iz perspektive „osnovne“ paradigme raspravljamo o karakteristikama vremenskog procesa (faza difuzije, brzina difuzije, širina difuzije) i prostornog procesa (učinak difuzije, prostorni uzorak) difuzije tehnologije u poljoprivrednim znanstveno-tehnološkim parkovima i njihovim mehanizmima utjecaja. Sažima se temeljni zakon difuzije „točkasto-osi“ difuzije tehnologije u parku. Iz perspektive paradigme „usvajanja“ analizirali su se čimbenici i mehanizmi [T18]usvajanja tehnologije od strane poljoprivrednika. Istražuju se učinci različitih okruženja i tehnologija s različitim atributima na ponašanje poljoprivrednika pri usvajanju. Na temelju najnovijih rezultata istraživanja fokusira se ponašanje i mehanizme usvajanja tehnologije od strane novih poslovnih agenata. Konačno, ističu se pitanja koja je potrebno dalje istražiti u proučavanju širenja tehnologije u poljoprivrednim inovacijama. (Chen i Li , 2022.).

Jedna od sastavnica prilagodbe klimatskim promjenama je promicanje inovacija. Isticanje inovacija upućuje i na komunikaciju o usvajanju inovacija, ali i donošenja odluka. Ovo je potonje društveni proces, jer često uključuje sudjelovanje više dionika, uključujući ponekad i članove njegove ili njezine vlastite obiteljske grupe. Sastavnice sustava za razmatranje u

procesu širenja inovacija su norme koje odražavaju ustaljene obrasce ponašanja članova društvenog sustava. U Quebecu su savjetnici i dobavljači poljoprivrednih organizacija i dionika [T19](prodavači inputa i poljoprivredne opreme) među glavnim sudionicima u poljoprivrednom sektoru. Osim podrške i savjeta poljoprivrednicima, ti su dionici također postali nositelji procesa osmišljavanja i širenja inovativnih poljoprivrednih praksi koje mogu dovesti do uspješne prilagodbe klimatskim promjenama. Ovi su dionici dali prednost pristupu usredotočenom na "ljudsku" stranu relacije; zaslužili su povjerenje poljoprivrednika i preuzeli vodeću ulogu u osmišljavanju i širenju inovativnih praksi za prilagodbu klimatskim promjenama i varijabilnostima. Na temelju analiza fokusnih grupa i intervjua s poljoprivrednicima i raznim nositeljima promjena, pokazujemo kako su odnosi među akterima na lokalnoj razini stvorili plodno tlo za pojavu materijalnih i nematerijalnih inovacija koje jačaju otpornost poljoprivrednog sustava, čak i ako izvorno takve inovacije nisu bile namijenjene borbi protiv učinaka globalnog zatopljenja.

3. **Strukturne karakteristike poljoprivredne proizvodnje.** Kontinentalna Hrvatska dominantna je ratarskom proizvodnjom, gdje su tradicionalni modeli poslovanja duboko ukorijenjeni, što može stvarati otpor prema usvajanju naprednih analitičkih pristupa

Van der Veen (2010.) navodi kako se inovacije u poljoprivredi prvenstveno odnose na potrebu povećanja proizvodnje (hrane, stočne hrane, sekundarnih proizvoda) kao i povećanja kvalitete (proizvoda, procesa proizvodnje, uvjeta uzgoja). Autor daje [T20]pregled trenutnih razmišljanja o tome kako nastaju poboljšanja i inovacije u poljoprivredi, koje oblike poprimaju i koji su čimbenici uključeni. Inovacije obično utječu na jedno ili više sljedećih područja: usjeve, životinje, uvjete uzgoja, alate i prakse upravljanja. Iako se pojavljuju "makro-izumi" (radikalne nove ideje), mnogi se tiču "mikro-izuma", odnosno promjena ili modifikacija alata i praksi koje su izradili vješti praktičari (poljoprivrednici, obrtnici), a ne izumitelji ili poduzetnici. Inovacije u poljoprivredi često se ne odnose toliko na usvajanje novouvedenih tehnologija, koliko na prilagodbu postojećih. Izraz 'poljoprivredna revolucija' ima tendenciju da se koristi kada se brojna poboljšanja u zasebnim područjima poljoprivrednog sustava pojavljuju zajedno kao kompleks, i, iako se ona mogu uvoditi postupno, nakon što dostignu kritičnu masu, njihov utjecaj na društvo može biti veličine koja zaslužuje izraz 'revolucija' (Van der Veen, 2010.)[T21].



Slika 4.23. Inovacijski programi u poljoprivredi - EU HORIZON (Beers i dr. 2024.).

Pametna poljoprivreda je razvoj koji naglašava korištenje informacijske i komunikacijske tehnologije u ciklusu kibernetičko-fizičkog upravljanja poljoprivredom. Očekuje se da će nove tehnologije poput Interneta stvari (IoT) [T22]i računarstva u oblaku iskoristiti ovaj razvoj i uvesti više robota i umjetne inteligencije u poljoprivredu. To je obuhvaćeno fenomenom velikih podataka, ogromnih količina podataka širokog spektra koji se mogu prikupiti, analizirati i koristiti za donošenje odluka. Opseg primjene velikih podataka u pametnoj poljoprivredi nadilazi primarnu proizvodnju; utječe na cijeli lanac opskrbe hranom. Veliki podaci koriste se za pružanje prediktivnih uvida u poljoprivredne operacije, donošenje operativnih odluka u stvarnom vremenu i redizajniranje poslovnih procesa za revolucionarne poslovne modele.

Rane i sur. (2024.), razmatraju rastući utjecaj umjetne inteligencije i velikih podataka te sugeriraju kako će veliki podaci uzrokovati velike promjene u ulogama i odnosima moći među različitim igračima u trenutnim mrežama lanca opskrbe hranom.

5.4.2. Usporedba s europskim kontekstom i konceptom „digital divide“

Digitalizacija poljoprivrednog sektora EU-a ključan je dio šire Digitalne agende EU-a i Zajedničke poljoprivredne politike (ZPP) čiji je cilj promicanje konkurentnosti, održivosti i otpornosti u poljoprivredi putem digitalne transformacije. Ovo izvješće analizira trenutno

stanje digitalizacije u poljoprivredi EU-a, obuhvaćajući usvajanje općih IT i softverskih alata te tehnologija specifičnih za poljoprivredne gospodarstva, ključne pokretače i prepreke, percipirane aspekte održivosti te prakse na razini poljoprivrednih gospodarstava u prikupljanju, upravljanju i dijeljenju podataka. Analiza se temelji na podacima ankete poljoprivrednih gospodarstava od 1444 ispitanika u devet država članica EU-a – Njemačkoj, Irskoj, Grčkoj, Španjolskoj, Francuskoj, Italiji, Litvi, Mađarskoj i Poljskoj prikupljenih između lipnja i listopada 2024. Rezultati pokazuju da, iako se opći IT i softverski alati široko koriste, skuplje tehnologije specifične za proizvodnju usjeva ili stoke manje su široko usvojene. Stope usvajanja veće su među većim poljoprivrednim gospodarstvima, onima s boljom internetskom vezom i onima sa specijaliziranom obukom. Ključni pokretači usvajanja uključuju povećanje učinkovitosti, uštede troškova, regulatorne pritiske i poboljšanu kvalitetu života, dok visoki troškovi i ograničene vještine ostaju značajne prepreke. Poljoprivrednici očekuju da će digitalne tehnologije imati pozitivne ekonomske, ekološke i društvene utjecaje. Prikupljanje podataka na razini poljoprivrednih gospodarstava još je uvijek uglavnom ručno ili se temelji na osnovnim digitalnim alatima, što povećava administrativno opterećenje za poljoprivrednike. Čini se da poljoprivrednici zauzimaju selektivan pristup dijeljenju podataka, uglavnom zbog zabrinutosti oko privatnosti, sigurnosti i kontrole podataka. Promicanje transparentnih politika podataka, osiguravanje da poljoprivrednici imaju koristi od dijeljenja i usvajanje ciljanog pristupa politikama za napredne tehnologije može pomoći u izgradnji povjerenja i podržati šire digitalno usvajanje.

Nalazi ovog istraživanja u skladu su s europskim trendovima digitalne transformacije poljoprivrede, gdje se prepoznaje postojanje **„dvostrukog digitalnog jaza“** (eng. *Double Digital Divide*) (Europska komisija, 2025.)

Prvi jaz odnosi se na pristup tehnologiji (infrastrukturni jaz), dok se drugi jaz odnosi na sposobnost učinkovite primjene tehnologije („vještinski jaz“). Dok je Europska unija značajno napredovala u smanjenju prvog jaza kroz investicije u ruralnu *broadband* infrastrukturu, drugi jaz ostaje persistentan izazov, posebno u regijama s nižom razinom ljudskog kapitala i slabijim institucijskim kapacitetima.

Bampasidou i dr. (2024.) tvrde kako koristeći alate transformacije digitalne asistencije (DA), visoko obrazovanje mora razviti vještine i talente potrebne poljoprivrednom sektoru kako bi iskoristio prednosti digitalizacije i suočio se s jedinstvenim izazovima razvoja radne snage: ono što ovdje nazivamo „digitalnim jazovima“ u poljoprivredi. Kako bi se ti jazovi uklonili, bit će potrebno riješiti probleme s razlikama u znanju i vještinama radne snage koje postoje između

radnika, sektora i geografskih područja. Štoviše, nastavni planovi i programi trebali bi se prilagoditi potrebama studenata i tržišta rada izbjegavajući disciplinske silose (Johnson i sur., 2021.). Kako akademski programi uvode promjene u nastavni plan i program, studenti sve više eksperimentiraju s alatima temeljenima na umjetnoj inteligenciji, sve više radnih mjesta zahtijeva znanje kodiranja, programiranja i korištenja alata umjetne inteligencije, a radne prakse na razini poljoprivrednih gospodarstava također se pomiču prema digitalnim aplikacijama (Bampasidou i dr., 2024[T23].).

Samadder i dr. (2023.) istražuju poteškoće poljoprivrednika[T24] pri usvajanju i korištenju ICT tehnologija za održivu poljoprivredu, s naglaskom na premošćivanje digitalnog jaza. Za procjenu digitalnog jaza među poljoprivrednicima, studija ispituje pristup tehnologiji, razinu digitalne pismenosti i internetsku povezivost. Priuštivost, svijest i složenost istaknuti su i analizirani kao prepreke usvajanju ICT-a. Kako bi se riješile te prepreke, razvijaju se prilagođena ICT rješenja, uključujući alate jednostavne za korištenje. Procijenjen je utjecaj tih rješenja na dugoročne poljoprivredne prakse. Interpretacije naglašavaju rješenja poput smanjenja troškova, subvencioniranja, poboljšane opskrbe električnom energijom, dostave informacija na lokalnim jezicima, osnivanja servisnih centara i pružanja programa obuke. Implementacija ovih rješenja može pomoći u premošćivanju digitalnog jaza, poboljšanju pristupa informacijama i promicanju održive poljoprivrede. Kako bi se prevladale digitalne prepreke, razvijaju se prilagođena IKT rješenja, uključujući alate jednostavne za korištenje. Proučava se dugoročni utjecaj ovih rješenja na poljoprivredne prakse. Ističe se važnost smanjenja troškova, subvencija, poboljšane opskrbe električnom energijom, širenja informacija na lokalnim jezicima, osnivanja servisnih centara i pružanja programa obuke u premošćivanju digitalnog jaza i poboljšanju poljoprivrednih praksi (Samadder i dr., 2023[T25].).

U kontekstu Republike Hrvatske, ovo je posebno važno jer hrvatska poljoprivreda karakterizirana je izrazitom fragmentacijom posjeda (prosječna veličina gospodarstva <5 ha), starenjem populacije (prosječna dob nositelja >55 godina) i niskom razinom formalnog obrazovanja (preko 60% nositelja ima samo osnovno ili srednje obrazovanje). (Zeleno izvješće, 2024.) Ovi strukturni čimbenici stvaraju „savršenu oluju“ za „vještinski jaz“, gdje čak i kada gospodarstva uspiju nabaviti tehnologiju, nedostatak ljudskog kapitala sprječava njezinu punu iskorištenost.

5.4.3. Značaj „vještinskog jaza“ za agrarne politike

Otkriće „vještinskog jaza“ ima duboke implikacije za kreiranje politika digitalne transformacije hrvatske poljoprivrede. Trenutni pristup, koji se primarno fokusira na subvencioniranje nabave

tehnologije (npr. potpore za kupnju GNSS sustava, dronova, pametnih meteo stanica, senzora, IoT uređaja, softvera i slično), **nije dovoljan** za postizanje visoke digitalne zrelosti. Umjesto toga, potrebne su **ciljane intervencije usmjerene na razvoj ljudskog kapitala**, posebno u kontinentalnim regijama.

Otkriće „vještinskog jaza“ zahtijeva paradigmatski pomak u razmišljanju kreatora politika: s fokusiranja isključivo na infrastrukturni pristup (prvi „digitalni jaz“) na fokusiranje na kapacitete i znanje (drugi „digitalni jaz“). Budući da su mehanizmi ovog jaza složeni i višeslojni, konkretne, segmentirane mjere za njegovo prevladavanje detaljno su razrađene u poglavlju 5.6.

5.5. Segmentacija gospodarstava: od „Početnika“ do „Lidera“

Dok prosječna vrijednost globalnog indeksa digitalne zrelosti (M = 2,75) pruža opću sliku stanja u sektoru, provedena klasterska analiza i klasifikacija prema CSIRO fazama otkrivaju duboku heterogenost i strukturnu polarizaciju hrvatskih poljoprivrednih gospodarstava. Identificirana četiri klastera (od „Digitalnih početnika“ do „Digitalnih lidera“) nisu samo statističke kategorije, već odražavaju stvarne socio-ekonomske i demografske podjele u ruralnim područjima Republike Hrvatske.

5.5.1. Digitalni jaz kao generacijski jaz

Najsnažniji nalaz segmentacije jest gotovo savršeno preklapanje profila digitalne zrelosti s demografskim karakteristikama nositelja gospodarstava, što potvrđuje tezu da je **digitalni jaz u hrvatskoj poljoprivredi primarno generacijski jaz**. Prije svega treba naglasiti da iako su Klasteri i CSIRO faze konceptualno različiti (prvi se empirijski, a drugi teorijski), njihovo gotovo savršeno preklapanje u ovom uzorku dodatno validira oba pristupa segmentaciji.

Dakle, Klaster „Digitalnih početnika“ (20,5% uzorka, faza *U nastajanju*) karakteriziraju najstariji nositelji (preko 60 godina) s najnižom razinom formalnog obrazovanja i najmanjim posjedima. Za ovu skupinu, nedostatak digitalne zrelosti nije nužno rezultat svjesnog otpora prema tehnologiji, već posljedica ograničenih kognitivnih resursa, nedostatka formalne edukacije i kratkoročnog horizonta planiranja zbog nadolazećeg umirovljenja. S druge strane, „Digitalni lideri“ (5,1% uzorka, faza *Transformativna*) gotovo su isključivo mladi, visokoobrazovani nositelji koji upravljaju većim i financijski stabilnijim gospodarstvima.

Ovaj nalaz ima dalekosežne implikacije za politiku ruralnog razvoja. On sugerira da **mjere za poticanje digitalizacije neće biti učinkovite bez paralelnog i snažnog poticanja generacijske obnove**. Uvođenje naprednih digitalnih alata na gospodarstva u fazi *U nastajanju* predstavlja neučinkovitu alokaciju resursa, budući da strukturni i demografski uvjeti onemogućuju njihovu dugoročnu i svrhovitu primjenu.

5.5.2. „Zamka" prijelazne faze (eng. *The Transitional Trap*)

Analiza distribucije po CSIRO fazama otkriva da se najveći dio hrvatske poljoprivrede (gotovo 40% u fazi *Prijelazna*, a dodatnih 35% u fazi *Konkurentna*) nalazi u svojevrsnoj „zamci" prijelazne faze. Ova gospodarstva su prešla početnu barijeru usvajanja osnovne tehnologije (npr. pametni telefoni, osnovni GNSS, jednostavni softveri za evidenciju), ali nisu uspjela uspostaviti integrirane digitalne sustave.

Kao što je pokazano u prethodnim analizama (Stup 3: Podaci i analitika; Stup 5: Pravila podataka), ova gospodarstva posjeduju „hardver", ali im nedostaje „softver" u smislu znanja, strategije i upravljanja podacima. Ona generiraju podatke (npr. putem senzora ili strojeva), ali ih ne koriste za donošenje poslovnih odluka. Ova „zamka" predstavlja ključno usko grlo za povećanje konkurentnosti sektora, jer gospodarstva ostaju na razini operativne učinkovitosti, bez postizanja strateške prednosti koju donosi transformativna digitalizacija.

5.5.3. Rizik „dvobrzinske" poljoprivrede

Postojanje male, ali izrazito digitalno zrele elite (5,1% u Transformativnoj fazi) nasuprot velikom broju tradicionalnih gospodarstava stvara rizik od razvoja **„dvobrzinske" poljoprivrede**.

„Digitalni lideri" (Klaster 4), koji su koncentrirani u urbanijim središtima i većim poljoprivrednim regijama, imaju kapacitet za usvajanje tehnologija četvrte poljoprivredne revolucije (Agriculture 4.0), poput interneta stvari (IoT), umjetne inteligencije (AI) i automatizacije. S druge strane, „Digitalni početnici" i „Tradicionalisti" (zajedno gotovo 60% uzorka) riskiraju marginalizaciju, smanjenje tržišnog udjela i gubitak konkurentnosti na europskom tržištu, koje sve više zahtijeva transparentnost, sljedivost i održivost, aspekte koji se danas ne mogu zamisliti bez napredne digitalne infrastrukture. Dugoročno, ovakva polarizacija prijeti stvaranjem „dvobrzinske poljoprivrede" koja će ubrzati strukturne promjene u sektoru. „Digitalni lideri" (Klaster 4), zbog niže cijene koštanja po jedinici proizvoda i veće tržišne moći, imat će kapacitet za širenje i konsolidaciju zemljišta. S druge strane, „Digitalni

početnici“ (Klaster 1) riskiraju ekonomsku marginalizaciju, što će neizbježno dovesti do napuštanja poljoprivrede i daljnje depopulacije ruralnih područja, čime se „digitalni jaz“ pretvara u izravni socio-ekonomski i demografski problem.

