Okvir za digitalnu zrelost visokih učilišta i instrument za njezinu procjenu

Đurek, Valentina

Doctoral thesis / Disertacija

2022

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:280446

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

Sveučilište u Zagrebu

Fakultet organizacije i informatike

Valentina Đurek

OKVIR ZA DIGITALNU ZRELOST VISOKIH UČILIŠTA I INSTRUMENT ZA NJEZINU PROCJENU

DOKTORSKI RAD

Zagreb, 2022.

Sveučilište u Zagrebu

Fakultet organizacije i informatike

Valentina Đurek

OKVIR ZA DIGITALNU ZRELOST VISOKIH UČILIŠTA I INSTRUMENT ZA NJEZINU PROCJENU

DOKTORSKI RAD

Mentorice:

prof.dr.sc. Nina Begičević Ređep

prof.dr.sc. Blaženka Divjak

Zagreb, 2022.

Sveučilište u Zagrebu

Faculty of Organization and Informatics

Valentina Đurek

A DIGITAL MATURITY FRAMEWORK FOR HIGHER EDUCATION INSTITUTIONS AND THE INSTRUMENT FOR ITS ASSESSMENT

DOCTORAL DISSERTATION

Supervisors:

Nina Begičević Ređep, PhD, full professor

Blaženka Divjak, PhD, full professor

Zagreb, 2022.

PODACI O DOKTORSKOM RADU

I. AUTOR

Ime i prezime	Valentina Đurek
Datum i mjesto rođenja	11.03.1974. Zabok
Naziv fakulteta i datum diplomiranja	Fakultet organizacije i informatike, 13.12.2003.
Sadašnje zaposlenje	Grad Zabok, pročelnica Upravnog odjela za EU fondove i strateške projekte

II. DOKTORSKI RAD

Naslov	Okvir za digitalnu zrelost visokih učilišta i instrument za njezinu procjenu
Broj stranica, slika, tabela, priloga, bibliografskih podataka	223 stranice, 36 slika, 68 tablica, 6 priloga te 233 bibliografska podatka
Znanstveno područje i polje iz kojeg je postignut akademski stupanj	Znanstveno područje društvenih znanosti, znanstveno polje informacijske i komunikacijske tehnologije
Mentor i voditelj rada	prof.dr.sc. Nina Begičević Ređep prof.dr.sc. Blaženka Divjak
Fakultet na kojem je rad obranjen	Sveučilište u Zagrebu, Fakultet organizacije i informatike
Oznaka i redni broj rada	165

III. OCJENA I OBRANA

Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena tema	19.09.2019.
Datum predaje rada	15.04.2022.
Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena pozitivna ocjena rada	28.04.2022.
Sastav Povjerenstva koje je rad ocijenilo	izv.prof.dr.sc. Igor Balaban prof.dr.sc. Dragutin Kermek izv.prof.dr.sc. Predrag Oreški
Datum obrane	31.08.2022.
Sastav Povjerenstva pred kojim je rad obranjen	izv.prof.dr.sc. Igor Balaban prof.dr.sc. Dragutin Kermek izv.prof.dr.sc. Predrag Oreški
Datum promocije	

Informacije o mentoricama

Prof. dr. sc. Nina Begičević Ređep je dekanica, redovita profesorica i znanstvena savjetnica u području društvenih znanosti, polje informacijske i komunikacijske znanosti na Fakultetu organizacije i informatike (FOI) Sveučilišta u Zagrebu. Nositeljica je kolegija Poslovno odlučivanje i kolegija Analiza poslovnih odluka na preddiplomskim i diplomskim sveučilišnim studijima FOI-ja. Predaje i na doktorskom studiju kao i na nekoliko poslijediplomskih sveučilišnih studija. Područja njenog interesa su vezana uz poslovno odlučivanje i teoriju odlučivanja, metode za višekriterijsko odlučivanje, strateško planiranje i odlučivanje, edukacijske tehnologije. Autorica je više od osamdeset znanstvenih radova te je suautorica sveučilišnog udžbenika Poslovno odlučivanje, više poglavlja knjiga te monografija. Od 2011. do 2015. obnašala je dužnost prodekanice za poslovanje na FOI-ju, te nakon toga preuzima funkciju prodekanice za znanstveno-istraživački rad koju je obnašala do 2019. Od listopada 2019. obnaša funkciju dekanice FOI-ja. Sudjelovala je kao istraživačica na više od petnaest domaćih i međunarodnih znanstvenih i stručnih projekata (Horizon 2020, INTERREG, Erasmus, HRZZ, Tempus, ESF, IPA, LLP, EUREKA i dr.). Trenutno vodi projekt Hrvatske zaklade za znanost pod nazivom "Podizanje zrelosti visokih učilišta za implementaciju analitika učenja (HELA)" te koordinira timom FOI-ja na projektu B "e-Škole: Uspostava sustava razvoja digitalno zrelih škola. U uredništvu je međunarodnog časopisa IJAHP (International Journal of the Analytic Hierarchy Process) te časopisa Croatian Operational Research Review. U programskom je odboru konferencija SYMORG, CECIIS, DIGITOMICS, IFIP DSS, SST. Recenzentica je za časopise Applied Soft Computing, Project Management, IJAHP, Central European Journal of Operational Research, Journal of Information and Organizational Sciences, Management i druge. Članica je Hrvatskog društva za operacijska istraživanja. Također je članica U.S. Alumnia i U.S. Affiliates Community-ja. U 2018. godini osnovala je Laboratorij za strateško planiranje i odlučivanje čija je voditeljica. Osmislila je i održala više radionica i stručnih usavršavanja s fokusom na strateško planiranje i odlučivanje kao i uvođenje digitalnih tehnologija u obrazovanje. Bila je stipendistica američke Vlade te se usavršavala na University of Pittsburgh – Katz Graduate School of Business pod mentorstvom profesora Thomasa Saatya. Bila je članica više povjerenstava i radnih skupina, poput Povjerenstva za uvođenje informatike osnovanog od strane MZO-a, članica Povjerenstva za izradu strategije digitalnog sazrijevanja škola i školskog sustava, Povjerenstva za e-učenje Sveučilišta u Zagrebu i dr. Bila je predsjednica Povjerenstva za obrazovanje, gospodarstvo i međuregionalnu suradnju Varaždinske županije, vijećnica u Županijskoj skupštini Varaždinske županije u nekoliko

mandata, predsjednica Povjerenstva za ravnopravnost spolova Varaždinske županije, članica Upravnog vijeća Instituta za društvena istraživanja, članica Nadzornog odbora Tehnološkog parka Varaždin (TPV) kao i članica skupštine TPV-a i dr. Za svoj znanstveni rad kao i društveni doprinos dobila je više priznanja i nagrada.

Prof. dr. sc. Blaženka Divjak redovita je profesorica u trajnom zvanju iz područja prirodnih znanosti, polje matematika i znanstvena savjetnica iz područja društvenih znanosti, polje informacijskih i komunikacijskih znanosti na Fakultetu organizacije i informatike (FOI) Sveučilišta u Zagrebu. Nositeljica je nekoliko matematičkih kolegija (Matematika 1, Matematika 2, Matematičke metode za informatičare, Diskretne strukture s teorijom grafova) na preddiplomskim i diplomskim studijima informatike, kolegija vezanih uz upravljanje projektima, s naglaskom na međunarodne EU projekte na diplomskom studiju ekonomike poduzetništva i doktorskom studiju informacijskih i komunikacijskih znanosti te kolegija povezanih s e-učenjem i strategijama u visokom obrazovanju na poslijediplomskim doktorskim i specijalističkim studijima na Fakultetu organizacije i informatike. Područja njezinog interesa vezana su uz diferencijalnu geometriju, matematičku edukaciju, strateško planiranje u visokom obrazovanju, e-učenje, analitike učenja te primjenu matematičkih metoda u odlučivanju i društvenim znanostima. Autorica je ili suautorica oko 100 znanstvenih radova, oko 50 stručnih radova, oko 80 izlaganja na znanstvenim konferencijama te oko 70 izlaganja na stručnim skupovima i konferencijama. Na dvadesetak znanstvenih i stručnih konferencija bila je pozvana predavačica. Autorica je sedam knjiga od kojih su dvije sveučilišni udžbenici iz matematike. Nadalje, autorica je poglavlja u pet knjiga, urednica četiri stručne knjige te članica uredništva nekoliko znanstvenih i stručnih časopisa.
Od 2017. do 2020. obnašala je dužnost ministrice znanosti i obrazovanja Republike Hrvatske. Od 2010. do 2014. bila je prorektorica za studente i studije Sveučilišta u Zagrebu. U dva mandata, od 1999. do 2003. i od 2007. do 2010. bila je prodekanica za znanost i međunarodnu suradnju Fakulteta organizacije i informatike u Varaždinu Sveučilišta u Zagrebu. Koordinirala i vodila 15 nacionalnih i međunarodnih znanstvenih i razvojnih projekata na razini projekta/radnog paketa (zProjekti, NZZ, HRZZ, Tempus, FP7, ESF, IPA, LLP, Eureka, Erasmus itd.), a sudjelovala u još 20-tak projekata kao istraživač/suradnik. Trenutno je voditeljica *projekta RAPIDE: Relevant assessment and pedagogies for inclusive digital education* financiran sredstvima Europske komisije iz programa ERASMUS+ koji traje od 2021. do 2023. Treba istaknuti i projekt *Razvoj metodološkog okvira za strateško odlučivanje u visokom obrazovanju - primjer implementacije otvorenog učenja i učenja na daljinu -*

HigherDecision kojeg je u periodu od 2015. do 2019. financirala Hrvatska zaklada za znanost (HRZZ), a u sklopu kojeg izrađeno pet doktorskih disertacija. Pod njezinim mentorstvom izrađeno je deset doktorskih disertacija.

Bila je predsjednica Odbora za upravljanje kvalitetom Sveučilišta u Zagrebu od 2009. do 2010., Vijeća za Nacionalni inovacijski sustav od 2008. do 2009. te nacionalnog Povjerenstva za praćenje aktivnosti Joint Research Centre-a od 2006. do 2010., zamjenica predsjednice Odbora za znanstveni, stručni i umjetnički rad Sveučilišta u Zagrebu od 2002. do 2006. Bila je članica Upravnog odbora međunarodne organizacije European Access Network od 2005. do 2017., Nacionalne skupine eksperata za Bolonjski proces od 2011. do 2014., Radne grupe za pregovore o pristupanju Hrvatske Europskoj uniji za poglavlje Znanost i istraživanje 2006., Poglavarstva Varaždinske županije zadužena za obrazovanje, znanost, kulturu i informiranje od 2001. do 2005., nacionalnog Povjerenstva za praćenje Okvirnih programa FP od 2006. do 2010. i predstavnica (*High Level Representative*) Hrvatske u europskoj Eureka mreži od 2002. do 2004. Dobitnica je više nagrada i priznanja za svoj znanstveni i stručni rad.

Zahvaljujem svojim mentoricama prof.dr.sc. Nini Begičević Ređep i prof.dr.sc Blaženki Divjak na potpori i nesebičnom prenošenju znanja pri nastajanju ovog rada, ali i u školovanju koje mu je prethodilo.

Zahvaljujem Ivanu H. i Željku K. na podršci, razumijevanju i pomoći pri nastajanju mog doktorskog rada.

Zahvaljujem Maji Č. i Nikoli K. na pruženoj motivaciji i ruci pomoći kad god je ona bila potrebna.

Zahvaljujem svojim prijateljicama i prijateljima na svim riječima ohrabrenja i potpori.

Posebno zahvaljujem svojoj obitelji: mami, Nikoli, Maji, Evi, Iki i Borisu na neizmjernoj ljubavi, vjeri u moj uspijeh i beuzvjetnoj potpori.

Okvir za digitalnu zrelost visokih učilišta i instrument za njezinu procjenu

Valentina Đurek

Sažetak

Koncept digitalne zrelosti značajan je u visokim učilištima koja zbog brzog razvoja informacijsko-komunikacijskih tehnologija imaju sve veću potrebu za unapređenjem postojećih i razvojem novih nastavnih i poslovnih procesa s ciljem podizanja razine digitalne zrelosti koja doprinosi povećanju kvalitete učenja, poučavanja i poslovanja. Informacijsko društvo, informacijske tehnologije (IT) ili informacijsko-komunikacijske tehnologije (IKT) pojmovi su koji su generirani znanstvenim, tehnološkim i tehničkim napretkom. Danas su znanje i informacije glavni nositelji produktivnosti, konkurencije, bogatstva i prosperiteta zemalja. Na znanstvenoj i tehnološkoj razini dolazi do brzih promjena u evoluciji IKT-a koje su korisne za visoka učilišta, dok je na obrazovnoj razini brzina promjena relativno konstantna. Iako IKT omogućuje promjene u načinu učenja i poučavanja, one ne jamče podizanje kvalitete učenja i poučavanja te njenu održivost već zahtijevaju višestrani sistemski pristup, uključujući ulaganje u infrastrukturu, ulaganje u profesionalni razvoj profesora, promjenu kurikuluma, preispitivanje procjene studenata i ocjenjivanje profesora, promicanje i poticanje suradnje i otvorenog sadržaja te integraciju svega navedenog u dobro vođenom okruženju. Nadalje, kvalitetni visokoobrazovni sustav te istraživačka izvrsnost danas nisu mogući bez moderne i napredne IKT koja je nezaobilazan temelj za nove metode i iskorake u istraživanjima, kao i u učenju i poučavanju. Korištenje i integracija IKT-a u svakodnevni rad svih zaposlenika, učenje i poučavanje, znanstveno-istraživački rad, transfer tehnologije, razvoj IKT kulture te odgovarajuća IKT infrastruktura doprinose razvoju digitalne zrelosti visokih učilišta (VU). Cilj predloženog istraživanja jest identificirati područja i elemente relevantne za digitalnu zrelost VU-a te izvršiti procjenu razine zrelosti VU-a u Republici Hrvatskoj. Istraživanje ovog doktorskog rada rezultirat će razvojem Okvira za digitalnu zrelost visokih učilišta (ODZVU) i razvojem Instrumenta za procjenu digitalne zrelosti visokih učilišta (IPDZVU).

Ključne riječi: digitalna zrelost, okvir za digitalnu zrelost, instrument digitalne zrelosti, model zrelosti, visoka učilišta

The Digital Maturity Framework for Higher Education Institutions and the Instrument for its Assessment

Valentina Đurek

Abstract

The concept of digital maturity is significant in Higher Education Institutions (HEI) which, due to the rapid development of information and communication technologies, have an increasing need to develop and improve existing teaching and business processes to raise digital maturity and increase the quality of learning, teaching and business processes. Information society, information technology (IT), or information and communication technology (ICT) are terms that are generated by scientific, technological, and technical progress. Today, knowledge and information are the main drivers of the productivity, competition, wealth, and prosperity of countries. Accordingly, countries have focused on different approaches to increase quality education. At the scientific and technological level, there are a rapid change in the evolution of ICT useful for higher education institutions (HEI), while at the educational level the pace of change is relatively constant. ICT allows for changes in the way we learn and teach, but these changes do not guarantee the improvement of the quality of learning and teaching and its sustainability. The changes require a multifaceted systemic approach, including investment in infrastructure, investing in the professional development of professors, changing curricula, reviewing student evaluations and evaluating professors, promoting and encouraging collaboration and open content, and integrating all of the above in a well-managed environment. A high-quality HEI and research excellence are not possible without modern and advanced ICT which is an indispensable foundation for new methods and exploits in research, as well as in learning and teaching. The employment and integration of ICT in everyday work, learning and teaching, scientific research, technology transfer, development of ICT culture, adequate ICT infrastructure contribute to the event of digital maturity (DM) of HEI. The initial aim of the proposed research is to identify the areas and elements relevant to the DM of the HEI and relevant for the assessment of HEI's DM level in Croatia. The research of this PhD thesis will result in the development of the Digital Maturity Framework for Higher Education Institutions (DMFHEI) and the Instrument for Assessment of Digital Maturity of Higher Education Institutions (IADMHEI).

Keywords: digital maturity, digital maturity framework, digital maturity instrument, higher education institutions

Okvir za digitalnu zrelost visokih učilišta i instrument za njezinu procjenu

Valentina Đurek

Prošireni sažetak

Koncept razine digitalne zrelosti institucije javlja se zbog potrebe za stvaranjem jednostavnog mjerila pomoću kojeg bi bilo moguće razlikovati različita stanja organiziranosti, poslovanja institucije ili nekog drugog promatranog područja. Na osnovi takvog mjerila osmišljen je način kako ocijeniti napredak promatranog sustava u odnosu na početno stanje. Postoje različiti načini određivanja razine zrelosti, ovisno o kontekstu primjene, no zajedničko im je da razinu zrelosti predstavlja vrijednost koja odražava trenutno stanje organiziranosti promatranog sustava. Može se reći kako je model zrelosti okvir koji za svaku od postojećih razina zrelosti detaljno opisuje aktivnosti koje se u njoj odvijaju. Razrada svih modela zrelosti proizlazi iz ideje kako je moguće procijeniti razinu zrelosti pojedinih dijelova institucije. Dakle, napredak institucije može se predočiti kroz nekoliko osnovnih koraka (razina zrelosti) koji predstavljaju prikaz napretka koji je institucija u svom djelovanju ostvarila ili treba ostvariti kako bi iz početnog stanja došla u stanje digitalno zrele institucije.

Model zrelosti i okvir zrelosti usko su povezani. Iz modela zrelosti proizašli su okviri za digitalnu zrelost koji su modificirani ovisno o područjima za koja su namijenjeni. Model zrelosti procjenjuje trenutnu razinu zrelosti institucije dok okvir za digitalnu zrelost opisuje područja i elemente relevantne za procjenu digitalne zrelosti institucije. Digitalna zrelost postiže se digitalnom transformacijom ustanove planskom primjenom IKT-a u poslovanju, učenju i poučavanju.

Kvalitativnom analizom relevantne literature utvrđeno je da nema razvijenog okvira za digitalnu zrelost visokih učilišta i razvijenog instrumenta za procjenu digitalne zrelosti visokih učilišta. Postoje okviri koji se koriste u zemljama Europske unije: DigComp, DigComp 2.0, DigComp 2.1, DigComOrg, DigComEdu, OpenEdu, SELFIE (detaljna analiza okvira prezentirana je u Poglavlju 2.3.). Navedeni okviri većinom su generički okviri koji se trebaju prilagođavati kako bi poslužili visokim učilištima što je autoricu motiviralo i usmjerilo na daljnje istraživanje i razvoj Okvira za digitalnu zrelost visokih učilišta (ODZVU) i Instrumenta za procjenu digitalne zrelosti visokih učilišta (IPDZVU) koji su i rezultat istraživanja ovog doktorskog rada.

Pregled postojećeg stanja koji je obuhvatio izvore o strateškom planiranju i odlučivanju o IKT-u u visokom obrazovanju, modele zrelosti kao i okvire digitalne zrelosti u obrazovanju, polazna

je točka za provođenje istraživanja razvoja ODZVU i IPDZVU. Razvijeni Okvir za digitalnu zrelost visokih učilišta omogućit će identifikaciju područja i elemenata važnih kako za digitalnu zrelost VU-a tako i za strateško planiranje uvođenja IKT-a na VU.

IPDZVU služi za procjenu razine digitalne zrelosti na kojoj se institucija nalazi. Procjena zrelosti pomoću instrumenta može se koristiti za mjerenje trenutne razine zrelosti određenog područja VU-a, omogućujući dionicima da jasno identificiraju točke prednosti i potrebna poboljšanja kako bi prema njima odredili što treba učiniti te time postigli veću digitalnu zrelost na pojedinim razinama. Pomoću ODZVU visoka učilišta mogu planirati i provoditi primjenu IKT-a, a primjenom IPDZVU procjenjuju svoju razinu zrelosti.

IPDZVU omogućit će procjenu digitalne zrelosti VU-a po područjima i elementima identificiranima u ODZVU-u.

Ključne riječi: digitalna zrelost, okvir za digitalnu zrelost, instrument digitalne zrelosti, model zrelosti, visoka učilišta

The Digital Maturity Framework for Higher Education Institutions and the Instrument for its Assessment

Valentina Đurek

Extended abstract

The concept of the maturity level of an institution arises because of the need to create a simple benchmark by which it would be possible to distinguish different states of organization, a business of the institution, or some other observed area. Based on such a benchmark, a way is developed to evaluate the progress of the observed system in relation to the initial state. There are different ways to determine the level of maturity, depending on the context of the application, but they all have in common that the level of maturity is a value that reflects the current state of organization of the observed system. It can be said that the maturity model is a framework that details the activities for each of the existing maturity level that take place in it. The development of all maturity models starts with the idea that it is possible to estimate the maturity level of individual parts of an institution. Thus, the progress of an institution can be represented through several basic steps (maturity level) that represent the progress that the institution has made or needs to make in order to get from the initial state to the state of a digitally mature institution.

The maturity model and the maturity framework are closely related. Maturity models have resulted in digital maturity frameworks that have been modified depending on the areas for which they are intended. The Maturity Model assesses the current level of maturity of the institution while the digital maturity Framework describes the areas and elements relevant to the assessment of the digital maturity of the institution. Digital maturity is achieved through the digital transformation of the institution through the planned application of ICT in business, learning, and teaching.

Qualitative analysis of the relevant literature has shown that there is no developed framework for the digital maturity of higher education institutions and a developed instrument for assessing the digital maturity of HEI. There are frameworks used in the countries of the European Union: DigComp, DigComp 2.0, DigComp 2.1, DigComOrg, DigComEdu, OpenEdu, SELFIE (a detailed analysis of the framework is presented in Chapter 2.3. Frameworks and instruments of digital maturity). These frameworks are mostly generic frameworks that need to be adapted to serve HEI, which motivated the author and directed her to further research and development of this framework and instrument, which are the result of research in this doctoral thesis.

A qualitative literature review, which has included strategic planning and decision making on digital technology in HEI, maturity models as well as digital maturity frameworks in education, is the starting point for conducting research into the development of the Digital Maturity Framework for Higher Education Institutions (DMFHEI) and the Instrument for Assessment of Digital Maturity of Higher Education Institutions (IADMHEI). The developed DMFHEI will enable the identification of areas and elements relevant to the digital maturity of HEIs and will be important in strategic planning for the deployment of ICT at HEIs.

The IADMHEI serves to assess the level of digital maturity at which an institution is positioned. Also, IADMHEI can be used to measure the current level of maturity of a particular aspect of HEI, allowing stakeholders to clearly identify points of benefit and improvement and to determine what needs to be done to achieve greater maturity at individual levels. HEI can plan and implement digital technologies by applying the DMFHEI, and assessing their maturity levels using the IADMHEI.

The IADMHEI will allow the assessment of the digital maturity of the HEI by the areas and elements identified in the DMFHEI.

Keywords: digital maturity, digital maturity framework, digital maturity instrument, higher education institutions

Sadržaj

1. Uvod 1
2. Pregled istraživanja 4
   2.1. Odlučivanje o informacijsko-komunikacijskoj tehnologiji na visokim učilištima 4
      2.1.1. Pojam odlučivanja i vrste poslovnih odluka 4
      2.1.2. Strateško odlučivanje o informacijsko-komunikacijskoj tehnologiji na visokim učilištima 5
   2.2. Digitalna zrelost i modeli zrelosti 10
   2.3. Okviri i instrumenti digitalne zrelosti 15
3. Ciljevi, istraživačka pitanja, hipoteze i metodologija istraživanja 23
   3.1. Ciljevi, istraživačka pitanja, hipoteze istraživanja 23
   3.2. Metodologija istraživanja 24
      3.2.1. Identifikacija problema 27
      3.2.2. Prijedlog artefakta 29
      3.2.3. Razvoj artefakta 29
      3.2.4. Evaluacija 31
4. Opisi metoda za razvoj modela zrelosti (okvira i instrumenta) 33
   4.1. Metoda fokus grupe 33
   4.2. Metoda Delphi 36
   4.3. Metoda sortiranja karata 39
   4.4. Pokazatelj valjanosti sadržaja 43
   4.5. Analitički hijerarhijski proces – metoda AHP 45
   4.6. Analitički mrežni proces – metoda ANP 58
   4.7. Metoda DEMATEL 62
   4.8. Istraživanje pomoću rubrike 65
   4.9. Kompozitni indeks 67
   4.10. Metoda DEX 70
5. Model za procjenu digitalne zrelosti 73
   5.1. Razvoj Okvira za digitalnu zrelost visokih učilišta (ODZVU) 73
      5.1.1. Primjena metode fokus grupe u istraživanju 74
      5.1.2. Istraživanje metodom Delphi 84
         5.1.2.1. Provedba Delphi istraživanja 84
      5.1.3. Istraživanje metodom sortiranja karata 98
         5.1.3.1. Provedba metode sortiranja karata 99

5.1.4. Okvir za digitalnu zrelost visokih učilišta - rezultati istraživanja 106
5.1.4.1. Područje ODZVU: Vodstvo, planiranje i upravljanje 108
5.1.4.2. Područje ODZVU: Osiguranje kvalitete 109
5.1.4.3. Područje ODZVU: Znanstveno-istraživački rad uz podršku IKT-a 110
5.1.4.4. Područje ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a 111
5.1.4.5. Područje ODZVU: Učenje i poučavanje uz podršku IKT-a 112
5.1.4.6. Područje ODZVU: IKT kultura 114
5.1.4.7. Područje ODZVU: IKT infrastruktura 115
5.2. Instrument za procjenu digitalne zrelosti visokih učilišta 116
5.2.1. Sudionici u istraživanju 117
5.2.2. Određivanje težinskih koeficijenata područja ODZVU 120
5.2.3. Određivanje težinskih koeficijenata elemenata ODZVU 124
5.2.3.1. Rezultati istraživanja za elemente područja ODZVU: Vodstvo, planiranje i upravljanje 124
5.2.3.2. Rezultati istraživanja za elemente područja ODZVU: Osiguranje kvalitete 126
5.2.3.3. Rezultati istraživanja za elemente područja ODZVU: Znanstveno-istraživački rad uz podršku IKT-a 127
5.2.3.4. Rezultati istraživanja za elemente područja ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a 128
5.2.3.5. Rezultati istraživanja za elemente područja ODZVU: Učenje i poučavanje uz podršku IKT-a 129
5.2.3.6. Rezultati istraživanja za elemente područja ODZVU: IKT kultura 130
5.2.3.7. Rezultati istraživanja za elemente područja ODZVU: IKT infrastruktura 131
5.2.4. Težinski koeficijenti područja i težinski koeficijenti elemenata ODZVU – rezultati 132
5.2.5. Razine zrelosti ODZVU 134
5.2.5.1. Definiranje područja i elemenata 134
5.2.5.2. Definiranje razina zrelosti 134
5.2.5.3. Definiranje opisnica 146
5.2.5.4. Rezultati istraživanja razina digitalne zrelosti visokih učilišta upotrebom rubrike 169
5.2.6. Kompozitni indeks 169
6. Digitalna zrelost visokih učilišta u Republici Hrvatskoj – rezultati istraživanja 174
6.1. Digitalna zrelost VU 174
6.2. Digitalna zrelost područja ODZVU 184

7. Evaluacija 190
7.1. Analiza osjetljivosti preko Spearmanovog koeficijenta korelacije ranga 190
7.2. Pouzdanost procjene između ispitanika 196
7.2.1. Cohen kappa koeficijent pouzdanosti 196
7.2.2. Postotak suglasnosti između ispitanika 199
8. Zaključak 202
Popis literature 209
Prilozi 224
Prilog 1. Istraživanje metodom Delphi - upitnik 224
Prilog 2. Istraživanje metodom sortiranja karata 229
Prilog 3. Istraživanje metodom DEMATEL 232
Prilog 4. Istraživanje metodom AHP – primjer za područje *Vodstvo planiranje i upravljanje* 233
Prilog 5. Istraživanje upotrebom rubrike – primjer za područje *Transfer tehnologije i služenje društvu uz podršku IKT-a* 236
Prilog 6. Digitalna zrelost VU 238

Popis slika

Slika 1: Okvir za digitalnu zrelost visokih učilišta [izvor: rad autorice, prilagođeno prema [103]] 24
Slika 2: Evaluacija ODZVU-a i IPDZVU-a 32
Slika 3: Interakcija unutar fokus grupe 35
Slika 4: Postupak provođenja Delphi metode 37
Slika 5: Otvoreno sortiranje karata 41
Slika 6: Zatvoreno sortiranje karata 42
Slika 7: Hijerarhijski model problema odlučivanja [Prilagođeno prema: [166]] 46
Slika 8: Dijagram toka demonstracijskog primjera AHP modela 48
Slika 9: Kriteriji i podkriteriji demonstracijskog modela metode AHP 49
Slika 10: Hijerarhijska struktura u metodi AHP [Izvor: [166]] 59
Slika 11: Mrežna struktura u metodi ANP [Izvor: [166]] 60
Slika 12: Sastavnice rubrike 66
Slika 13: Analiza rezultata demonstracijskog primjera 72
Slika 14: Hodogram razvoja Okvira za digitalnu zrelost visokih učilišta 74
Slika 15: Rezultat prve fokus grupe 79
Slika 16: Stupanj obrazovanja ispitanika u prvom krugu Delphi istraživanja 86
Slika 17: Upravljačka funkcija ispitanika u prvom krugu Delphi istraživanja 87
Slika 18: Znanstveno-nastavno, nastavno ili suradničko zvanje ispitanika u prvom krugu Delphi istraživanja 88
Slika 19: Stupanj obrazovanja ispitanika u istraživanju metodom sortiranja karata 100
Slika 20: Znanstveno-nastavno, nastavno ili suradničko zvanje ispitanika u istraživanju metodom sortiranja karata 101
Slika 21: Stupanj obrazovanja ispitanika u istraživanju 117
Slika 22: Zvanje ispitanika u istraživanju 118
Slika 23: Upravljačka funkcija ispitanika 119
Slika 24: Težinski koeficijenti područja ODZVU 123
Slika 25: Digitalna zrelost VU_1 175
Slika 26: Digitalna zrelost VU_4 176
Slika 27: Digitalna zrelost VU_33 177
Slika 28: Zbirna analiza rezultata - najveća digitalna zrelost 178
Slika 29: Zbirna analiza rezultata - najmanja digitalna zrelost 179

Slika 30: Digitalna zrelost područja ODZVU 1_Vodstvo, planiranje i upravljanje..... 184
Slika 31: Digitalna zrelost područja ODZVU 2_Osiguranje kvalitete 185
Slika 32: Digitalna zrelost područja ODZVU 3_Znanstveno-istraživački rad uz podršku IKT-a 185
Slika 33: Digitalna zrelost područja ODZVU 4_Transfer tehnologije i služenje društvu uz podršku IKT-a 186
Slika 34: Digitalna zrelost područja ODZVU 5_Učenje i poučavanje uz podršku IKT-a 187
Slika 35: Digitalna zrelost područja ODZVU 6_IKT kultura 187
Slika 36: Digitalna zrelost područja ODZVU 7_IKT infrastruktura 188

Popis tablica

Tablica 1: Modeli postizanja zrelosti u obrazovnom sektoru (izbor)..... 13
Tablica 2: Pregled okvira za procjenu digitalne zrelosti obrazovnih institucija 20
Tablica 3: Plan istraživanja 26
Tablica 4: Saatyjeva ljestvica relativnih važnosti [Izvor: [167]] 46
Tablica 5: Vrijednosti RI slučajnih indeksa [Izvor: [163]] 53
Tablica 6: Rezultati indeksa konzistencije (CR) 54
Tablica 7: Pregled težinskih koeficijenta kriterija i podkriterija..... 55
Tablica 8: Demonstracijski primjer kompozitnog indeksa 69
Tablica 9: Rezultati druge fokus grupe 80
Tablica 10: Rezultati istraživanja metodom Delphi za područje: Vodstvo, planiranje i upravljanje 89
Tablica 11: Rezultati istraživanja metodom Delphi za područje: Osiguranje kvalitete..... 90
Tablica 12: Rezultati istraživanja metodom Delphi za područje: Znanstveno-istraživački rad uz podršku IKT-a 90
Tablica 13: Rezultati istraživanja metodom Delphi za područje: Transfer tehnologije i služenje društvu uz podršku IKT-a 91
Tablica 14: Rezultati istraživanja metodom Delphi za područje: Učenje i poučavanje uz podršku IKT-a..... 91
Tablica 15: Rezultati istraživanja metodom Delphi za područje: IKT kultura 92
Tablica 16: Rezultati istraživanja metodom Delphi za područje: IKT infrastruktura..... 92
Tablica 17: Rezultati istraživanja metodom Delphi za pitanje „U kojoj mjeri se slažete da je element bitan za digitalnu zrelost visokih učilišta?“ 93
Tablica 18: Rezultati istraživanja metodom Delphi za područje: Vodstvo, planiranje i upravljanje 93
Tablica 19: Rezultati istraživanja metodom Delphi za područje: Osiguranje kvalitete..... 94
Tablica 20: Rezultati istraživanja metodom Delphi za područje: Znanstveno-istraživački rad uz podršku IKT-a 94
Tablica 21: Rezultati istraživanja metodom Delphi za područje: Transfer tehnologije i služenje društvu uz podršku IKT-a 95
Tablica 22: Rezultati istraživanja metodom Delphi za područje: Učenje i poučavanje uz podršku IKT-a..... 95
Tablica 23: Rezultati istraživanja metodom Delphi za područje: IKT kultura 96

Tablica 24: Rezultati istraživanja metodom Delphi za područje: IKT infrastruktura 96
Tablica 25: Rezultati istraživanja metodom Delphi za pitanje „U kojoj mjeri se slažete da je element smješten u ispravno područje?“ 97
Tablica 26: Rezultati istraživanja metodom sortiranja karata za područje: Vodstvo, planiranje i upravljanje 102
Tablica 27: Rezultati istraživanja metodom sortiranja karata za područje: Osiguranje kvalitete 102
Tablica 28: Rezultati istraživanja metodom sortiranja karata za područje: Znanstveno-istraživački rad uz podršku IKT-a 103
Tablica 29: Rezultati istraživanja metodom sortiranja karata za područje: Transfer tehnologije i služenje društvu uz podršku IKT-a 103
Tablica 30: Rezultati istraživanja metodom sortiranja karata za područje: Učenje i poučavanje uz podršku IKT-a 104
Tablica 31: Rezultati istraživanja metodom sortiranja karata za područje: IKT kultura 104
Tablica 32: Rezultati istraživanja metodom sortiranja karata za područje: IKT infrastruktura 105
Tablica 33: Rezultati istraživanja metodom sortiranja karata za pitanje „Prema Vašoj procjeni, kojem od sedam predloženih područja Okvira za digitalnu zrelost visokih učilišta pripada pojedini element?“ 105
Tablica 34: Okvir za digitalnu zrelost visokih učilišta 106
Tablica 35: Opisnice elemenata područja ODZVU: Vodstvo, planiranje i upravljanje 108
Tablica 36: Opisnice elemenata područja ODZVU: Osiguranje kvalitete 109
Tablica 37: Opisnice elemenata područja ODZVU: Znanstveno-istraživački rad uz podršku IKT-a 111
Tablica 38: Opisnice elemenata područja ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a 112
Tablica 39: Opisnice elemenata područja ODZVU: Učenje i poučavanje uz podršku IKT-a 113
Tablica 40: Opisnice elemenata područja ODZVU: IKT kultura 114
Tablica 41: Opisnice elemenata područja ODZVU: IKT infrastruktura 115
Tablica 42: Određivanje težinskih koeficijenata područja ODZVU - agregirana matrica 120
Tablica 43: Određivanje težinskih koeficijenata područja ODZVU - Težinska supermatrica 121

Tablica 44: Određivanje težinskih koeficijenata područja ODZVU - Potenciranje težinske supermatrice 121
Tablica 45: Određivanje težinskih koeficijenata područja ODZVU - Granična supermatrica 122
Tablica 46: Težinski koeficijenti područja ODZVU 122
Tablica 47: Težinski koeficijenti elemenata područja ODZVU: Vodstvo, planiranje i upravljanje 126
Tablica 48: Težinski koeficijenti elemenata područja ODZVU: Osiguranje kvalitete 127
Tablica 49: Težinski koeficijenti elemenata područja ODZVU: Znanstveno-istraživački rad uz podršku IKT-a 128
Tablica 50: Težinski koeficijenti elemenata područja ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a 128
Tablica 51: Težinski koeficijenti elemenata područja ODZVU: Učenje i poučavanje uz podršku IKT-a 129
Tablica 52: Težinski koeficijenti elemenata područja ODZVU: IKT kultura 130
Tablica 53: Težinski koeficijenti elemenata područja ODZVU: IKT infrastruktura 131
Tablica 54: Težinski koeficijenti područja i težinski koeficijenti elemenata ODZVU 132
Tablica 55: Opisnice elemenata područja ODZVU: Vodstvo, planiranje i upravljanje 147
Tablica 56: Opisnice elemenata područja ODZVU: Osiguranje kvalitete 151
Tablica 57: Opisnice elemenata područja ODZVU: Znanstveno-istraživački rad uz podršku IKT-a 154
Tablica 58: Opisnice elemenata područja ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a 157
Tablica 59: Opisnice elemenata područja ODZVU: Učenje i poučavanje uz podršku IKT-a 159
Tablica 60: Opisnice elemenata područja ODZVU: IKT kultura 163
Tablica 61: Opisnice elemenata područja ODZVU: IKT infrastruktura 166
Tablica 62: Struktura kompozitnog indeksa na primjeru rezultata istraživanja na odabranom VU 171
Tablica 63: Spearmanov koeficijent korelacije ranga - rangiranje alternativa 192
Tablica 64: Spearmanov koeficijent korelacije ranga za par: Rang alternativa i Ranga alternativa VPU -5% 194
Tablica 65: Zbirni rezultati usporedbe Spearmanovog koeficijenta korelacije ranga 195
Tablica 66: Cohen kappa koeficijent pouzdanosti za dvoje ispitanika 197

Tablica 67: Cohen kappa koeficijent pouzdanosti za sve ispitanike u istraživanju 198
Tablica 68: Stupanj suglasnosti ispitanika oko procjene razine zrelosti VU 200

Popis kratica korištenih u radu

AHP	analitički hijerarhijski proces (engl. *Analytic Hierarchy Process*)
AMP (ANP)	analitički mrežni proces (engl. *Analytic Network Process*)
CMM	model postizanja zrelosti (engl. *Capability Maturity Model*)
DEMATEL	laboratorij za donošenje i procjenu odluka (engl. *Decision-making trial and evaluation laboratory*)
DEX	metoda višekriterijskog odlučivanja (engl. *Decision EXpert*)
DM	digitalna zrelost (engl. *Digital Maturity*)
DSR	znanost o dizajniranju (engl. *Design Science Research*)
FAHP	neizraziti analitički hijerarhijski proces (engl. *Fuzzy Analytic Hierarchy Process*)
GDPR	opća uredba o zaštiti podataka (engl. *General Data Protection Regulation*)
HEI-LEVEL	razina digitalne zrelosti visokog učilišta (dobivena iz rubrike) (engl. *Higher Education Institution Level*)
HEI–LP	razina digitalne zrelosti visokog učilišta iz rubrike transformirana linearno u prioritete (engl. *Higher Education Institution Level Priority*)
HEI-ML	digitalna zrelost visokog učilišta (engl. *Higher Education Institution Maturity Level*)
HEI-TEP	razina zrelosti elementa (dobivena u kompozitnom indeksu) (engl. *Higher Education Institution Total Element Priority*)
IT	informacijska tehnologija (engl. *Information Technology*)
IKT (ICT)	informacijsko-komunikacijska tehnologija (engl. *Information and Communication Technology*)
IS	informacijski sustavi (engl. *Information Systems*)
IST	informacijski sustavi i tehnologije (engl. *Information Systems and Technology*)
IPDZVU (IADMHEI)	instrument za procjenu digitalne zrelosti visokih učilišta (engl. *Instrument for the Assessment of Digital Maturity of Higher Education Institutions*)
KPA	ključna procesna područja (engl. *Key Process Areas*)
LMS	sustav za upravljanje učenjem (engl. *Learning Management System*)
LP	vrijednosti prioriteta (engl. *Level Prioritiy*)
MCDM	metoda višekriterijskog odlučivanja (engl. *Multiple-criteria decision-making method*)
MM	model zrelosti (engl. *Maturity Model*)

ODZVU (DMFHEI)	okvir za digitalnu zrelost visokih učilišta (engl. *Digital Maturity Framework for Higher Education Institutions*)
PCA	analiza glavnih komponenata (engl. *Principal Component Analysis*)
PRISMA	smjernice za izvještavanje sustavnih pregleda i meta-analiza (engl. *Preferred Reporting Items for Systematic Reviews and Meta-analyses*)
RH (RC)	Republika Hrvatska (engl. *Republic of Croatia*)
SEI	Institut softverskog inženjerstva (engl. *Software Engineering Institute*)
SPICE	poboljšanje softverskog procesa i određivanje sposobnosti (engl. *Software Process Improvement and Capability Determination*)
TOPSIS	tehnika za rangiranje preferencija prema sličnosti idealnom rješenju (engl. *Technique for Order Preference by Similarity to an Ideal Solution*)
VU (HEI)	visoka učilišta (engl. *Higher Education Institutions*)

Popis oznaka korištenih u radu

c_i	suma stupaca u totalnoj matrici veza u metodi DEMATEL
CI	indeks konzistencije (engl. *Consistency Index*)
CR	omjer konzistencije (engl. *Consistency Ratio*)
CVI	indeks valjanosti sadržaja (engl. *Content Validity Index*)
CVR	omjer valjanosti sadržaja (engl. *Content Validity Ratio*)
D	normalizirana matrica utjecaja u metodi DEMATEL
d_i	razlika između rangova prve i druge varijable
K	kriterij
N	ukupan broj ispitanika
n	broj ispitanika koji pojedinu varijablu smatraju jako važnom
p_o	relativni uočeni dogovor među ocjenjivačima
p_e	hipotetska vjerojatnost slučajnog dogovora
r_i	suma redaka u totalnoj matrici veza u metodi DEMATEL
r_s	Spearmanov koeficijent korelacije
RI	slučajni indeks (engl. *Random Index*)
T	totalna matrica veza u metodi DEMATEL
x_{ij}	stupanj utjecaja kriterija *i* nad kriterijem *j*
Z	matrica utjecaja među kriterijima u metodi DEMATEL
κ	- Cohen kappa koeficijent
λ_{max}	prosječna vrijednost vektora konzistencije
α	prag najjačih veza u metodi DEMATEL

1. Uvod

Informacijsko društvo, informacijske tehnologije (IT) ili informacijsko-komunikacijske tehnologije (IKT) pojmovi su koji su generirani znanstvenim, tehnološkim i tehničkim napretkom. Na znanstvenoj i tehnološkoj razini dolazi do brzih promjena u razvoju i primjeni IKT-a koje su korisne i za visoka učilišta uz kvalitetno planiranje i primjenu IKT-a. Koncept digitalne zrelosti značajan je visokim učilištima koja zbog brzog razvoja IKT-a imaju sve veću potrebu za unapređenjem postojećih i razvojem novih nastavnih i poslovnih procesa s ciljem podizanja razine digitalne zrelosti i povećanja kvalitete učenja, poučavanja i poslovanja. Visoka učilišta u Republici Hrvatskoj (RH) su sveučilišta sa svojim sastavnicama - fakultetima i umjetničkim akademijama; veleučilišta i visoke škole. U RH trenutno djeluje 119 visokih učilišta sa statusom ustanove: 8 javnih sveučilišta, 2 privatna sveučilišta, 68 fakulteta i umjetničkih akademija te 1 sveučilišni centar na javnim sveučilištima, 4 privatna veleučilišta, 11 javnih veleučilišta, 22 privatne visoke škole i 3 javne visoke škole [1].

Pregled postojećeg stanja, analiza postojećih okvira i instrumenta, polazna su točka za provođenje razvoja Okvira za digitalnu zrelost visokih učilišta (ODZVU) i Instrumenta za procjenu digitalne zrelosti visokih učilišta (IPDZVU). S obzirom na potrebu strateškog planiranja i odlučivanja o uvođenju IKT-a u visoko obrazovanje, istraživanje je također obuhvatilo pregled metoda za odlučivanje primjenjivanih u visokom obrazovanju.

Visoko obrazovanje ispunjeno je ozbiljnim izazovima na više razina suradnje (uprava, nastavnici, studenti, ostali dionici), a razvojem tehnologije u svim oblastima društva (znanost, obrazovanje, gospodarstvo) povećava se pritisak kako bi se osigurale tehnološke mogućnosti u kontekstu obrazovnih potreba [2]. U Strategiji obrazovanja, znanosti i tehnologije 2014. [3] navodi se da je potrebno posebno poticati inovativne pristupe u izvođenju studijskih programa i primjenu najsuvremenijih nastavnih pomagala, uključujući značajnu primjenu IKT-a. Visoka učilišta koriste IKT za razvoj nastavnih materijala za kolegije, prijenos znanja i iskustava, olakšavanje međusobne komunikacije nastavnika i studenata, poticanje pedagoške inovacije, povećanje suradnje i kolaboracije, provedbu istraživanja, poticanje profesionalnog razvoja, provedbu upravljačkih kao i administrativnih aktivnosti. Autorice Kozina i Kirinić [4] navode da je danas zrelost visokih učilišta u provedbi strategije istih jedan od preduvjeta za suočavanje s izazovima neizvjesnog okruženja. Nevezano za to koliko se ulaže u brigu o učenju i poučavanju, istraživanju, znanosti i projektima, potrebno je osigurati podobne procese za implementaciju strategije i njene potporne procese.

Koncept razine zrelosti institucije javlja se zbog potrebe za stvaranjem jednostavnog mjerila pomoću kojeg bi bilo moguće razlikovati različita stanja organiziranosti, poslovanja institucije ili nekog drugog promatranog područja. Dakle, napredak institucije može se predočiti kroz nekoliko osnovnih koraka (razina zrelosti) koji predstavljaju prikaz napretka koji je institucija u svom djelovanju ostvarila ili treba ostvariti kako bi iz početnog stanja došla u stanje digitalno zrele institucije.

U literaturi postoje razne definicije okvira. Autori Johnson, Nilsen, Frankfort-Nachmias i Nachmias definiraju okvir na sljedeći način: "Okvir je dizajn za višekratnu upotrebu cijelog ili dijela sustava koji predstavljaju skup apstrakta klase i način na koji njihovi elementi djeluju [5]"; "Okvir uključuje koncepte, konstrukte ili kategorije i identificira odnos između varijabli [6]"; "Okvir označava strukturu, pregled, nacrt, sustav ili plan koji se sastoji od različitih opisnih kategorija, npr. koncepata, konstrukta ili varijabli te odnosa između njih [7]."

Instrument služi za procjenu razine digitalne zrelosti na kojoj se institucija nalazi. Procjena zrelosti pomoću instrumenta može se koristiti za mjerenje trenutne razine zrelosti određenog područja visokog učilišta, omogućujući dionicima da jasno identificiraju točke prednosti kao i potrebna poboljšanja te prema njima odrede što treba učiniti kako bi postigli veću razinu zrelosti na pojedinim područjima.

Ovaj rad slijedi korake metodologije znanosti o dizajniranju stoga su i poglavlja organizirana na sljedeći način:

- U prvom poglavlju opisana je analiza postojećeg stanja kao motivacija za provođenje istraživanja s ciljem razvoja Okvira za digitalnu zrelost visokih učilišta (ODZVU) i Instrumenta za procjenu digitalne zrelosti visokih učilišta (IPDZVU).
- U drugom poglavlju dan je pregled istraživanja vezanih uz odlučivanje o primjeni IKT-a na visokim učilištima (pojam odlučivanja i vrste poslovnih odluka, strateško odlučivanje o IKT-u na visokim učilištima). Također, objašnjeni su pojmovi digitalne zrelosti i modela zrelosti te su prikazani rezultati analize postojećih okvira i instrumenata digitalne zrelosti.
- U trećem poglavlju definirani su ciljevi, istraživačka pitanja i hipoteze te je opisana metodologija provedbe istraživanja.
- U četvrtom poglavlju opisane su metode za razvoj modela zrelosti (ODZVU i IPDZVU): metoda fokus grupe, metoda sortiranja karata, pokazatelj valjanosti sadržaja,

metoda Delphi, metoda analitički hijerarhijski proces, metoda analitički mrežni proces, metoda DEMATEL, rubrika, kompozitni indeks, metoda DEX.

- U petom poglavlju prikazan je razvijen ODZVU koji se sastoji od 7 područja i 42 elementa te je predstavljen razvijen IPDZVU.
- U šestom poglavlju prezentirani su rezultati istraživanja digitalne zrelosti visokih učilišta u Republici Hrvatskoj te rezultati analize digitalne zrelosti područja ODZVU.
- U sedmom poglavlju dana je evaluacija modela za procjenu digitalne zrelosti visokih učilišta primjenom Spearmanovog koeficijenta korelacije ranga te primjenom pouzdanosti procjene između ispitanika.
- U osmom poglavlju, temeljem provedene evaluacije u šestom poglavlju, izveden je zaključak o postignutim ciljevima i potvrđenim hipotezama. U istom poglavlju naveden je popis diseminacijskih aktivnosti novog artefakta kako to predviđa posljednji korak znanosti o dizajniranju.

2. Pregled istraživanja

Na početku istraživanja provedena su tri glavna koraka temeljena na metodologiji PRISMA (engl. *Preferred Reporting Items for Systematic Reviews and Meta-analyses*): pretraživanje literature, odabir prihvatljivih radova i ekstrakcija te sažetak podataka [8].

U fazi analize literature odabrana su tri sučelja (baze podataka): EBSCOhost, Scopus i Science Direct. U fazi odabira prikladnih radova izuzeti su duplicirani radovi s viškom informacija i studije temeljene na rezultatima naslova i pregledom sažetaka. U prvoj je fazi ukupno pronađeno 359 članaka, a nakon selekcije analizirano ih je 79. Baze su pretraživane za pojmove zrelost (engl. *maturity*), model zrelosti (engl. *maturity model*) i digitalna zrelost (engl. *digital maturity*), okvir (engl. *framework*), instrument (engl. *instrument*), strateško odlučivanje (engl. *strategic decision making*), strateško planiranje (engl. *strategic planning*) u kombinaciji s riječima visoko učilište (engl. *higher education institution*).

2.1. Odlučivanje o informacijsko-komunikacijskoj tehnologiji na visokim učilištima

2.1.1. Pojam odlučivanja i vrste poslovnih odluka

Pojam odlučivanja je u širokoj primjeni, no pojedini autori ga na različite načine definiraju. Odlučivanje se definira kao odabir nekog smjera djelovanja između više alternativa [9].

Kod poslovnog odlučivanja, ovisno o razini odlučivanja, odluke se reflektiraju na veći ili manji broj članova poslovne organizacije, a ponekad i na sve zaposlene što je osnovni razlog zbog kojeg je poslovnom odlučivanju potrebno posvetiti odgovarajuću pozornost [10].

Svrha odlučivanja jest uspješnim, ekonomičnim i pravodobnim odlukama postići pozitivan ishod, a ukoliko je moguće izbjeći pogrešan odabir alternative koja može dovesti do negativnog ishoda, a posljedice umanjiti ili ublažiti. Odlučivanje je proces utvrđivanja i odabiranja načina rješavanja nekog problema u skladu s ciljevima organizacije i okolnostima u kojima ona djeluje [11], odabir nekog smjera djelovanja između više alternativa [12], odnosno proces identifikacije problema i proces rješavanja problema [13] ili skup aktivnosti koji započinje identifikacijom problema, a završava izborom alternative [14].