5.5.4. Strateške implikacije segmentacije gospodarstava

Nalazi segmentacije nedvojbeno pokazuju da pristup „jedna veličina za sve“ (eng. *one-size-fits-all*) u kreiranju agrarnih i digitalnih politika u Hrvatskoj nije održiv.

Ovakva segmentacija jasno demonstrira da pristup „jedna veličina za sve“ (eng. *one-size-fits-all*) u agrarnim politikama nije samo neučinkovit, već ekonomski neopravdan. Različite faze zrelosti zahtijevaju različite vrste institucionalne i financijske podrške, čime se otvara prostor za dizajniranje preciznih, ciljanih intervencija koje su detaljno predložene u poglavlju 5.6.

Zaključno, segmentacija potvrđuje da digitalna transformacija hrvatske poljoprivrede nije linearni proces, već složen mozaik koji zahtijeva diferencirane, ali sinkronizirane intervencije na razini ljudskog kapitala, tehnološke infrastrukture i institucionalne podrške.

5.6. Praktične i političke implikacije (preporuke za kreiranje politika)

Praktične i političke implikacije ovog istraživanja proizlaze izravno iz njegovog primarnog znanstvenog doprinosa. Budući da je ovo prvo istraživanje koje je sustavno procijenilo i kvantificiralo digitalnu zrelost hrvatskih poljoprivrednih gospodarstava, uspostavljena metodologija i prilagođeni CSIRO indeks digitalne zrelosti pružaju neophodan **dijagnostički alat**.

Ovaj alat služi ne samo za trenutnu procjenu stanja, već i kao temelj za funkciju praćenja, evaluacije i strateškog planiranja digitalne transformacije na razini cijelog sektora. Konačni cilj ovakve procjene jest pomoći poljoprivrednoj industriji u razvoju sustavne digitalne strategije koja transformira sektor iz stanja *ad hoc* usvajanja tehnologije u svrhovitu i učinkovitu digitalnu transformaciju.

Na temelju empirijskih nalaza, nameće se potreba za paradigmatskim pomakom u kreiranju agrarnih politika, koji se očituje kroz sljedeće konkretne preporuke prikazane kao zasebna podpoglavlja.

5.6.1. Odmak od isključivih „tvrdih“ investicija prema „mekim“ kompetencijama

Jedan od ključnih nalaza ovog istraživanja jest da veličina gospodarstva i financijski kapaciteti značajno predviđaju usvajanje tehnologije (Stup 2), ali ne i sposobnost analize podataka (Stup 3) niti uspostavu pravila upravljanja podacima (Stup 5). Stoga se preporučuje:

- **Uvjetovanje investicija edukacijom** – mjere ruralnog razvoja i nacionalni planovi oporavka i otpornosti (NPOO) trebale bi uvesti obvezujuću komponentu edukacije uz potpore za nabavu precizne poljoprivredne tehnike i softvera. Primjerice, poljoprivrednik koji aplicira za nabavu GNSS sustava ili senzora ili bespilotnog zrakoplova ili slično, mora istovremeno aplicirati za (ili već pohađati) tečaj iz analitike poljoprivrednih podataka i druge odgovarajuće tečajeve i edukacije.
- **Osnivanje regionalnih centara za digitalne kompetencije** – umjesto centraliziranih edukacija, potrebno je decentralizirati savjetodavne usluge osnivanjem mobilnih ili lokalnih „Digitalnih točaka“ u kontinentalnim županijama (Panonska i Sjeverna Hrvatska), gdje je „vještinski jaz“ najizraženiji.

5.6.2. Diferencirane mjere prema profilima digitalne zrelosti (klasterima)

Budući da su identificirani klasteri (od „Digitalnih početnika“ do „Digitalnih lidera“) pokazali drastično različite potrebe, pristup „jedna mjera za sve“ (eng. *one-size-fits-all*) je neučinkovit. Politike moraju biti segmentirane:

- **Za „Digitalne početnike“ i „Tradicionaliste“ (Faze: U nastajanju i Prijelazna)** – fokus mora biti na osnovnoj digitalnoj pismenosti i jednostavnim, besplatnim ili visoko subvencioniranim mobilnim aplikacijama za vođenje evidencije (npr. digitalni poljoprivredni dnevnik). Ovdje je ključno uvođenje vršnjak-vršnjaku (eng. *peer-to-peer*) modela učenja, gdje lokalni uzori demonstriraju jednostavnost korištenja.
- **Za „Pragmatičare“ (Faza: Konkurentna)** – potrebno je poticati integraciju postojećih, ali trenutno razjedinjenih digitalnih alata u jedinstvene sustave upravljanja gospodarstvom (eng. *Farm Management Information Systems - FMIS*). Poticaji bi trebali biti usmjereni na softverska rješenja i konzultantske usluge za integraciju podataka.
- **Za „Digitalne lidere“ (Faza: Transformativna)** – ova gospodarstva (njih 5,1%) trebaju postati „svjetionici“ poljoprivredne proizvodnje (eng. *lighthouse farms*). Država ih treba uključiti u pilot-projekte za testiranje naprednih tehnologija (IoT, AI, Digital Twins, blockchain za sljedivost i slično) te im dodijeliti ulogu mentora i demonstracijskih centara za ostale poljoprivrednike.

5.6.3. Demografski usmjerene politike i generacijska obnova

S obzirom na to da su dob i razina obrazovanja nositelja najrobusniji prediktori digitalne zrelosti, politike generacijske obnove moraju postati okosnica digitalne transformacije:

- **Digitalni poslovni plan za mlade poljoprivrednike** – pri dodjeli potpora za „Mlade poljoprivrednike“, uz standardni poslovni plan, trebalo bi zahtijevati izradu „Digitalnog plana razvoja“ gospodarstva, čime se od samog početka poslovanja nameće kultura upravljanja podacima.
- **Programi „Digitalnog mentorstva“** – poticanje suradnje između visokoobrazovanih mladih poljoprivrednika i starijih, iskusnih nositelja gospodarstava, gdje se znanje o tradicionalnoj agronomiji razmjenjuje za znanje o digitalnim alatima.

5.6.4. Uspostava okvira za upravljanje i sigurnost podacima

Najniže prosječne vrijednosti zabilježene su u dimenziji *Pravila podataka* (Stup 5). Poljoprivrednici u Hrvatskoj još uvijek ne percipiraju podatke kao stratešku imovinu, niti su svjesni rizika i prava vezanih uz njih. Preporučuje se:

- **Izrada nacionalnih smjernica za poljoprivredne podatke** – Ministarstvo poljoprivrede, u suradnji s Hrvatskom agencijom za poljoprivredu i hranu (HPA), trebalo bi izraditi priručnik o vlasništvu, dijeljenju i zaštiti poljoprivrednih podataka (u skladu s GDPR-om i EU Uredbom o slobodnom protoku nepersonalnih podataka).
- **Poticanje „Zadruga za podatke“ (eng. *data-cooperatives*)** – modeliranje poticaja za udruživanje poljoprivrednika u **„Zadruge za podatke“** koje bi kolektivno pregovarale s dobavljačima tehnologije o uvjetima korištenja i vlasništvu nad generiranim podacima.

5.6.5. Jačanje uloge savjetodavne službe

Hrvatska savjetodavna služba u poljoprivredi mora proći vlastitu **(ali i stvarnu)** digitalnu transformaciju. Savjetodavci moraju prijeći s tradicionalne agronomske podrške na ulogu **„digitalnih integratora“** koji poljoprivrednicima pomažu u interpretaciji podataka s preciznih uređaja i njihovom prevođenju u konkretne agrotehničke mjere.

Savjetodavna služba mora proći transformaciju iz tradicionalne agronomske podrške u mrežu „konzultanata za digitalno upravljanje farmama“ (eng. *digital farm management consultants*),

koji će poljoprivrednicima pružati kontinuiranu, podatkovno vođenu podršku u optimizaciji proizvodnje.

5.6.6. Operativna i strateška razina primjene alata

Osim na razini državnih politika, uspostavljeni indeks ima izravnu primjenu u operativnom upravljanju. Pojedinačnim gospodarstvima i specifičnim poljoprivrednim sektorima (npr. ratarstvo, voćarstvo, stočarstvo) omogućuje da samostalno procijene svoje trenutne razine zrelosti, identificiraju specifična područja snage i slabosti, te na temelju toga postave realne ciljeve. Isto tako, razvijeni alat pruža okvir za razvoj i evaluaciju ciljanih inicijativa za digitalno poboljšanje.

Jedna od najvažnijih dugoročnih implikacija jest mogućnost **longitudinalnog praćenja**. Kada se ovaj alat za procjenu bude administrirao kroz vrijeme (npr. u dvogodišnjim ili petogodišnjim intervalima), kreatorima politika i industriji omogućit će se precizno praćenje napretka prema zacrtanim strateškim ciljevima digitalizacije, čime se zatvara krug između dijagnostike, intervencije i evaluacije.

Iako ovo istraživanje pruža robustnu metodološku osnovu i otvara prostor za daljnja istraživanja u ovoj domeni, važno je prepoznati i njegova ograničenja, prije svega vezana uz veličinu i strukturu uzorka, što utječe na mogućnost potpune generalizacije rezultata na sva gospodarstva u Hrvatskoj (što će biti detaljnije razrađeno u poglavlju 5.7).

Također, dok ovaj rad mjeri *zrelost i spremnost*, buduća istraživanja (poglavlje 5.8) morat će uzeti u obzir i samu *fizičku implementaciju* novih tehnologija, njihovu sposobnost uklapanja u stvarne radne procese te analizu tehničkog okruženja s aspekta troškovne učinkovitosti.

5.7. Ograničenja istraživanja

Iako je ovo istraživanje pružilo sveobuhvatan i metodološki robustan uvid u digitalnu zrelost hrvatske poljoprivrede, potrebno je prepoznati određena ograničenja koja definiraju granice valjanosti i generalizacije dobivenih rezultata.

5.7.1. Ograničenja uzorka i generalizacije

Iako je prikupljeno 565 valjanih odgovora, što statistički zadovoljava kriterije za pouzdanu analizu, taj uzorak čini manje od 0,4% ukupne ciljne populacije od 150.587 poljoprivrednih gospodarstava u Republici Hrvatskoj. Nadalje, istraživanje je eksplicitno ograničeno na

gospodarstva veličine do 100 hektara. Stoga se dobiveni nalazi, posebice oni koji se odnose na ključnost demografskih čimbenika i „vještinskog jaza“, ne mogu u potpunosti generalizirati na velika agrobiznis gospodarstva (>100 ha), koja vjerojatno posjeduju drugačije organizacijske strukture, veće financijske kapacitete i specijalizirano IT osoblje. Također, unutar samog uzorka, određene niše[T26] poljoprivredne grane (npr. pčelarstvo, maslinarstvo) i pojedine županije s manjim brojem ispitanika imaju ograničenu statističku snagu za dubinske mikro-regionalne usporedbe.

5.7.2. Ograničenja presječnog dizajna (eng. *Cross-sectional design*)

Podaci su prikupljeni u jednoj vremenskoj točki, što omogućuje snažnu deskripciju trenutnog stanja i identificiranje korelacija, ali ne i utvrđivanje strogih uzročno-posljedičnih veza (kauzaliteta). Na primjer, iako je utvrđeno da visoka razina obrazovanja korelira s višom digitalnom zrelošću, presječni dizajn ne može sa sigurnošću potvrditi je li obrazovanje izravni *uzrok* usvajanja tehnologije ili je riječ o trećem, neizmjerenu čimbeniku (npr. poduzetnički duh ili pristup mrežama znanja) koji uzrokuje i jedno i drugo (Wang, Cheng 2020.).

5.7.3. Pristranost samoprocjene (eng. *Self-reporting bias*)

Korišteni CSIRO upitnik oslanja se na subjektivnu procjenu samih nositelja gospodarstava. Postoji rizik od tzv. „Dunning-Krugerovog efekta“, gdje ispitanici s nižom razinom stvarnog znanja o digitalnim tehnologijama mogu precijeniti vlastitu zrelost, dok visoko zreli poljoprivrednici, svjesni složenosti naprednih alata (poput AI ili prediktivne analitike), mogu podcijeniti vlastite rezultate

Donaldson idr. (2002.) ističu kako pristranost samoprocjene i monometodsku pristranost često ugrožavaju valjanost istraživanja provedenih u poslovnim okruženjima te time ometaju razvoj teorija organizacijskog ponašanja. Njihov rad ocrtava konceptualni okvir za razumijevanje motivacijskih čimbenika među zaposlenicima za davanje pristranih odgovora na pitanja koja postavljaju organizacijski istraživači.

Primjenom longitudinalnih, višemetodskih i skupova s više osobina podataka, ilustrira se različite aspekte problema u tvrdnji kako tradicionalni pristupi kontroli pristranosti samoprocjene ne sprječavaju problem adekvatno. Rezultati sugeriraju potrebu za razvojem teorije učinaka metoda i pratećih analitičkih tehnika kako bi se poboljšala točnost psiholoških istraživanja u poslovnim okruženjima (Donaldson idr., 2002[T27].).

5.7.4. Metodološka ograničenja prilagodbe modela

Iako je prilagođeni CSIRO model pokazao izvrsnu pouzdanost (Cronbachov $\alpha > 0,8$ za sve stupove) i jednodimenzionalnost, svaka adaptacija međunarodnog modela na lokalni kontekst nosi rizik od gubitka određenih nijansi. Specifičnosti hrvatskog institucionalnog okvira, poput kompleksne birokracije pri korištenju EU fondova ili specifičnog stanja ruralne infrastrukture, možda nisu u potpunosti obuhvaćene originalnim dimenzijama modela, što je djelomično kompenzirano visokom objašnjenom varijancom u dimenziji „Pravila podataka“, ali svakako predstavlja prostor za daljnju validaciju instrumenta.

5.8. Smjernice za buduća istraživanja

Prepoznata ograničenja i specifični nalazi ovog istraživanja, posebice fenomen „vještinskog jaza“ i postojanje četiriju distinktnih klastera, otvaraju nekoliko važnih smjernica za buduća znanstvena istraživanja u području digitalizacije poljoprivrede.

1. Longitudinalne studije digitalne transformacije

Buduća istraživanja trebala bi prijeći s analize presjeka na longitudinalni dizajn istraživanja, odnosno pratiti ista gospodarstva kroz vremensko razdoblje od 3 do 5 godina. Takav pristup omogućio bi razumijevanje dinamike digitalne transformacije, odnosno razjasnio bi koji točno događaji ili intervencije (npr. generacijska smjena, dobivanje EU potpore, suša...) potiču gospodarstvo da prijeđe iz „Prijelazne“ u „Konkurentnu“ fazu zrelosti.

2. Kvalitativne studije slučaja „Digitalnih lidera“

Dok je ovo istraživanje kvantitativno identificiralo Klaster 4 („Digitalni lideri“, 5,1% uzorka), buduća istraživanja trebala bi koristiti kvalitativne metode (dubinski intervjui, studije slučaja) kako bi se otvorila „crna kutija“ njihovog uspjeha. Potrebno je detaljno mapirati koje specifične softverske i hardverske alate koriste, kako su prevladali početne barijere i kako organiziraju svoje interne procese upravljanja podacima. Ovi bi nalazi poslužili kao izravni „nacrt“ za savjetodavne službe.

3. Usporedba s velikim agrobiznisima

S obzirom na to da je ovo istraživanje fokusirano na SME-ove (do 100 ha), nužno je provesti komparativnu analizu s gospodarstvima iznad 100 hektara. Buduća istraživanja trebala bi

ispitati postoji li „točka loma“ (eng. *threshold effect*) u veličini posjeda nakon koje digitalna zrelost eksponencijalno raste zbog ekonomije razmjera i zapošljavanja specijaliziranog kadra.

4. Dublja analiza uzroka „vještinskog jaza“ i prostornih nejednakosti

Budući da je ovo istraživanje detektiralo „vještinski jaz“ u Panonskoj i Sjevernoj Hrvatskoj, buduća istraživanja trebala bi ispitati uzroke ovog jaza koristeći multivarijatne statističke metode (npr. hijerarhijsku regresijsku analizu ili strukturalno modeliranje jednadžbi). Konkretno, potrebno je kvantificirati relativni doprinos sljedećih potencijalnih čimbenika u objašnjavanju prostornih razlika u digitalnoj zrelosti:

- **Specifični agroekološki uvjeti i poljoprivredne grane** (npr. ratarstvo u Slavoniji, stočarstvo u Lici, maslinarstvo u Dalmaciji) koje mogu imati različite potrebe za digitalizacijom.
- **Lokalne poticajne mjere i savjetodavne usluge**, odnosno njihova dostupnost i kvaliteta na razini županija.
- **Demografska struktura poljoprivrednika** (razlike u dobi, obrazovanju i veličini gospodarstava).
- **Infrastrukturni čimbenici**, posebice dostupnost širokopojasnog (eng. *broadband*) interneta i mobilne mreže u ruralnim područjima.
- **Kulturni i socijalni čimbenici**, poput razine otvorenosti prema inovacijama, društvenih mreža poljoprivrednika i primjera dobre prakse.

5. Povezivanje digitalne zrelosti s okolišnim i ekonomskim ishodima

Konačno, najvažniji smjer za buduća istraživanja jest izravno povezivanje izračunatog „Globalnog indeksa digitalne zrelosti“ (Globalni_DRI) s objektivnim poslovnim i okolišnim pokazateljima. Budućim modelima potrebno je integrirati podatke o prinosima po hektaru, stopi povrata na investiciju (ROI), smanjenju upotrebe sredstava za zaštitu bilje, poboljšivaša i gnojiva te ugljičnom otisku gospodarstva. Time bi se znanstveno nedvojbeno dokazala pretpostavka da viša razina digitalne zrelosti ne znači samo „modernije“ gospodarstvo, već i ekonomski profitabilniju i ekološki održiviju poljoprivredu.