Odluka predstavlja izbor jedne između više alternativa nastojeći da taj izbor bude što optimalniji. Dobra odluka, kao rezultat odlučivanja ima sljedeće karakteristike: ona mora biti

nedvosmislena, precizna, jasna i ostvariva te prije svega pravovremena [15] ili omogućiti prednost pri djelovanju koje će donijeti zadovoljavajuće stanje stvari za određenu stranu, tj. korisnika djelovanja [16].

Odluke se s obzirom na važnost za poduzeće / ustanovu u kojoj se donose, dijele na: strateške, taktične i operativne odluke [17]. Strateške odluke su najznačajnije u poduzeću/ustanovi i na temelju njih se određuje strategija i ciljevi poduzeća / ustanove. To su dugoročne, visokorizične odluke koje mogu rezultirati prosperitetom organizacije / ustanove, ako su donesene kvalitetne, dobre odluke, ali i propašću, ako su donesene pogrešne odluke; stoga je i odgovornost donositelja strateških odluka vrlo velika. Taktičke odluke su potrebne za realizaciju strateških odluka i umjerenog su rizika. Operativne odluke su potrebne za realizaciju taktičkih odluka, koriste se za rješavanje rutinskih problema, najčešće u situacijama koje se ponavljaju i niskog su rizika. Menadžerske odluke obično se svrstavaju u dvije kategorije, a to su programirane i neprogramirane odluke. Autor Daft [18] navodi da programirane odluke uključuju situacije koje su se dogodile dovoljno često da su na osnovu njih donesena pravila koja će se primjenjivati u budućnosti (kao što je na primjer odluka o narudžbi papira i drugih uredskih potrepština). Neprogramirane odluke donose se kao reakcija na jedinstvene situacije, nisu prethodno određene i uglavnom su nestrukturirane te imaju posljedice značajne za organizaciju. Zbog njihove kompleksnosti i neizvjesnosti prilično su složene, a velik broj neprogramiranih odluka vezan je uz strateško planiranje (npr., odluka o gradnji nove tvornice, odluka o preseljenju sjedišta tvrtke u drugi grad…) [18].

2.1.2. Strateško odlučivanje o informacijsko-komunikacijskoj tehnologiji na visokim učilištima

Strateško planiranje je kreiranje misije, vizije i temeljnih vrijednosti organizacije; identificiranje akcija kako bi se vizija, misija i ciljevi postigli te planiranje načina kako će se evaluirati postizanje tih strateških odrednica. Autor Kadoić [19] navodi da je rezultat strateškog planiranja strateški plan (strategija). Isti autor navodi sljedeće korake u strateškom planiranju: 1. Identificiranje vizije i misije; 2. Razvoj strateških usmjerenja (interna, eksterna); 3. Izrada strategija (namjeravanih i nenamjeravanih); 4. Strateško programiranje – definiranje strateških ciljeva, kreiranje akcijskih planova i taktika; 5. Evaluacija strategije i pregled strateškog plana i 6. Strateško učenje i strateško razmišljanje.

Autorica Luić [20] definira strateško planiranje u školi. Navodi da je strateško planiranje moguće definirati kao disciplinirani napor, koji ima za cilj donošenje temeljnih odluka i poduzimanje temeljnih aktivnosti koje oblikuju i vode to što organizacija je, ono čime se ona bavi i razloge zbog kojih se bavi time čime se bavi, koncentrirajući se pri tome na budućnost. Pri tome je osnovni cilj strateškog planiranja da jasno utvrdi prirodu i karakter organizacije (škole) i sektora koji ona predstavlja (obrazovanja) i upravlja njenim razvojem. Kroz proces strateškog planiranja škola utvrđuje svoju misiju, svoje ciljeve, prioritete i strategije, te definira mjere za procjenu uspješnosti ostvarenja tih ciljeva. Faze u strateškom planiranju su: 1. Procjena situacije, 2. Formuliranje strategije, 3. Primjena strategije i 4. Strateško upravljanje.

Autorice Divjak i Begičević Ređep [21] u svom su radu predstavile ciklus strateškog odlučivanja na VU. Ciklus strateškog odlučivanja sastoji se od četiri faze:

1. Prepoznavanje i istraživanje problema - identificiranje ključnih čimbenika za procjenu spremnosti organizacije za odluku o usvajanju inovacija i ključnih pokazatelja uspješnosti za mjerenje učinka difuzije inovacija,

2. Razvoj metodologije odlučivanja i donošenja odluke - primjena i unapređenje metodologije višekriterijske analize odluka tako da omogući donošenje kvalitetnijih strateških odluka na VU,

3. Provedba i praćenje strateške odluke - identificiranje ključnih faktora koji utječu na uspješnost provedbe strateške odluke i njihove međuzavisnosti te razvoj modela za mjerenje zrelosti i uspješnosti implementacije strateških odluka na VU,

4. Evaluacija učinaka provedbe odluke - primjena kvalitativnih i kvantitativnih metoda za evaluaciju, te evaluacija upotrebom strukturalne teorije kauzalnosti prema interpretaciji kauzalnosti J. Pearla koja se primjenjuje za detektiranje efekta primjene određenih odluka.

Analiza literature uključila je 24 izvora o strateškom planiranju i odlučivanju o IKT-u u visokom obrazovanju.

Integracija strateškog planiranja u visoko obrazovanje omogućila je okvir koji je temelj za određivanje vizije, misije, vrijednosti, ciljeva i strategije institucija. U literaturi se navodi da postoji značajna povezanost između strateškog planiranja i raspodjele resursa kao ključne komponente za utvrđivanje institucionalne uspješnosti [22]. Proces strateškog planiranja koristi

se za mjerenje institucionalne učinkovitosti, uključujući sve važne aktivnosti, a usko je povezan s procesom donošenja odluka.

Grupa autora Taylor i ost. [23] i autori Newman i Couturier [24] navode kako je jedan od ključnih razloga za razvoj strategije na razini visokih učilišta činjenica da tržišne politike danas imaju utjecaj na sustav visokog obrazovanja. Autor Moja [25] u svom radu navodi da je vizija visokih učilišta da ona postanu pokretači promjena, a ne da se prilagođavaju promjenama odnosno vanjskim pritiscima i vanjskim potrebama. Visoka učilišta trebaju prilagoditi svoje resurse, aktivnosti i znanje kako bi strategija mogla biti smjer i djelokrug za postizanje željenih rezultata u promjenjivom okruženju [26].

Načelo i praksa strateškog upravljanja nije samo zadaća više razine menadžmenta (akademske i administrativne uprave) koja je uključena u strateško planiranje. U proces strateškog planiranja potrebno je uključiti sve tri razine upravljanja (operativnu razinu, taktičku razinu i stratešku razinu upravljanja). Visoka učilišta djeluju u kompleksnom i promjenjivom okruženju te su stoga potrebni brzi i učinkoviti strateški odgovori na vanjske čimbenike [27].

Strateško planiranje jedna je od osnovnih aktivnosti koja je odgovornost rukovodstva visokih učilišta. Autori Raluca i Alecsandru [28] identificiraju visoka učilišta, studente i zaposlenike kao tri ključna čimbenika koji predstavljaju istovremeno i ponudu i potražnju na zahtjevnom tržištu visokog obrazovanja i tržištu visoko kvalificirane radne snage.

Pregled literature pokazao je da neki autori smatraju da su sustavi financiranja neki od glavnih čimbenika koji utječu na strategiju visokih učilišta [26], [29], [30].

Izazovi s kojima se danas suočavaju visoka učilišta postavljaju visoke zahtjeve za razvojem novog i inovativnog modela strateške analize i strateškog planiranja čiji je cilj pomoći visokim učilištima da se lakše prilagode novim izazovima i da osiguraju svoju održivost [31]. Grupa autora Whittington i ost. [32] predlaže korištenje Johnsonovog modela za strateško planiranje i analizu na visokim učilištima. Johnsonov model sastoji se od tri ključna elementa: strateški položaj, strateški izbor i strategija na djelu. Isti autori smatraju da je potrebno poduzeti određene akcije kako bi se poboljšao strateški proces na visokim učilištima: primjena metodologije uravnoteženih ciljeva (engl. *Balanced Scorecard - BSC*), izrada upitnika za evaluaciju strateškog procesa i izrada plana upravljanja rizikom.

Autor Zechlin [33] navodi tri instrumenta kao početne točke u strateškom planiranju u visokom obrazovanju: SWOT analiza (engl. *Strenghts, Weaknesses, Opportunities and Threats Analysis*)

- metoda kojom se ocjenjuje strategija poduzeća pomoću četiri ključna faktora: snage, slabosti, prilike i prijetnje, Portfolio analiza (engl. *Portfolio Analysis*) - skup tehnika za vrednovanje odgovarajućih strategija za poželjne kombinacije poslovnih aktivnosti i strateških poslovnih jedinica u poslovnom sustavu i Upravljanje internim ugovorima (engl. *Internal Contract Management*) - instrument koji uključuje pregovore kolektiva o ciljevima i aktivnostima koje se odvijaju između razine visokog učilišta i razine sveučilišta s ciljem postizanja međusobnog dogovora ili ugovora.

Grupa autora Savić i ost. [34] u svom radu navodi karakteristike, standarde, kriterije i indikatore kvalitete e-učenja i prezentiraju višekriterijski hibridni model za evaluaciju kvalitete e-učenja. Predmetni model temelji se na metodi analitičkog hijerarhijskog procesa (engl. *Analytic Hierarchy Process - AHP*), analizi trendova i metodi usporedbe podataka. Razvoj kvalitete e-učenja uključuje definiranje strategije kvalitete kao i definiranje procesa analize kvalitete, dizajna, realizacije, evaluacije i kontinuiranog poboljšanja unutar sustava e-učenja [35].

Grupa autora Wongsathan i ost. [36] istražuje kriterije za donošenje odluka o kvaliteti na visokim učilištima korištenjem metode višekriterijskog odlučivanja - neizraziti analitički hijerarhijski proces (engl. *Fuzzy Analytical Hierarchy Process - Fuzzy AHP*). Navedena metoda primijenjena je u višekriterijskom odlučivanju za odabir elemenata najvećeg prioriteta odnosno prioritetnih elemenata koji u najvećoj mjeri doprinose postizanju kvalitete visokog učilišta.

Različiti autori koriste Fuzzy-metodu AHP prilikom npr. donošenja odluka za odabir najboljeg tehničkog visokog učilišta u Indiji [37], za procjenu kvalitete znanja u sustavima upravljanja znanjem u kontekstu visokog obrazovanja u Tajlandu [38] te oblikovanje i prioritizaciju modela intelektualnog kapitala prilikom procjene doprinosa uspješnosti sveučilišta [39].

Neki autori koriste u svojim radovima kombinaciju metoda za višekriterijsko odlučivanje: metodu AHP i metodu TOPSIS (engl. *Technique for Order Preference by Similarity to an Ideal Solution*). Autori [40] u svom radu koriste metodu AHP i metodu TOPSIS za odabir buduće karijere studenata promatranjem mnogobrojnih mogućnosti kao alternativa na temelju četiri kriterija: područje interesa, mogućnost zaposlenja, trajanje i školarina. Autori Yıldızbaşı i Daneshvar Rouyendegh [41] koriste kombinaciju metode AHP i metode TOPSIS za evaluaciju performansi računalnih programskih jezika na visokim učilištima.

Grupa autora Sanchez i ost. [42] koriste kombinaciju metoda za višekriterijsko odlučivanje: metodu AHP i metodu PROMETHEE za odabir i hijerarhiju pokazatelja održivosti kampusa na visokim učilištima.

Strukturiranje problema jedan je od najvažnijih faza procesa odlučivanja. Dobro postavljen problem ima izravan utjecaj na učinkovito donošenje odluka, posebno kada koristimo višekriterijske metode odlučivanja. Metoda AHP [43] i metoda ANP [44] koriste se za odlučivanje o pitanjima uvođenja e-učenja na visoka učilišta. Prednost metode AHP je u tome što strukturira problem odlučivanja, omogućuje integriranje kvalitativnih i kvantitativnih faktora u odlučivanju, provjerava konzistentnost donositelja odluka, manje je osjetljiva na greške u procjeni zbog redundantnosti uspoređivanja u parovima, omogućuje kratko vrijeme za donošenje odluke uz manje troškove te postojanje programskih alata koji podržavaju metodu. Prednost metode ANP je u tome što ona sadrži strukturu povratnih informacija koje omogućuju mrežno definiranje problema. Za razliku od metode AHP metoda ANP ne predstavlja linearnu hijerarhiju već modelira utjecaje između elemenata mreže.

Autorica Divjak [45] u svom radu navodi da su glavne karakteristike strateškog odlučivanja u hrvatskom visokom obrazovanju: visoka ovisnost visokih učilišta (VU) o Ministarstvu znanosti i obrazovanja; VU je ponekad labavo povezana institucija, npr. sveučilište se sastoji od fakulteta koji često međusobno i ne surađuju; odlučivanje uključuje kompleksne faktore uspjeha; upravljanje VU nije kontinuirano zbog izbora članova uprave svakih 2, 3 ili 4 godine na fakultetima, sveučilištu, ministarstvu; donositelji odluka često nemaju adekvatna znanja, vještine i vizije o strateškom planiranju i vođenju; strateški dokumenti i odluke se pohranjuju u ladicama i često ne provode; ne provodi se nadzor (nadgledanje) provođenja strateških odluka kao ni evaluacija (vrednovanje) učinaka odluka.

Ključni faktori koji strateško odlučivanje u visokom obrazovanju čine teškim su kompleksnost, slaba struktura i nezavisnost te odlučivanje na više razina u hijerarhiji (nacionalna, sveučilišna, fakultetska razina; odjeli i osobna razina). Kriteriji kojima je moguće opisati alternative u strateškom odlučivanju u visokom obrazovanju imaju kvalitativna i kvantitativna svojstva [43] [45].

2.2. Digitalna zrelost i modeli zrelosti

Informacijski sustavi i tehnologije (IST) daju potporu upravljanju organizacijama i pomoć su menadžerima u donošenju odluka.

Kako bi visoka učilišta postigla svoju misiju proizvodnje i prijenosa znanja za društvo, uključujući nastavne i znanstvene aktivnosti, ona postaju složeni i međusobno povezani sustavi u kojima se pomoću IT-a podržavaju složeni procesi, aktivnosti nadzora i upravljanja [46].

U procesu razvoja IT-a tvrtke, ustanove i organizacije prolaze put od slabo organizirane pa sve do sposobnije, održivije strukture koja je sposobna upravljati i optimizirati sve procese. Navedeni rast ili transformacija je nemoguća bez ciljanog upravljanja i učinkovitog korištenja raspoloživih resursa i znanja, što se u konačnici odražava u konceptu razvoja organizacijske zrelosti.

Autori Bacchini i Aceituno [47], [48] definiraju zrelost kao vrlo napredan ili razvijen oblik stanja razvoja i mjeru sposobnosti organizacije za kontinuirano poboljšanje u određenoj disciplini. Dakle, zrelost podrazumijeva evolucijski proces od rane faze prema željenom scenariju ili završnoj fazi.

Model zrelosti (engl. *Maturity Model - MM*) je široko primijenjen alat koji se pokazao korisnim za procjenu poslovnih procesa ili određenih aspekata organizacije jer predstavlja smjernice prema organiziranijem i sustavnijem načinu poslovanja [49].

Modeli zrelosti predstavljaju teorijske koncepte koji poslovnim organizacijama omogućuju da odrede svoje karakteristike u odabranoj problemskoj domeni (arhitektura, upravljanje ljudskim potencijalima, upravljanje procesima i slično) tako da „izmjere“ svoju zrelost prema ljestvicama i kriterijima koje definira konkretan model zrelosti. Modeli zrelosti definiraju osnovne elemente (kriterije, čimbenike) koje organizacija treba usvojiti, a koji su potrebni za uspostavu učinkovitih poslovnih procesa za različite domene poslovanja [50].

Procjena zrelosti može se koristiti za mjerenje trenutne razine zrelosti određenog aspekta organizacije omogućujući dionicima da jasno identificiraju točke prednosti i poboljšanja te prema njima odrede što treba učiniti kako bi postigli veću zrelost u pojedinim područjima.

Autor Crosby [51] je razvio koncept Mreže zrelosti upravljanja kvalitetom (engl. *Quality Management Maturity Grid*). U njegovom se konceptu pet stupnjeva zrelosti organizacije (neizvjesnost, buđenje, prosvjetljenje, mudrost i izvjesnost) može mjeriti sa šest kategorija

(razumijevanje i atributi menadžmenta, status organizacije kvalitete, rješavanje problema, troškovi kvalitete kao postotak prodaje, akcije poboljšanja kvalitete i karakteristična izjava).

Model zrelosti potreban je kako bi se utvrdila postojeća razina zrelosti poslovnih procesa u poduzeću. Rezultati evaluacije trebali bi pomoći u daljnjem razvoju i unapređenju upravljanja procesima u organizaciji. Procjena zrelosti kao i podizanje razina zrelosti je dugotrajan proces i zahtijeva određene napore i od strane menadžmenta i od strane ostalih dionika uključenih u proces poslovanja, ali to je nužan uvjet za razvoj organizacije u smislu modernog pristupa upravljanja poduzećem ili institucijom.

Model postizanja zrelosti (engl. *Capability Maturity Model* - CMM) prepoznat je u različitim vrstama organizacija i u različitim područjima primjene kao način postizanja strateških ciljeva i kontinuiranog poboljšanja organizacijske konkurentnosti. Model je razvijen na Institutu softverskog inženjerstva (engl. *Software Engineering Institute – SEI*) 1987. u Sjedinjenim Američkim Državama [52]. Uloga CMM modela promatra se s aspekta modela za ocjenu zrelosti cjelokupnog poslovnog sustava, a razine zrelosti i područja ključnih procesa prezentiraju se kao osnova za određivanje aktivnosti projekta reinženjerstva poslovnih procesa.

Pregledom literature utvrđeno je da su se modeli postizanja zrelosti razvijali i prilagođavali i za druga područja kao što su graditeljstvo [53], zdravstvo [54], proizvodnja [55], poslovni procesi [56], menadžment kvalitete [57], projektni menadžment [58], IT menadžment [59], menadžment znanja [60], inovacije [61], društvene mreže [62].

Kvalitativnom analizom literature utvrđeno je da su razvijeni i razni drugi modeli zrelosti uključujući: CMMI (engl. *Capability Maturity Model Integration*) [63], OPM3 (engl. *Organizational Project Management Maturity Model*) [64] i SPICE (engl. *Software Process Improvement and Capability Determination*) [65].

Modeli postizanja zrelosti razvijeni su i u području obrazovanja s naglaskom na sposobnost institucija za isporuku uspješnih programa obrazovanja i osiguranje ishoda učenja unutar ponuđenog predmeta.

U *Tablici 1* prikazan je izbor modela postizanja zrelosti razvijenih za primjenu u obrazovnom sektoru te je napravljena usporedna analiza po pet kriterija:

- razina obrazovanja za koji je model razvijen,
- područje primjene modela,
- broj područja i elemenata u modelu,

- pripadajući instrument (da li je razvijen instrument za model),
- vrsta modela (kvalitativan ili kvantitativan model).

Analiza odabranih modela postizanja zrelosti za primjenu u obrazovnom sustavu pokazala je da je samo jedan model primijenjen u osnovnim i srednjim školama (engl. *ICT in School Education Maturity Model - ICTE-MM*) dok se ostali modeli primjenjuju u visokom obrazovanju. Svi analizirani modeli koji se primjenjuju u visokom obrazovanju su kvalitativni, a samo dva analizirana modela imaju razvijen instrument (engl. *Curriculum Design Maturity Model - CDMM* i engl. *Online Course Quality Maturity Model Based on Evening University and Correspondence Education - OCQMM*).

U analiziranim modelima koji se primjenjuju u visokom obrazovanju broj područja varira od 5 do 10, a broj elemenata od 32 do 63.

Analizom literature zaključeno je da su razvijeni modeli zrelosti u obrazovanju usmjereni na kvalitetu e-učenja i online tečajeva, kurikulum, poboljšanje obrazovnih vještina i znanja profesora, na angažman studenta prve godine te samoprocjenu obrazovnih ustanova i proces planiranja.

Analizirani modeli postizanja zrelosti u obrazovnom sektoru većinom ne uključuju strateško planiranje, transfer tehnologije, osiguranje kvalitete ili znanstveno-istraživački rad u visokom obrazovanju.

Tablica 1: Modeli postizanja zrelosti u obrazovnom sektoru (izbor)

Naziv	Autori	Opis	Razina obrazovanja	Područje primjene	Broj područja / elemenata	Razvijen instrument	Kvalitativni / kvantitativni
E-Learning Maturity Model (eMM)	Marshall [66]	Primjenom eMM-a institucije mogu procijeniti kvalitetu svojih aktivnosti vezanih uz e-učenja i usporediti spremnost institucije za razvoj, provedbu i primjenu e-učenja.	visoko obrazovanje	e-učenje	5/35	ne	kvalitativni
Student Engagement, Success and Retention (SESR-MM)	Nelson i ost. [67]	SESR-MM je usredotočen na institucionalne sposobnosti na način da ocjenjuje iskustva i angažmane studenata prve godine.	visoko obrazovanje	studenti (uspjeh studenata)	5/63	ne	kvalitativni
Curriculum Design Maturity Model (CDMM)	Thong i ost. [68]	CDMM je usredotočen na projektiranje institucionalnih kurikuluma koji se sastoje od pet razina zrelosti procesa. Razvijen je i predložak za evaluaciju za svaki modul razvijen u kurikulumu.	visoko obrazovanje	razvoj kurikuluma	5/32	da	kvalitativni
Teaching Capability	Chen i ost. [69]	T-CMM je usredotočen na povećanje kvalitete nastavnog procesa i	visoko obrazovanje	nastavni proces	10/49	ne	kvalitativni

Maturity Model (T-CMM)		poboljšanje obrazovnih vještina i znanja profesora.					
Online Course Quality Maturity Model Based on Evening University and Correspondence Education (OCQMM)	Gu i ost. [70]	OCQMM primjenjuje se za procjenu kvalitete online tečajeva na večernjem sveučilišnom i dopisnom obrazovanju. Također, primjenjuje se u institucijama koje se bave obrazovanjem odraslih pomoću online tečajeva kako bi poboljšale implementacijski postupak i kvalitetu provedbe online tečajeva.	visoko obrazovanje	online nastava	6/24	da	kvalitativni
ICT in School Education Maturity Model (ICTE-MM)	Solar i ost. [71]	ICTE-MM model pruža osnovu za samoprocjenu škola vezanu uz primjenu IKT standarda. Model olakšava proces planiranja jer nije samo dijagnostički alat, već je i koristan ravnateljima prilikom procesa odlučivanja o ulaganju u IKT infrastrukturu.	osnovna i srednja škola	primjena IKT-a	5/25	da	kvalitativni i kvantitativni

2.3. Okviri i instrumenti digitalne zrelosti

Kvalitativnom analizom literature identificirana su 23 okvira za procjenu digitalne zrelosti obrazovnih institucija. Svaki od identificiranih okvira analiziran je prema sljedećim karakteristikama: postojanje pratećeg instrumenta; područja, elementi i opisnici okvira; implementirani razvojni pristupi; područja primjene i primjeri njihovih najboljih praksi.

Slijedi kratak opis svakog analiziranog okvira.

- Ae-MoYS [72] (engl. *Assessing the e-Maturity of your School*) je okvir i online samoevaluacijski upitnik koji se sastoji od 5 područja i 30 opisnika. Koristi kvalitativne i kvantitativne razvojne pristupe, a može se primijeniti u osnovnim i srednjim školama. Ae-MoYS je primjer najbolje prakse u zemljama Europske unije.
- eLearning Roadmap [73] (engl. *eLearning Roadmap*) je okvir i matrica koja se sastoji od 5 područja i 108 opisnika. Koristi kvalitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. eLearning Roadmap je primjer najbolje prakse u Irskoj.
- eLEMÉR [74] (engl. *Self-evaluation on ICT usage at Hungarian School*) je okvir i online samoevaluacijski upitnik koji se sastoji od 4 područja, 40 elemenata i 10 opisnika. Koristi kvalitativni i kvantitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. eLEMÉR je primjer najbolje prakse u Mađarskoj.
- ePOBMM [75] (engl. *The ePortfolios & Open Badges Maturity Matrix*) je okvir i matrica koja se sastoji od 7 područja i 300 opisnika. Koristi kvalitativni razvojni pristup s područjima primjene uglavnom u visokoškolskim ustanovama. Glavna funkcija okvira je omogućiti alat koji će upravljati komunikacijom između polaznika, voditelja edukacije i donositelja odluka. Matricu mogu koristiti menadžeri u obrazovanju kako bi pregledali i/ili planirali promjene koje su potrebne za podržavanje boljeg učenja i djelotvornijeg ePortfelja i prakse otvorenih znački. ePOBMM je primjer najbolje prakse u zemljama Europske unije.
- FCMM [76] (engl. *Future Classroom Maturity Model*) je okvir i online samoevaluacijski upitnik koji se sastoji od 5 područja i 25 opisnika. Koristi kvalitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. FCMM je primjer najbolje prakse u zemljama Europske unije.
- HEInnovative [77] (engl. *The HEInnovate self-assessment tool*) je online samoevaluacijski upitnik koji se sastoji od 8 područja (Vodstvo i upravljanje; Organizacijski kapacitet: financiranje, ljudi i poticaji; Poduzetničko učenje i poučavanje; Priprema i podrška poduzetnicima; Digitalna transformacija i sposobnost;

Transfer znanja i suradnja; Otvorenost institucije za međunarodnu suradnju i Mjerenje utjecaja) koje ispitanici mogu ocijeniti na ljestvici od „neprimjenjivo“ (n/a) do 5, u skladu s time koliko se slažu ili ne slažu s izjavom u odnosu na svoju ustanovu. Na ljestvici 1 predstavlja najnižu, a 5 najvišu ocjenu. HEI Innovative je namijenjen za primjenu u visokoškolskim ustanovama širom svijeta.