6. ZAKLJUČAK

Glavni cilj ovog doktorskog rada bio je identificirati i procijeniti razinu digitalne zrelosti poljoprivrednih gospodarstava (SME-ova) u Republici Hrvatskoj te razviti metodologiju za njihovo segmentiranje i usmjeravanje digitalne transformacije. Polazeći od prilagođenog CSIRO modela, istraživanje je pružilo prvi sveobuhvatni empirijski uvid u to kako hrvatski poljoprivrednici usvajaju tehnologiju, razvijaju kompetencije i upravljaju podacima.

Provedene analize na uzorku od 565 gospodarstava omogućile su donošenje sljedećih ključnih zaključaka:

6.1. Potvrda istraživačkih hipoteza

Na temelju statističke obrade podataka, sve tri postavljene istraživačke hipoteze su potvrđene:

- **Hipoteza 1 (H1): Poljoprivredni subjekti u Republici Hrvatskoj imaju nižu razinu digitalne zrelosti u usporedbi s prosjekom digitalne zrelosti malih i srednjih poduzeća u drugim sektorima gospodarstva.**
    - **H1 je potvrđena.** Rezultati pokazuju da se hrvatska poljoprivreda nalazi u ranim fazama digitalizacije (Globalni DRI = 2,75), s dominacijom faza *U nastajanju* i *Prijelazna* (ukupno 59,8% uzorka). U usporedbi s DESI indeksima za druge sektore (npr. maloprodaja, financije), poljoprivreda značajno zaostaje, posebice u dimenzijama integracije podataka i digitalnih javih usluga.
- **Hipoteza 2 (H2): Postoji značajna povezanost između organizacijskih čimbenika (npr. veličina gospodarstva, stupanj obrazovanja vlasnika, dob) i digitalne zrelosti poljoprivrednih gospodarstva.**
    - **H2 je potvrđena.** Regresijski modeli i klasterska analiza nedvojbeno su pokazali da su **dob i razina obrazovanja nositelja** najrobusniji prediktori digitalne zrelosti. Veličina gospodarstva utječe primarno na nabavu tehnologije (hardvera), ali ne i na razvoj „mekih“ kapaciteta poput analitike i strategije.
- **Hipoteza 3 (H3): Ne postoji jedinstvena i općeprihvaćena metodologija prilagođena specifičnostima poljoprivrednog sektora za evaluaciju digitalne zrelosti.**

- **H3 je potvrđena.** Istraživanje je demonstriralo nužnost adaptacije generičkih modela (poput CSIRO) na hrvatski kontekst. Validacija modela (Cronbachov $\alpha > 0,8$ za sve stupove i PCA analiza koja objašnjava 76,4% varijance) potvrdila je da je razvijeni instrument pouzdan i primjenjiv za dijagnostiku stanja u domaćoj poljoprivredi.

6.2. Ključni znanstveni i praktični doprinosi

U pogledu znanstvenog doprinosa ovaj rad predstavlja prvi empirijski *baseline* (polaznu točku) digitalne zrelosti hrvatske poljoprivrede. Znanstvena novost ogleda se u otkriću fenomena **„vještinskog jaza“** (eng. *skills gap*) u kontinentalnoj Hrvatskoj, gdje gospodarstva posjeduju tehnologiju, ali im nedostaju analitičke kompetencije za njezinu iskorištenost. Također, rad doprinosi literaturi dokazujući da u malim obiteljskim gospodarstvima ljudski kapital (znanje nositelja) nadmašuje fizički kapital (veličinu posjeda) kao glavni pokretač transformacije.

Po pitanju praktičnog doprinosa razvijena metodologija i indeks (Globalni_DRI) služe kao dijagnostički alat koji Ministarstvu poljoprivrede, savjetodavnim službama i samim gospodarstvima omogućuje:

1. **Samoprocjenu** (eng. self-assessment) – gospodarstva na ovaj način mogu sama procijeniti svoju digitalnu zrelost.
2. **Segmentaciju** – identifikacija 4 klastera (od „Početnika“ do „Lidera“) omogućuje kreiranje ciljanih mjera umjesto pristupa „jedna mjera za sve“.
3. **Longitudinalno praćenje** – alat omogućuje praćenje napretka sektora kroz vrijeme.

6.3. Preporuke za kreatora politika i praksu

Na temelju utvrđenog stanja, nameću se sljedeće strateške preporuke:

1. **Pomak s „tvrdih“ na „meke“ investicije** – buduće mjere ruralnog razvoja (npr. putem Strateškog plana ZPP-a) trebale bi uvjetovati potpore za nabavu precizne poljoprivredne tehnike obveznom edukacijom iz analitike podataka i digitalnog upravljanja.
2. **Ciljane intervencije po klasterima**

- Za **Klaster 1 („Početnici“)** – fokus na osnovnu digitalnu pismenost i jednostavne mobilne alate.
- Za **Klaster 2 i 3 („Tradicionalisti“ i „Pragmatičari“)** – poticanje integracije podataka i uvođenja FMIS-a (eng. *Farm Management Information Systems*).
- Za **Klaster 4 („Lideri“)** – uloga demonstracijskih centara i mentora („*lighthouse farms*“).

3. **Regionalno djelovanje** – u kontinentalnim regijama (Panonska i Sjeverna Hrvatska) nužno je osnivanje lokalnih centara za digitalne kompetencije kako bi se premostio „vještinski jaz“ i smanjila ovisnost o centraliziranim edukacijama u Zagrebu.
4. **Upravljanje podacima** (eng. *Data Governance*) – obzirom na najniže rezultate u ovoj dimenziji, potrebno je izraditi nacionalne smjernice o vlasništvu i zaštiti poljoprivrednih podataka te poticati formiranje „zadruga za podatke“ (eng. *data-cooperatives*).

6.4. Ograničenja i smjernice za buduća istraživanja

Iako je istraživanje pružilo robustne nalaze, ono je ograničeno presječnim dizajnom (eng. *cross-sectional*) i oslanjanjem na samoprocjenu ispitanika. Buduća istraživanja trebala bi:

- provesti **longitudinalne studije** kako bi se pratila dinamika usvajanja tehnologije,
- uključiti **objektivne pokazatelje** (npr. stvarni prinosi, ROI) kako bi se kvantificirao ekonomski učinak digitalne zrelosti te
- proširiti uzorak na **velika agrobiznis gospodarstva** (>100 ha) radi provedbe komparativne analize.

Digitalna transformacija hrvatske poljoprivrede nije pitanje samo nabave novih strojeva ili softvera; to je prvenstveno pitanje **promjene kulture, znanja i strategije**. Rezultati ovog istraživanja jasno poručuju da tehnologija sama po sebi ne donosi zrelost, ona je samo **alat**. Prava transformacija događa se kada nositelj gospodarstva, oslonjen na svoje znanje i stratešku viziju, počne koristiti podatke za donošenje boljih odluka. Hrvatska poljoprivreda ima potencijal za taj skok, ali on zahtijeva **sustavnu**, **educiranu** i **segmentiranu podršku** koja će pratiti stvarne potrebe svakog gospodarstva pojedinačno.

7. LITERATURA

1.Aagaard, A., Presser, M., Collins, T., Beliatis, M., Skou, A. K., & Jakobsen, E. M. (2021). The role of digital maturity assessment in technology interventions with industrial internet playground. Electronics, 10(10), 1134.

2.Algebra, (2023), Digitalna transformacija, at: https://www.algebra.hr/mba/about/eleadership/digitalna-transformacija/ access 03.01.2025

3.AlManei, M., Salonitis, K., & Tsinopoulos, C. (2018). A conceptual lean implementation framework based on change management theory. Procedia CIRP, 72, 1160-1165.

4.Ancín, M., Pindado, E., Sanchez, M., 2022. New trends in the global digital transformation process of the agri-food sector: an exploratory study based on Twitter. Agric. Syst. 203, 103520 https://doi.org/10.1016/j.agsy.2022.103520

5.Bampasidou, M., Goldgaber, D., Gentimis, T., Mandalika, A., (2024), Overcoming 'Digital Divides': Leveraging higher education to develop next generation digital agriculture professionals, Computers and Electronics in Agriculture, Volume 224, 2024, ISSN 0168-1699, https://doi.org /10.1016/ j.compag.2024.109181. https://www.sciencedirect.com/science/article/pii/S0168169924005726

6.Barney, J. B., (1991), "Firm Resources and Sustained Competitive Advantage". Journal of Management. 17 (1): 99–120. doi:10.1177/014920639101700108. S2CID 220588334.

7.Becker, G. S. (2002). The age of human capital. Becker, Gary Stanley. "The age of human capital." (2002): 3-8.

8.Becker, G. S. (1994). Human capital revisited. In Human capital: A theoretical and empirical analysis with special reference to education, third edition (pp. 15-28). The University of Chicago Press.

9.Weiss, Y. (2015). Gary Becker on human capital. Journal of Demographic Economics, 81(1), 27-31.

10.Becker, G. S. (1992). Human capital and the economy. Proceedings of the American philosophical society, 136(1), 85-92.

11.Berman, S. (2012). Digital transformation: opportunities to create new business models. Strategy & Leadership, 40(2), 16–24. https://doi.org/10.1108/

12.Bernus, P., Noran, O., (2017). Data Rich – But Information Poor. 206-214. 10.1007/978-3-319-65151-4_20. www.sciencedirect.com/science/article/pii/S0960148126006695)

13.Bertini, P. (2016) "Focus on technology hinders true digital transformation", http://www.brandknewmag.com/focus-on-technology-hinderstrue-digital-transformation/

14.Bosc, P. M., Berdegué, J., Goïta, M., van der Ploeg, J. D., Sekine, K., & Zhang, L. (2013 June). Investing in smallholder agriculture for food security. Rome: Committee on World Food Security

15.Buntak, K., Kovacic, M., & Mutavdžija, M. (2021). Measuring Digital Transformation Maturity of Supply Chain.

16.Caire, G. (1967). Becker (Gary S.)-Human capital, A theoretical and empirical analysis with special reference to education. Revue économique, 18(1), 132-133.

17.Chen, X., & Li, T. (2022). Diffusion of Agricultural Technology Innovation: Research Progress of Innovation Diffusion in Chinese Agricultural Science and Technology Parks. Sustainability, 14(22), 15008. https://doi.org/10.3390/su142215008

18.Commission Recommendation of 6 May 2003 concerning the definition of micro, small and medium sized enterprises (notified under document number C(2003) 1422), https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A32003H0361

19.Creswell, J. W., & Creswell, J. D. (2018), (5th ed.). APA, Research design SAGE Publications.

20.Davis, F. D.; Bagozzi, R. P.; Warshaw, P. R. (1989), Technology acceptance model. J Manag Sci, 35.8: 982-1003.

21.Daouda, Oumarou & Bryant, Christopher. (2016). Social Networks and the Diffusion of Innovative Practices to Help Agriculture Adapt to Climate Change and Variability.

22.Davis, F.D. (1986). A technology acceptance model for empirically testing new end-user information systems: Theory and results. Doctoral dissertation. Cambridge, MA. MIT Sloan School of Management.

23.Davis, F.D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. MIS Quarterly, 13, 319-339.

24.Davis, F.D., Bagozzi, R.P., Warshaw, P.R. (1989). User acceptance of computer technology: A comparison of two theoretical models. Management Science, 35, 982-1003. Suvremena Psihologija 15 (2012), 2, 205-224 © "Naklada Slap", 2012. Sva prava pridržana. 221

25.Davis, F.D., Bagozzi, R.P., Warshaw, P.R. (1992). Extrinsic and intrinsic motivation to use computers in the workplace. Journal of Applied Social Psychology, 22, 11-32.

26.Davis, F.D., Venkatesh, V. (1996).A critical assessment of potential measurement biases in the technology acceptance model: three experiments. International Journal of HumanComputer Studies, 45, 19-45.

27.Davis, F.D., Venkatesh, V. (2004). Toward preprototype user acceptance testing of new information systems: implications for software project management. IEEE Transactions on Engineering Management, 51, 31-46.

28.Defilippis, J. (2002a): Ekonomika poljoprivrede, Školska knjiga, Zagreb

29.Defilippis, J. (2002b): Obiteljska gospodarstva Hrvatske, AGM, Zagreb

30.DESI Index, 2022 - Indeks DESI 2021. (2022), Indeks gospodarske i društvene digitalizacije (DESI) at https://www.carnet.hr/wp-content/uploads/2021/11/DESI_2021__Croatia__hr.pdf Hrvatska,

31.Digital Europe: Pushing the frontier, capturing the benefits. Source: Bughin, J., Hazan, E.,

Labaye, E., Manyika, J., Dahlström, P., Ramaswamy, S., & de Billy, C. C. (2016). McKinsey Global Institute, p. 9. McKinsey Global Institute's Digitisation Index for Europe

32.Digital transformation, definition, EU 2020 - EU - Digital transformation, definition (2020). https://ec.europa.eu/croatia/ what_is_digital_transformation_changing

33.Donaldson, Stewart & Grant-Vallone, Elisa. (2002). Understanding Self-Report Bias in Organizational Behavior Research. Journal of Business and Psychology. 17. 245-260. 10.1023/A:1019637632584.

34.Dresch, A, D. C. Collatto, D. P. Lacerda (2018): Theoretical understanding between competitiveness and productivity: firm level, Ingeniería y competitividad, vol.20 no.2

35.EU – Digital maturity assessment (2023), available at: https://european-digital-innovation-hubs.ec.europa.eu/system/files/2023-02/DMA%20Tool%20%28EDIH%20Network%29-Quick%20user%20guide_13-02-2023_0.pdf, access: Feb 19th 2024

36.Europska komisija (2026), Pregled zajedničke poljoprivredne politike, Počeci, funkcije i pravila ZPP-a, praćenje njegove uspješnosti i njegova uloga u oblikovanju budućnosti EU-a. https://agriculture.ec.europa.eu/common-agricultural-policy/cap-overview_hr

37.Europska komisija (2026), Javno mišljenje o zajedničkoj poljoprivrednoj politici Procjenom i razumijevanjem javnog mnijenja Europska komisija može bolje oblikovati zajedničku poljoprivrednu politiku u skladu s potrebama i prioritetima građana EU-a.https://agriculture.ec.europa.eu/common-agricultural-policy/cap-overview/cap-glance/eurobarometer_hr?prefLang=hr

38.Europska komisija, Tur Cardona, J., Ciaian, P., Antonioli, F., Fellmann, T., Rocciola, F. et al., (2025), The state of digitalisation in EU agriculture - Insights from farm surveys, Publications Office of the European Union, Luxembourg, 2025, https://data.europa.eu/doi/10.2760/4688498, JRC141259.

39.Europska komisija, Shaping Europe's digital future, (2024), Digitalizacija poljoprivrednog sektora EU-a https://digital-strategy.ec.europa.eu/hr/policies/digitalisation-agriculture

40.Europska komisija, (2021), Digital Europe Programme https://commission.europa.eu/funding-and-tenders/find-funding/eu-funding-programmes/digital-europe-programme_en

41.Europska Komisija (2017). "Digital Economy and Society Index Metodological Note". http://ec.europa.eu/newsroom/document.cfm?doc_id=43048

42.Europska Komisija (2017), Vodič za korisnike o definiciji malih i srednjih poduzeća, https://op.europa.eu/hr/publication-detail/-/publication/79c0ce87-f4dc-11e6-8a35-01aa75ed71a1

43.Europska komisija (2019), Mala i srednja poduzeća, https://ec.europa.eu/growth/smes_en

44.Europska komisija (2022), Hrvatska u indeksu digitalnog gospodarstva i društva, https://digital-strategy.ec.europa.eu/hr/policies/desi-croatia

45.Eurostat (2018, November). Farms and farmland in the European Union-statistics. European

Union. Retrieved July 5, 2021, from https://ec.europa.eu/eurostat/statistics-explained/index.php/Farms_and_farmland_in_the_European_Union_-_statistics#Farmland_in_2016

46.Evans, N., D. (2017), Assessing your organization's digital transformation maturity, source; https://www.cio.com/article/230462/assessing-your-organization-s-digital-transformation-maturity-2.html, access 8.2.2024.

47.Falciola, J., M. Jansen, V. Rollo (2020): Defining firm competitiveness: A multidimensional framework, World Development Volume 129, May 2020

48.FAO (2013, May 30). International year of family farming 2014 Master plan. FAO. Retrieved March 22, 2021, from http://www.fao.org/fileadmin/user_upload/iyff/docs/Final_Master_Plan_IYFF _2014_30-05.pdf

49.Francisco J. Santos, Carmen Guzmán, Pedro Ahumada, Assessing the digital transformation in agri-food cooperatives and its determinants, Journal of Rural Studies, Volume 105, 2024, 103168, ISSN 0743-0167, https://doi.org/10.1016/j.jrurstud.2023.103168.

50.Fruk, M., Gorup, D. (2020) I2connect – connecting advisors to boost interactive innovation in agriculture and forestry, II International conference "Innovation – Guarantee for Future of Agribusiness in Croatia", Croatian Society of Agricultural Economists, Zagreb

51.Fuchs L. i Kern L., (2026), "Data Rich, Information Poor? Making Sense of Progress Monitoring Data to Guide Intervention Decisions" – Webinar, Vanderbilt University, Lehigh University. https://intensiveintervention.org/resource/data-rich-information-poor-making-sense-progress-monitoring-data-guide-intervention

52.Gouarderes, F. (2018): Europski parlament, Inovacijska politika, dokument EP, EU, http://www.europarl.europa.eu/RegData/etudes/fiches_techniques/2017/N54598/hr.pdf

53.Graeub, B. E., Chappell, M. J., Wittman, H., Ledermann, S., Kerr, R. B., & Gemmill-Herren, B. (2016). The state of family farms in the world. World development, 87, 1–15. https://doi.org/10.1016/j. worlddev.2015.05.012

54.Grahovac, P. (2005.): Ekonomika poljoprivrede, Golden marketing – Tehnička knjiga, Zagreb

55.Greenwood, J. (1997). The third industrial revolution: Technology, productivity, and income inequality, No. 435. American Enterprise Institute

56.Grimshaw, D.J. and Kala, S. and International Development Research Centre (Canada) (2011), Strengthening Rural Livelihoods: The Impact of Information and Communication Technologies in Asia,

57.ISBN 9781853397226, https://books.google.hr/books?id=Ls4ygEB9jrsC, Practical Action Pub, International Development Research Centre

58.Grievson, O., Holloway, T., Johnson, B., (2022), Digital Water Book: A Strategic Digital Transformation for the Water Industry Published on Sep 12, https://www.iwa-network.org/publications/digital-water-book-a-strategic-digital-transformation-for-the-water-industry

59.Haberli J. C., Oliveira T., Yanaze M., Spers E.E., (2019) Performance, farmer perception, and the routinisation (RO) moderation on ERP post-implementation. Heliyon. 2019 Jun 18;5(6):e01784. doi: 10.1016/j.heliyon.2019.e01784. PMID: 31286074; PMCID: PMC6587053.

60.Haixia Li, Yu Guo, Huajian Zhao, Yang Wang, David Chow, Towards automated greenhouse: A state of the art review on greenhouse monitoring methods and technologies based on internet of things, Computers and Electronics in Agriculture, Volume 191, 2021, 106558, ISSN 0168-1699, https://doi.org/10.1016/j.compag.2021.106558.

61.Huffman, W. E,. Orazem,P. F., Ch. 43 Agriculture and Human Capital in Economic Growth: Farmers, Schooling and Nutrition, Ed.: Evenson,R. Pingali P., Handbook of Agricultural Economics, Elsevier, Vol, 3, 2007, Pp 2281-2341, ISSN 1574-0072, ISBN 9780444518736, https://doi.org/10.1016/S1574-0072(06)03043-X. (https://www.sciencedirect.com/science/article/pii/S157400720603043X)

62.I-scoop (2016). "Digitization, digitalization and digital transformation: the differences", https://www.i-scoop.eu/digital-transformation/digitization-digitalization-digital-transformation-disruption/

63.Jerbić, B. i Švaco, M. (2023). Artificial intelligence and robotics as the driving power of modern society. Rad Hrvatske akademije znanosti i umjetnosti. Tehničke znanosti, 1-55.

64.Jovanović, M. i sur. (2017). "Composite indices in technology management: A critical approach". In Jeremić, V., Radojičić, Z., Dobrota, M. ed. Emerging Trends in the Development and Application of Composite Indicators, Hershey, PA: IGI Global, pp. 38–71, doi: 10.4018/978-1-5225-0714-7

65.Jovanović, M., Dlačić J., & Okanović, M. (2018). Digitalization and society's sustainable development – Measures and implications. Proceedings of Rijeka Faculty of Economics: Journal of Economics and Business, 36(2), 905- 928.

66.Kormos, Erik & Wisdom, Kendra. (2021). Rural Schools and the Digital Divide: Technology in the Learning Experience. Theory & Practice in Rural Education. 11. 10.3776/tpre.2021.v11n1p25-39.

67.Kumar, P.; Srivastava, P.K.; Tiwari, P.; Mall, R.K. Chapter 20—Application of GPS and GNSS Technology in Geosciences. In GPS and GNSS Technology in Geosciences; Petropoulos, G.P., Srivastava, P.K., Eds.; Elsevier: Amsterdam, The Netherlands, 2021; pp. 415–427. ISBN 978-0-12-818617-6

68.Kutnjak, A., Pihir, I., & Furjan, M. T. (2020). Assessing Digital Transformation Readiness Using Digital Maturity Indices. In Central European Conference on Information and Intelligent Systems (pp. 307-314). Faculty of Organization and Informatics Varazdin.

69.Lavie, Dovev (2008). "The Competitive Advantage of Interconnected Firms". 21st Century Management: A Reference Handbook. pp. I-324 – I-334. doi:10.4135/9781412954006.n32. ISBN 9781412949729.

70.Levi Jakšić, M. i sur. (2018a). Tehnološko preduzetništvo. Beograd: Fakultet organizacionih nauka.

71. Lugonja, D., Jurišić, M., Plaščak, I., Zbukvić, I., Glavica-Tominić, D., Krušelj, I., Radočaj, D. (2022) Smart Agriculture Development and Its Contribution to the Sustainable Digital Transformation of the Agri-Food Sector, Tehnički Glasnik 16, 2(2022), 264-267

72.Lynn, T., Rosati, P., Edel, C., Declan, C., Fox, G., and O'Gorman, C., (2022) Digital Towns: Accelerating and Measuring the Digital Transformation of Rural Societies and Economies. Palgrave Macmillan Cham, Switzerland. ISBN 978-3-030-91247-5

73.Manyika, J., Ramaswamy, S., Khanna, S., Sarrazin, H., Pinkus, G., Sethupathy, G., & Yaffe, A. (2015). Digital America: A tale of the haves and have-mores. McKinsey Global Institute, p.30.

74.Maru A, Berne D, De Beer J et al. (2018), Digital and Data-Driven Agriculture: Harnessing the Power of Data for Smallholders [version 1; not peer reviewed]. F1000Research 2018, 7:525 (document) (https://doi.org/10.7490/f1000research.1115402.1)

75.Matt, C., Hess, T., & Benlian, A. (2015). Digital Transformation Strategies. Business & Information Systems Engineering, 57, 339-343.

76.McKinsey Global Survey on digital transformations (2018), at ttps://www.mckinsey.com/ business-functions/organization/our-insights/unlocking-success-in-digital-transformations# access 8.2.2024.

77.Van Hilten, M., Wolfert, S. (2022), 5G in agri-food - A review on current status, opportunities and challenges, Computers and Electronics in Agriculture, Volume 201, 2022, 107291, ISSN 0168-1699, https://doi.org/10.1016/j.compag.2022.107291.

78.Nambisan, S., Lyytinen, K., Majchrzak, A., & Song, M. (2017). Digital Innovation Management: Reinventing innovation management research in a digital world. MIS Quarterly, 41, 223–238

79.Obeidat, M., North, M., Burgess, L., Parker, R., North, S. (2015). DRIP – Data Rich, Information Poor: A Concise Synopsis of Data Mining. Universal Journal of Management. 3. 29-35. 10.13189/ujm.2015.030105.

80.OECD Izvješće o Republici Hrvatskoj (2025) - Policies for the Future of Farming and Food in Croatia https://www.oecd.org/en/publications/policies-for-the-future-of-farming-and-food-in-croatia_011c6272-en.html

81.Parra-López, C., Carmona-Torres, C., (2026), Digital/4.0 technologies for affordable and clean energy in agriculture: Recent applications and forward-looking strategic directions, Renewable Energy, Elsevier, vol. 268, 2026, 125843, ISSN 0960-1481, https://doi.org/10.1016/j.renene.2026.125843. (https:// Bernus, Peter & Noran, Ovidiu. (2017).

82.Paustian, M., & Theuvsen, L. (2017). Adoption of precision agriculture technologies by German crop farmers. Precision Agriculture, 18, 701–716. https://doi.org/10.1007/s11119-016-9

83.Petrač, B. (2002.): Agrarna ekonomika, Ekonomski fakultet u Osijeku: Poljoprivredni fakultet, Osijek

84.Radočaj, D., Plaščak, I., Jurišić, M. (2023), Global Navigation Satellite Systems as State-of-the-Art Solutions in Precision Agriculture: A Review of Studies Indexed in the Web of Science, Faculty of Agrobiotechnical Sciences Osijek, Josip Juraj Strossmayer University of Osijek, Vladimira Preloga 1, 31000 Osijek, Croatia

85.Rane, N., Choudhary, S. P. i Rane, J. (2024). Acceptance of artificial intelligence: key factors, challenges, and implementation strategies. Journal of Applied Artificial Intelligence, 5(2), 50-70.

86.Rotz, S., Gravely, E., Mosby, Duncan, I. E., Finnis, E. Horgan, M., LeBlanc, J., Martin, R., Tait Neufeld, H., Nixon, A., Pant, L., Shalla, V., Fraser, E., (2019), Automated pastures and the digital divide: How agricultural technologies are shaping labour and rural communities, Journal of Rural Studies, Volume 68, 2019, Pages 112-122, ISSN 0743-0167, https://doi.org/10.1016/j.jrurstud.2019.01.023. (https://www.sciencedirect.com/science/article/pii/S0743016718307769)

87.Samadder, S., Pandya, S., Lal, S., (2023). Bridging the Digital Divide in Agriculture: An Investigation to ICT Adoption for Sustainable Farming Practices in Banaskantha District of Gujarat, India. International Journal of Environment and Climate Change. 13. 1376-1384. 10.9734/ijecc/2023/v13i92367.

88.Savastano, M., Zentner, H., Spremić, M. i Cucari, N. (2022). Assessing the relationship between digital transformation and sustainable business excellence in a turbulent scenario. Total quality management & business excellence, 1-22.

89.Schmarzo, B. (2017). "What is Digital Transformation?", znanstveni članak, dostupno na: https://www.cio.com/article/3199030/analytics/what-is-digital-transformation.html

90.Schultz, T. W. (1993). Origins of increasing returns. John Wiley & Sons.

91.Schultz, T. W. (1993). The economic importance of human capital in modernization. Education

92.Schultz, T. W., & Schultz, T. W. (1982). Investing in people: The economics of population quality. Univ of California Press.

93.Schultz, T. W. (1990). Human capital investment. Beijing Institute of Economics Press: Beijing, China.

94.Schultz, T. W. (1980). Investment in entrepreneurial ability. The Scandinavian Journal of Economics, 437-448.

95.Schultz, T. W. (1975). The Value of the Ability to Deal with Disequilibria. Journal of Economic Literature, 13(3), 827–846. http://www.jstor.org/stable/2722032

96.Schultz, T. W. (1975). The value of the ability to deal with disequilibria. Journal of economic literature, 13(3), 827-846.

97.Schultz, T. W. (1972). Human capital: Policy issues and research opportunities. In Economic Research: Retrospect and Prospect, Volume 6, Human Resources (pp. 1-84). NBER.

98.Schultz, T. W. (1971). Investment in human capital. The role of education and of research.

99.Schultz, T. W. (1968). Institutions and the rising economic value of man. American Journal of

Agricultural Economics, 50(5), 1113-1122.
100. Schultz, T. W. (1962). Reflections on investment in man. Journal of political economy, 70(5, Part 2), 1-8.
101. Schultz, T. W. (1961). Investment in Human Capital. The American Economic Review, 51(1), 1–17. http://www.jstor.org/stable/1818907
102. Schultz, T. W. (1961). Reflections on Investment in Man. The American Economic Review, 51(1), 1–17. http://www.jstor.org/stable/1818907
103. Schultz, T. W. (1961). Investment in human capital. The American economic review, 51(1), 1-17.
104. Schultz, T. W. (1961). Education and economic growth. Teachers College Record, 62(10), 46-88.
105. Schultz, T. W. (1960). Capital formation by education. Journal of political economy, 68(6), 571-583.
106. Schultz, T. W. (1959). Investment in man: An economist's view. Social service review, 33(2), 109-117. economics, 1(1), 13-19.
107. Schwab, K. (2016). The Fourth Industrial Revolution, Geneva: World Economic Forum.
108. Shannon, D.; Clay, D.E.; Sudduth, K.A. An Introduction to Precision Agriculture. In Precision Agriculture Basics; John Wiley & Sons, Ltd.: Hoboken, NJ, USA, 2018; pp. 1–12. ISBN 978-0-89118-367-9
109. Spremić, M. (2017) Digitalna transformacija poslovanja. Sveučilište u Zagrebu, Ekonomski Fakultet. Zagreb
110. Sudarić, T., Živić, T., Zmaić, K. (2022) Digital transformation in the higher education system: situation, experiences, advantages, successfulness, and opportunities of distance learning at the Faculty of Agrobiotechnical Sciences Osijek, 1st International Conference on Advantages in Science and Technology: Proceedings COAST 2022 / Jovanović, Đorđe ; Grgurević, Nikša (ur.). Herceg Novi: Fakultet za menadžment u Sremskim Karlovcima Univerziteta Union, 2022. str. 497-515 (predavanje, međunarodna recenzija, cjeloviti rad (in extenso), znanstveni), Access 12.01.2024.
111. The Economist (1999) “Catch the wave: The long cycles of industrial innovation are becoming shorter”, https://www.economist.com/node/186628
112. Tomičić Furjan, M., Tomičić-Pupek, K., Pihir, I. (2020), “Understanding Digital Transformation Initiatives: Case Studies Analysis”, Business Systems Research, 11. 125-141.
113. Van der Veen, M., (2010). Agricultural innovation: invention and adoption or change and adaptation?. World Archaeology. 42. 1-12. 10.1080/00438240903429649.
114. Van Hilten M, Ongena G and Ravesteijn P (2020) Blockchain for Organic Food Traceability: Case Studies on Drivers and Challenges. Front. Blockchain 3:567175. doi:10.3389/fbloc.2020.567175
115. Vial, G., 2019. Understanding digital transformation: a review and a research agenda. J. Strat.

Inf. Syst. 28 (2), 118–144. https://doi.org/10.1016/j.jsis.2019.01.003.

116. Vrontis, D., Shams, R., Thrassou, A., & Pereira, V. (Eds.). (2026). The Realities and Illusions of Defending Competitive Advantage: A Resource-Based View Perspective. Taylor & Francis.
117. Wang X, Cheng Z. Cross-sectional studies: strengths, weaknesses, and recommendations. Chest. 2020;158(1S):S65-S71. doi:10.1016/j.chest.2020.03.012.
118. Wang X, Kattan MW. Cohort studies: design, analysis, and reporting. Chest. 2020;158(1S):S72-S78. doi:10.1016/j.chest.2020.03.014.
119. Westeren, K. I., H. Cader, M. F. Sales, J. O. Similä, J. Staduto (2020): Competitiveness and Knowledge, An International Comparison of Traditional Firms, Routledge
120. Westerman, G., Bonnet, D., McAfee, A. (2014). The nine elements of digital transformation. MIT Sloan Management Review, 55(3), 1-6.
121. Wisenthige, K., & C. Guoping, (2016). Firm level competitiveness of small and medium enterprises (SMEs): analytical framework based on pillars of competitiveness model. International Research Journal of Management, IT and Social Sciences, 3(9)
122. Wolfert, S., Ge, L., Verdouw, C., Bogaardt, M.-J., (2017), Big Data in Smart Farming – A review, Agricultural Systems, Vol. 153, pp 69-80, ISSN 0308-521X, https://doi.org/10.1016/j.agsy.2017.01.023.
123. (https://www.sciencedirect.com/science/article/pii/S0308521X16303754)
124. Zeleno izvješće za 2024 - Godišnje izvješće o stanju poljoprivrede u 2024. godini (Zeleno izvješće za 2024.), (2025), Ministarstvo poljoprivrede, šumarstva i ribarstva, Ulica grada Vukovara 78, Zagreb, https://poljoprivreda.gov.hr/
125. Zhang, A., Hobman, E., Smith D. & Guan X. (2022) Enabling a digital transformation in Agriculture, Data management system, a digital maturity index and assessment tool for the agricultural industry, https://www.crdc.com.au/sites/default/files/Digital%20Maturity%20%20index%20and%20assessment%20tool.pdf
126. Beers G., Montero A., Marquardt, D., Schuttelaar, J., (2024), Communities on Digital Innovation in Agrifood, SmartAgriHubs Community, https://www.smartagrihubs.eu/synergy-days/day-1-plenaries-synergy-days-2024.pdf

8. SAŽETAK[T28]

Doktorski rad usmjeren je na utvrđivanje razine digitalne zrelosti i razvoj metodološkog okvira za planiranje digitalne transformacije poljoprivrednih gospodarstava u Republici Hrvatskoj, s ciljem povećanja njihove konkurentnosti, učinkovitosti i održivosti poslovanja. Istraživanje je usmjereno na procjenu sposobnosti poljoprivrednih subjekata za usvajanje i učinkovitu primjenu digitalnih tehnologija, razvoj digitalnih kompetencija, upravljanje podacima te njihovu integraciju u poslovne i proizvodne procese.

Poseban naglasak stavljen je na identifikaciju čimbenika koji utječu na razinu digitalne zrelosti te razvoj podloge za učinkovitije planiranje i upravljanje procesom digitalne transformacije. Glavni cilj istraživanja bio je utvrditi razinu digitalne zrelosti poljoprivrednih subjekata u Republici Hrvatskoj primjenom razvijenog Globalnog DRI indeksa, dok su specifični ciljevi uključivali utvrđivanje demografskih, organizacijskih i prostornih čimbenika povezanih s razinom digitalne zrelosti te oblikovanje smjernica i preporuka za planiranje digitalne transformacije poljoprivrednih gospodarstava.

U skladu s ciljevima postavljene su tri hipoteze. Prva hipoteza (H1) pretpostavlja da poljoprivredni subjekti u Republici Hrvatskoj imaju nižu razinu digitalne zrelosti u odnosu na prosjek digitalne zrelosti malih i srednjih poduzeća u drugim sektorima gospodarstva. Druga hipoteza (H2) pretpostavlja postojanje statistički značajne povezanosti između organizacijskih i demografskih čimbenika, uključujući veličinu gospodarstva, razinu obrazovanja, dob i iskustvo nositelja gospodarstva, i razine digitalne zrelosti poljoprivrednih gospodarstava. Treća hipoteza (H3) polazi od pretpostavke da ne postoji jedinstvena i općeprihvaćena metodologija za evaluaciju digitalne zrelosti prilagođena specifičnostima poljoprivrednog sektora. Empirijsko istraživanje provedeno je na uzorku od 565 poljoprivrednih gospodarstava.

Podaci su prikupljeni neposrednim anketiranjem, pri čemu su educirani anketari osobno posjećivali nositelje gospodarstava, pružali potrebna pojašnjenja te odgovore izravno unosili u digitalni obrazac. Takav način prikupljanja podataka omogućio je visoku razinu odaziva, smanjio mogućnost pogrešnog razumijevanja specifičnih digitalnih i tehnoloških pojmova te omogućio uključivanje gospodarstava koja bi mogla biti nedovoljno zastupljena u istraživanjima provedenima isključivo digitalnim metodama.

Statistička obrada podataka provedena je primjenom statističkog softvera Jamovi i programskog jezika R. U analitičkom postupku primijenjene su deskriptivne i inferencijalne statističke metode, uključujući analizu glavnih komponenti (PCA), analizu unutarnje konzistentnosti mjernog instrumenta, K-means klastersku analizu, analizu varijance (ANOVA) te višestruku linearnu regresiju.