- JISC [78] (engl. *Jisc Strategic ICT Toolkit*) je okvir i online samoevaluacijski upitnik koji se sastoji od 6 područja i 69 opisnika. Koristi kvalitativni i kvantitativni razvojni pristup s područjima primjene u visokoškolskim ustanovama. JICS je primjer najbolje prakse u Ujedinjenom Kraljevstvu.
- LIKA [79] (šved. *Ledning, Infrastruktur, Kompetens, Användning*) je okvir i online samoevaluacijski upitnik koji se sastoji od 4 područja i 78 opisnika. Koristi kvalitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. LIKA je primjer najbolje prakse u Švedskoj.
- Microsoft IF & SRT [80] (engl. *Microsoft Innovation Framework & Self-reflection Tool*) je okvir i online samoevaluacijski upitnik koji se sastoji od 4 područja, 16 elemenata i 96 opisnika. Koristi kvalitativni i kvantitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. Microsoft IF & SRT se primjenjuje širom svijeta.
- NAACE SRF [81] (engl. *The Naace Self Review Framework*) je okvir i online samoevaluacijski upitnik koji se sastoji od 6 područja, 11 elemenata i 220 opisnika. Koristi kvalitativni i kvantitativni razvojni pristup s područjima primjene na razini vrtića, osnovne i srednje škole. NAACE SRF je primjer najbolje prakse u Ujedinjenom Kraljevstvu.
- OPEKA [82] (engl. *An Aggregative Questionnaire and Reporting System*) je okvir i online samoevaluacijski upitnik koji se sastoji od 3 područja, 17 elemenata i 145 opisnika. Koristi kvalitativni i kvantitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. OPEKA je primjer najbolje prakse u Finskoj.
- SCALE CCR [83] (engl. *Up-scaling Creative Classrooms in Europe*) je okvir opisan s 8 područja i 28 elemenata. Koristi kvalitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. SCALE CCR je primjer najbolje prakse u Europi.
- School Mentor [84] (engl. *School Mentor*) je okvirni i online samoevaluacijski upitnik koji se sastoji od 6 područja i 150 opisnika. Koristi kvalitativni i kvantitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. School Mentor je primjer najbolje prakse u Norveškoj.

- Venstress [85] (engl. *Venstress*) je online samoevaluacijski upitnik koji je opisan s 20 pokazatelja. Koristi kvalitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. Venstress je primjer najbolje prakse u Nizozemskoj.
- DigComp [86] (engl. *The Digital Competence Framework for Citizens*) služi kao alat za poboljšanje digitalnih kompetencija građana odnosno omogućava građanima samovrednovanje, postavljanje ciljeva učenja, identificiranje mogućnosti usavršavanja i olakšava proces zapošljavanja. Okvir se sastoji od pet područja (Informacije; Komunikacije; Stvaranje sadržaja; Sigurnost i Rješavanje problema) koja uključuju 21 element. Svako područje može se procijeniti na tri razine: Početnik; Samostalni korisnik i Iskusni korisnik. Prva verzija DigComp [86] okvira objavljena je 2013., a unaprijeđena verzija DigComp 2.0 [87] objavljena je 2016. Pet ključnih područja iz prve verzije DigComp okvira dopunjeno je kako slijedi: Informacije i informacijska pismenost; Komunikacije i kolaboracija; Stvaranje digitalnog sadržaja; Sigurnost i Rješavanje problema. Verzija okvira DigComp 2.1 [88] objavljena je 2017. Za razliku od prethodnih verzija gdje se svako područje moglo ocijeniti s tri razine (Početnik; Samostalni korisnik i Iskusni korisnik), u novoj verziji se svako područje može ocijeniti s osam razina: Početnik (Početnik 1 i Početnik 2); Prosječan (Prosječan 1 i Prosječan 2); Napredan (Napredan 1 i Napredan 2) i Visoko specijaliziran (Visoko specijaliziran 1 i Visoko Specijaliziran 2). DigComp okvir i njegove inačice koriste se kao pomoć prilikom kreiranja i podrška su politikama vezanim uz obrazovanje, učenje i zapošljavanje; prilikom planiranja obrazovanja, usavršavanja i zapošljavanja te prilikom procesa procjena i certificiranja. DigComp i njegove inačice primjer su najbolje prakse u zemljama Europske unije.
- DigCompOrg [89] (engl. *A European Framework for Digitally-Competent Educational Organizations*) je sveobuhvatan i općeniti konceptualni okvir koji se odražava na sve aspekte procesa sustavne integracije digitalnog učenja u obrazovnu ustanovu. Sastoji se od 7 područja, 15 elemenata i 74 opisnika. Okvir je prvenstveno namijenjen učenju i poučavanju i aktivnostima koje obrazovna ustanova poduzima kako bi poduprla učenje. Okvir potiče samorefleksiju i samoprocjenu unutar obrazovnih institucija budući da one postupno produbljuju implementaciju digitalnog učenja. Okvir omogućava donositeljima odluka (na lokalnoj, regionalnoj, nacionalnoj i međunarodnoj razini) osmisliti, implementirati i ocijeniti programe, projekte i političke intervencije za integraciju IKT-a u obrazovni sustav. DigCompOrg osmišljen je s ciljem da se usredotoči uglavnom na aktivnosti poučavanja, učenja i procjenu aktivnosti koje

provodi određena obrazovna institucija, ali nije namijenjen za procjenu administrativnih i upravljačkih informacijskih sustava obrazovne institucije. DigCompOrg je primjer najbolje prakse u zemljama Europske unije.

- DigCompEdu [90] (engl. *European Framework for the Digital Competence of Educators*) sastoji se od 22 temeljne kompetencije za nastavnike koje su sistematizirane u 6 područja: Profesionalni angažman; Digitalni resursi; Učenje i poučavanje; Procjena; Osnaživanje učenika i Usmjeravanje učenika za stjecanje digitalnih kompetencija. Koristi kvalitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. DigCompEdu je primjer najbolje prakse u zemljama Europske unije.
- OpenEdu [91] (engl. *A Support Framewrok for Higher Education Institutions*) sastoji se od 10 dimenzija podijeljenih u dvije kategorije: dimenzije jezgre i poprečne dimenzije. Postoji 6 temeljnih dimenzija (Pristup; Sadržaj; Pedagogija; Prepoznavanje; Suradnja i Istraživanje) i 4 poprečne dimenzije (Strategija; Tehnologija; Kvaliteta i Liderstvo). Sve su dimenzije međusobno povezane; dimenzije jezgre nisu važnije od poprečnih. Temeljne dimenzije predstavljaju „što“ otvorenog obrazovanja, a poprečne dimenzije ukazuju na „kako“ to postići. Koristi kvalitativni razvojni pristup s područjima primjene u visokim učilištima kod donošenja strateških odluka vezanih za otvoreno učenje. OpenEdu je primjer najbolje prakse u zemljama Europske unije.
- SELFIE [92] (eng. Self-reflection on Effective Learning by Fostering the Use of Innovative Educational Technologies) alat je koji pomaže školama u implementaciji IKT u učenje, poučavanje i vrednovanje učenika. SELFIE je online samoevaluacijski upitnik kojim se anonimno prikupljaju stajališta učenika, nastavnika i ravnatelja škole o tome kako se tehnologija upotrebljava u njihovoj školi u područjima: Rukovodstvo, Infrastruktura, Stručno usavršavanje nastavnika i Digitalne kompetencije učenika. Glavna svrha alata za samoprocjenu SELFIE je samoprocjena učinkovitosti učenja poticanjem inovacija kroz obrazovne tehnologije. Koristi kvalitativni razvojni pristup s područjima primjene u osnovnim i srednjim školama. SELFIE je primjer najbolje prakse u zemljama Europske unije.
- e-Škole: Uspostava sustava razvoja digitalno zrelih škola u RH (pilot-projekt) [93], [94], [95] Okvir za digitalnu zrelost škola u Republici Hrvatskoj sastoji se od 5 područja koja sadrže 37 elemenata. Područja u okviru su: Planiranje, upravljanje i vođenje (sadrži 6 elemenata), IKT u učenju i poučavanju (sadrži 7 elemenata), Razvoj digitalnih kompetencija (sadrži 7 elemenata), IKT kultura (sadrži 7 elemenata) i IKT infrastruktura (sadrži 10 elemenata). Mjerni instrument za procjenu digitalne zrelosti

škola je rubrika koja se sastoji od 37 redova, koji odgovaraju elementima Okvira za digitalnu zrelost škola i 5 stupaca koji označavaju razine zrelosti: digitalno neosviještena, digitalna početnica, digitalno osposobljena, digitalno napredna i digitalno zrela. Za svaki od 37 elemenata svih 5 razina zrelosti je definirano opisnicama. Instrument za procjenu digitalne zrelosti škola primijenjen je u postupku samovrednovanja i vanjskog vrednovanja na uzorku od 151 škole koje su sudjelovale u pilot projektu.

- Okvir HEDC (engl. *Higher Education Digital Capability*) nudi sveobuhvatan pogled visokim učilištima za mapiranje i mjerenje digitalnih sposobnosti kroz životni ciklus studenata i u konačnici za podršku praktičnim i održivim pristupima digitalnim uslugama i online učenju [96].

Na temelju kvalitativne analize literature dopunjen je inicijalni pregled [97] postojećih okvira za procjenu digitalne zrelosti obrazovnih institucija. Dopunjeni pregled je dostupan u *Tablici 2*. Kvalitativnom analizom literature zaključeno je da ne postoji sveobuhvatni koncept ispitivanja digitalne zrelosti visokih učilišta, već su postojeći okviri generički okviri ili okviri koji imaju primjenu u osnovnim i srednjim školama. Pregled postojećeg stanja koji je obuhvatio okvire digitalne zrelosti obrazovnih institucija, polazna je točka za provođenje istraživanja razvoja Okvira za digitalnu zrelost visokih učilišta i Instrumenta za procjenu digitalne zrelosti visokih učilišta. Primjenom Okvira digitalne zrelosti visoka učilišta mogu planirati i provoditi primjenu IKT-a, a primjenom instrumenta procjenjuju razinu zrelosti svoje institucije.

Tablica 2: Pregled okvira za procjenu digitalne zrelosti obrazovnih institucija

Naziv	Vrsta	Područja /Elementi /Opisnici	Pristup	Razina	Sudionici	Područje
Ae-MoYS	Okvir i online samoevaluacijski upitnik	5/-/30	Kvalitativni / kvantitativni	osnovna i srednja škola	profesori, ravnatelji	EU
E-LEARNING ROADMAP	Okvir i matrica	5/-/27x4	Kvalitativni	osnovna i srednja škola	ravnatelji	Irska
eLEMER	Okvir i online samoevaluacijski upitnik	4/40/100	Kvalitativni / kvantitativni	osnovna i srednja škola	učenici profesori	Mađarska
ePOBMM	Okvir i matrica	7/-/60x5	Kvalitativni	Većinom VU	rukovodstvo	EU
FCMM	Okvir i online samoevaluacijski upitnik	5/-/5x5	Kvalitativni	osnovna i srednja škola	profesori, ravnatelji, stručni suradnici	EU
HEInnovative	Okvir i online samoevaluacijski upitnik	8 područja	Kvalitativni	VU	profesori, ravnatelji, stručni suradnici	Svijet
JISC	Okvir i online samoevaluacijski upitnik	6/-/69	Kvalitativni / kvantitativni	VU	rukovodstvo	Ujedinjeno Kraljevstvo

LIKA	Okvir i online samoevaluacijski upitnik	4/-/78	Kvalitativni	osnovna i srednja škola	profesori	Švedska
MICROSOFT IF&SRT	Okvir i online samoevaluacijski upitnik	4/16/16x6	Kvalitativni / kvantitativni	osnovna i srednja škola	ravnatelji	Svijet
NACCE SRF	Okvir i online samoevaluacijski upitnik	6/11/55x4	Kvalitativni / kvantitativni	vrtići, osnovne i srednje škole	profesori, ravnatelji, stručni suradnici, konzultanti	Ujedinjeno Kraljevstvo
OPEKA	Okvir i online samoevaluacijski upitnik	3/17/145	Kvalitativni / kvantitativni	osnovna i srednja škola	profesori	Finska
SCALE CCR	Okvir	8/28/-	Kvalitativni	osnovna i srednja škola	rukovodstvo	Europa
SCHOOL MENTOR	Okvir i online samoevaluacijski upitnik	6/-/30x5	Kvalitativni / kvantitativni	osnovna i srednja škola	ravnatelji	Norveška
VENSTRESS	Online samoevaluacijski upitnik	20 indikatora	Kvantitativni	osnovna i srednja škola	profesori, ravnatelji, stručni suradnici	Nizozemska
DigComp	Okvir	5/21/-	Kvalitativni	osnovna i srednja škola, visoka učilišta (VU)	profesori	Europska unija

DigComp 2.0	Okvir	5/21/-	Kvalitativni	osnovna i srednja škola, visoka učilišta (VU)	profesori	Europska unija
DigComp 2.1	Okvir	5/21/-	Kvalitativni	osnovna i srednja škola, visoka učilišta (VU)	profesori	Europska unija
DigComOrg	Okvir	7/15/74	Kvalitativni	osnovna i srednja škola, visoka učilišta (VU)	profesori, ravnatelji	Svijet
DigComEdu	Okvir	6/22/-	Kvalitativni	osnovna i srednja škola, visoka učilišta (VU)	studenti, profesori, rukovodstvo	Europska unija
OpenEdu	Okvir	10/41/317	Kvalitativni	Visoka učilišta (VU)	rukovodstvo	Europska unija
SELFIE	Online samoevaluacijski upitnik	5/-/74	Kvalitativni	osnovna i srednja škola	učenici, profesori, rukovodstvo	Europska unija
e-Škole	Okvir i online samoevaluacijski upitnik	5/37	Kvalitativni	osnovna i srednja škola	profesori, rukovodstvo	Republika Hrvatska
HEDC	Okvir	16/70	Kvalitativni	Visoka učilišta (VU)	rukovodstvo	Svijet

3. Ciljevi, istraživačka pitanja, hipoteze i metodologija istraživanja

Okvir za digitalnu zrelost visokih učilišta sadrži identificirana područja i elemente važne za postizanje digitalne zrelosti visokih učilišta. Na temelju Okvira za digitalnu zrelost visokih učilišta može se razviti Instrument za procjenu razine digitalne zrelosti visokih učilišta, a može se ugraditi i mogućnost davanja preporuke za podizanje razina zrelosti pojedinih područja i elemenata definiranih u Okviru za digitalnu zrelost visokih učilišta.

3.1. Ciljevi, istraživačka pitanja, hipoteze istraživanja

U skladu s navedenim, identificirani su sljedeći **ciljevi istraživanja:**

C1: Razviti okvir za digitalnu zrelost visokog učilišta.

C2: Razviti instrument za procjenu digitalne zrelosti visokog učilišta.

C3: Procijeniti razinu digitalne zrelosti nekoliko visokih učilišta.

Istraživačka pitanja:

IP1: Koja su područja i elementi važni za postizanje određene razine digitalne zrelosti visokih učilišta?

IP2: Koja je trenutna razina digitalne zrelosti visokih učilišta u Republici Hrvatskoj?

Hipoteze istraživanja:

H1: Razvijeni okvir za digitalnu zrelost visokih učilišta bit će valjan.

Validacija ODZVU-a bit će kvalitativna i kvantitativna te će se provesti primjenom metode fokus grupa [98], metode sortiranja karata (engl. *Q-sorting method*) [99], primjenom metode Delphi [100] i primjenom pokazatelja valjanosti sadržaja (engl. *Content validity ratio – CVR*) [101] s ciljem usuglašavanja područja i elemenata relevantnih za digitalnu zrelost visokih učilišta.

H2: Razvijeni Instrument za mjerenje digitalne zrelosti visokih učilišta bit će pouzdan.

Validacija IPDZVU izvršit će se provedbom pilot-istraživanja procjene digitalne zrelosti visokih učilišta na nekoliko visokih učilišta u Republici Hrvatskoj u kojem će sudjelovati više ispitanika s iste institucije. Ispitanici će na visokim učilištima u postupku samovrednovanja procjenjivati digitalnu zrelost svog visokog učilišta te će se vršiti usporedba njihovih procjena primjenom pouzdanosti procjene između ispitanika [102].

3.2. Metodologija istraživanja

Istraživanje slijedi korake metodologije znanosti o dizajniranju (engl. *Design Science Research - DSR*) kroz tri istraživačka ciklusa: *ciklus relevantnosti, ciklus rigoroznosti* i *ciklus dizajniranja* [103] *(Slika 1).*

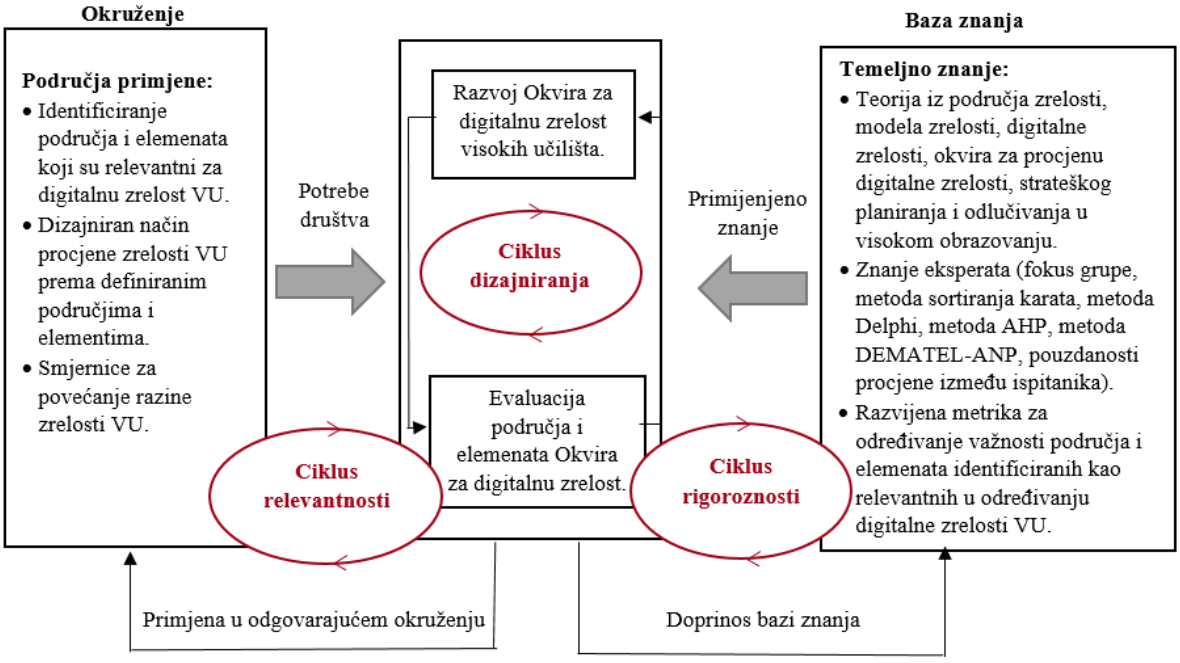

Slika 1: Okvir za digitalnu zrelost visokih učilišta [izvor: rad autorice, prilagođeno prema [103]]

Ciklus relevantnosti uključuje studente, profesore, upravu i sve dionike povezane s visokim učilištem, odnosno sustavom koji se istražuje te uključuje sljedeće podatke iz područja primjene: identificiranje područja i elemenata koji su relevantni za digitalnu zrelost VU-a,

dizajniran način procjene zrelosti VU prema definiranim područjima i elementima te omogućene smjernice za povećanje razine zrelosti VU što je ujedno i doprinos društvu.

Ciklus rigoroznosti pomoću različitih izvora znanja utječe na razvoj artefakta. Rigoroznost se u ovom istraživanju očituje u: teorijskom znanju iz područja strateškog planiranja i odlučivanja u visokom obrazovanju, modela zrelosti, digitalne zrelosti, razvoja modela zrelosti na temelju sustavne analize literature i znanja eksperata dobivenih primjenom metode fokus grupe, metode sortiranja karata, primjene pouzdanosti procjene između ispitanika (engl. *inter-rater reliability*), metode AHP, metode ANP i primjenom metode Delphi te razvojem metrike za određivanje važnosti područja i elemenata identificiranih kao relevantnih u određivanju digitalne zrelosti VU. Ciklus rigoroznosti ostvarit će doprinos znanosti jer će pridonijeti sistematizaciji okvira za digitalnu zrelost te modela zrelosti i povećanju znanja iz područja digitalne zrelosti; razvoju okvira za digitalnu zrelost visokih učilišta i razvoju instrumenta za mjerenje digitalne zrelosti visokih učilišta.

Ciklus dizajniranja služi da bi se inicijalan skup artefakata dobivenih kroz ciklus relevantnosti i ciklus rigoroznosti evaluirao i uskladio.

DSR predstavlja novo znanje i objašnjava kako artefakti, koji su rezultat istraživanja, u obliku konstrukta, tehnika i metoda, modela, unaprijeđene tehnologije predstavljaju valjani znanstveni doprinos. DSR istraživanje se provodi kroz pet koraka [103].

1. Identifikacija problema
2. Prijedlog artefakta
3. Razvoj artefakta
4. Evaluacija
5. Zaključak rezultata istraživanja.

Istraživanje je temeljeno na mješovitim metodama odnosno na kombiniranju kvalitativnih i kvantitativnih metoda. Epistemološki pristup je pragmatizam jer omogućava kombinaciju različitih metoda istraživanja i prikupljanja podataka, ali i druge epistemološke pristupe. Plan istraživanja prikazan je u *Tablici 3*.

Tablica 3: Plan istraživanja

	Ciljevi faze	Metode	Rezultati
1. Identifikacija problema	Definirati i opisati digitalnu zrelost u području obrazovanja te kako se ona procjenjuje postojećim mehanizmima	Analiza literature	1. Postoje okviri za procjenu digitalne zrelosti institucija, no ne i za VU. 2. Na temelju rezultata prethodnih istraživanja utvrđeno je da u problemima odlučivanja u VU-ima postoje zavisnosti među elementima strukture kojima se opisuju problemi odlučivanja. 3. Na procjenu razine digitalne zrelosti utječe velik broj elemenata koji se izražavaju kvalitativno ili kvantitativno.
2. Prijedlog artefakata	Identificirati područja i elemente koji su relevantni za digitalnu zrelost visokog učilišta.	Analiza literature Metoda fokus grupe Metoda Delphi Metoda sortiranja karata Pokazatelj valjanosti sadržaja	Identificirana područja i elementi ODZVU-a.
	Odrediti težine pojedinih područja i elemenata.	Metoda DEMATEL (ANP) (eksperti)	Mrežna struktura područja kroz klastere i čvorove.
		Metoda AHP (eksperti)	Izračun važnosti (težine, prioriteti) elemenata.
	Definirati način određivanja zrelosti na razini elemenata.	Rubrika	Za svaki element definirane su izjave koje opisuju svaku razinu zrelosti te je implementirana mogućnost identificiranja međurazine.
3. Razvoj artefakata	Integrirati rezultate prethodne faze u cjelokupni model za procjenu digitalne zrelosti	Složene metode agregacije Kompozitni indeks Metoda Dex	Teorijski okvir za procjenu digitalne zrelosti takav da: 1. Omogućava evaluaciju visokog učilišta s pozicije svakog pojedinog elementa. 2. Temeljem procjena iz 1 kreira se završna kvantitativna i kvalitativna procjena (klasifikacija) digitalne zrelosti VU-a.

4. Evaluacija	Evaluirati ODZVU i IPDZVU	Delphi, pouzdanost procjene između ispitanika, pokazatelj valjanosti sadržaja, pilot istraživanje, upitnik	Evaluiran ODZVU i IPDZVU spreman za primjenu: a) Područja i elementi usuglašeni i potvrđeni. b) Mrežna struktura identificirana, važnosti područja i elemenata potvrđene. c) Rubrika za procjenu zrelosti VU-a po svakom elementu evaluirana. d) Način izračuna važnosti (težina, prioriteta) elemenata evaluiran. e) Način određivanja završne procjene digitalne zrelosti evaluiran i potvrđen. f) Cjelokupna ocjena ODZVU-a i IPDZVU-a. Pregled razina digitalnih zrelosti VU-a u RH.
5. Zaključak	Demonstrirati ODZVU i IPDZVU	Izrada znanstvenih radova i primjenjivati na VU	ODZVU i IPDZVU korišteni u praksi.

3.2.1. Identifikacija problema

Tema ove doktorske disertacije je Okvir za digitalnu zrelost visokih učilišta i instrument za njezinu procjenu. U fazi identifikacije problema odnosno na početku istraživanja provedena su tri glavna koraka temeljena na metodologiji PRISMA (engl. *Preferred Reporting Items for Systematic Reviews and Meta-Analyses*): pretraživanje literature, odabir prihvatljivih radova i ekstrakcija te sažetak podataka [8]. Sustavna analiza literature provedena je u bazama podataka EBSCO, SCOPUS, ScienceDirect. U fazi odabira prikladnih radova izuzeti su duplicirani radovi s viškom informacija i studije temeljene na rezultatima naslova i pregledom sažetaka. U prvoj je fazi (tijekom 2017.) ukupno pronađeno 359 članaka, a nakon selekcije analizirano ih je 39. Baze su pretraživane za pojmove zrelost (engl. *maturity*), model zrelosti (engl. *maturity model*) i digitalna zrelost (engl. *digital maturity*) u kombinaciji s riječima visoko učilište (engl. *higher education institution*) i okvir (engl. *framework*). Tijekom 2019. revidirani su okviri za procjenu digitalne zrelosti institucija. Druga faza analize literature uključila je dodatnih 12 članaka tijekom koje su identificirana 23 okvira za procjenu digitalne zrelosti obrazovnih institucija, Okvir za digitalnu zrelost škola razvijen u sklopu pilot-projekta „e-Škole“ i 24 članka o strateškom planiranju i odlučivanju o IKT-u u visokom obrazovanju.

Sustavna analiza literature pokazala je da ne postoji sveobuhvatni koncept ispitivanja digitalne zrelosti visokih učilišta što je ujedno polazna je točka za provođenje istraživanja u sklopu ove doktorske disertacije odnosno razvoja Okvira za digitalnu zrelost visokih učilišta i Instrumenta za procjenu digitalne zrelosti visokih učilišta. Primjenom Okvira digitalne zrelosti visoka učilišta mogu planirati i provoditi primjenu IKT-a, a primjenom instrumenta procjenjuju razinu zrelosti svoje institucije.

Detaljan pregled analize literature prikazan je u poglavljima: 2.1. Odlučivanje o informacijsko-komunikacijskoj tehnologiji na visokim učilištima (2.1.1. Pojam odlučivanja i vrste poslovnih odluka, 2.1.2. Strateško odlučivanje o informacijsko-komunikacijskoj tehnologiji na visokim učilištima), 2.2. Digitalna zrelost i modeli zrelosti i 2.3. Okviri i instrumenti digitalne zrelosti.

3.2.2. Prijedlog artefakta

Artefakti koji se predlažu u ovom radu su Okvir za digitalnu zrelost visokih učilišta (ODZVU) i Instrument za procjenu digitalne zrelosti visokih učilišta (IPDZVU). ODZVU se sastoji od područja i elemenata koji su relevantni za digitalnu zrelost VU-a. Instrument obuhvaća metodu prikupljanja podataka o razinama zrelosti za svaki element i metodu za agregiranje prikupljenih podataka te određivanje ukupne razine zrelosti. Primjenom artefakta ODZVU-a, VU mogu strateški planirati i donositi odluke o uvođenju IKT-a u učenje, poučavanje i poslovanje. Primjenom IPDZVU-a VU može izvršiti samovrednovanje čiji rezultat je razina digitalne zrelosti na kojoj se VU nalazi, kao i povratna informacija o tome koja područja i elemente treba poboljšati kako bi se podigla razina ukupne digitalne zrelosti VU-a.

3.2.3. Razvoj artefakta

Artefakt ODZVU je razvijen korištenjem sljedećih metoda:

a) Analiza literature, fokus grupe – na temelju rezultata analize relevantne literature kao i područja i elemenata okvira digitalne zrelosti obrazovnih institucija, određen je inicijalni popis područja i elemenata ODZVU-a. Metoda fokus grupe primijenjena je s ciljem provedbe grupne dubinske diskusije te je temeljem dobivenih rezultata nadograđen inicijalni popis područja i elemenata digitalne zrelosti VU koji su definirani u prethodnom koraku temeljem analize literature [98].

b) Metoda Delphi [100] i metoda sortiranja karata [99] – primijenjene su za finalno određivanje područja i elemenata unutar predloženih područja te je izvršen izračun pokazatelja valjanosti sadržaja [101]. Metodom Delphi su specificirana područja i elementi unutar područja na temelju usuglašavanja stavova nezavisnih eksperata kroz više ciklusa. U istraživanju su sudjelovali eksperti koji imaju dvostruku ekspertizu: upravljanje VU-om i bavljenje IKT-om na VU. Nakon provedbe metode Delphi, metodom sortiranja karata s drugom nezavisnom skupinom eksperata provjerena je valjanost područja i elemenata ODZVU-a usuglašenih kroz metodu Delphi [100].

Kroz navedene metode provjerit će se hipoteza **H1** i ostvarenje cilja istraživanja **C1**.

Artefakt IPDZVU dizajniran će se primjenom sljedećih metoda:

a) Rubrika je jednodimenzionalna ili višedimenzionalna tablica kriterija postavljenih na nekoliko razina koja se primjenjuje za različite procjene. Rubrika se najčešće primjenjuje u obrazovanju kao alat za potporu učenju, ocjenjivanju i vrednovanju te

profesionalnom razvoju. Prema autoru Knightu [104] rubrika je instrument za objektivnu i autentičnu procjenu visokoškolske ustanove. Preporuka je da se rubrika sastoji od četiri ili pet razina [105]. U ovom radu rubrika se primjenjuje kao instrument za procjenu zrelosti VU u kojem su se za svaki element ODZVU-a definirale izjave koje opisuju svaku od pet razina zrelosti.

b) Metoda za strukturiranje problema odlučivanja – DEMATEL predstavlja metodu za projektiranje i analiziranje strukturnih modela s povratnim vezama između elemenata. Potreba za određivanjem veza između područja i elemenata IPDZVU-a temelji se na prepoznatoj specifičnosti odlučivanja u visokom obrazovanju koja se odnosi na zavisnost između područja i elemenata problema odlučivanja [106].
c) Metode za višekriterijsko odlučivanje – metode AHP i ANP [107] primijenjene su za određivanje težinskih koeficijenata područja i elemenata. Metodom AHP i metodom ANP te primjenom grupnog odlučivanja eksperata dobiveni su težinski koeficijenti područja i elemenata digitalne zrelosti koji su potrebni za procjenu konačne razine zrelosti nekog VU-a.
d) Metoda DEX (engl. *Decision EXpert*) koristi kvalitativne varijable što ju čini prikladnom za procjenu razine digitalne zrelosti VU-a na temelju razvijene rubrike [108].
e) Kompozitni indeks je primjenjen za usporedbu ranga VU-a prema razinama zrelosti. Opravdanost njegove primjene leži u tome što se kompozitni indeks koristi u istraživanjima društvenih pojava kada je potrebno promatrati više varijabli da bi se dobila kompleksna ocjena odnosno kako bi se pratilo više dimenzija nekog fenomena [109] što je slučaj u ovom istraživanju.

Kroz primjenu navedenih metoda ostvarit će se cilj istraživanja **C2**.

3.2.4. Evaluacija

ODZVU obuhvaća potvrđena područja i elemente digitalne zrelosti VU-a. IPDZVU sadrži opis elemenata za pet razina zrelosti: Digitalno neosviješteno VU; Digitalno početno VU; Digitalno osnaženo VU; Digitalno sposobno VU i Digitalno zrelo VU te metodologiju određivanja kvantitativne razine digitalne zrelosti VU-a i usporedba ranga digitalne zrelosti VU-a.

U fazi evaluacije ODZVU-a primijenjene su metoda Delphi i metoda sortiranja karata kako bi se provjerila hipoteza H1 vezana uz valjanost ODZVU-a. Metoda Delphi i metoda sortiranja karata provedene su s dva različita/nezavisna skupa eksperata – predstavnika različitih VU-a u Hrvatskoj (najmanje 20 eksperata). Cilj primjene te dvije metode je provjera valjanosti okvira odnosno hipoteze **H1**.

U fazi razvoja metrike za procjenu razine digitalne zrelosti primijenjene su metoda AHP i metoda ANP za izračun težinskih koeficijenata područja i elemenata, na temelju procjena eksperata, a stabilnost dobivenih rezultata provjerena je primjenom analize osjetljivosti. Evaluacija IPDZVU-a provedena je na uzorku VU-a kako bi se provjerila pouzdanost IPDZVU-a. Proveden je postupak samovrednovanja na najmanje tridesetak VU-a u RH od strane dva ispitanika po VU te usporedba procjena kao i izračun pouzdanosti procjene između ispitanika. Izračunom pouzdanosti procijenjen je stupanj suglasnosti različitih eksperata u procjenama. Izračun pouzdanosti je koristan jer ispitanici ne moraju nužno tumačiti odgovore na isti način, a isto tako mogu se slagati ili ne slagati oko pojedinih odgovora ili vještina koje se procjenjuju [99].

Kroz navedene metode provjerena je hipoteza **H2**.

Procjena digitalne zrelosti VU-a izvršena je na temelju prikupljenih podataka samovrednovanjem i primjenom razvijene metrike za procjenu razine digitalne zrelosti VU-a. Omogućena je i usporedba ranga VU-a prema razini digitalne zrelosti primjenom kompozitnog indeksa. Kroz primjenu navedenih metoda, ostvarit će se istraživački cilj **C3**.

Na *Slici 2* prikazane su metode koje se koriste u evaluaciji ODZVU-a i IPDZVU-a.

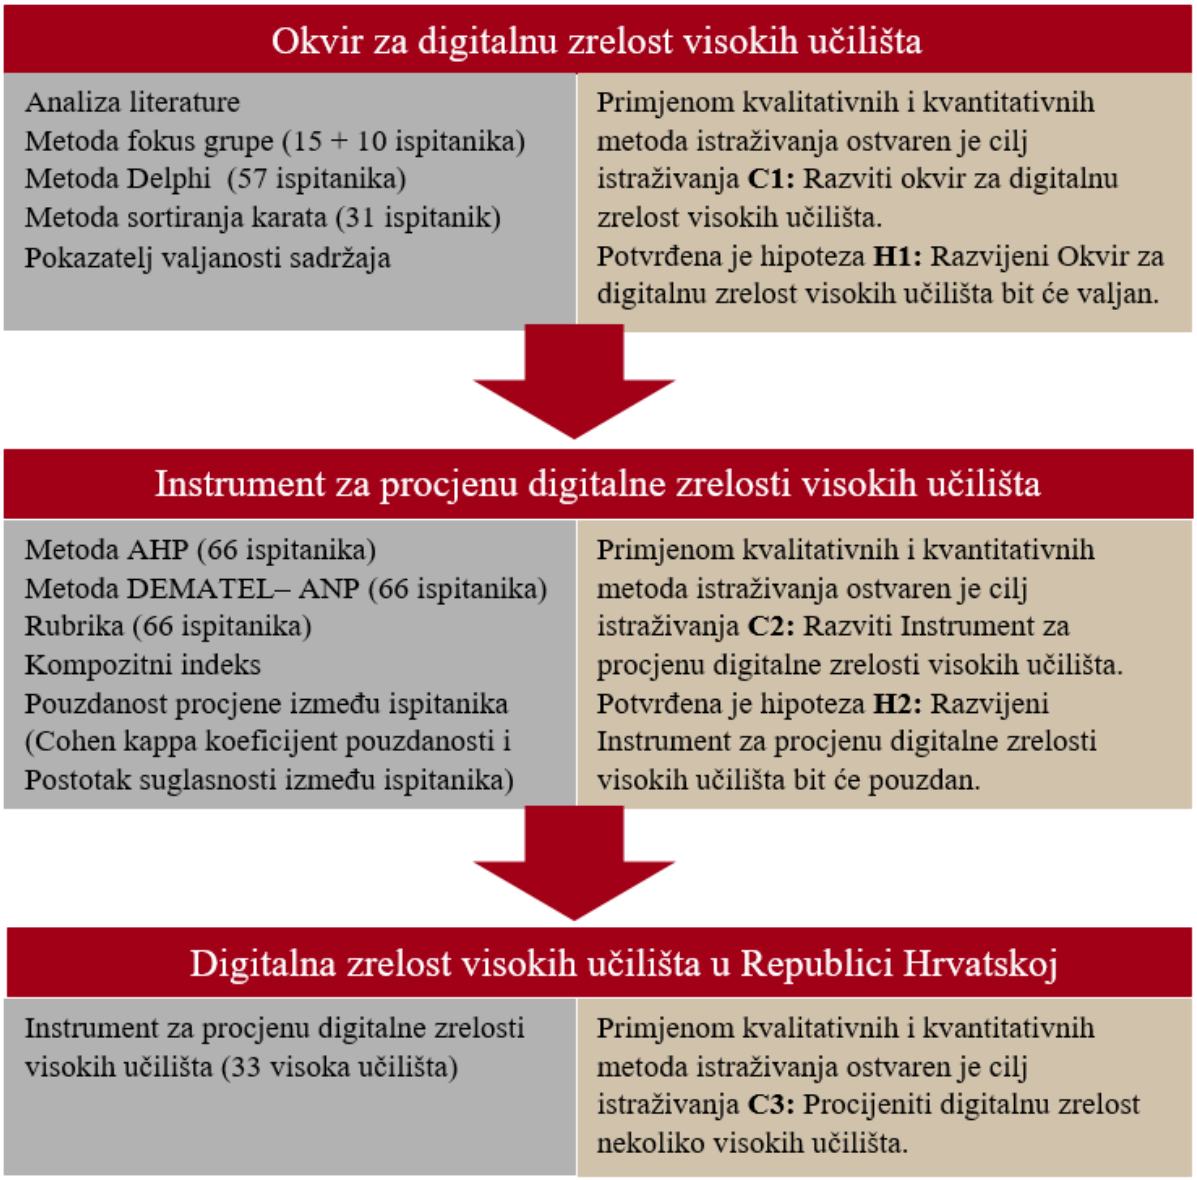

Slika 2: Evaluacija ODZVU-a i IPDZVU-a

4. Opisi metoda za razvoj modela zrelosti (okvira i instrumenta)

4.1. Metoda fokus grupe

Kvalitativne metode istraživanja osmišljene su kako bi se istražilo ljudsko ponašanje i njegova značenja te utjecaj sociokulturnog konteksta u kojem se ponašanje događa [110]. Metoda fokus grupe je kvalitativni oblik istraživanja koji uključuje grupnu diskusiju o nekoj zadanoj temi. Osnovni cilj fokus grupe je potaknuti dubinsku diskusiju kojom će se istražiti vrijednosti ili stavovi ispitanika prema nekom problemu ili temi. Informacije prikupljene ovom metodom u funkciji su konstrukcije i/ili testiranja modela koji najbolje oslikava istraživani problem.

Metoda fokus grupe može se definirati kao strukturirana i usredotočena rasprava s malom skupinom ljudi koju vodi moderator (moderator) ili koristi tim za moderiranje [111] kako bi se pomoću skupa otvorenih pitanja dobili kvalitativni podaci. Izraz fokus ima važno značenje - naglašava da će grupa raspravljati o preciznoj temi od interesa, a ne o općenitostima [112].

Fokus grupe mogu se koristiti za prikupljanje informacija o novim temama, stvoriti nove hipoteze, ocijeniti instrumente i programe ili bolje objasniti raspon i dubinu stavova, vjerovanja i iskustava unutar definirane populacije [113]–[115], a istovremeno su korisne kada istraživač želi procijeniti moguće učinke grupne interakcije na zanimljivu temu [115]–[117].

Fokus grupe su oblik grupnog intervjua, ali bitno je razlikovati te dvije metode. Grupni intervju uključuje istovremeno intervjuiranje određenog broja ljudi, a naglasak je na pitanjima i odgovorima između istraživača i sudionika intervjua. Fokus grupa se, međutim, oslanja na interakciju unutar grupe koja se temelji na temi koju je zadao istraživač.

U usporedbi s promatranjem, fokus grupa omogućuje prikupljanje veće količine informacija u kraćem roku. U metodi opažanja čeka se da se dogodi promatrano ponašanje, dok u fokus grupi moderator postavlja pitanja sudionicima. U ovom smislu fokus grupe nisu prirodni već organizirani događaji.

Fokus grupe se mogu upotrebljavati u preliminarnoj i eksploratornoj fazi istraživanja [114], [118], tijekom istraživanja kako bi evaluirali ili izradili plan aktivnosti [118], mogu se koristiti ili kao samostalna metoda ili kao dio istraživanja s ostalim metodama, posebno za triangulaciju i provjeru valjanosti. Fokus grupe mogu pomoći pri ispitivanju ili generiranju hipoteza te kod razvoja čestica ili koncepta za upitnike i intervjue [118].

Glavna svrha istraživanja fokus grupa je ukazati na stavove, osjećaje, vjerovanja, iskustva i reakcije ispitanika na način na koji to ne bi bilo izvedivo pomoću drugih metoda, npr.

promatranja, intervjuiranja pojedinaca ili ankete. Ti stavovi, osjećaji i uvjerenja mogu biti djelomično neovisni o grupi ili njenom društvenom okruženju, ali vjerojatnije je da će se otkriti socijalnim okupljanjem i interakcijom koja podrazumijeva fokus grupu. Fokus grupe često se primjenjuju kada postoje razlike u moći između sudionika i donositelja odluka ili profesionalaca, te kada se želi istražiti stupanj konsenzusa o određenoj temi [114].

Provođenje metode fokus grupe obično traje 1-2 sata, a djeluju u skladu s unaprijed određenim proceduralnim pravilima. U radu fokus grupe sudjeluje moderator koji vodi raspravu i osigurava da svi sudionici imaju priliku izraziti svoje stavove. Unutar područja kvalitativne metodologije, fokus grupe se često nalaze između promatranja u prirodnom okruženju i pojedinačnih intervjua. Odnosno, mogućnost spontane grupne interakcije i dijaloga u fokus grupama može približiti grupno ponašanje promatrano u prirodnim okruženjima, dok upotreba moderatora za vođenje rasprave u fokus grupi, u skladu s unaprijed određenim temama, približava pojedinačne intervjue. Autor Kitzinger [117] navodi da je interakcija u fokus grupama ključna jer interakcija između sudionika ističe njihov pogled na svijet, jezik kojim se koriste u diskusiji, vjerovanja i vrijednosti o situaciji [118]. Interakcija ne omogućuje samo raspravu između sudionika već omogućava i ponovno procjenjivanje vlastitih mišljenja.

Preporučeni broj ljudi u grupi obično je šest do deset [119], ali neki su istraživači upotrijebili do petnaest osoba [120] ili samo četiri [117]. Brojevi grupa također se razlikuju, neka istraživanja koriste samo jedan sastanak sa svakom od nekoliko fokus grupa [121], druge se više puta susreću s istom grupom. Autorica Gibbs [118] navodi da nije uvijek lako identificirati najprikladnije sudionike u fokus grupi. Naime, ako je grupa previše heterogena, bilo s obzirom na spol ili u pogledu profesionalne perspektive, razlike među sudionicima mogu značajno utjecati na njihov doprinos. Alternativno, ako je grupa homogena s obzirom na specifične karakteristike; različita mišljenja i iskustva možda neće biti otkrivena. Sudionici se trebaju osjećati ugodno jedni s drugima. Susret s drugima sudionicima za koje smatraju da imaju slične karakteristike ili razine razumijevanja za određenu temu bit će motivirajući za razliku od susreta s sudionicima za koje smatraju da su različiti [115].

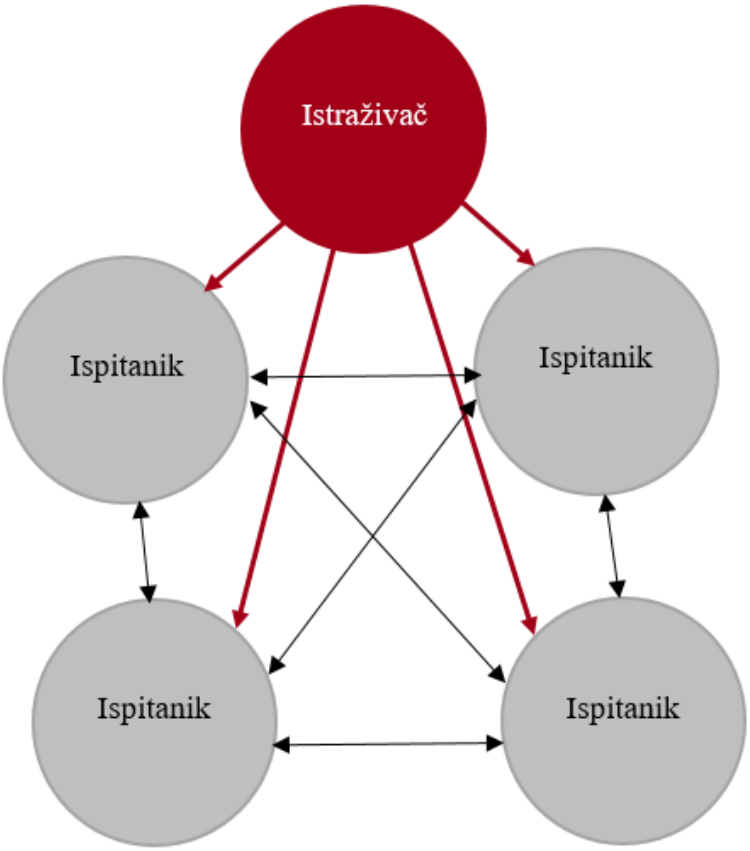

Slika 3: Interakcija unutar fokus grupe

Nakon što je fokus grupa organizirana, uloga moderatora grupe postaje presudna, posebno u smislu pružanja jasnih objašnjenja svrhe grupe, pomaganja sudionicima da se osjećaju ugodno i olakšavanja interakcije između članova grupe *(Slika 3).* Tijekom provedbe fokus grupe moderatori će trebati potencirati raspravu postavljanjem otvorenih pitanja te izazvati sudionike, posebice kako bi ukazali na različitosti ljudi i iznudili raznovrstan niz značenja na temu o kojoj se raspravlja. Moderatori također moraju osigurati da svi sudionici sudjeluju u raspravi i dobivaju priliku za govor. U isto vrijeme moderatori se potiču da ne pokazuju previše odobravanja [114], kako ne bi favorizirali pojedine sudionike. Moderatori moraju izbjegavati davanje osobnih mišljenja kako ne bi utjecali na sudionike prema nekom određenom stavu ili mišljenju.

U usporedbi s drugim kvalitativnim tehnikama prikupljanja podataka, metoda fokus grupe može brže i s manje troškova producirati rezultate. Metodom fokus grupe lakše je upravljati jer koristi prirodniji oblik komunikacije (npr. grupnu raspravu) i potiče grupnu interakciju [113]–[115].

4.2. Metoda Delphi

Pedesetih godina prošlog stoljeća korporacija RAND[1] razvila je metodu Delphi kako bi dobila najpouzdaniji konsenzus grupe stručnjaka [122]. Delphi se može okarakterizirati kao metoda za strukturiranje procesa grupne komunikacije na način da se grupa pojedinaca nezavisno suočava sa složenim problemom [123]. U literaturi se Delphi istraživanja različito terminološki određuju kao postupak [124], anketa [125], tehnika [126]–[128], metodologija [129],[130] i metoda [123], [131]–[134]. Metodološka strukturiranost pripreme i provedbe istraživanja opravdava korištenje termina metoda. Metoda Delphi, kao jedinstvena metoda za donošenje i rafiniranje grupne prosudbe, temelji se na obrazloženju da je skupina stručnjaka bolja od jednog stručnjaka kad ne postoje egzaktna znanja [135]. Metodu Delphi karakteriziraju četiri ključna elementa [136]: anonimnost panelista, koja im omogućuje slobodno izražavanje svog mišljenja bez pritiska da se usklade s grupnim razmišljanjima; ciklus, koji omogućuje panelistima da preciziraju svoje stavove na temelju povratnih informacija o grupi u svakom krugu; povratne informacije koje informiraju paneliste o perspektivama ostalih panelista, pružajući mogućnost pojašnjenja i/ili promjene mišljenja; statistička analiza odgovora koja omogućava kvantitativnu analizu i interpretaciju podataka.

Cilj metode Delphi je postizanje konsenzusa među stručnjacima prikupljanjem podataka pomoću niza ciklusnih faza upitnika [122], [137]. Ovaj ciklusni postupak uključuje više ciklusa izrade upitnika, a svaki se temelji na rezultatima prethodnog kruga [137]. Nakon svakog kruga rezultati se bilježe, analiziraju i vraćaju stručnjacima na ponovnu procjenu. Tijekom više ciklusa, od stručnjaka se traži da razmotre složene odgovore svih panelista i razmisle o vlastitim odgovorima. Ovaj sustav povratnih informacija omogućuje stručnjacima da preispitaju svoje početno mišljenje i tako pomognu u razvoju rješenja problema istraživanja na sinergijski način. Snage metode Delphi su anonimnost stručnjaka, kontrolirana povratna informacija i mogućnost provođenja različitih statističkih analiza kako bi se pomoglo u interpretaciji podataka [137]. Ključni princip metode Delphi je tvrdnja da je mišljenje grupe snažnije od mišljenja pojedinaca [138]. Najvažniji preduvjeti za upotrebu metode Delphi su potreba za prosudbom stručnjaka, grupni konsenzus za postizanje rezultata, anonimnost prilikom prikupljanja podataka, složeni višedimenzionalni i interdisciplinarni problem istraživanja, nedostatak konsenzusa, iskusni i sposobni stručnjaci, disperzija stručnjaka i vremensko ograničenje. U kvalitativnim istraživanjima koja se uglavnom temelje na prosudbama i mišljenjima pojedinaca postoji preduvjet za korištenje metode Delphi. Metoda Delphi može se koristiti za kvalitativno

[1]The RAND Corporation: https://www.rand.org/

istraživanje koje istražuje i identificira prirodu i temeljne elemente fenomena kao osnovu za studiju. Jedna od glavnih primjena metode Delphi je tijekom rješavanja problema u operacijskim istraživanjima i u metodama višekriterijskog odlučivanja (engl. *Multiple-criteria decision-making - MCDM*) [139] te u predviđanju trendova, procjenama budućih potreba, prioriteta s ciljem usuglašavanja mišljenja između nezavisnih eksperata bez međusobnog utjecaja. Metoda Delphi provodi se u četiri koraka *(Slika 4):*

1. Ispunjavanje preduvjeta za provođenje metode Delphi
2. Određivanje strukture i veličine panela
3. Prikupljanje mišljenja stručnjaka
4. Određivanje stupnja postignutog konsenzusa.