Pouzdanost pojedinih stupova digitalne zrelosti procijenjena je Cronbachovim koeficijentom alfa, dok su dimenzionalnost i opravdanost konstrukcije Globalnog DRI indeksa ispitane PCA analizom. Za utvrđivanje razlika u razini digitalne zrelosti prema demografskim, organizacijskim i prostornim obilježjima primijenjena je ANOVA, dok su regresijski modeli korišteni za identifikaciju ključnih prediktora Globalnog DRI indeksa i pojedinačnih stupova digitalne zrelosti.

Klasterska analiza omogućila je izdvajanje homogenih skupina poljoprivrednih gospodarstava prema njihovim obilježjima digitalne zrelosti. Rezultati istraživanja potvrđuju sve tri postavljene hipoteze.

Utvrđeno je da se hrvatska poljoprivreda nalazi u ranim fazama digitalne transformacije, s vrijednošću Globalnog DRI indeksa od 2,75. U fazama „U nastajanju“ i „Prijelazna“ nalazi se ukupno 59,8 % istraživanih gospodarstava. U usporedbi s pokazateljima digitalne zrelosti drugih sektora gospodarstva, poljoprivreda značajno zaostaje, osobito u dimenzijama integracije podataka i digitalnih javnih usluga.

Rezultati pokazuju da dob i razina obrazovanja nositelja gospodarstva predstavljaju najrobustnije prediktore digitalne zrelosti. Istodobno, veličina gospodarstva prvenstveno je povezana s nabavom i dostupnošću tehnologije, ali nije jednako značajna za razvoj „mekih“ kapaciteta, poput analitike podataka, upravljanja i strateškog planiranja digitalne transformacije.

Provedena validacija pokazala je visoku pouzdanost razvijenog mjernog instrumenta, pri čemu je Cronbachov α za sve stupove digitalne zrelosti bio veći od 0,80. PCA analiza potvrdila je opravdanost konstrukcije Globalnog DRI indeksa, pri čemu je model objasnio 76,4 % ukupne varijance.

Rezultati potvrđuju primjenjivost razvijenog instrumenta za sustavnu procjenu i dijagnostiku digitalne zrelosti poljoprivrednih gospodarstava u hrvatskom kontekstu te ukazuju na potrebu prilagodbe generičkih modela digitalne zrelosti, poput CSIRO modela, specifičnostima poljoprivrednog sektora.

Znanstveni doprinos rada ogleda se u uspostavljanju prve empirijske polazne osnove za procjenu digitalne zrelosti hrvatske poljoprivrede te razvoju metodološkog okvira prilagođenog njezinim sektorskim specifičnostima.

Posebna znanstvena novost istraživanja jest identifikacija fenomena „vještinskog jaza“ u kontinentalnoj Hrvatskoj, koji se očituje u nesrazmjeru između dostupnosti digitalnih tehnologija i razine analitičkih i digitalnih kompetencija potrebnih za njihovu učinkovitu primjenu.

Istraživanje dodatno pokazuje da u malim obiteljskim gospodarstvima ljudski kapital, odnosno znanje, obrazovanje i kompetencije nositelja gospodarstva, predstavlja važniji čimbenik digitalne transformacije od fizičkog kapitala, odnosno veličine gospodarstva.

Dobiveni rezultati predstavljaju znanstvenu i metodološku osnovu za daljnja istraživanja te oblikovanje ciljanih politika, mjera potpore i strategija usmjerenih na ubrzavanje digitalne transformacije hrvatske poljoprivrede.

9. SUMMARY

This doctoral thesis focuses on determining the level of digital maturity and developing a methodological framework for planning the digital transformation of agricultural holdings in the Republic of Croatia, with the aim of enhancing their competitiveness, efficiency, and business sustainability. The research centers on assessing the capacity of agricultural entities to adopt and effectively implement digital technologies, develop digital competencies, and manage and integrate data into business and production processes.

Particular emphasis is placed on identifying factors influencing the level of digital maturity and developing a foundation for more effective planning and management of the digital transformation process. The primary research objective was to determine the digital maturity level of agricultural entities in the Republic of Croatia using the developed Global DRI Index, while specific objectives included identifying demographic, organizational, and spatial factors associated with digital maturity levels, as well as formulating guidelines and recommendations for planning the digital transformation of agricultural holdings.

Three hypotheses were formulated in alignment with these objectives. The first hypothesis (H1) posits that agricultural entities in the Republic of Croatia exhibit a lower level of digital maturity compared to the average digital maturity of small and medium-sized enterprises in other economic sectors. The second hypothesis (H2) posits the existence of a statistically significant relationship between organizational and demographic factors—including farm size, education level, age, and the experience of the farm holder—and the level of digital maturity of agricultural holdings. The third hypothesis (H3) is based on the premise that there is no single, universally accepted methodology for evaluating digital maturity tailored to the specific characteristics of the agricultural sector. Empirical research was conducted on a sample of 565 agricultural holdings.

Data were collected through direct surveying, wherein trained interviewers personally visited farm holders, provided necessary clarifications, and entered responses directly into a digital form. This data collection method ensured a high response rate, minimized the risk of misinterpreting specific digital and technological terms, and enabled the inclusion of farms that might otherwise be underrepresented in studies conducted solely via digital methods.

Statistical data processing was performed using Jamovi statistical software and the R programming language. The analytical process employed descriptive and inferential statistical methods, including Principal Component Analysis (PCA), analysis of the measurement instrument's internal consistency, K-means cluster analysis, Analysis of Variance (ANOVA),

and multiple linear regression.

The reliability of individual digital maturity pillars was assessed using Cronbach's alpha coefficient, while the dimensionality and construct validity of the Global DRI Index were examined via PCA. ANOVA was applied to determine differences in digital maturity levels based on demographic, organizational, and spatial characteristics, whereas regression models were used to identify key predictors of the Global DRI Index and individual digital maturity pillars.

Cluster analysis enabled the identification of homogeneous groups of agricultural holdings based on their digital maturity characteristics. The research results confirm all three proposed hypotheses.

It was found that Croatian agriculture is in the early stages of digital transformation, with a Global DRI Index value of 2.75. A total of 59.8% of the surveyed holdings fall into the "Emerging" and "Transitional" stages. Compared to digital maturity indicators in other economic sectors, agriculture lags significantly behind, particularly in the dimensions of data integration and digital public services.

The results indicate that the age and education level of the farm holder are the most robust predictors of digital maturity. At the same time, farm size is primarily associated with technology acquisition and availability but is not equally significant for the development of "soft" capabilities, such as data analytics, management, and strategic planning for digital transformation. The validation demonstrated high reliability of the developed measurement instrument, with Cronbach's α exceeding 0.80 for all digital maturity pillars. PCA analysis confirmed the validity of the Global DRI Index construction, with the model explaining 76.4% of the total variance.

The results confirm the applicability of the developed instrument for the systematic assessment and diagnosis of the digital maturity of agricultural holdings within the Croatian context and highlight the need to adapt generic digital maturity models—such as the CSIRO model—to the specificities of the agricultural sector.

The scientific contribution of this work lies in establishing the first empirical baseline for assessing the digital maturity of Croatian agriculture and developing a methodological framework tailored to its sectoral specificities.

A particular scientific novelty of the research is the identification of a "skills gap" phenomenon in continental Croatia, manifested as a disparity between the availability of digital technologies and the level of analytical and digital competencies required for their effective application.

The research further demonstrates that, in small family farms, human capital—specifically the

knowledge, education, and competencies of the farm operator—is a more significant factor in digital transformation than physical capital, such as farm size.

The findings provide a scientific and methodological foundation for future research and for the formulation of targeted policies, support measures, and strategies aimed at accelerating the digital transformation of Croatian agriculture.

10. PRILOZI

DODACI

Dodatak A: Anketni upitnik o digitalnoj zrelosti poljoprivrednih gospodarstava

INDEKS DIGITALNE ZRELOSTI

ALAT ZA PROCJENU U POLJOPRIVREDI

– ANKETNI UPITNIK –

ALAT ZA PROCJENU

Ovaj alat za procjenu razvijen je kako bi se indeks digitalne zrelosti mogao prikazati za svaki od stupova.

SVRHA PROCJENE

Osmišljen je za prepoznavanje digitalnih snaga i slabosti agrobiznisa u poljoprivrednoj industriji. Izgradnjom ovakvog alata poljoprivredna gospodarstva dobivaju alat za bolje razumijevanje trenutačne digitalne zrelosti i područja mogućih poboljšanja.

Nalazi ove procjene mogu također poslužiti industriji pri razvoju nacionalne digitalne strategije za poljoprivredu i povezanih prioriteta ulaganja.

O IZRAĐIVAČU IZVORNE VERZIJE ALATA

Izvornu verziju ovog alata razvila je australska institucija CSIRO (Commonwealth Scientific and Industrial Research Organisation - nacionalno državno tijelo za znanstveno istraživanje u Australiji, osnovano 1926. godine pod imenom Advisory Council for Science and Industry (hrv. savjetno vijeće za znanost i industriju), a financira ga 10 korporacija za istraživanje i razvoj - RDC (Rural Research and Development Corporations - pomažu u pokretanju poljoprivrednih inovacija od 1989. godine i omogućuju australskoj vladi i primarnim proizvođačima zajedničko ulaganje u istraživanje i razvoj). Dobio je etičko dopuštenje od CSIRO-ovog Odbora za etiku ljudskih istraživanja (07 3833 5693).

Skupne podatke moguće je koristiti za informiranje tijekom strateškog planiranja, ali i za razumijevanje digitalne zrelosti u poljoprivredi.

-

Upute - Kako ispuniti alat za ocjenjivanje:

- alat sadrži 54 pitanja i anketa bi trebala trajati desetak do petnaest minuta. Trebaju je ispuniti rukovoditelji uključeni u donošenje odluka. Prilikom odgovaranja na pitanja, razmislite o svom poslovanju i digitalnim tehnologijama koje koristite. Digitalne tehnologije obuhvaćaju niz tehnologija uključujući senzore, aplikacije, GPS, dronove, strojeve, alate za analizu podataka, programe za vizualizaciju, kao i drugi hardver i softver za automatizaciju poslovnih procesa. Na kraju procjene dobit ćete povratne informacije o digitalnoj zrelosti vašeg poslovanja.

- Svaka od skupina pitanja odnosi se na pojedini stup digitalne zrelosti i razvojnu fazu u organizaciji, na farmi, odnosno poljoprivrednom gospodarstvu. Ima 5 stupova i 5 skupina pitanja;

- Napomena vezana uz pitanja: svako se pitanje mora pojasniti i pojednostavniti kako bi svaki ispitanik i anketar mogli lakše utvrditi i potvrditi odgovor;

- Nakon pitanja vezanih uz digitalizaciju i stupove digitalne zrelosti, postavljaju se osnovna pitanja iz demografskog spektra (starost, spol, naobrazba)

- Uz ova pitanja i moguća pojašnjenja anketari (u pravilu poljoprivredni savjetnici i suradnici u procesu prijenosa znanja) mogu podatke unijeti u upitnik i potvrditi odabrane odgovore slanjem skeniranih upitnika, odnosno preslika istih e-poštom ili drugim kanalima.

- Razdoblje anketiranja ne bi trebalo trajati više od 4 do 5 tjedana, odnosno 25 radnih dana, ako se uzme broj od potencijalnih 50-ak savjetnika koji bi na terenu anketirali i moguće slanje dijela upitnika na teren, odnosno ispitanicima e-mailom i drugim putem, predviđeni uzorak od minimalno 383 ispitanika vjerojatno bi bio realiziran u navedenom roku, uz mogući (POŽELJAN) veći broj ispitanika, a nakon pregleda i analize odgovora, upitnika i svih materijala, broj prispjelih odgovora i ispitanika bio bi početnih 500 do 600, pa bi nakon moguće redukcije, došli na broj od cca 385 ispitanika.

-

Dobrodošli! Ova anketa pomaže vam da procijenite koliko je vaše gospodarstvo spremno za digitalnu transformaciju. Digitalne tehnologije mogu značajno poboljšati vašu produktivnost, smanjiti troškove i učiniti vaš rad lakšim. Kroz pet ključnih područja, provest ćemo vas kroz najvažnije aspekte digitalne poljoprivrede. Prije nego što započnete s odgovorima, pročitajte kratke priče koje će vam pomoći da bolje razumijete što se od vas traži.

Stup 1: Strategija i kultura - 13 pitanja		
Zašto je ovo važno? Zamislite da želite unaprijediti svoje gospodarstvo kupnjom nove opreme, ali nemate plan kako je koristiti. Bez strategije ulaganja u tehnologiju mogu biti neučinkovita. S druge strane, ako imate jasnu viziju kako vam tehnologija može pomoći tada možete donijeti prave odluke koje će vam dugoročno donijeti korist. Također, kultura unutar gospodarstva – način na koji vi i vaši zaposlenici prihvaćate nove promjene – može odrediti uspjeh digitalne transformacije.		
Strategija Uzmimo primjer obitelji koja vodi poljoprivredno gospodarstvo već generacijama. Gospodarstvo se razvijalo uz tradicionalne metode, no dolaskom digitalnih tehnologija, sin preuzima inicijativu i želi uvesti nove alate poput GPS-a za preciznu sjetvu/sadnju i dronova za nadzor usjeva. Njegov otac je skeptičan jer ne vidi jasnu korist i boji se troškova. No, sin mu pokazuje plan: kako će novi alati smanjiti troškove gnojiva, povećati prinose i olakšati posao. S jasnom strategijom, gospodarstvo može napraviti veliki iskorak u budućnost bez nepotrebnih gubitaka.		
Strategija	**Pitanja za procjenu**	**Skala odgovora**
P1- 1	Naše poslovanje ima jasan plan koji pokazuje put i korake za korištenje digitalnih tehnologija i podataka za donošenje poslovnih odluka i automatizaciju našeg poslovanja.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P1-2	Korištenje digitalnih tehnologija i automatizacija poslovnih operacija ključni su dio naše strategije za povećanje produktivnosti i konkurentnosti.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P1-3	Kada naše poslovanje ulazi u nove digitalne tehnologije, biramo tehnologije koje će nam dugoročno odgovarati.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P1-4	Naše poslovanje neprestano traži sve novije i novije digitalne tehnologije koje će unaprijediti naše poslovanje.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P1- 5	Razmišljajući o ulaganju vašeg poduzeća ili gospodarstva u sljedećih 12-18 mjeseci, koliki postotak otprilike planirate potrošiti na nove digitalne tehnologije?	1=0-20%; 2=21-40%; 3=41-60%; 4=61-80%; 5=više od 80%
P1- 6	Naše poduzeće ima dugoročni plan za ulaganje u nove digitalne tehnologije i zapošljavanje/osposobljavanje osoblja digitalnom mogućnošću.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
Kultura Zamislite da uvodite novi digitalni sustav za upravljanje gospodarstvom, ali vaši zaposlenici ga ne žele koristiti jer se boje promjena ili im je previše kompliciran. Digitalna transformacija uspješna je samo ako su ljudi spremni prihvatiti tehnologiju		

i vidjeti njezine prednosti. Ključ je u edukaciji, podršci i postupnom uvođenju promjena kako bi se svi osjećali sigurno i motivirano za korištenje novih alata.		
Kultura		
P1- 7	Osoblje u našem poduzeću potiče se na korištenje i eksperimentiranje s novim digitalnim tehnologijama.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P1-8	Od osoblja u našem poduzeću očekuje se da koristi podatke za donošenje odluka.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P1-9	Osoblje u našem poduzeću potiče se na razmjenu digitalnih iskustava i uvide s drugim poduzećima u industriji.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P1-10	Relevantni dionici mog područja (npr. udruge, konzultanti, državni odjeli, savjetnici) aktivno promiču i pokazuju vrijednost digitalnih tehnologija (npr. pružaju informacije putem brošure i radionica, ocrtavaju prednosti i troškove novih tehnologija).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
Vodstvo u industriji Zamislite poljoprivrednika koji aktivno sudjeluje na sajmovima i edukacijama, prateći trendove u digitalnoj poljoprivredi. On redovito surađuje s drugim poljoprivrednicima i tehnološkim stručnjacima te dijeli svoja iskustva. Takvi pojedinci postaju predvodnici industrije jer pomažu drugima da lakše uvedu nove tehnologije i donose pametne odluke.		
Vodstvo u industriji		
P1- 11	Relevantni dionici mog područja komuniciraju poslovne strategije najbolje prakse za korištenje dostupnih podataka i primjenu analitike za donošenje odluka (npr. putem demonstracija tehnoloških tvrtki i/ili vodećih poduzeća).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P1-12	Relevantni dionici mog područja uspostavili su mreže ljudi i partnerstva koja pružaju snažnu podršku našem poslovanju o pitanjima digitalne tehnologije.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P1-13	Relevantni dionici mog područja pružili su smjernice najbolje prakse o tome kako treba upravljati podacima.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem

Stup 2: Tehnologija - 13 pitanja
Zašto je ovo važno? Nekada su poljoprivrednici ovisili samo o svojoj intuiciji i iskustvu, ali danas imamo mnogo digitalnih alata koji mogu poboljšati donošenje odluka. Od kvalitete internetske veze do automatizacije poslovnih procesa, tehnologija igra ključnu ulogu u modernoj poljoprivredi.
Komunikacijska infrastruktura Zamislite da imate sustav za praćenje rada traktora putem mobilne aplikacije, ali signal vam je toliko loš da podaci stižu s kašnjenjem ili uopće ne dolaze. Dobra komunikacijska infrastruktura ključna je za povezivanje svih digitalnih alata na gospodarstvu. Ako nemate dobar signal ili stabilan internet, čak i najbolje tehnologije postaju beskorisne.