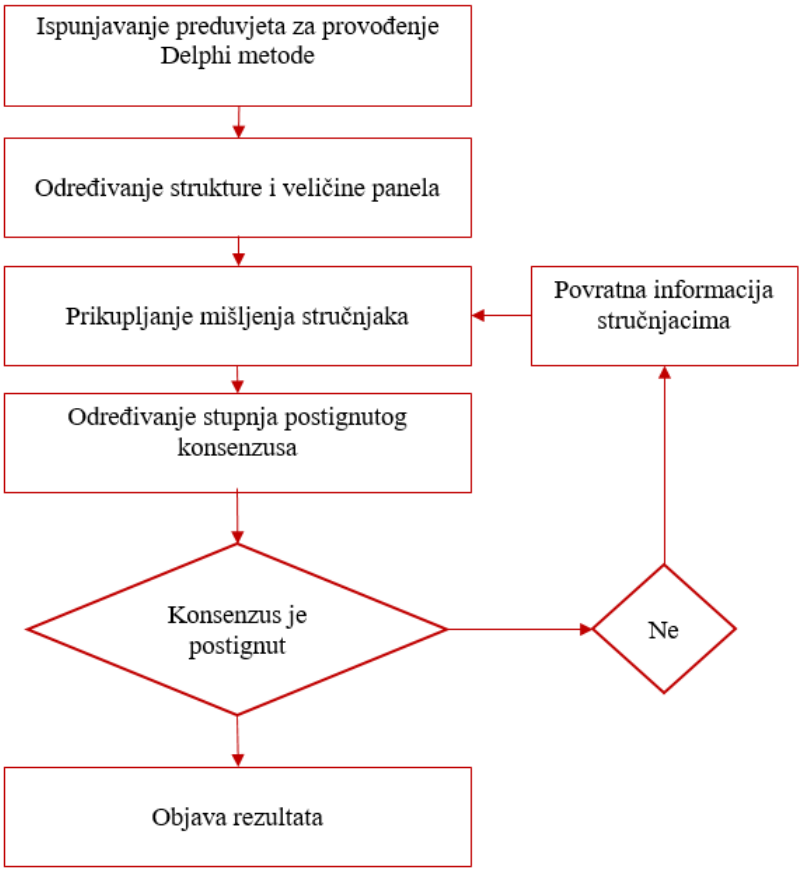

Slika 4: Postupak provođenja Delphi metode

Jedna od najvažnijih faza metode Delphi je određivanje strukture i veličine panela jer valjanost rezultata ovisi o kompetencijama i znanju članova panela [140]. U panelu trebaju sudjelovati stručnjaci koji imaju znanje i ekspertizu o predmetu istraživanja. U literaturi se navodi da veličina panela ovisi o predmetu istraživanja, prirodi različitih gledišta te vremenskim i

financijskim resursima koji su na raspolaganju tijekom istraživanja [141]. Također, predlaže se korištenje kombinacije heterogene grupe i pojedinaca koji su stručnjaci u više područja, a ne preporučuje se korištenje homogenih grupa [140]. Različiti autori u literaturi navode različiti broj stručnjaka uključenih u panel. Prema autoru Claytonu [100], ako se koristi heterogena grupa stručnjaka dovoljno je pet do deset sudionika u panelu. Grupa autora Ali Mosa Al-araibi i ost. [127] predlažu jedanaest do petnaest sudionika u panelu. Autori Manizade i van der Schaf [129], [132] smatraju da je potrebno dvadeset, odnosno dvadeset i jedan sudionik u panelu dok u nekim istraživanjima autori smatraju da je potrebno više od šezdeset ispitanika u panelu [124], [125], [135].

Prikupljanje mišljenja stručnjaka je treći korak provođenja metode Delphi. Prikupljanje mišljenja provodi se pomoću ispunjavanja upitnika. Prilikom kreiranja upitnika najvažnije je da pitanja budu jasno definirana, da pitanja nisu dvosmislena i da ih svi članovi panela razumiju na isti način. Predlaže da se da se upitnik sastoji od 20-25 pitanja jer veći broj pitanja može dovesti do pada koncentracije i do gubljenja interesa za ispunjavanje od strane stručnjaka. Prvi krug provođenja metode Delphi započinje podjelom upitnika stručnjacima uz napomenu da je važno da panel zna koji su ciljevi provođenja metode Delphi. Likertova ljestvica [142] omogućuje ispitanicima da odrede svoj stupanj suglasnosti s određenom izjavom u upitniku. Broj stupnjeva kod Likertove ljestvice se može razlikovati od 3 do 9. Prilikom obrade podataka dobivenih Likertovom ljestvicom, stupnjevi se kodiraju brojevima od 5 do 1, pri čemu se brojem 5 označava najpozitivniji stav, a brojem 1 najnegativniji (5 - potpuno se slažem; 4 - uglavnom se slažem; 3 - ne mogu se odlučiti; 2 - uglavnom se ne slažem; 1 - uopće se ne slažem). Ako brojem 5 označavamo najpozitivniji stav, važno je znati da osoba ima pozitivan stav prema određenoj izjavi samo ako se slaže s pozitivnom ocjenom ili ako se ne slaže s negativnom ocjenom. Za negativne izjave vrijedi obrnuto. Nakon popunjavanja upitnika, koordinacijska grupa provodi statističku obradu rezultata istraživanja. Rezultati istraživanja dostavljaju se stručnjacima koji su popunjavali upitnike i daju im se upitnici na ponovo popunjavanje ako nije postignut konsenzus.

Četvrti korak provođenja metode Delphi je postizanje konsenzusa odnosno usuglašenosti mišljenja stručnjaka. Završetak provođenja metode Delphi nastupa kada se više ne događaju značajne promjene u mišljenju stručnjaka. Nakon provedbe metode Delphi potrebno je prezentirati rezultate istraživanja tako da se prikažu osnovni statistički podaci za svaki krug provođenja metode Delphi te da se grafički prezentiraju dobiveni rezultati.

4.3. Metoda sortiranja karata

Metoda sortiranja karata ili metoda Q-sorting (engl. *Q-sorting method*) je teorijski utemeljen i kvantitativan alat za ispitivanje mišljenja i stavova. Metoda omogućava IS (engl. *Information Systems*) istraživačima sustavno i kvantitativno ispitivanje ljudske subjektivnosti. Metodu Q-sorting osmislio je britanski fizičar i psiholog William Stephenson 1935. On je istraživao načine proučavanja stavova, mišljenja, ponašanja, osobnosti, interakcije, kao i sve ostalo što je povezano sa subjektivnim samoopažanjem. Metoda Q-sorting omogućava znanstvenu osnovu za proučavanje subjektivnosti [143]–[145], pri čemu subjektivnost podrazumijeva osobni stav pojedinca prema bilo kojem društvenom i/ili osobnom pitanju. Autori Stephenson [146] i Brown [144] navode da je metoda Q-sorting, metoda za istraživanje i objašnjenje obrazaca subjektivnosti i životnog iskustva pojedinaca.

Autor Goldman [147] navodi da je metoda Q-sorting kvalitativna istraživačka metoda koja omogućuje sustavno proučavanje subjektivnosti i komunikativnosti subjektivnih opažanja u okruženju o određenoj temi. Metoda Q-sorting prihvaća stajalište i razumijevanje ispitanika kao polazišnu točku u daljnjim istraživanjima. Autor Brown [144] smatra da je metoda Q-sorting najprikladnija metoda za istraživanje društvenih problema i osiguravanje dubljeg razumijevanja mišljenja, uvjerenja, perspektiva, odluka, okvira ili priča pojedinaca o bilo kojem subjektu koji ima subjektivnu komponentu dok autorica Ramlo [148] navodi da je to odgovarajuća metoda u slučajevima kada istraživač želi utvrditi različite perspektive i konsenzus unutar grupe u vezi s bilo kojom temom. Zbog toga je ova metodologija široko rasprostranjena u psihologiji, političkim i društvenim znanostima [145], a počela se širiti i na područja ekonomije i menadžmenta [149].

Četiri su osnovna koraka provođenja metode Q-sorting [145]:

1. *Izrada i oblikovanje Q uzorka* (engl. *Q-set*)

Q-sorting istraživanje započinje sakupljanjem sažetka (engl. *concourse*), koje autor Stephenson [146] definira kao zbirku izjava prikupljenih iz razgovora licem u lice, pisanjem ili iz bilo koje situacije u kojoj je uključena komunikativnost. Sažetak je zapravo koncept koji bi trebao sadržavati sve relevantne aspekte područja istraživanja. Sažetak predlažu istraživači, a tijekom provedbe metode Q-sorting ispitanici u istraživanju sortiraju odabrane izjave o sažetku prema redoslijedu preferencija. Iako ne postoji definiran broj izjava koje čine Q-uzorak, većina autora se slaže da bi broj izjava trebao biti između 20 i 100: Webler, Danielson i Tuler [150] predlažu 20-60 karata; Brown [144] predlaže 40-50 karata; Watts i Stenner [151] predlažu 40-80 karata,

Kerlinger [152] predlaže da je potrebno najmanje 60 Q-sort karata, odnosno varijabli kako bi zaključak imao statističku stabilnost i pouzdanost. Autor McKeown [143] navodi da broj Q-sort karata može varirati od 30 do 100, ali se najčešće koristi između 50 do 70 Q-sort karata. Autori Popovich i ost. [153] navode da je veliki broj uspješnih istraživanja koja su provedena metodom Q-sorting sadržavao 49 do 70 Q-sort karata.

2. *Odabir sudionika (P-uzorak ili* engl. *P-set)*

P-uzorak predstavlja odabrane ispitanike u postupku provođenja metode Q-sorting odnosno razvrstavanju izjava. Metoda Q-sorting ne zahtijeva veliki broj sudionika [146]. Ispitanici u istraživanju su stručnjaci koji su teoretski relevantni za problem istraživanja. Autor Brown [144] naglašava da je minimalan broj sudionika potreban za istraživanje onoliki koji će omogućiti da se u istraživanju utvrdi postojanje čimbenika za uspoređivanje jedne varijable (u ovom radu elemenata) s drugom i navodi da se ne preporučuje veliki broj ispitanika jer dolazi do redundantnosti kod interpretiranja problema istraživanja. Autori Stenner i Stainton-Rogers [154] navode da nema potrebe za velikim brojem sudionika u ispitivanju metodom Q-sorting jer je istraživanje navedenom metodom usmjereno na istraživanje značenja i kvalitete, a ne na generalizaciju odnosno općenitost.

3. *Q-sorting intervju (prikupljanje podataka)*

Sortiranje karata može se provoditi na dva načina što ukazuje na postojanje dvije vrste ove metode [155]. Prva vrsta je otvoreno sortiranje karata kod kojeg sudionici dobivaju kartice koje prikazuju koncepte unaprijed utvrđenih kategorija tog sadržaja *(Slika 5)*. Sudionici sortiraju kartice u skupine ili sadržajne kategorije dodjeljujući im imena prema vlastitom nahođenju. Otvoreno sortiranje karata može se provoditi pojedinačno ili u grupi.

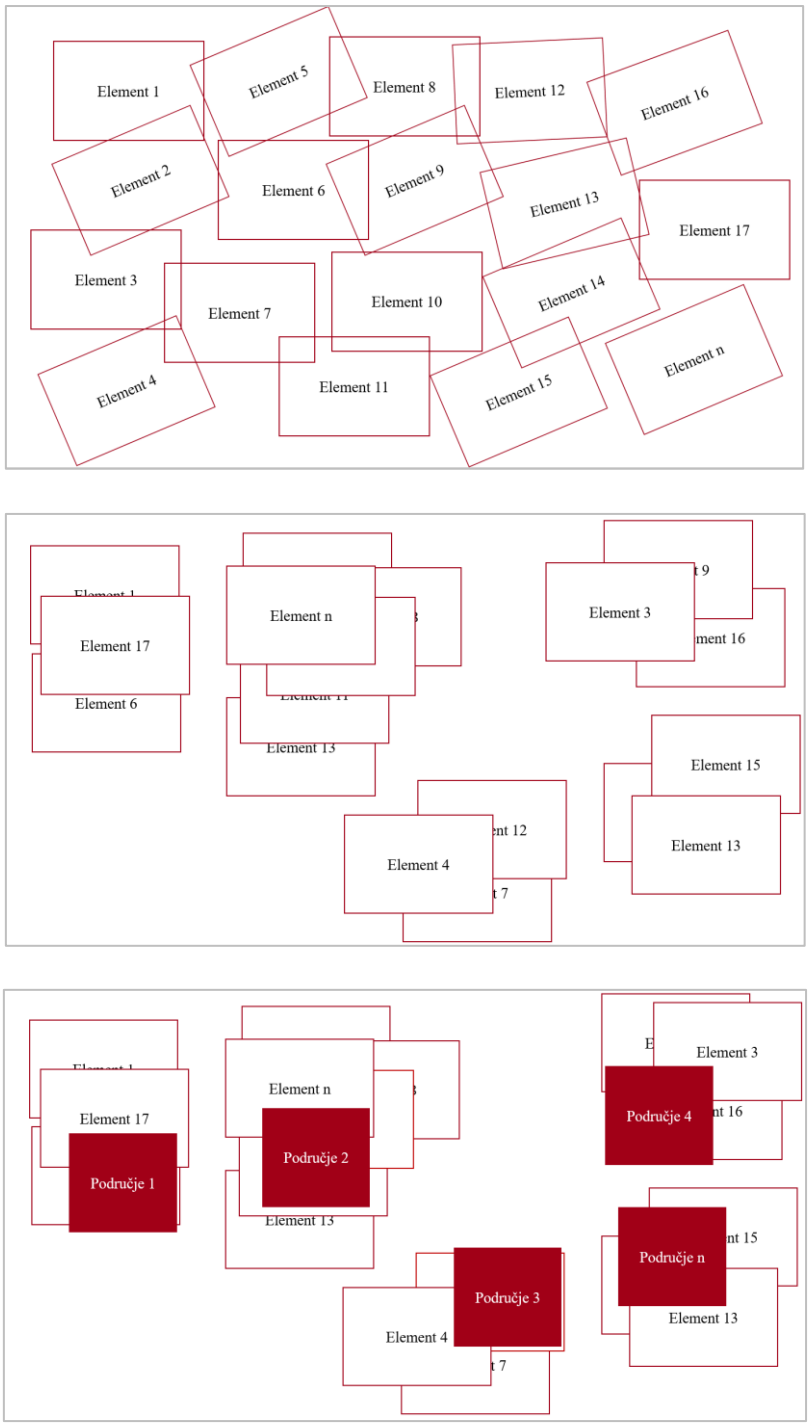

Slika 5: Otvoreno sortiranje karata

Druga vrsta je zatvoreno sortiranje karata *(Slika 6)* koje se provodi tako da se korisnicima daju karte s ispisanim različitim temama koje moraju razvrstati u unaprijed određene kategorije. Nakon sortiranja karata, važno je s korisnicima diskutirati njihove odabire te razumjeti zašto su karte grupirane na određeni način.

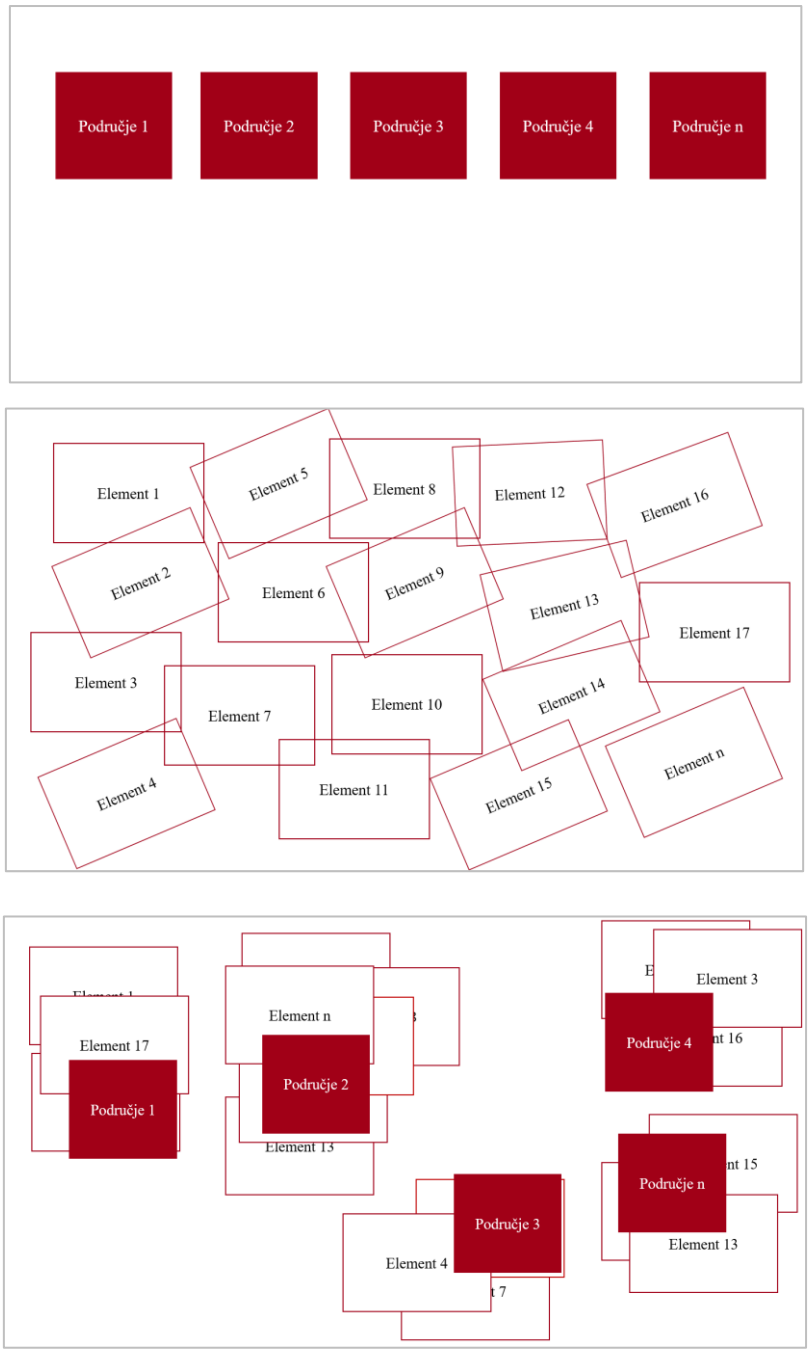

Slika 6: Zatvoreno sortiranje karata

4. *Analiza Q-sorting (analiza podataka)*

Analiza podataka provodi se kvalitativnim i kvantitativnim metodama. Kvalitativnom metodom, analizom dvaju neovisnih stručnjaka i kvantitativnom metodom primjenom omjera valjanosti sadržaja koje su objašnjene u Poglavlju 4.4.

4.4. Pokazatelj valjanosti sadržaja

Za mjerenje valjanosti okvira potreban je valjani instrument [156]. Valjanost sadržaja potrebno je razmotriti prilikom razvoja okvira i instrumenata [157]. Autor Straub [158] navodi da je valjanost sadržaja stupanj u kojem stavke u instrumentu mogu opisati sadržaj u cjelini i instrument u cjelini. Vrijednost sadržaja može se provesti pomoću nekoliko metoda ovisno koriste li se u istraživanju kvalitativne ili kvantitativne analize.

Metode koje se koriste u kvalitativnoj analizi valjanosti sadržaja su:

a) dubinska analiza literature [159] koja se primjenjuje mjerenjem konstrukata na temelju istraživačkih pitanja istraživača u dosadašnjim istraživanjima. Vrijednost sadržaja korištenjem ove metode oslanja se samo na postojeća znanja bez sudjelovanja stručnjaka i njihovih znanja [160].
b) stručna procjena valjanosti sadržaja [161] koja uključuje stručnjake kao iskusne pojedince koji mogu iznijeti svoje stavove o predstavljenom sadržaju.

Metode koje se koriste u kvantitativnoj valjanosti sadržaja su:

a) omjer valjanosti sadržaja - CVR [101] metoda je koja uključuje upitnik koji je procijenila skupina stručnjaka. Ova metoda primjenjuje ljestvicu od tri stupnja za procjenu svake pojedinačne izjave i predmeta istraživanja u cjelini. U razvijenom upitniku postoji i odjeljak za komentare koji služi kako bi ispitanici/stručnjaci mogli iznijeti svoje stavove o pojedinim izjavama ili o predmetu istraživanja u cjelini. Broj stručnjaka koji sudjeluje u istraživanju nije definiran i ovisi o predmetu istraživanja. Prilikom istraživanja u sklopu ove doktorske disertacije korišten je CVR jer omogućuje rigorozan metodološki pristup za ocjenu valjanosti pojedinih elemenata i područja istraživanja. CVR se koristi u različitim područjima istraživanja i smatra se jednim od najprihvaćenijih alata za ocjenu valjanosti sadržaja. Vrijednost sadržaja za svaku izjavu izračunata je korištenjem Lawsheove CVR formule (*4.4.1*) koja daje vrijednosti između -1 i +1.

U Lawsheovoj formuli *n* označava broj ispitanika koji pojedinu varijablu smatraju jako važnom *N* predstavlja ukupan broj ispitanika.

$$CVR = \frac{n - \frac{N}{2}}{\frac{N}{2}} \qquad (4.4.1)$$

Ukoliko su svi ispitanici odgovorili da im je određena varijabla „jako važna“ tada je vrijednost CVR = 1,00. Ukoliko je više od polovine ispitanika (>50%), ali manje od svih (<100%) ispitanika odgovorilo da je određena varijabla „jako važna“, tada je vrijednost CVR pozitivna i kreće se od 0,00 do 0,99. Ukoliko je manje od polovine ispitanika (<50%) odgovorilo da im je varijabla „jako važna“ tada je vrijednost CVR negativna.

Pozitivne vrijednosti upućuju na to da više od polovine ispitanika smatra izjavu bitnom. CVR se izračunava za svaki pojedini element. Minimalna vrijednost koeficijenta CVR za deset ispitanika iznosi 0,62 [101] kako bi se zadovoljila statistička značajnost od 5%, što znači da je minimalno devet ispitanika ocjenjuju određenu stavku kao „jako važnu“. Samo oni elementi koji imaju CVR veći ili jednak tom minimalnom iznosu ostaju u daljnjem razmatranju.

b) indeks valjanosti sadržaja (engl. *Content Validity Index - CVI)* [162] je metoda koja se najčešće koristi u kvantitativnoj procjeni. Indeks valjanosti sadržaja je metoda u kojoj ispitanici ocjenjuju izjave pomoću ljestvice za ocjenjivanje. Ljestvica se sastoji od četiri boda, pri čemu su „1 = nebitno“, „2 = donekle relevantno“, „3 = prilično relevantno“ i „4 = vrlo relevantno“. U metodi CVI određen je broj ispitanika i on se kreće od tri do deset u ovisnosti o predmetu istraživanja. CVI se računa [163] kao omjer broja ispitanika koji su pojedinu tvrdnju ocijenili s 3 „prilično relevantno“ ili 4 „vrlo relevantno“ i ukupnog broja ispitanika (*4.4.2*).

$$CVI = \frac{broj\ ispitanika\ koji\ su\ tvrdnju\ ocijenili\ s\ 3\ ili\ 4}{ukupan\ broj\ ispitanika} \qquad (4.4.2)$$

Ukoliko je CVI >0,79 tvrdnja je prihvatljiva. Ukoliko se CVI kreće u rasponu od 0,70 do 0,79 tvrdnju je potrebno modificirati. Tvrdnja je neprihvatljiva ukoliko je CVI < 0,70.

4.5. Analitički hijerarhijski proces – metoda AHP

Analitički hijerarhijski proces - metoda AHP jedna je od najpoznatijih metoda višekriterijskog odlučivanja. Višekriterijsko odlučivanje primjenjuje se kada u problemu odlučivanja trebamo odabrati najbolju inačicu na temelju više kriterija i podkriterija. Karakteristike problema višekriterijskog odlučivanja su prisutnost većeg broja kriterija ili atributa, neusporedivost mjernih jedinica između kriterija, prisutnost većeg broja alternativa koje se međusobno razlikuju po vrijednostima određenih kriterija te izbor alternative koja je ukupno gledano između svih alternativa najbolja.

Glavni elementi problema odlučivanja su ciljevi koji se žele postići odlukom, alternative između kojih se bira, kriteriji kojima se mjeri postizanje ciljeva i težine tih kriterija koje odražavaju njihovu važnost s obzirom na problem.

Problem višekriterijskog odlučivanja moguće je prikazati pomoću tablice odlučivanja ili matrice koja je tipa *nxk* gdje se u redovima nalazi *n* alternativa ili mogućnosti, a u stupcima *k* kriteriji ili atributi. Polje *ij* matrice predstavlja vrijednost atributa *j* alternative *i*. Redak matrice predstavlja vrijednosti atributa jedne alternative dok jedan stupac predstavlja vrijednosti jednog atributa za alternative koje su predmet odlučivanja.

Metodu AHP prvi puta spominje autor Saaty 1972. [164], a detaljno ju opisuje 1977. [165]. Mnogi autori u svojim radovima najčešće se referenciraju na knjigu istog autora objavljenu 1980. [166] u kojoj autor navodi da se primjena metode AHP sastoji od četiri glavna koraka:

1. Razviti hijerarhijski model problema odlučivanja s ciljem na vrhu, kriterijima i podkriterijima na nižim razinama te alternativama na dnu modela *(Slika 7).* Potrebno je prepoznati cilj koji se želi postići, definirati alternative koje zadovoljavaju postavljene zahtjeve, definirati prioritete zahtjeva kako bi se alternative implementirale i ostvario globalni cilj. Složenost problema raste s brojem kriterija i s brojem alternativa. Sposobnost ljudskog uma u međusobnom razlikovanju velikog broja alternativa i kriterija je ograničena, te se u skladu s time, pri formiranju hijerarhije ne preporučuje više od 5 ± 2 elemenata na istoj razini.