Komunikacijska infrastruktura	Pitanja za procjenu	Skala odgovora
P2- 1	Dobro razumijemo trenutne i nove komunikacijske opcije koje su nam dostupne u poslovanju (npr. LoRaWAN, 5G, satelit, WI-FI…).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P2-2	Naša trenutna komunikacijska infrastruktura u potpunosti zadovoljava naše potrebe u pogledu pokrivenosti i pouzdanosti - danas i u doglednoj budućnosti.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P2-3	Naša trenutna komunikacijska infrastruktura ima kapacitet za rukovanje količinom podataka koji su nam potrebni (npr. slanje podataka u oblak ili preuzimanje podataka iz oblaka).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P2-4	Naše poduzeće aktivno je u potrazi za razumijevanjem i prilikama za poboljšanjem naše komunikacijske infrastrukture (npr. 5G, LoRaWAN, satelit).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
Tehnologija u poslovanju Pokušajte se sjetiti koliko ste puta ručno vodili evidenciju o troškovima, prinosima i korištenju resursa. Danas postoje softveri koji vam to mogu automatski izračunati, uštedjeti vrijeme i smanjiti greške. Na primjer, senzori u tlu mogu vam reći kada treba zaliti usjeve, a sustavi za preciznu sjetvu omogućuju vam optimalno korištenje sjemena.		
Tehnologija u poslovanju		
P2-5	Koliko je približno operacija vašeg poduzeća automatizirano (npr. sustavi fakturiranja i plaćanja, proizvodne operacije, logistika)?	1=nijedna operacija nije automatizirana; 3=nešto; 5=sve operacije su automatizirane
P2-6	Razmišljajući o digitalnim tehnologijama u vašem poslovanju, koliko ih je jednostavno koristiti?	1=nijedna od tehnologija nije jednostavna za korištenje; 3=neke tehnologije jesu; 5=sve su tehnologije jednostavne za korištenje
P2-7	Kako biste ocijenili u kojoj se mjeri digitalne tehnologije koriste u vašem poslovanju?	1=jedva korišten (korištene samo osnovne funkcije); 3= umjereno iskorišten (korištene su neke funkcije); 5=potpuno iskorišteno (sve funkcije korištene)
P2-8	Kako biste ocijenili tehničku podršku koju vaše poduzeće dobiva od pružatelja tehnologija i usluga?	1=vrlo loše; 3=zadovoljavajuće; 5=izvrsno
Pozicija na tehnološkom tržištu Zamislite da ste u situaciji da trebate kupiti novi stroj, ali na tržištu postoji na desetke opcija – kako odabrati pravu opciju? Poljoprivrednici često imaju problem s odabirom tehnologije jer im nedostaju informacije o isplativosti, integraciji s postojećim sustavima i dugoročnoj koristi.		
Pozicija na tehnološkom tržištu		
P2-9	Kada razmišljamo o kupnji novih digitalnih tehnologija, teško nam je odrediti potencijalni povrat ulaganja.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem (potrebno obrnuto kodiranje)

P2-10	Dobro poznajemo opcije digitalne tehnologije koje su trenutno na tržištu (npr. dronovi, senzori, roboti i aplikacije).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P2-11	Većina digitalnih tehnologija na tržištu može se lako integrirati s onim što trenutno imamo.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P2-12	Teško je pronaći nove digitalne tehnologije koje bi zadovoljile potrebe našeg poslovanja.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem (potrebno obrnuto kodiranje)
P2-13	Teško je odabrati koju digitalnu tehnologiju kupiti jer postoji previše opcija.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem (potrebno obrnuto kodiranje)

Stup 3: Podaci i analitika - 16 pitanja

Zašto je ovo važno?

Podaci su temelj svake uspješne odluke u digitalnoj poljoprivredi. Zamislite da imate polje pšenice i želite znati koliko gnojiva trebate koristiti. Ako se oslonite samo na iskustvo i intuiciju, postoji šansa da će utrošak gnojiva biti prevelik ili premali. No, ako koristite podatke iz odgovarajućeg senzora, možete točno znati kada i koliko gnojiva treba koristiti. Podaci vam pomažu da bolje iskoristite resurse i povećate prinos.

Podaci

Naše gospodarstvo generira gomilu podataka – od vremenskih uvjeta, stanja tla, prinosa, korištenja gnojiva i još mnogo toga. Ali, postavlja se pitanje – što radimo s tim podacima? Ako ih zapisujemo na papir ili ih ne koristimo, oni nam ne pomažu. Ključno je skupljati podatke na organiziran način i koristiti ih za bolje donošenje odluka. Na primjer, poljoprivrednici koji prate podatke iz satelita i dronova mogu ranije primijetiti probleme s usjevima i pravovremeno reagirati.

Podaci	**Pitanja za procjenu**	**Skala odgovora**
P3-1	Naše poduzeće prikuplja sve podatke koji su nam potrebni za donošenje najboljih mogućih poslovnih odluka (uključujući interne podatke iz senzora i strojeva; vanjske podatke iz drugih poduzeća i drugih izvora kao što su primjerice sateliti).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P3-2	Koliko prikupljenih podataka se elektronički pohranjuje?	1=jedva išta od podataka; 3=neki od podataka; 5=svi podaci
P3-3	Koliko je vaših podataka pohranjeno u oblaku i dostupno za pristup vama i drugim poduzećima (kao što su vaši pružatelji usluga)?	1=ni jedan podatak; 3=neki od podataka; 5=svi podaci
P3-4	Koliko je podataka prikupljenih u vašem poduzeću visoke kvalitete i za koje se može lako koristiti donošenje odluka?	1=jedva išta od podataka; 3=neki od podataka; 5=svi podaci
P3- 5	Koliko se podataka prikupljenih u vašem poduzeću koristi za donošenje odluka?	1=jedva išta od podataka; 3=neki od podataka; 5=svi podaci

P3- 6	Kontinuirano preispitujemo kako koristimo podatke i koje su naše buduće potrebe za podacima, a koji su korisni za poboljšanje poduzeća.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P3- 7	U našem poduzeću podaci su visoko cijenjeni pri donošenju odluka.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
Analitika Prikupljanje podataka nije dovoljno – važno ih je znati analizirati. Recimo da imate podatke o temperaturi i vlažnosti tla tijekom godine. Ako ih ne usporedite s prinosima, ne možete vidjeti povezanost između vremenskih uvjeta i uspjeha vaših kultura. Digitalni alati mogu automatski analizirati podatke i davati preporuke – na primjer, kada primijeniti gnojivo ili kada očekivati bolesti biljaka.		
Analitika		
P3-8	Prilikom donošenja odluka integriramo podatke iz više izvora kako bismo dobili visokokvalitetne uvide (npr. podaci iz našeg poduzeća, drugih poduzeća i/ili poduzeća u javnoj domeni).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P3-9	Naše poduzeće koristi alate za podršku odlučivanju ili sustave za donošenje odluka (npr. kartiranje zemljišta, proračunski alati za hranidbu životinja, planiranje resursa poduzeća i slično).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P3-10	Naše poduzeće koristi alate koji pružaju predviđanja o tome što bi se moglo dogoditi u budućnosti kao pomoć našem donošenju odluka (npr. alati za predviđanje vremenskih prilika, alati za predviđanje prinosa i slično).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P3-11	Razmišljajući o skupovima podataka koje prikuplja vaše poduzeće, koliko se lako oni mogu kombinirati za analizu?	1=nije nimalo lako; 3=donekle lako; 5=vrlo lako
P3-12	Relevantni dionici mog područja (npr. udruge, konzultanti, državni odjeli, savjetnici) uspostavili su digitalne sustave koji podržavaju upravljanje velikim skupovima podataka kojima upravlja naše poduzeće.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
Interoperabilnost Jeste li se ikada našli u situaciji da koristite više digitalnih alata, ali oni međusobno ne „razgovaraju“? Na primjer, imate aplikaciju za vremensku prognozu i sustav za navodnjavanje, ali ih ne možete povezati. To je problem interoperabilnosti – sposobnosti različitih sustava da međusobno razmjenjuju podatke. Idealno bi bilo da svi vaši digitalni alati rade zajedno, omogućujući vam jednostavno upravljanje svim informacijama na jednom mjestu.		
Interoperabilnost		
P3-13	Digitalno komuniciramo s drugim tvrtkama pomoću platformi za integraciju sustava kao što su usluge temeljene na oblaku.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P3-14	Kada druga poduzeća (npr. savjetnici, trgovci na malo/veliko, tvrtke za preradu) od vaše tvrtke traže elektroničke podatke, koliko često se podaci traže u formatu različitom od vaše poslovne evidencije?	1=cijelo vrijeme (traže ga u različitim formatima); 3=neko vrijeme; 5=nikad (traže u istom formatu)

P3-15	Kada vaše poduzeće prima elektroničke podatke od drugih poduzeća (npr. savjetnika, trgovaca na malo/veliko, prerađivača), koliko često su podaci u različitom formatu od vaše poslovne evidencije?	1=cijelo vrijeme (u drugom je formatu); 3=neko vrijeme; 5=nikad (u istom je formatu)
P3-16	Kada primate podatke od drugih poduzeća, u kojoj su mjeri podaci točni i dosljedni tijekom vremena?	1=nikada; 3=neko vrijeme; 5=cijelo vrijeme

Stup 4: Sposobnost - 9 pitanja

Zašto je ovo važno?

Možete imati najbolju tehnologiju na svijetu, ali ako vi i vaši zaposlenici ne znate kako je koristiti, ona vam neće donijeti nikakvu korist. Ključ uspjeha digitalne poljoprivrede nije samo u alatima, već i u znanju kako ih primijeniti.

Digitalna pismenost

Zamislite da ste kupili novi sustav za preciznu gnojidbu, ali ne znate ga postaviti ili očitati podatke. Mnogi poljoprivrednici izbjegavaju nove tehnologije jer im nedostaje edukacija. Digitalna pismenost znači razumjeti osnovne funkcije tehnologije – od aplikacija na mobitelu do složenih softverskih rješenja.

Pristup stručnjacima i edukacija

Poljoprivrednici ne moraju biti IT stručnjaci, ali je važno znati kome se obratiti kada trebaju pomoć. Postoje razne edukacije, radionice i savjetodavne službe koje mogu pomoći u korištenju digitalnih alata. Što češće koristite tehnologiju i učite o njoj, to će vam postati jednostavnija i korisnija.

Rješavanje problema

Svi se ponekad suočimo s tehničkim problemima – sustav za navodnjavanje ne radi, podaci iz drona nisu dostupni ili aplikacija ne očitava pravilno podatke. Važno je imati osnovno znanje kako riješiti manje probleme, ali i znati kome se obratiti kada nešto ne možete riješiti sami.

Sposobnost	**Pitanja za procjenu**	**Skala odgovora**
P4-1	Dobro razumijemo trenutne i nove digitalne tehnologije relevantne za naše poslovanje.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P4-2	Znamo gdje potražiti stručnu pomoć za pitanja vezana uz digitalne tehnologije.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P4-3	Znamo gdje potražiti stručnu pomoć o tome kako koristiti podatke za donošenje odluka.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P4-4	Imamo osoblje koje je sposobno upravljati digitalnim tehnologijama (uključujući digitalne uređaje, aplikacije i strojeve) koji se koriste u našem poduzeću.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P4- 5	Imamo osoblje koje je sposobno integrirati, analizirati i interpretirati podatke za informirano donošenje odluka.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P4- 6	Imamo osoblje koje je sposobno komunicirati i surađivati s drugim stranama o pitanjima koja se tiču digitalnih tehnologija.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem

P4- 7	Imamo osoblje koje je sposobno riješiti probleme koji se ponekad pojave pri korištenju digitalnih tehnologija.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P4- 8	Imamo osoblje koje je sposobno održavati i pohranjivati podatke u sigurno dostupnom obliku, kao što je oblak.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P4- 9	Koliko često osoblje sudjeluje u tečajevima osposobljavanja (npr. proširenja) i/ili radionicama o tome kako koristiti digitalne tehnologije i podatke za donošenje odluka?	1=rijetko ikada; 3=ponekad; 5=uvijek kad se ukaže prilika

Stup 5: Pravila podataka - 3 pitanja

Zašto je ovo važno?

Podaci su vrijedna imovina svakog poljoprivrednika. No, ako nisu zaštićeni ili se koriste na pogrešan način, mogu postati problem. Zamislite da imate vrijedne informacije o stanju tla i prinosima, ali ih netko drugi koristi bez vašeg dopuštenja. Pravila upravljanja podacima pomažu u zaštiti vaših informacija i osiguravaju da ih koristite na ispravan način.

Sigurnost podataka

Imate li sigurnosne kopije svojih podataka? Čuvate li ih na način da ih ne možete izgubiti? Mnogi poljoprivrednici bilježe važne podatke samo na papiru, ali u slučaju gubitka takvih zapisa, sve informacije nestaju. Digitalna sigurnost znači pohranjivanje podataka na sigurnim mjestima, korištenje jakih lozinki i zaštita od neželjenog pristupa.

Privatnost i dijeljenje podataka

Poljoprivrednici često razmjenjuju podatke s pružateljima usluga, institucijama ili drugim gospodarstvima. No, postavlja se pitanje – tko smije imati pristup tim podacima i kako se oni koriste? Primjerice, ako koristite digitalnu platformu za analizu tla, važno je znati jesu li vaši podaci zaštićeni i hoće li ih netko drugi koristiti u marketinške svrhe bez vašeg dopuštenja.

Jasna pravila o podacima

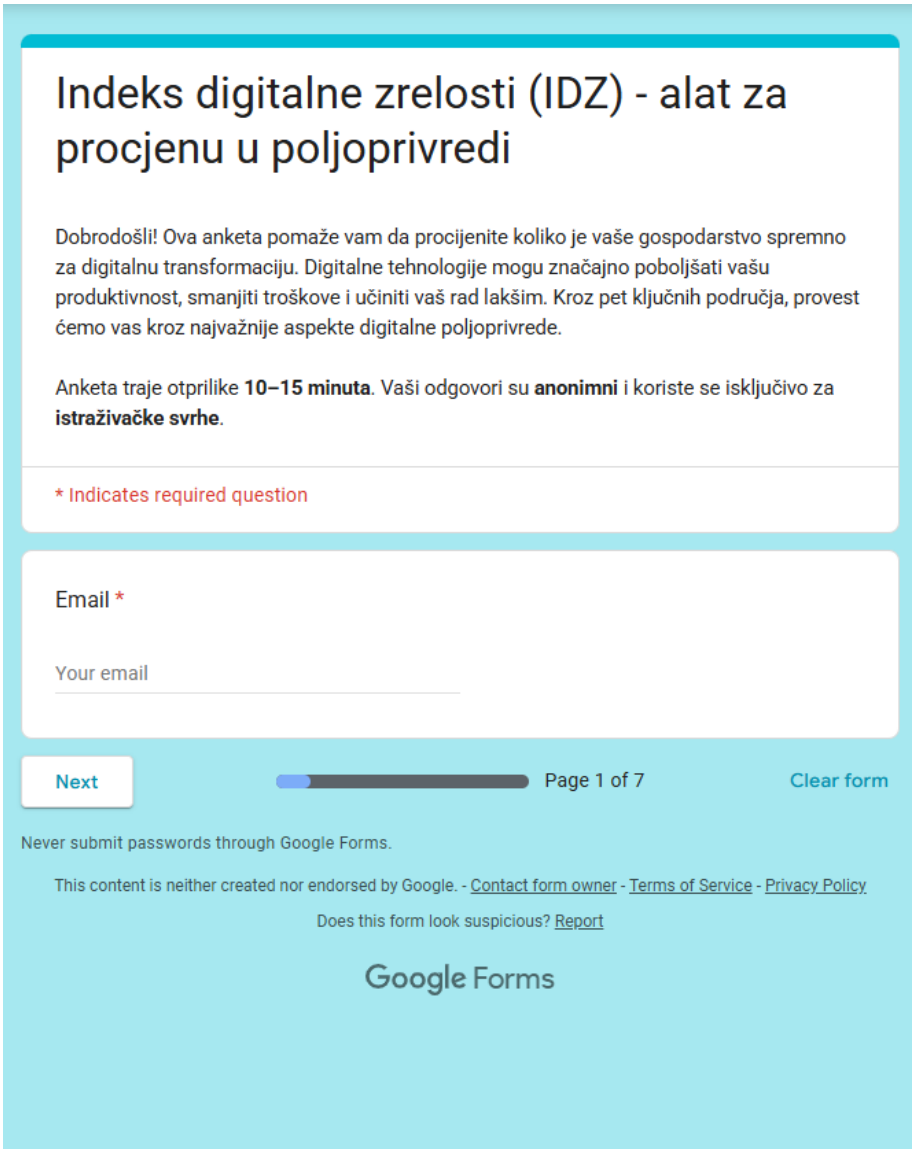
Važno je imati jasne smjernice o tome tko unutar vašeg gospodarstva smije pristupati podacima i kako se oni koriste. Na primjer, tko može pregledavati financijske izvještaje ili planove navodnjavanja? Postavljanjem jasnih pravila osiguravate kontrolu nad informacijama i sprječavate moguće zlouporabe.

Pravila podataka	**Pitanja za procjenu**	**Skala odgovora**
P5-1	Naše poduzeće ima određeno osoblje odgovorno za upravljanje podacima.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P5-2	Naše poduzeće ima uspostavljene sustave za upravljanje podacima kako bi se osigurala sigurnost i privatnost podataka (npr. elektroničko prikupljanje, pohrana i dijeljenje podataka, sigurnosno kopiranje podataka, korištenje jakih lozinki).	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem
P5-3	Pri razmjeni podataka s drugim stranama postoje sporazumi o tome kako bi se podaci trebali upotrebljavati.	1=uopće se ne slažem; 3=niti se slažem niti ne slažem; 5=u potpunosti se slažem

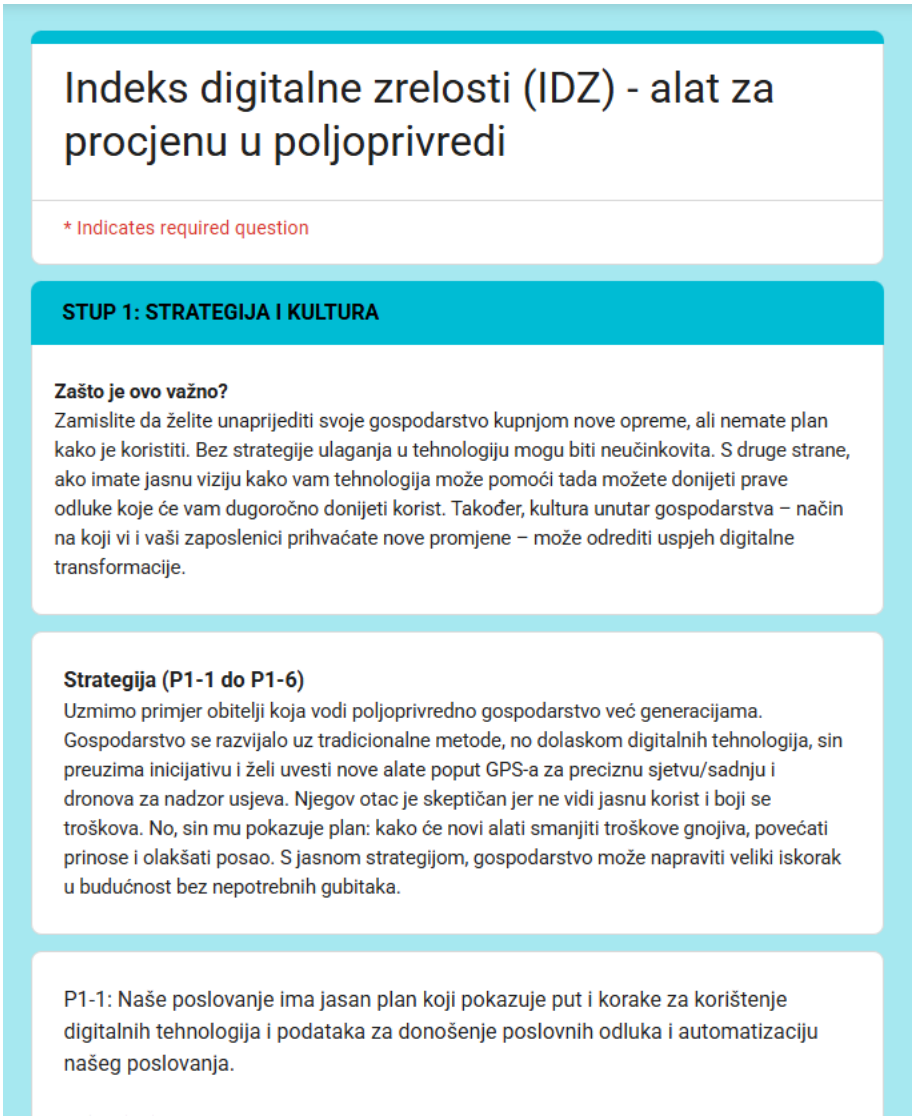
Demografija	Pitanja za procjenu	Skala odgovora
Ova posljednja pitanja koristit će se za opisivanje šireg uzorka poljoprivrednog poduzeća koji koriste ovaj alat za procjenu spremnosti na digitalnu transformaciju. Vaši pojedinačni odgovori bit će privatni i povjerljivi.		
Poslovna funkcija	Koja je vaša glavna djelatnost? (odaberite sve što je primjenjivo i/ili po potrebi dopišite ono što nije navedeno)	Poljoprivredne zalihe (npr. sjeme, gnojivo, pesticidi…) Konzultanti za poljoprivredu (npr. agronomi, veterinari i drugi stručnjaci…) Pružatelji tehnologije i usluga (npr. komunikacije, strojevi, senzori, digitalna tehnologija…) Poljoprivredna proizvodnja (npr. OPG, PG, obrt…) Skladištenje i rukovanje (npr. logistika nabave i opskrbe…) Prerada i proizvodnja (npr. prerada mesa; mlin; pakirnica…) Pakiranje i distribucija (npr. uvoz, izvoz i veleprodaja; upravljanje maloprodajom…) Transport i logistika (npr. upravljanje transportom i otpremom; upravljanje opskrbom, distribucijom i nabavom…) Korporativne usluge (npr. financijsko upravljanje; stručnjaci za oglašavanje i marketing…)
Sektor industrije	Koji je glavni sektor vašeg poslovanja? (odaberite sve što je primjenjivo i/ili po potrebi dopišite ono što nije navedeno)	Akvakultura (uključujući ribarstvo), Mesna goveda, Mliječna goveda, Ovčje meso, Ovčja vuna, Svinjetina, Povrće, Voće i orašasti plodovi, Rasadnička proizvodnja, Grožđe i vino, Mljekara, Perad (meso ili jaja) Ratarstvo
Veličina poduzeća	Koliko je djelatnika zaposleno u vašem poduzeću? (uključujući i sebe)	1-5, 6-10. 11-15. 16-20. 21-30. preko 30
Poslovni prihodi	Koliki je godišnji bruto prihod vašeg poduzeća?	0-100 tisuća EUR 100-200 tisuća EUR 200.000 – 500.000 EUR 500 tisuća do 1 milijun EUR 1 do 10 milijuna EUR Više od 10 milijuna EUR
Dob	Koliko imate godina?	_____
Spol	Kojeg ste spola?	Muško Žensko

		Radije ne bih rekao/rekla
Obrazovanje	Koji je vaš najviši stupanj obrazovanja?	Osnovna škola Srednja strukovna škola – poljoprivreda Srednja strukovna škola - ostalo Gimnazija Viša stručna sprema - poljoprivreda Viša stručna sprema - ostalo Preddiplomski studij - poljoprivreda Preddiplomski studij - ostalo Diplomski studij - poljoprivreda Diplomski studij - ostalo Poslijediplomski studij - poljoprivreda Poslijediplomski studij - ostalo
Poštanski broj	Koji je poštanski broj vašeg poduzeća?	_____

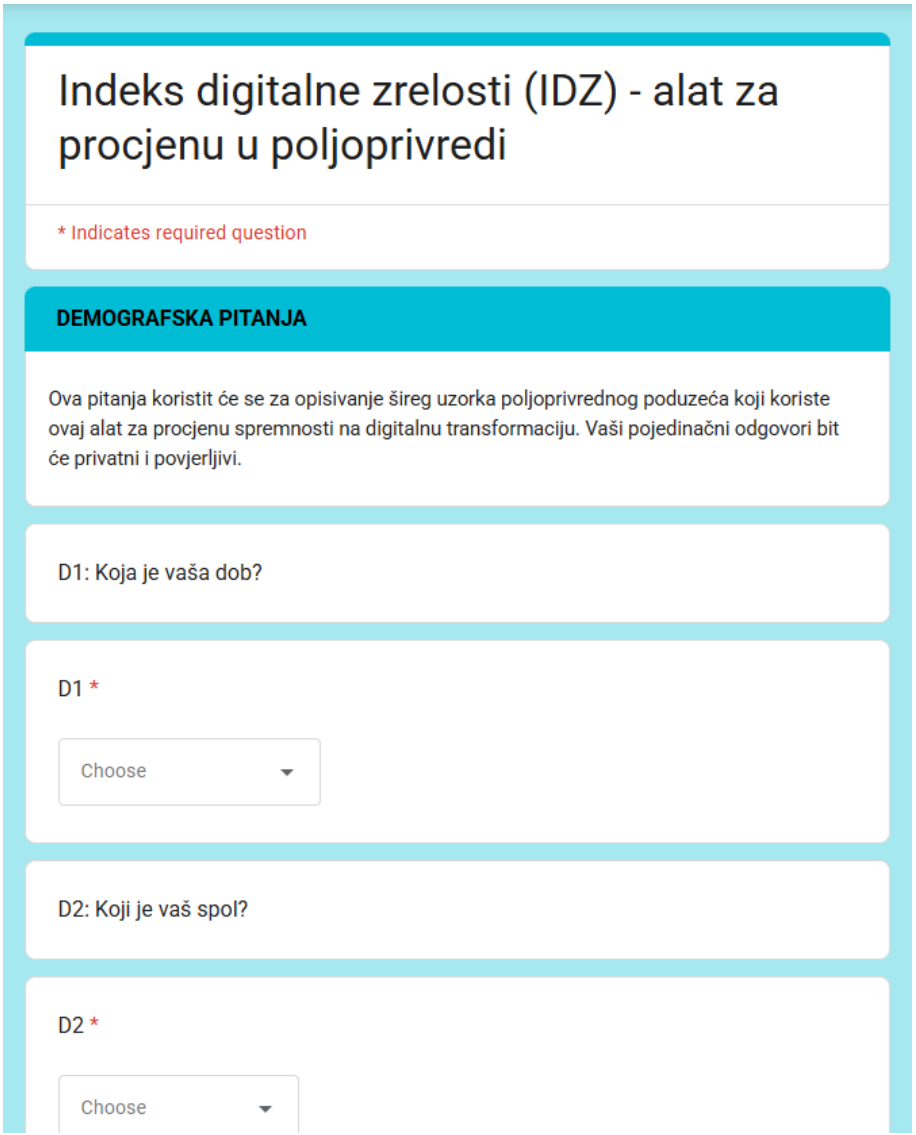
Dodatak B: Prikaz sučelja digitalnog upitnika (Google Forms)



Slika B.1. Naslovnica upitnika



Slika B.2. Prikaz pitanja iz Stupa 1 (Strategija i kultura)



Slika B.3. Prikaz demografskih pitanja

Dodatak C:

KRATICE

ADOPT model - (Adoption and Diffusion Outcome Prediction Tool / Alat za predviđanje ishoda usvajanja i širenja – ADOPT) kvantitativni je model temeljen na webu koji je razvio CSIRO radi predviđanja stope, vršne razine i vremenskog okvira usvajanja poljoprivrednih inovacija.

AI - kratica koja najčešće označava umjetnu inteligenciju (engl. Artificial Intelligence / AI).

AKIS Strateškim planom Zajedničke poljoprivredne politike Republike Hrvatske 2023. – 2027. predviđena je izgradnja sustava prijenosa znanja i inovacija u poljoprivredi (engl. Agricultural Knowledge and Innovation System – AKIS) u Republici Hrvatskoj.

ANOVA - Analiza varijance (ANOVA) je statistička metoda koja se koristi za usporedbu aritmetičkih sredina triju ili više različitih skupina kako bi se utvrdilo postoje li među njima statistički značajne razlike.

APPRRR - Agencija za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju

ATU – U kontekstu modela prihvaćanja tehnologije (napose TAM - Technology Acceptance Model), Stav prema korištenju (engl. Attitude Toward Using, A) predstavlja korisnikovu pozitivnu ili negativnu procjenu i osjećaj prema implementaciji i svakodnevnom korištenju određene tehnologije ili sustava.

CSIRO Commonwealth Scientific and Industrial Research Organisation (CSIRO), nacionalno državno tijelo za znanstveno istraživanje u Australiji

DESI (Digital Economy and Society Index) Godišnji ukupni rezultati Indeksa gospodarstva i društva digitalnog okruženja (DESI) za države članice Europske unije (npr. od 2017. do 2022.), (ponderirani indeks od 0 do 100)

DT - Digitalna transformacija (DT) je usvajanje digitalne tehnologije za transformiranje usluga ili poduzeća, zamjenom nedigitalnih ili ručnih procesa digitalnim procesima ili zamjenom starijih digitalnih tehnologija novijim digitalnim tehnologijama.

DZ (digitalna zrelost), prikazuje se kao sustavni i trajni proces prilagodbe promjenjivom digitalnom okruženju, te kao naučena sposobnost kako se organizacije sustavno pripremaju za dosljednu prilagodbu tekućim digitalnim promjenama, što daleko nadilazi puku implementaciju nove tehnologije.

GDPR Opća uredba o zaštiti podataka (General Data Protection Regulation-GDPR)

GNSS, označava Globalni navigacijski satelitski sustav (eng. Global Navigation Satellite System).To je općeniti, zajednički naziv za sve satelitske sustave koji omogućuju korisnicima na Zemlji određivanje njihovog točnog zemljopisnog položaja (koordinata), brzine i vremena.

Globalni indeks digitalne zrelosti (Globalni_DRI) - Globalni indeks digitalne zrelosti ili spremnosti (Global Digital Readiness Index - DRI) krovni je pojam za nekoliko međunarodnih metričkih sustava koji procjenjuju sposobnost država ili organizacija da usvoje, primijene i iskoriste prednosti digitalnih inovacija.

HCT - Teorija ljudskog kapitala (eng. Human Capital Theory). Teorija ljudskog kapitala (Human Capital Theory - HCT) je ekonomska teorija koja promatra znanje, vještine, kompetencije i zdravlje radnika kao oblik kapitala u koji se može investirati, slično kao u fizičku imovinu poput strojeva ili tvornica.Ključna postavka teorije je da investiranje u ljude (ponajviše kroz obrazovanje i trening) izravno povećava njihovu produktivnost, što posljedično dovodi do većih prihoda za pojedinca i bržeg gospodarskog rasta za društvo.

HPA - Hrvatska agencija za poljoprivredu i hranu

Hrvatska poljoprivredna savjetodavna služba (HPSS)

IDZ – indeks digitalne zrelosti - sustavne procjene razine digitalnog napretka – bilo na razini države i društva, bilo na razini pojedinačnih organizacija

IT/ICT- i ICT (informacijsko-komunikacijska tehnologija / IKT) bliski su pojmovi koji se često koriste kao zamjena, ali imaju važne razlike u opsegu i primjeni.

IoT IoT ili internet stvari je mreža povezanih fizičkih uređaja (stvari ili things) čija je svrha razmjenjivati podatke s ostalim uređajima koji imaju pristup internetu. U uređaje su ugrađene softverske tehnologije čiji je cilj povezivanje s ostalim uređajima unutar mreže bez ljudske pomoći.

K-means clustering - metoda K-srednjih vrijednosti jedna je od najpopularnijih metoda strojnog učenja za grupiranje podataka (klasterizaciju) na temelju kontinuiranih varijabli. Cilj ove metode je podijeliti skup podataka u \(K\) unaprijed definiranih, nepreklapajućih grupa (klastera), pri čemu je svaki objekt dodijeljen grupi s čijim centrom (središnjom vrijednošću) ima najveću sličnost.

Kaiser-Meyer-Olkin (KMO) mjera prikladnosti uzorkovanja je statistički pokazatelj koji se koristi prije provođenja analize čimbenika ili analize glavnih komponenti (PCA).

MANOVA - Višestruka analiza varijance (MANOVA) je statistička metoda koja se koristi za testiranje razlika između grupa kada imate dvije ili više zavisnih kontinuiranih varijabli istovremeno.

MPŠR - Ministarstvo poljoprivrede, šumarstva i ribarstva

NUTS regije - Republika Hrvatska je prema NUTS klasifikaciji (Nomenklatura prostornih jedinica za statistiku) podijeljena na četiri statističke regije 2. razine (NUTS 2), koje služe za potrebe regionalne statistike i povlačenje sredstava iz fondova Europske unije. Detaljne

informacije potražite na stranici Državnog zavoda za statistiku

OECD - Organizacija za gospodarsku suradnju i razvoj (Organisation for Economic Co-operation and Development) forum je i središte znanja za podatke, analize i najbolje prakse u području javnih politika. Surađujemo s više od 100 zemalja diljem svijeta na izgradnji snažnijih, pravednijih i čišćih društava, pomažući u oblikovanju boljih politika za bolji život.

OPG obiteljska poljoprivredna gospodarstva - Obiteljsko poljoprivredno gospodarstvo (skraćeno OPG) je fizička osoba ili skupina fizičkih osoba članova zajedničkog kućanstva, koje obavljaju poljoprivrednu djelatnost na poljoprivrednom gospodarstvu koristeći se vlastitim ili unajmljenim proizvodnim jedinicama.

PCA - Analiza glavnih komponenti (PCA) ključna je statistička metoda za validaciju konstrukata i strukture upitnika koji mjere digitalnu zrelost organizacija. Digitalna zrelost je višedimenzionalni pojam (obuhvaća kulturu, tehnologiju, procese, strategiju), a PCA pomaže utvrditi odražavaju li prikupljeni podaci doista te teoretske dimenzije.

PEU Percipirana lakoća korištenja (engl. Perceived Ease of Use, PEU) jedan je od ključnih koncepata u modelima prihvaćanja tehnologije, primarno u Modelu prihvaćanja tehnologije (TAM) kojeg je 1989. godine razvio Fred Davis. Definira se kao stupanj do kojeg osoba vjeruje da će korištenje određenog sustava ili tehnologije biti bez napora (fizičkog ili mentalnog).

Percipirana korisnost (engl. Perceived Usefulness - PU) jedan je od temeljna dva faktora u Modelu prihvaćanja tehnologije (engl. Technology Acceptance Model - TAM), kojeg je razvio Fred Davis 1989. godine.Definira se kao stupanj do kojeg osoba vjeruje da će korištenje određenog sustava ili tehnologije poboljšati njezin učinak na poslu ili u svakodnevnim aktivnostima.

RBV - Pristup utemeljen na resursima (eng. Resource-Based View – RBV) je strateški okvir koji tvrdi da konkurentska prednost poduzeća proizlazi iz njegovih unutarnjih resursa i sposobnosti, a ne prvenstveno iz pozicioniranja na tržištu. U kontekstu digitalne transformacije, RBV služi kao ključni model za razumijevanje kako tehnologija, podaci i digitalne vještine stvaraju dugoročnu vrijednost.

RDC (Rural Research and Development Corporations) - Korporacije za ruralna istraživanja i razvoj (RDC) su zajednička partnerstva industrije i vlade u Australiji koja financiraju i usmjeravaju istraživanja, inovacije i proširenje u primarnoj industriji.

SD (standardna devijacija), je statistička mjera koja pokazuje koliko se vrijednosti u nekom skupu podataka u prosjeku razlikuju (odstupaju) od njihove srednje vrijednosti (prosjeka).

SME - Poljoprivredni MSP-ovi (mali i srednji poduzetnici), u koje spadaju i obiteljska poljoprivredna gospodarstva (OPG), obrti, mikro i mala poduzeća, čine temelj hrvatskog i

europskog agrarnog sektora. Oni potiču lokalnu ekonomiju, osiguravaju samodostatnost hrane i čuvaju ruralna područja od iseljavanja.

SP ZPP - Strateški plan Zajedničke poljoprivredne politike 2023.-2027.

Strateškim planovima u okviru Zajedničke poljoprivredne politike (ZPP) podupire se prelazak na pametan, održiv, konkurentan, otporan i diversificiran poljoprivredni sektor, čime se osigurava dugoročna sigurnost opskrbe hranom. Ti planovi ujedno pridonose djelovanju u području klime, zaštiti prirodnih resursa i očuvanju/povećanju bioraznolikosti te jačanju socioekonomske strukture ruralnih područja. Njima se podupiru brojne intervencije usmjerene na posebne potrebe država članica i njihovih regija. Osmišljeni su u skladu s novim pristupom usmjerenim na rezultate i uspješnost u cilju ostvarenja konkretnih rezultata u odnosu na posebne ciljeve ZPP-a na razini EU-a, ali i doprinos europskom zelenom planu. U planovima u okviru ZPP-a prvi se put definira strategija koja obuhvaća sve glavne instrumente koji se financiraju iz ZPP-a: izravna plaćanja, potporu za ruralni razvoj i intervencije specifične za određene tržišne sektore.