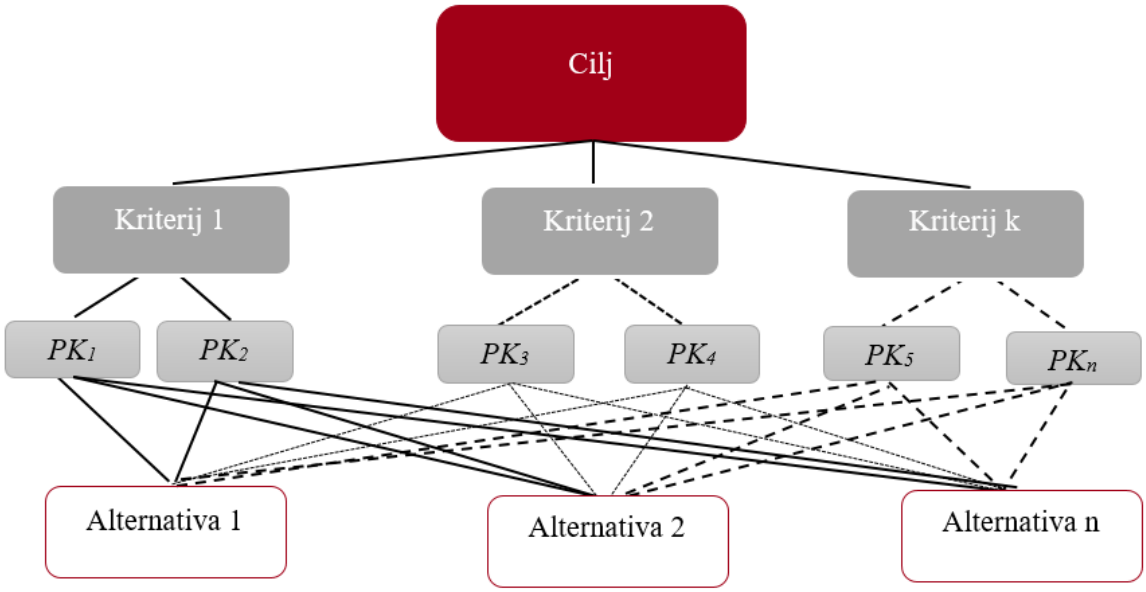

Slika 7: Hijerarhijski model problema odlučivanja [Prilagođeno prema: [166]]

2. U svakom čvoru hijerarhijske strukture međusobno se uspoređuju u parovima elementi tog čvora u odnosu na to koliko je puta jedan od njih važniji od drugog za postizanje cilja pomoću Saatyjeve ljestvice relativnih važnosti (*Tablica 4*).

Tablica 4: Saatyjeva ljestvica relativnih važnosti [Izvor: [167]]

Intenzitet važnosti	Definicija	Objašnjenje
1	jednako važno	Dvije aktivnosti jednako doprinose cilju.
2 3	slabo, blago važnije umjereno važnije	Na temelju iskustva i procjena daje se umjerena prednost jednoj aktivnosti u odnosu na drugu.
4 5	umjerenije do strogo važnije	Na temelju iskustva i procjena, strogo se favorizira jedna aktivnost u odnosu na drugu.
6 7	važna do vrlo stroga, dokazana važnost	Jedna aktivnost izrazito se favorizira u odnosu na drugu, njezina dominacija dokazuje se u praksi.
8 9	vrlo, vrlo stroga do ekstremna važnost	Dokazi na temelju kojih se favorizira jedna aktivnost u odnosu na drugu, potvrđeni su s najvećom uvjerljivošću.
2,4,6,8	međuvrijednosti	
1.1 – 1.9	slične aktivnosti	Pri usporedbi aktivnosti koje su po važnosti blizu jedna drugoj, potrebne su decimalne vrijednosti kako bi se preciznije izrazila razlika u njihovoj važnosti.

3. Iz procjena relativnih važnosti elemenata odgovarajuće razine hijerarhijske strukture problema izračunaju se lokalne težine (prioriteti) kriterija i podkriterija, a na posljednjoj razini prioriteti alternativa. Ukupni prioriteti alternativa izračunavaju se tako da se njihovi lokalni prioriteti ponderiraju s težinama svih čvorova kojima pripadaju gledajući od najniže razine u hijerarhijskom modelu prema najvišoj i zatim zbroje.
4. Provodi se analiza osjetljivosti.

Metoda AHP zasniva se na sljedećim aksiomima [168], [43]:

1. *Aksiom recipročnosti*. Ako je element A *n* puta značajniji od elementa B, tada je element B *1/n* puta značajniji od elementa A.
2. *Aksiom homogenosti.* Usporedba ima smisla jedino ako su elementi usporedivi.
3. *Aksiom zavisnosti.* Dopušta se usporedba elemenata jedne razine u odnosu na element više razine, tj. usporedbe na nižim razinama zavise od elementa više razine.
4. *Aksiom očekivanja*. Svaka promjena u strukturi hijerarhije zahtijeva ponovni postupak računanja prioriteta.

Metoda AHP primjenjuje se u upravljanju inovacijama industrijskih poduzeća [169], odabiru ponuda za radove u javnim poduzećima [170], istraživanju u zdravstvu [171], u odabiru projektnih prijedloga [172], primjene na visokim učilištima u njihovoj evaluaciji, određivanju marketinške strategije, mjerenju performansi, mjerenju kvalitete obrazovanja, strateškom planiranju, nabavi, rangiranju [173].

Demonstracijski primjer AHP modela (*Slika 8)* izrađen je u četiri koraka:

1. Određivanje kriterija i podkriterija,
2. Procjena važnosti kriterija u parovima,
3. Matrica procijenjenih omjera važnosti kriterija i podkriterija te
4. Izračun težinskih koeficijenata kriterija i podkriterija.

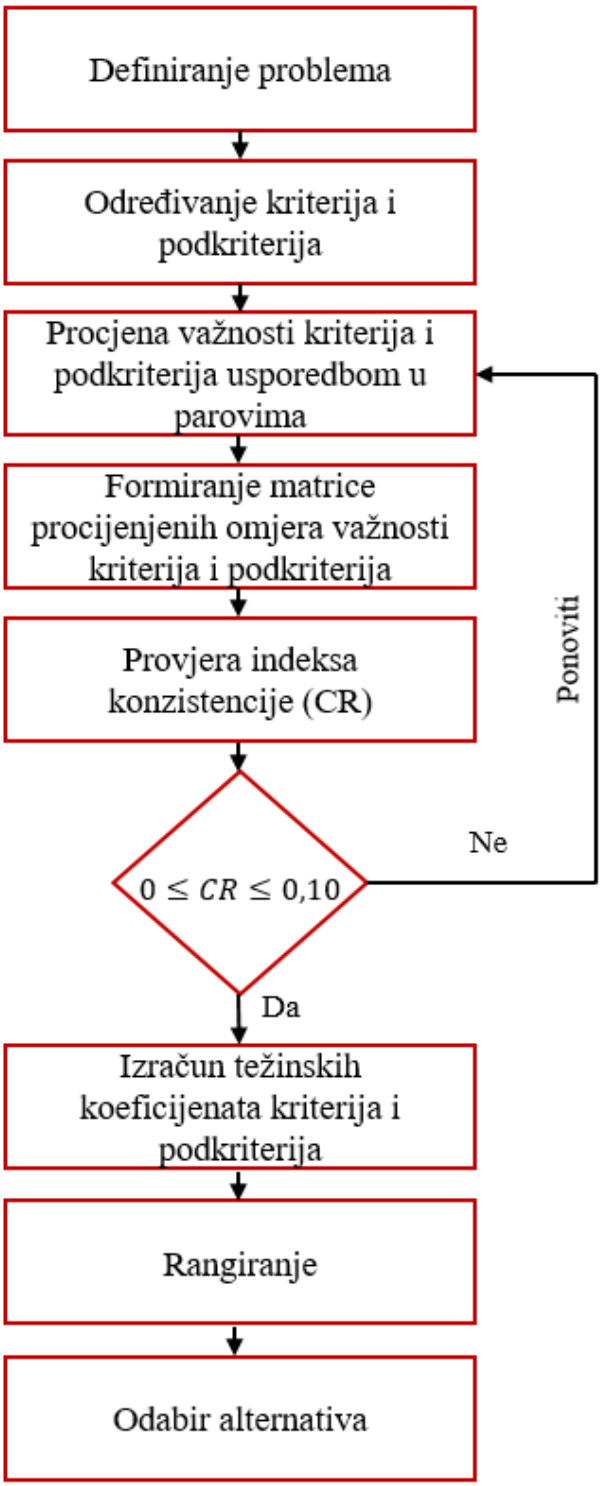

Slika 8: Dijagram toka demonstracijskog primjera AHP modela

Korak 1. Određivanje kriterija i podkriterija. Kriteriji relevantni u demonstracijskom primjeru podijeljeni su u četiri skupine K1., K2., K3. i K4.. Svaka skupina ima podkriterije. Sveukupan broj podkriterija je 17 (*Slika 9)*.

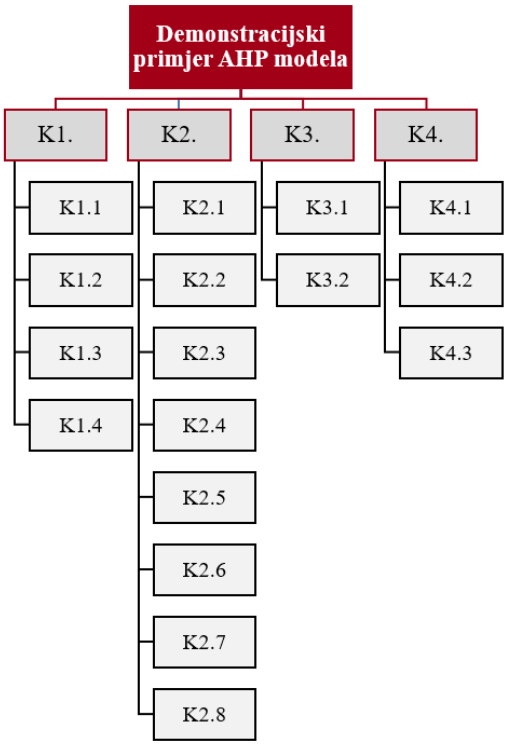

Slika 9: Kriteriji i podkriteriji demonstracijskog modela metode AHP

Korak 2. Procjena važnosti kriterija i podkriterija u parovima. U drugom koraku razvoja demonstracijskog primjera AHP modela izvršena je usporedba kriterija u parovima grupnim odlučivanjem prema Saatyjevoj ljestvici relativne važnosti (*Tablica 4*). Saatyjeva ljestvica omogućuje da pojedinac, ukoliko poznaje problematiku na koju se odnosi problem odlučivanja, može koristiti tu ljestvicu za davanje konzistentnih procjena važnosti kriterija u parovima [174]. U grupnom odlučivanju sudjelovalo je šest stručnjaka ($N=6$). Nakon provedenog grupnog odlučivanja dobiveni su rezultati koji se mogu analizirati i interpretirati zasebno za svakog sudionika i grupno kao sinteza rezultata sudionika procesa grupnog odlučivanja.

Korak 3. Matrica procijenjenih omjera važnosti kriterija i podkriterija. U trećem koraku razvoja demonstracijskog primjera AHP modela formirana je matrica procijenjenih omjera važnosti kriterija K1., K2., K3. i K4. prikazana za svakog stručnjaka u razvoju demonstracijskog primjera. Na (*4.5.2*) prikazana je matrica procijenjenih omjera važnosti kriterija za *Sudionika* 1. Proračun je izrađen u

alatu Microsoft Excel. U *i-tom* redu i *j-tom* stupcu matrice (*4.5.1*) nalazi se vrijednost procijenjenog omjera prioriteta kriterija K_i i kriterija K_j, tj.:

$$\begin{aligned} K_1 : K_3 &= 3 \\ K_1 : K_4 &= 2 \\ K_2 : K_1 &= 2 \\ K_2 : K_3 &= 3 \\ K_2 : K_4 &= 4 \\ K_3 : K_4 &= 3 \end{aligned} \qquad (4.5.1)$$

$$\begin{array}{c} \\ K1. \\ K2. \\ K3. \\ K4. \end{array} \begin{array}{c} \begin{array}{cccc} K1. & K2. & K3 & K4. \end{array} \\ \begin{bmatrix} 1 & 0.5 & 3 & 2 \\ 2 & 1 & 3 & 4 \\ 0.33 & 0.33 & 1 & 3 \\ 0.5 & 0.25 & 0.33 & 1 \end{bmatrix} \end{array} \qquad (4.5.2)$$

Matrica relativnih procjena težina – Sudionik 1

Rezultati usporedbe kriterija u parovima za preostalih pet sudionika istraživanja (*Sudionik* 2 - (*4.5.3*), *Sudionik* 3 - (*4.5.4*), *Sudionik* 4 - (*4.5.5*), *Sudionik* 5 - (*4.5.6*), *Sudionik* 6 - (*4.5.7*)) prikazani su u matrici procijenjenih omjera važnosti kriterija K1., K2., K3. i K4..

$$\begin{array}{c} \\ K1. \\ K2. \\ K3. \\ K4. \end{array} \begin{array}{c} \begin{array}{cccc} K1. & K2. & K3. & K4. \end{array} \\ \begin{bmatrix} 1 & 0.33 & 0.5 & 3 \\ 3 & 1 & 3 & 3 \\ 2 & 0.33 & 1 & 3 \\ 3 & 0.33 & 0.33 & 1 \end{bmatrix} \end{array} \qquad (4.5.3)$$

$$\begin{array}{c} \\ K1. \\ K2. \\ K3. \\ K4. \end{array} \begin{array}{c} \begin{array}{cccc} K1. & K2. & K3. & K4. \end{array} \\ \begin{bmatrix} 1 & 0.25 & 0.33 & 0.5 \\ 4 & 1 & 2 & 3 \\ 3 & 0.5 & 1 & 3 \\ 2 & 0.33 & 0.33 & 1 \end{bmatrix} \end{array} \qquad (4.5.4)$$

$$\begin{array}{c} \\ K1. \\ K2. \\ K3. \\ K4. \end{array} \begin{array}{c} \begin{array}{cccc} K1. & K2. & K3. & K4. \end{array} \\ \begin{bmatrix} 1 & 0.33 & 0.33 & 2 \\ 3 & 1 & 2 & 4 \\ 3 & 0.5 & 1 & 3 \\ 0.5 & 0.25 & 0.33 & 1 \end{bmatrix} \end{array} \quad (4.5.5)$$

$$\begin{array}{c} \\ K1. \\ K2. \\ K3. \\ K4. \end{array} \begin{array}{c} \begin{array}{cccc} K1. & K2. & K3. & K4. \end{array} \\ \begin{bmatrix} 1 & 0.5 & 0.33 & 2 \\ 2 & 1 & 3 & 3 \\ 3 & 0.33 & 1 & 3 \\ 0.5 & 0.33 & 0.33 & 1 \end{bmatrix} \end{array} \quad (4.5.6)$$

$$\begin{array}{c} \\ K1. \\ K2. \\ K3. \\ K4. \end{array} \begin{array}{c} \begin{array}{cccc} K1. & K2. & K3. & K4. \end{array} \\ \begin{bmatrix} 1 & 0.25 & 2 & 2 \\ 4 & 1 & 4 & 4 \\ 0.5 & 0.25 & 1 & 2 \\ 0.5 & 0.25 & 0.5 & 1 \end{bmatrix} \end{array} \quad (4.5.7)$$

Uz prethodno prikazane rezultate usporedbe kriterija u parovima, svaki sudionik istraživanja uspoređivao je u parovima dodatno četiri grupe podkriterija: podkriterije K1.1 − K1.4, podkriterije K2.1 − K2.8, podkriterije K3.1 − K3.2 i podkriterije K4.1 − K4.3 prema kojima su izrađene matrice procijenjenih omjera važnosti podkriterija. Rezultati usporedbe kriterija za jednog od sudionika istraživanja – *Sudionik 1* prikazani su (*4.5.8*) - (*4.5.11*) .

$$\begin{array}{c} \\ K1.1 \\ K1.2 \\ K1.3 \\ K1.4 \end{array} \begin{array}{c} \begin{array}{cccc} K1.1 & K1.2 & K1.3 & K1.4 \end{array} \\ \begin{bmatrix} 1 & 0.5 & 0.33 & 0.33 \\ 2 & 1 & 0,5 & 0.33 \\ 3 & 2 & 1 & 3 \\ 3 & 3 & 0.33 & 1 \end{bmatrix} \end{array} \quad (4.5.8)$$

$$\begin{array}{c} \\ K2.1 \\ K2.2 \\ K2.3 \\ K2.4 \\ K2.5 \\ K2.6 \\ K2.7 \\ K2.8 \end{array} \begin{array}{c} \begin{array}{cccccccc} K2.1 & K2.2 & K2.3 & K2.4 & K2.5 & K2.6 & K2.7 & K2.8 \end{array} \\ \begin{bmatrix} 1 & 0.5 & 0.5 & 0.33 & 0.33 & 0.33 & 0.33 & 0.25 \\ 2 & 1 & 3 & 2 & 2 & 0.5 & 0.5 & 0.33 \\ 2 & 0.33 & 1 & 0.33 & 2. & 0.5 & 0.5 & 0.5 \\ 3 & 0.5 & 3 & 1 & 3 & 2 & 2 & 0.5 \\ 3 & 0.5 & 0.5 & 0.33 & 1 & 3 & 0.5 & 0.33 \\ 3 & 2 & 2 & 0.5 & 0.33 & 1 & 3 & 3 \\ 3 & 2 & 2 & 0.5 & 2 & 0.33 & 1 & 2 \\ 4 & 3 & 2 & 2 & 3 & 0.33 & 0.5 & 1 \end{bmatrix} \end{array} \quad (4.5.9)$$

$$\begin{array}{c} \\ K3.1 \\ K3.2 \end{array} \begin{array}{c} \begin{array}{cc} K3.1 & K3.2 \end{array} \\ \begin{bmatrix} 1 & 3 \\ 0.33 & 1 \end{bmatrix} \end{array} \quad (4.5.10)$$

$$\begin{array}{c} \\ K4.1 \\ K4.2 \\ K4.3 \end{array} \begin{array}{c} \begin{array}{ccc} K4.1 & K4.2 & K4.3 \end{array} \\ \begin{bmatrix} 1 & 2 & .033 \\ 0.5 & 1 & 0.33 \\ 3 & 3 & 1 \end{bmatrix} \end{array} \quad (4.5.11)$$

Vrlo važna značajka u primjeni metode AHP je konzistentnost procjena donositelja odluke. Metoda AHP spada u primjenjive metode i zato što ima sposobnost identificirati i analizirati nekonzistentnost donositelja odluke u procesu uspoređivanja elemenata hijerarhije. Čovjek je rijetko konzistentan pri procjenjivanju vrijednosti ili odnosa kvalitativnih elemenata u hijerarhiji, a uzroci nekonzistentnosti mogu biti različiti: pomanjkanje koncentracije, administrativna greška, nepostojanje konzistencije u stvarnom problemu koji treba modelirati, neadekvatna struktura modela, nedostatak informacija [175]. Autor Hunjak [174] navodi da je nekonzistentnost moguće najjednostavnije objasniti pomoću sljedećeg primjera. Pretpostavimo da imamo tri kamena A, B i C za koje znamo da ukupno teže 22 kg, ali nam nisu poznate njihove pojedinačne težine. Mi znamo njihove omjere težina A:B = 2:1 (kamen A je dvostruko teži od kamena B) i A:C = 3:1 (kamen A je trostruko teži od kamena C). Iz ovoga proizlazi diobeni omjer težina 6:3:2 iz kojeg lako izračunamo da su

tražene težine kamena redom 12, 6 i 4 kg. Umjesto kamena možemo zamisliti da međusobno uspoređujemo kriterije te im izračunavamo težine kao mjeru njihove važnosti. Isto tako možemo uspoređivati alternative po prioritetima kako bismo odredili prioritet svake od njih. Problemi nastaju zbog toga što naše procjene obično nisu konzistentne.

Tijekom procjene važnosti kriterija u parovima provjerava se konzistentnost procjena donositelja odluke i utvrđuje ispravnost dobivenih težinskih koeficijenata kriterija i prioriteta alternativa. Da bi matematički utvrdili konzistentnost matrice, koristi se sljedeći postupak:

- izračunaju se sume stupaca,
- normira se matrica (svaki stupac se podijeli sa zbrojem elemenata tog stupca),
- u normiranoj matrici se izračunaju sume redova – težine,
- težine se podijele s vektorom prioriteta prve matrice,
- izračuna se λ_{max} kao prosječna vrijednost dobivenih veličina.

Metoda AHP omogućuje praćenje konzistentnosti procjena u svakom trenutku postupka. Autori Saaty i Vargas [107] definiraju indeks konzistencije (*4.5.12*) kao:

$$CI = \frac{(\lambda_{max} - n)}{(n-1)} \quad . \qquad (4.5.12)$$

Autori Hunjak i Jakovčević [176] objašnjavaju izračunavanje omjera konzistencije *CR* (*4.5.13*) pomoću indeksa konzistencije (CI) i slučajnog indeksa (*RI*) (*Tablica 5*).

$$CR = \frac{CI}{RI} \qquad (4.5.13)$$

Tablica 5: Vrijednosti RI slučajnih indeksa [Izvor: [163]]

n	1	2	3	4	5	6	7	8	9	10
RI	0	0	0,52	0,89	1,11	1,25	1,35	1,40	1,45	1,49

Ako za matricu A vrijedi $CR \leq 0{,}10$, procjene relativnih važnosti kriterija (prioriteta alternativa) smatraju se prihvatljivima. Omjer konzistencije (*CR*) kod svih matrica u ovom istraživanju je prihvatljiv i iznosi ≤ 0,10, tj. manje ili jednako od 10% (*Tablica 6*).

Tablica 6: Rezultati indeksa konzistencije (CR)

Kriteriji	Indeks konzistencije
K1-K4	0,02
K1.1 - K1.4	0,03
K2.1 - K2.8	-0,05
K4.1 - K4.3	0,02

Korak 4. Izračun težinskih koeficijenata kriterija i podkriterija. U četvrtom se koraku pristupilo računanju težinskih koeficijenata kriterija i podkriterija tako da su zbrojeni stupci matrice, a na temelju toga izračunala se normalizirana matrica tako da se svaki element prethodne matrice podijelio sa zbrojem stupca kojem pripada. Nakon toga izračunate su težine koeficijenata kriterija i težine koeficijenata podkriterija, tj. prioriteti kao prosječne vrijednosti elemenata redova normalizirane matrice. Zatim se geometrijskom sredinom rezultata dobivenih kod sudionika istraživanja izračunala ukupna težina koeficijenata kriterija i težina koeficijenata podkriterija (*Tablica 7).*

Tablica 7: Pregled težinskih koeficijenta kriterija i podkriterija

Kriteriji i podkriteriji	Težinski koeficijenti
K1.	**0,17**
K1.1	0,25
K1.2	0,15
K1.3	0,31
K1.4	0,28
K2.	**0,49**
K2.1	0,18
K2.2	0,14
K2.3	0,13
K2.4	0,17
K2.5	0,09
K2.6	0,10
K2.7	0,10
K2.8	0,08
K3.	**0,24**
K3.1	0,60
K3.2	0,40
K4.	**0,11**
K4.1	0,32
K4.2	0,37
K4.3	0,30

Istraživanje je pokazalo da najveći težinski koeficijent 0,49 ima kriterij *K2.* koji obuhvaća podkriterije K2.1 (težinska vrijednost iznosi 0,18), K2.4 (težinska vrijednost iznosi 0,17), K2.2 (težinska vrijednost iznosi 0,14), K2.3 (težinska vrijednost iznosi 0,13), K2.7 (težinska vrijednost iznosi 0,10), K2.6 (težinska vrijednost iznosi 0,10), K2.5 (težinska vrijednost iznosi 0,09) i K2.8 (težinska vrijednost iznosi 0,08).

Zatim slijedi kriterij *K3.* s težinskim koeficijentom 0,24 koji obuhvaća podkriterije K3.1 (težinska vrijednost iznosi 0,60) i K3.2 (težinska vrijednost iznosi 0,40).

Treći kriterij po važnosti je *K1.* s težinskim koeficijentom 0,17 koji obuhvaća podkriterije K1.3 (težinska vrijednost iznosi 0,31), K1.4 (težinska vrijednost iznosi 0,28), K1.1 (težinska vrijednost iznosi 0,25) i K1.2 (težinska vrijednost iznosi 0,15).

Najmanju važnost ima kriterij *K4.* s težinskim koeficijentom 0,11 koji obuhvaća podkriterije K4.2 (težinska vrijednost iznosi 0,37), K4.1 (težinska vrijednost iznosi 0,32) i K4.3 (težinska vrijednost iznosi 0,30).