TAM - Model prihvaćanja tehnologije (eng. Technology Acceptance Model). Model prihvaćanja tehnologije (eng. Technology Acceptance Model – TAM) jedna je od najpoznatijih i najutjecajnijih teorija u informacijskim znanostima koja objašnjava kako korisnici prihvaćaju i počinju koristiti novu tehnologiju. Model su 1989. godine razvili Fred Davis i suradnici.

TFP (TFP - Total Factor Productivity) Ukupna faktorska produktivnost ekonomski je pokazatelj koji mjeri učinkovitost s kojom se svi proizvodni faktori (prvenstveno rad i kapital) pretvaraju u konačne proizvode ili usluge. Za razliku od parcijalne produktivnosti (poput produktivnosti rada koja mjeri samo učinak po radniku), TFP obuhvaća kombinirani utjecaj svih resursa.

VIF statistike (Variance Inflation Factor) odnosno faktor inflacije varijance, mjera je koja se koristi u regresijskoj analizi za otkrivanje multikolinearnosti. Multikolinearnost se javlja kada su dvije ili više nezavisnih varijabli u modelu snažno međusobno povezane, što otežava procjenu stvarnog utjecaja svake pojedine varijable na zavisnu varijablu.

Dodatak D1:

ŽIVOTOPIS

Darko Lugonja rođen je u Osijeku 1967. godine. Osnovnu i srednju školu završio je u Zagrebu. U veljači 1990. godine diplomira s temom o transferu tehnologija i znanja u području međunarodnih ekonomskih odnosa na Fakultetu političkih znanosti Sveučilišta u Zagrebu. Potom završava izobrazbu za računalnog operatera i programera na Zavodu za primjenu računala u Zagrebu.

Interes za istraživanjem i edukacijom u području informatike, organizacije i razvoja poslovanja potiče ga na poslijediplomski magistarski studij na Ekonomskom fakultetu Sveučilišta u Zagrebu, a 1994. završava međunarodni poslijediplomski studij poslovnog upravljanja i magisterij po MBA programu. Uz magisterij te rad na međunarodnim i EU projektima (PHARE, IPA, HORIZON, TAIEX), završava tečajeve iz područja EU institucija, javne uprave, proračunskog planiranja, te ECDL. Tijekom karijere razvija interes za istraživanja organizacije, tehnologije, znanja, digitalne transformacije. Karijeru započinje u privatnom sektoru, uz angažmane u javnom sektoru i prosvjeti, te značajnije angažmane u tvrtkama poput VW i Audi koncerna, Shell-a, Sysprint-a, i II Ekonomskoj školi u Zagrebu.

Od travnja 2006. godine radi u Ministarstvu poljoprivrede, šumarstva i ribarstva, na implementaciji ISAMM sustava, projektima TAIEX i Twinning (PHARE, IPA, HORIZON, TAIEX). Od 2019. godine radi kao voditelj Odjela za mehanizaciju i primjenu inovativnih tehnologija u poljoprivredi. Član je više povjerenstava, stručnih tijela i radnih skupina pri EK i Ministarstvu, vodi radnu skupinu HORIZON 2020 FAIRShare projekta, u Ministarstvu i Upravi za stručnu podršku razvoju poljoprivrede.

U ožujku 2023. godine upisuje Poslijediplomski doktorski studij agroekonomike na Fakultetu agrobiotehničkih znanosti u Osijeku (FAZOS) sveučilišta „Josipa Jurja Strossmayera“ u Osijeku. Do kraja 2024. godine pohađao je i položio sve razlikovne i obvezne ispite i počeo s radom na pripremi teme i teze svog doktorskog rada. U veljači 2025. brani temu doktorskog rada pod nazivom „Evaluacija digitalne zrelosti i planiranje digitalne transformacije poljoprivrednih gospodarstva u Republici Hrvatskoj“, a u ožujku i travnju 2026. godine provodi istraživanje koje potvrđuje i hipoteze i ciljeve istraživanja.

Tijekom karijere i znanstvenog usavršavanja, sudjelovao je na nizu znanstvenih i stručnih konferencija, te objavio više znanstvenih i stručnih radova:

1. Lugonja, D., Sudarić, T., Plaščak, I., Fruk, M., Puhelek Puština, N. i Zbukvić Spahić, I. (2026). Ostvarivanje digitalne transformacije poljoprivrede kroz sustav prijenosa znanja i povezanost s primjenom informacijsko-komunikacijskih tehnologija – izazovi i prilike. Agroeconomia Croatica, 16 (1.), 86-98., dostupno na:

https://hrcak.srce.hr/349864

2. Lugonja, D. i Zbukvić Spahić, I. (2026.), Pametna poljoprivreda kao odgovor na klimatske izazove i nedostatak radne snage, Gospodarski list, 14. svibnja 2026, dostupno na https://gospodarski.hr/rubrike/nove-tehnologije/inovacije-kroz-digitalizaciju-u-poljoprivredi/
3. Lugonja, D., (2025.), panelist na okruglom stolu, na temu „Znanje i inovacije kao pokretač“ na prvoj konferenciji o investicijama i inovacijama u poljoprivredi – KIIP Agrow, 24. rujna 2025., Terme Tuhelj, Hrvatska, dostupno na https://nrm.hr/aktivnosti/kiipgrow-konferencija-o-investicijama-i-inovacijama-u-poljoprivredi/
4. Lugonja, D. (2025.), Predstavljanje teme i istraživanja doktorskog rada na „Danu doktorata, Evaluacija digitalne zrelosti i planiranje digitalne transformacije poljoprivrednih gospodarstva u Republici Hrvatskoj (Digital maturity evaluation and digital transformation planning for the agricultural holdings in the Republic of Croatia dostupno na: https://www.fazos.unios.hr/storage/Dokumenti/Dan%20doktorata/DD25_%20Zbornik%20sa%C5%BEetaka.pdf
5. Lugonja, D.; Fruk, M.; Sudarić, T.; Plaščak, I.; Jurišić, M.; Radočaj, D. (2024.), Measuring the digital transformation maturity in agriculture, The ISDTA and DIGITAGRA 2024 Conference, FAZOS, Osijek, dostupno na: https://ict-agriculture.com/wp-content/uploads/2025/07/Book-of-Abstracts-2nd-ISDTA.pdf
6. Lugonja, D.; Fruk, M.; Sudarić, T.; Plaščak, I.; Jurišić, M.; Radočaj, D. (2024.), poster „Assessing digital transformation maturity for implementing digitalization in agriculture“, Transfer znanja i tehnologije, VI. međunarodni znanstveno-stručni skup, Inovacije i agrobiznis, Hrvatsko agroekonomsko društvo (HAED), dostupno na https://haed.hr/wp-content/uploads/2024/11/Inovacije_Program_2.pdf
7. Lugonja, D. (2023.) FAIRshare UC „Pitanja i odgovori“ poster, Fakultet agrobiotehničkih znanosti Osijek, znanstveno-stručni skup, Hrvatsko agroekonomsko društvo (HAED), „Inovacije i agrobiznis, 24.11.2023., Osijek, dostupno na: https://haed.hr/dogadanja/v-medunarodni-znanstveno-strucni-skup/
8. Lugonja, D. (2023.) FAIRshare UC „QandA“ – presentation, Thesalonikki (GR), dostupno na: https://www.h2020fairshare.eu/fairshare-final-conference/, https://www.h2020fairshare.eu/wp-content/uploads/2023/07/Draft_FAIRshare-Final-Conferenceprogramme2.pdf
9. Lugonja, D. (2023.) FAIRshare UC „QandA“ - MofA poster at 62. IALB – 12. EUFRAS

– 9. SEASN – Working Congress 2023 in Germany / Saxony / Dresden, 10th - 14th September 2023, dostupno na: https://www.ialb.sachsen.de/download/IALB-EUFRAS-SEASN_2023_Saxony-Program_100723.pdf

10. Lugonja, D., Jurišić, M., Plaščak, I., Radočaj, D., Glavica-Tominić, D., Zbukvić, I., Krušelj, I., (2022), Smart Agriculture Development and Its Contribution to the Sustainable Digital Transformation of the Agri-Food SectorTehnički glasnik, Vol. 16 No. 2, 2022., str. 264-267, Dostupno na: https://hrcak.srce.hr/clanak/400307
11. Lugonja, D., (2022.), Primjena novih tehnologija u poljoprivredi, panelist, konferencija „Agrotech 2022“, 20. – 21. listopad 2022, Sveti Martin na Muri, dostupno na: https://agrotech2022.listlabs.net/
12. Lugonja, D., Zbukvić, I., Glavica-Tominić, D., Krušelj, I., (2021), Kružna ekonomija i održivost - online poster, konferencija Inovacije i agrobiznis: Kružna ekonomija i održivost, dostupno na: https://haed.hr/znanstveni-skup/knjiga-sazetaka-iii-medunarodni-znanstveno-strucni-skup-inovacije-i-agrobiznis/
13. Lugonja, Darko (2020), Change Management as a Support to the Organizations' Digital Transformation - State of the Art, CECIIS - Central European Conference on Information and Intelligent Systems; Varazdin, (2020).Lugonja, Darko. Central European Conference on Information and Intelligent Systems; Varazdin, (2020)., dostupno na: https://www.proquest.com/openview/5f643ed3a7ed59fa3e2d7180d25288b0/1?pq-origsite=gscholar&cbl=1986354
14. Lugonja, D., (2020), Interoperability. A digital transformation to sustainable information society (eBook), 2020/3/4, GRIN Verlag, dostupno na: https://www.lehmanns.de/search/show-searchresults
15. Lugonja, D. (2019), The concepts of Inter-Institutional Interoperability and Open Innovation, GRIN Verlag, dostupno na: https://www.grin.com/document/507926
16. Škiljan, Z. Lugonja, D., Krušelj, I., (2019), Sinergija javne uprave i poljoprivredno-prehrambenog sektora kao uvjet uspješne digitalne transformacije, Akademija tehničkih znanosti Hrvatske (HATZ), dostupno na: https://www.hatz.hr/wp-content/uploads/2019/12/Darko-Lugonja_MPS.pdf

Dodatak D2:

BIOGRAPHY

Darko Lugonja was born in Osijek in 1967. He completed his primary and secondary education in Zagreb. In February 1990, he graduated from the Faculty of Political Science at the University of Zagreb with a thesis focusing on technology and knowledge transfer in the field of international economic relations. Subsequently, he completed training as a computer operator and programmer at the Institute for Computer Application in Zagreb.

His ambitions in research and education regarding information technology, organization, and business development led him to pursue postgraduate studies at the Faculty of Economics and Business, University of Zagreb; in 1994, he completed an MBA degree in the international postgraduate program in business management. In addition to his master's degree and work on international and EU projects (PHARE, IPA, HORIZON, TAIEX), he completed courses covering EU institutions, public administration, and budget planning, as well as the ECDL certification. Throughout his career, he has developed an interest in researching organizations, technology, knowledge, and digital transformation. He began his career in the private sector while also undertaking engagements in the public sector and education, working with notable organizations such as the VW and Audi groups, Shell, Sysprint, and the Second School of Economics in Zagreb.

Since April 2006, he has been employed in the Ministry of Agriculture, Forestry and Fisheries, on the implementation of the ISAMM system and EU projects (PHARE, IPA, HORIZON, TAIEX). Since 2019, he has been appointed to the position of Head of the Department for Mechanization and the Application of Innovative Technologies in Agriculture. He is a member of various commissions, expert bodies, and working groups within the European Commission and the Ministry, and leads the HORIZON 2020 FAIRShare project working group within the Ministry and the Directorate for Professional Support to Agricultural Development.

In March 2023, he enrolled in the postgraduate doctoral study program in Agricultural Economics at the Faculty of Agrobiotechnical Sciences Osijek (FAZOS), Josip Juraj Strossmayer University of Osijek. By the end of 2024, he had attended and passed all required bridging and mandatory exams and begun work on preparing the topic and thesis for his doctoral dissertation. In February 2025, he defended his doctoral thesis proposal titled "Evaluation of Digital Maturity and Planning of Digital Transformation of Agricultural Holdings in the Republic of Croatia," and in March and April 2026, he conducted research that confirmed both the hypotheses and the research objectives.

Throughout his career and professional development, he has participated in numerous scientific and professional conferences and published several scientific and professional papers:

1. Lugonja, D., Sudarić, T., Plaščak, I., Fruk, M., Puhelek Puština, N. i Zbukvić Spahić, I. (2026). Ostvarivanje digitalne transformacije poljoprivrede kroz sustav prijenosa znanja i povezanost s primjenom informacijsko-komunikacijskih tehnologija – izazovi i prilike. Agroeconomia Croatica, 16 (1.), 86-98. Available at https://hrcak.srce.hr/349864

2. Lugonja, D. i Zbukvić Spahić, I. (2026.), Pametna poljoprivreda kao odgovor na klimatske izazove i nedostatak radne snage, Gospodarski list, 14. svibnja 2026, Available at https://gospodarski.hr/rubrike/nove-tehnologije/inovacije-kroz-digitalizaciju-u-poljoprivredi/

3. Lugonja, D., (2025.), Panelist at the roundtable on the topic "Znanje i inovacije kao pokretač" at the first conference on investment and innovation in agriculture – KIIP Agrow, September 24, 2025, Terme Tuhelj, Croatia. Available at https://nrm.hr/aktivnosti/kiipgrow-konferencija-o-investicijama-i-inovacijama-u-poljoprivredi/

4. Lugonja, D. (2025.), Presentation of the doctoral thesis topic and research at "PhD Day": Evaluation of Digital Maturity and Planning of Digital Transformation of Agricultural Holdings in the Republic of Croatia (Digital maturity evaluation and digital transformation planning for the agricultural holdings in the Republic of Croatia, Available at : https://www.fazos.unios.hr/storage/Dokumenti/Dan%20doktorata/DD25_%20Zbornik%20sa%C5%BEetaka.pdf

5. Lugonja, D.; Fruk, M.; Sudarić, T.; Plaščak, I.; Jurišić, M.; Radočaj, D. (2024.), Measuring the digital transformation maturity in agriculture, The ISDTA and DIGITAGRA 2024 Conference, FAZOS, Osijek, Available at : https://ict-agriculture.com/wp-content/uploads/2025/07/Book-of-Abstracts-2nd-ISDTA.pdf

6. Lugonja, D.; Fruk, M.; Sudarić, T.; Plaščak, I.; Jurišić, M.; Radočaj, D. (2024.), poster „Assessing digital transformation maturity for implementing digitalization in agriculture", Transfer znanja i tehnologije, VI. međunarodni znanstveno-stručni skup, Inovacije i agrobiznis, Hrvatsko agroekonomsko društvo (HAED), Available at

7. Lugonja, D. (2023.) FAIRshare UC „Pitanja i odgovori" poster, Fakultet agrobiotehničkih znanosti Osijek, znanstveno-stručni skup, Hrvatsko agroekonomsko društvo (HAED), „Inovacije i agrobiznis, 24.11.2023., Osijek, Available at: https://haed.hr/dogadanja/v-medunarodni-znanstveno-strucni-skup/

8. Lugonja, D. (2023.) FAIRshare UC „QandA" – presentation, Thesalonikki (GR), Available at : https://www.h2020fairshare.eu/fairshare-final-conference/

9. Lugonja, D. (2023.) FAIRshare UC „QandA" - MofA poster at 62. IALB – 12. EUFRAS – 9.

SEASN – Working Congress 2023 in Germany / Saxony / Dresden, 10th - 14th September 2023, Available at : https://www.ialb.sachsen.de/download/IALB-EUFRAS-SEASN_2023_Saxony-Program_100723.pdf

10. Lugonja, D., Jurišić, M., Plaščak, I., Radočaj, D., Glavica-Tominić, D., Zbukvić, I., Krušelj, I., (2022), Smart Agriculture Development and Its Contribution to the Sustainable Digital Transformation of the Agri-Food SectorTehnički glasnik, Vol. 16 No. 2, 2022., str. 264-267, Available at : https://hrcak.srce.hr/clanak/400307

11. Lugonja, D., (2022.), Primjena novih tehnologija u poljoprivredi, panelist, „Agrotech 2022“ conference, 20.–21.10.2022, Sveti Martin na Muri, Available at: https://agrotech2022.listlabs.net/

12. Lugonja, D., Zbukvić, I., Glavica-Tominić, D., Krušelj, I., (2021), Kružna ekonomija i održivost - poster, konferencija Inovacije i agrobiznis: Kružna ekonomija i održivost, Available at: https://haed.hr/znanstveni-skup/knjiga-sazetaka-iii-medunarodni-znanstveno-strucni-skup-inovacije-i-agrobiznis/

13. Lugonja, D. (2020), Change Management as a Support to the Organization's Digital Transformation - State of the Art, CECIIS - Central European Conference on Information and Intelligent Systems; Varazdin, (2020). Lugonja, Darko. Central European Conference on Information and Intelligent Systems; Varazdin, (2020)., Available at: https://www.proquest.com/openview/5f643ed3a7ed59fa3e2d7180d25288b0/1?pq-origsite=gscholar&cbl=1986354

14. Lugonja, D., (2020), Interoperability. A digital transformation to sustainable information society (eBook), 2020/3/4, GRIN Verlag, Available at: https://www.lehmanns.de/search/show-searchresults

15. Lugonja, D. (2019), The concepts of Inter-Institutional Interoperability and Open Innovation, GRIN Verlag, Available at: https://www.grin.com/document/507926

16. Škiljan, Z. Lugonja, D., Krušelj, I., (2019), Sinergija javne uprave i poljoprivredno-prehrambenog sektora kao uvjet uspješne digitalne transformacije, Akademija tehničkih znanosti Hrvatske (HATZ), Available at: https://www.hatz.hr/wp-content/uploads/2019/12/Darko-Lugonja_MPS.pdf