Od značajnih prednosti korištenja metode AHP u odlučivanju u visokom obrazovanju izdvajamo sljedeće [43]:

1. Metoda AHP strukturira problem odlučivanja i uspješno simulira proces donošenja odluka od definiranja cilja, kriterija i alternativa, do uspoređivanja kriterija i alternativa u parovima i dobivanja rezultata, odnosno utvrđivanja prioriteta svih alternativa u odnosu na postavljeni cilj.
2. Metoda AHP dekomponira realni proces odlučivanja tako što razlaže problem u hijerarhiju elemenata tog procesa uvažavajući činjenicu da donositelj odluka na mentalnom planu uglavnom ne razdvaja proces procjenjivanja kriterija od alternativa.
3. Metoda AHP omogućava kontrolu konzistentnosti procjena, vodeći računa o cjelini problema i funkcionalnim interakcijama kriterija i alternativa.
4. Metoda AHP integrira kvalitativne i kvantitativne faktore u odlučivanju. Praksa do uvođenja AHP-a ignorirala je važnost kvalitativnih faktora u odlučivanju, ne uzimajući u obzir da su svi ljudski problemi kombinacija psiholoških i fizičkih aktivnosti, kvalitativnih i kvantitativnih elemenata.
5. Metoda AHP je teorija relativnog mjerenja koja koristi apsolutnu ljestvicu za mjerenje kvalitativnih i kvantitativnih kriterija koji su homogeni i temeljeni na subjektivnim procjenama donositelja odluke.
6. Metoda AHP uspješno identificira i ukazuje na nekonzistentnost donositelja odluka praćenjem nekonzistentnosti u procjenama tijekom cijelog postupka, izračunavanjem indeksa i omjera konzistencije. Kod kombinacija kvalitativnih i kvantitativnih kriterija, mogućnosti za pojavu nekonzistentnosti su najizraženije.
7. Odlučivanje metodom AHP povećava znanje o problemu i snažno i brzo motivira donositelje odluke.
8. Primjenom metode AHP u procesu odlučivanja dolazi se do približnog rješenja problema i to obično većom brzinom nego na većini sastanaka te s manjim troškovima procesa donošenja odluke; dobiveni rezultati mogu se koristiti i kao ulazni podaci za projekt ili studiju izvodljivosti, odnosno za kompleksniju odluku.

9. Metoda AHP omogućuje donositelju odluka analizu osjetljivosti rezultata pomoću koje se provjerava stabilnost dobivenih rezultata i otvara mogućnost simulacija.
10. Postojanje kvalitetnih programskih alata koji podržavaju metodu AHP.

Metoda AHP ima i određena ograničenja s kojima se korisnici mogu susresti prilikom njene primjene, a mnogi znanstvenici se bave načinima za njihovo otklanjanje. Neka od ograničenja AHP-a koja se češće navode u literaturi [43]:

1. Nedovoljno velika ljestvica (Saatyeva ljestvice relativne važnosti) za uspoređivanje elemenata u parovima vezano uz neke probleme odlučivanja.
2. Velik broj potrebnih usporedbi u parovima kod većine problema.
3. Postizanje prihvatljivog omjera konzistencije je često vrlo teško (vremenski aspekt, dekoncentracija, smetnje i dr.).
4. Važno je dobro strukturirati problem odlučivanja jer posljedice neusporedivih kriterija i neusporedivih alternativa u modelu mogu biti vidljive u rezultatu.

4.6. Analitički mrežni proces – metoda ANP

Analitički mrežni proces – metodu ANP razvio je Thomas Saaty 1996. Metoda ANP je nova metoda koja proširuje postojeću metodu AHP na slučajeve ovisnosti i povratnih informacija (engl. *feedback*) i generalizira pristup supermatrice uveden u knjizi Tomasa Saatya iz 1980. [163] o Analitičkom hijerarhijskom procesu. Metoda ANP se opisuje kao nadogradnja metode AHP i kao metoda koja dekomponira probleme odlučivanja u mrežu koja se sastoji od klastera i čvorova [177].

Metoda AHP je najčešće korištena metoda višekriterijskog odlučivanja u odlučivanju u problemima školstva [178]. Temelji se na usporedbama u parovima elemenata odlučivanja. U parnim usporedbama koristi se Saatyjeva ljestvica (*Tablica 4*). Ljestvica se sastoji od devet stupnjeva (1-9). Vrijednost 1 znači da su dva elementa u paru podjednako važna. Vrijednost 3 znači slabu dominaciju jednog elementa nad drugim. Vrijednost 5 znači snažnu dominaciju jednog elementa nad drugim. Vrijednost 7 znači vrlo snažnu dominaciju jednog elementa nad drugim. Vrijednost 9 znači apsolutnu dominaciju jednog elementa nad drugim [43], [167].

Autorica Begičević Ređep [43] navodi da metoda ANP sadrži strukturu povratnih informacija koja omogućuje mrežno definiranje problema. U tome se razlikuje od metode AHP jer ne predstavlja linearnu hijerarhiju već modelira utjecaje između elemenata mreže. Mrežna ovisnost elemenata doprinosi boljem modeliranju stvarnih problema jer je većina problema iz stvarnog svijeta nelinearna i povratne informacije omogućuju preciznije određivanje prioriteta alternativa i kvalitetnije rješenje. Osnovna razlika između metode AHP i metode ANP je da u metodi AHP s obzirom na važnost kriterija određujemo prioritete alternativa, dok u metodi ANP, uz to što kriteriji utječu na važnost alternativa, i važnost alternativa utječe na određivanje težina kriterija. U hijerarhiji se važnost ili težina kriterija koristi za procjenu alternativa i njihovo postavljanje prioriteta. Odluka se donosi na temelju postojećih saznanja. Može se reći da je takav pristup tzv. idealistički pristup odlučivanju. U mreži svaka komponenta može ovisiti o drugoj komponenti. Postavlja se pitanje koja od dvije alternative je dominantnija nad određenim kriterijem, ali i pitanje koji je od dva kriterija dominantniji od određene alternative. Na primjer, je li određena osoba bolji učitelj ili glazbenik? Takav pristup je tzv. pragmatičan pristup odlučivanju [179].

Na *Slici 10* i *Slici 11* prikazana je razlika između hijerarhije i mreže. Hijerarhija je linearna struktura koja sadrži cilj na vrhu hijerarhije, kriterije na prvoj razini, podkriterije na drugoj razini, alternative na trećoj razini i petlju koja govori da svaki element ovisi o sebi. Mreža ima

strukturu povratnih informacija koja sadrži komponente i elemente unutar komponenti, točnije, klastere i čvorove unutar klastera te petlje (engl. *loops*) i lukove na koje se mrežne komponente spajaju. Osnovni element mreže je klaster, a klasteri se sastoje od čvorova koji se međusobno povezuju ovisno o njihovoj zavisnosti.

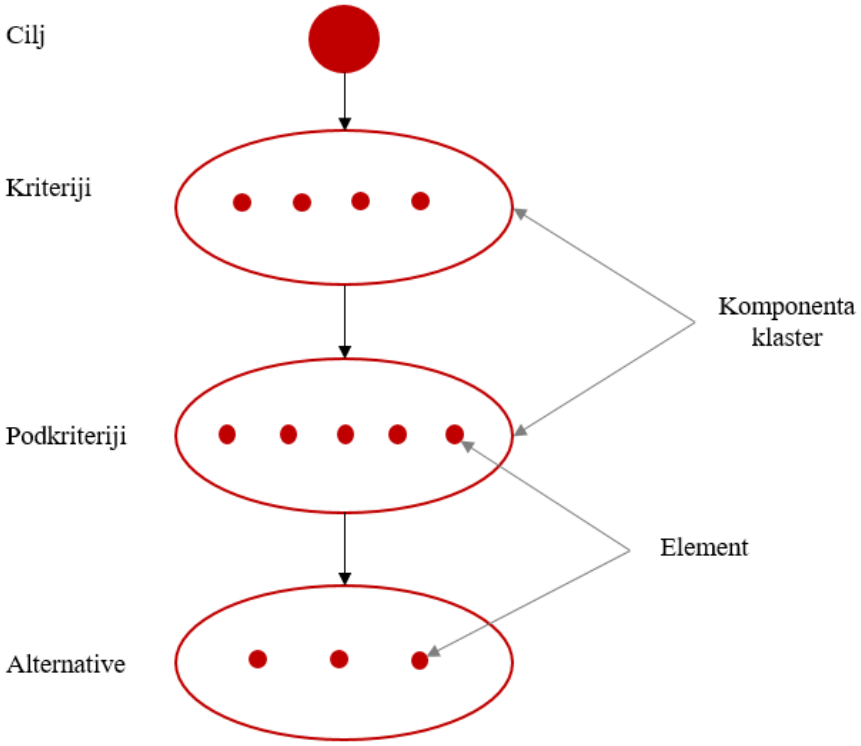

Slika 10: Hijerarhijska struktura u metodi AHP [Izvor: [166]]

Razlikujemo izvorne i odredišne čvorove. Zavisnosti su prikazane vezom (strelicom) između dva čvora među kojima postoji utjecaj. Strelica koja povezuje dva elementa ukazuje na utjecaj jednog elementa prema drugom. Izvorni čvor je onaj iz kojeg strelica izlazi i utječe na odredišni čvor prema kojem je strelica usmjerena, odnosno odredišni čvor ovisi o izvornom čvoru. Ako čvorovi utječu jedni na druge tada vezu nazivamo povratnom vezom. Mreža također omogućava modeliranje zavisnosti na način da jedna skupina utječe na drugu, a druga utječe na prvu, ali ne direktno, već indirektno kroz treću, tzv. prijelazni klaster. Ovisnosti se modeliraju između čvorova, ali ovisnosti između klastera su prikazane radi jednostavnosti. Prilikom stvaranja ANP modela potrebno je izbjegavati tzv. komponente izvora i odredišta koje su isključivo izvor ili odredište samo zato što takva struktura nije prirodna i može uzrokovati probleme prilikom primjene algoritma ANP za izračunavanje prioriteta elemenata. Ako se

usporedi s hijerarhijom AHP, ciljna komponenta je najbolji primjer izvorne komponente. Cilj utječe na komponente niže razine, ali nijedna komponenta ne utječe na njega.

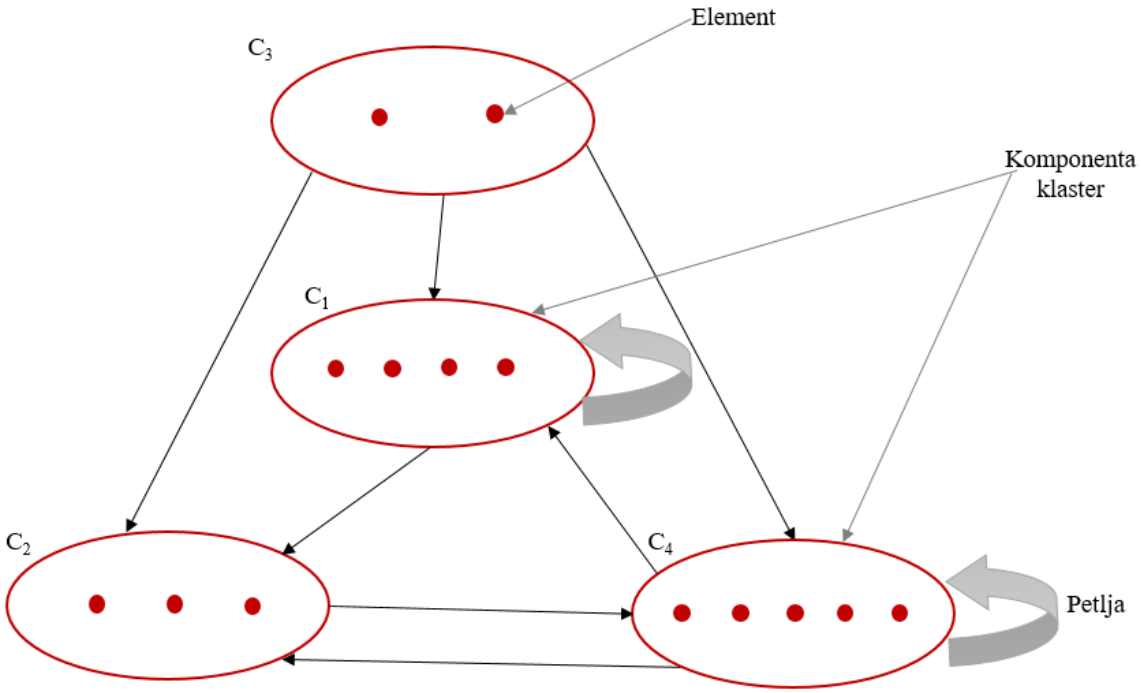

Slika 11: Mrežna struktura u metodi ANP [Izvor: [166]]

Postoje dvije osnovne zavisnosti između mrežnih komponenti: unutarnja i vanjska zavisnost (*Slika 11*). Ako su čvorovi unutar klastera međusobno povezani tada govorimo o unutarnjoj zavisnosti unutar klastera i označavamo ju kružnom petljom. Ako su povezani čvorovi koji pripadaju različitim klasterima, tada govorimo o vanjskoj zavisnosti i označavamo ju lukom između klastera. Nelinearna mreža prikazana je na *Slici 11*. Nelinearna mreža sadrži klastere i čvorove, kao i unutarnju i vanjsku zavisnost između elemenata [180].

Kad su usporedbe u parovima završene, izračunava se omjer neusklađenosti. U AHP postoje četiri osnovna koraka [43] [167]. Prvi korak je stvaranje hijerarhijske strukture, nakon čega slijedi dvostruka usporedba elemenata iste razine u strukturi u odnosu na superiorne elemente u hijerarhiji. Treći korak je izračunavanje prioriteta, a posljednji korak zahtijeva analizu osjetljivosti.

Dizajn mreže jedan je od najvažnijih koraka metode ANP jer prisiljava donositelja odluka na temeljnu analizu problema. Dizajn mreže u problemu odlučivanja ključni je faktor pronalaženja pravog rješenja. U literaturi ne postoje jasne upute o tome kako dizajnirati mrežu [180]. Metoda ANP provodi se u nekoliko koraka [181]:

1. Identificiranje klastera s pripadajućim kriterijima.
2. Izrada matrice utjecaja među kriterijima - sastoji od izračuna prioriteta između elemenata istog klastera i određivanja koji je element utjecajniji i u kojoj mjeri.
3. Izrada matrice utjecaja među klasterima – sastoji se od usporedbe u parovima matrica između klastera i izračunava prioritete između klastera.
4. Kada se izrade sve matrice usporedbi na razini kriterija izrađuje se netežinska supermatrica (engl. *unweighted supermatrix*) koja sadrži prioritete elemenata po blokovima. Na isti način možemo dobiti i težine klastera.
5. Izračunavanje težinske supermatrice (engl. *weighted supermatrix*).
6. Izračunavanje granične supermatrice tako da množimo težinsku supermatricu samu sa sobom tako dugo dok svi stupci matrice ne postanu međusobno jednaki. Za neku matricu kažemo da je stohastična ako zbroj vrijednosti njezinog stupca iznosi 1.

Ograničenja metode ANP uključuju veliki broj usporedba u parovima, dugotrajan postupak implementacije i veliku mogućnost za nerazumijevanje nekih usporedbi u parovima koje je potrebno napraviti. Složenost usporedbi u parovima na razini klastera moguće je smanjiti integriranjem ANP-a i DEMATEL-a [178], [182]. DEMATEL je korišten za identificiranje najjačih odnosa u mreži koji smanjuju broj izvedenih usporedbi u parovima.

4.7. Metoda DEMATEL

Metoda DEMATEL (engl. *Decision-making trial and evaluation laboratory*) razvijena je između 1972. i 1976. na Battelle Memorial institutu[2] u Ženevi u svrhu proučavanja i rješavanja složene i isprepletene problematike grupe odnosno odlučivanja unutar grupe [183]. Metoda DEMATEL može poboljšati razumijevanje specifične problematike, klasteriranje isprepletenih problema i pridonijeti identificiranju izvodljivih rješenja hijerarhijskom strukturom [184]. Za razliku od metode AHP gdje ne postoji zavisnost među kriterijima, primjenom metode DEMATEL može se utvrditi međuzavisnost između kriterija pomoću dijagrama uzroka i posljedica kako bi se prikazali odnosi i snage utjecaja među kriterijima [185]. Postupak metode DEMATEL sastoji se od nekoliko koraka [183], [185], [186], [187], [188]:

1. Prikupljanje mišljenja stručnjaka i izračun matrice *Z*, dimenzije $n \times m$ gdje *n* predstavlja broj kriterija, a *m* broj stručnjaka. Svaki stručnjak treba odrediti stupanj utjecaja jednog kriterija u odnosu na drugi kriterij za svaki par kriterija. Stupanj utjecaja vrednuje se od 0, 1, 2, 3 i 4 odnosno „nema utjecaja“, „nizak utjecaj“, „srednji utjecaj“, „visok utjecaj“ i „vrlo jak utjecaj“. Izraz x_{ij} određuje stupanj utjecaja kriterija *i* nad kriterijem *j*. Dijagonalni elementi matrice jednaki su nuli kada je *i*=*j*. Za svakog stručnjaka kreira se kvadratna matrica *n* oznaka X^1, X^2, X^3, … X^m. $X^m = [x_{ij}^m]$ gdje je *m* broj stručnjaka i gdje vrijedi $1 \leq m \leq Z$. Matrica *Z* izračunava se (*4.7.1*):

$$Z = [z_{ij}]; z_{ij} = \frac{1}{m} \sum_{k=1}^{m} x_{ij}^k \qquad (4.7.1)$$

2. Izračun normalizirane inicijalne matrice *D*. Svaki element matrice *D* ima vrijednost između nule i jedan. Inicijalna normalizirana matrica *D* izračunava se $D = Z \times S$ gdje je S (*4.7.2*).

$$S = \frac{1}{\max\limits_{1 \leq i \leq n} \sum_{j=1}^{n} a_{ij}} \qquad (4.7.2)$$

3. Izračun totalne matrice veza *T*. Matrica *T* izračunava se $T = D \times (I - D)^{-1}$ gdje je *I* jedinična matrica. U matrici *T* potrebno je izračunati sume stupaca *(c)* i sume redaka *(r)*.

[2] https://www.battelle.org/

Zbroj nekog retka označava totalni utjecaj koji pojedini kriterij ima na druge kriterije (r_i). Zbroj nekog stupca označava totalni utjecaj koji pojedini kriterij prima od ostalih kriterija (c_i). Za svaki kriterij može se izračunati zbroj totalnog utjecaja koji on ima na druge kriterije i koji prima od drugih kriterija $(r_i + c_i)$. Isto tako, može se izračunati i razlika $(r_i - c_i)$ koja predstavlja utjecaj kriterija na sustav. Ukoliko je razlika pozitivna tada je kriterij „uzorak“ u mreži, a kada je razlika negativna, tada je kriterij „primatelj“ u mreži [182].

4. Definicija praga i izrada dijagrama uzroka i posljedica. Matrica *T* pruža informacije o tome kako jedan kriterij utječe na drugi. Donositelji odluka trebaju definirati prag kako bi filtrirali one kriterije čije su vrijednosti veće od vrijednosti zadane pragom. Prag α izračunava se kao aritmetička sredina elemenata iz matrice *T*.

   Dijagram uzroka i posljedica izrađuje se tako da se u koordinatnom sustavu crtaju kombinacije $((r_i + c_i), (r_i - c_i))$ kako bi se vizualizirale kompleksne međuzavisnosti među kriterijima. U koordinatnom sustavu nacrtaju se sve točke kriterija, a među njima strelice utjecaja samo u slučajevima kada je neka ćelija u matrici *T* veća od praga.

Demonstracijski primjer metode DEMATEL izrađen je nakon što je šest sudionika *(N=6)* odredilo stupanj utjecaja jednog kriterija u odnosu na drugi kriterij za svaki par kriterija (K1., K2., K3. i K4) u demonstracijskom primjeru. Zatim je kreirana matrica *Z* (*4.7.3*). Prateći korake metode DEMATEL, matrica *Z* transformirana je u matricu *T* (*4.7.4*).

$$Z = \begin{array}{c} \\ K1. \\ K2. \\ K3. \\ K4. \end{array} \begin{array}{c} \begin{array}{cccc} K1. & K2. & K3. & K4. \end{array} \\ \begin{bmatrix} 0 & 3,5 & 2,2 & 2,8 \\ 2,5 & 0 & 2,2 & 2 \\ 1,7 & 1,7 & 0 & 3,3 \\ 2,2 & 1,5 & 2,7 & 0 \end{bmatrix} \end{array} \qquad (4.7.3)$$

Izračunata je vrijednost praga α=1,17 kao aritmetička sredina vrijednosti u matrici *T*. Crvene vrijednosti u matrici *T* predstavljaju vrijednosti veće od α. To su najjače veze utjecaja među dva kriterija u strukturi problema odlučivanja.

$$T = \begin{array}{c} \\ K1. \\ K2. \\ K3. \\ K4. \end{array} \begin{array}{c} \begin{array}{cccc} K1. & K2. & K3. & K4. \end{array} \\ \begin{bmatrix} 1,08 & 1,40 & 1,38 & 1,57 \\ 1,13 & 0,92 & 1,18 & 1,29 \\ 1,04 & 1,06 & 0,96 & 1,37 \\ 1,06 & 1,03 & 1,18 & 1,06 \end{bmatrix} \end{array} \quad (4.7.4)$$

Prva crveno obojana vrijednost je 1,40 (*K1.*, *K2.*) i ona označava da kriterij *K1.* utječe na kriterij *K2.*, tj. da je kriterij *K2.* zavisan od kriterija *K1.* Kriterij K1. utječe i na kriterije *K3.* i *K4.* odnosno kriteriji *K3.* i *K4.* su zavisni od kriterija *K1.* U matrici Z (*4.7.3*) prikazano je 12 veza među kriterijima (toliko ćelija je imalo vrijednost različitu od 0). U matrici T (*4.7.4*) imamo samo 7 veza. Moguće je i ručno povećavati vrijednost praga odnosno α čime možemo broj veza dodatno smanjivati i kasnije smanjiti složenost provedbe metode ANP.

Autori Kadoić i Divjak [106] te grupa autora Shaoa i ost. [189]navode glavne prednosti korištenja metode DEMATEL:

- Standardizirana ljestvica koja se koristi prilikom određivanja težina utjecaja među kriterijima.
- Provođenje metode DEMATEL postaje filter za najjače veze u problemu odlučivanja. Glavna uloga integracije metoda ANP i DEMATEL je ta da se smanjuje i složenost provođenja metode ANP jer se direktno smanjuje broj usporedbi koje je potrebno provesti u parovima. U nekim slučajevima provođenje metode DEMATEL ne rezultira smanjenjem inicijalnih veza utjecaja među kriterijima, ali tada možemo sami podešavati vrijednost praga α.
- Vrijednosti $(r_i + c_i)$ i $(r_i - c_i)$ mogu dati prvu informaciju o težinama kriterija što se kasnije može uključiti u mjere konzistencije u metodi ANP.

DEMATEL i ANP se često kombiniraju zajedno budući da je metoda ANP jako kompleksna te se zato metoda DEMATEL koristi za smanjenje složenosti primjene metode ANP. Kombinacija metoda DEMATEL i ANP u literature se naziva DEMATEL-ANP [106].

4.8. Istraživanje pomoću rubrike

Rubrika je tablica kriterija postavljenih na nekoliko razina. Rubrika se koristi s ciljem donošenja procjena o tome je li učenik/student postigao određenu razinu ishoda učenja ili drugog postignuća koje se vrednuje (kompleksni zadaci, aktivnosti ili zadatci poput istraživačkog rada, projekata, problemskih zadataka ili rasprava).

Primjena rubrike kao instrumenta za vrednovanje ima nekoliko prednosti: skraćuje vrijeme potrebno za vrednovanje, omogućava davanje ujednačene povratne informacije sudionicima u ispitivanju, potiče kritičko razmišljanje i omogućuje objektivno kriterijsko vrednovanje [190].

Rubrika je organizirana tako da prikazuje kriterije kojima se mjeri kvaliteta ostvarenog. Kriteriji su postavljeni na nekoliko razina. Razine sadrže opise za svaki nivo napretka. Kriteriji izvedbe jasno navode razinu očekivane izvedbe za svaku numeričku vrijednost u rubrici.

Rubrike su dokumenti koji artikuliraju očekivanja za zadatak ili skup zadataka nabrajanjem procjene kriterija i opisujući razinu kvalitete u odnosu na svaki od tih kriterija [191].

Budući da su rubrike - po definiciji - prilično detaljni vodiči za vrednovanje, mogu se koristiti za valjano ocjenjivanje višedimenzionalnih performansi [192], [193], a rubrike su glavni izbor za mnoge programere testiranja programa jer dopuštaju, barem umjereno, pouzdanu procjenu složenih izvedbi [194].

Korištenje rubrike za evaluaciju i povratne informacije ima nekoliko potencijalnih prednosti: jasnoća i transparentnost opisnica u rubrici mogu postupak vrednovanja učiniti bržim, lakšim i dosljednijim [195].

Rubrika se može primijeniti u razvoju i edukaciji novozaposlenog osoblja [196]. Ukoliko se rubrika koristi kao mehanizam za povratne informacije, tada rubrika pomaže ispitanicima da razumiju koja područja trebaju poboljšati [191]. Nadalje, rubrika je alat za samoprocjenu studenata kao pomoć pri učenju u različitim predmetima [197], alat za samoprocjenu učenika u srednjoj školi u učenju matematike [198], engleskog jezika i povijesti [199], alat za analizu literature [200], alat za analizu krajobraza [197], alat za upravljanje poslovnim informacijama [201], alat u programu razvoja vodstva [202], alat u dizajnu multimedijalnog sadržaja [203]. Rubrika je korištena kao mjerni instrument za procjenu digitalne zrelosti osnovnih i srednjih škola u Republici Hrvatskoj (e-škole) [93]–[95].

Postoje dvije vrste rubrika [204]:

1. analitička rubrika - podrazumijeva više kriterija i analizu razina ostvarenosti svakog od njih, tj. analitičke rubrike su višedimenzionalne i preporuka je da se koriste kao dio formativnog vrednovanja jer su dizajnirane kao alat za unapređenje.
2. holistička rubrika - opisuje za svaku razinu cjelokupno očekivano postignuće bez analitičke razrade, tj. one su jednodimenzionalne i omogućuje bržu procjenu predmeta istraživanja rada kao cjeline.

Tri su osnovna koraka za izradu rubrike (*Slika 12)*:

1. Definiranje kriterija koji su predmet procjene.

2. Definiranje razina prema kojima se kriteriji ocjenjuju.

3. Definiranje opisnica kriterija za svaku razinu.

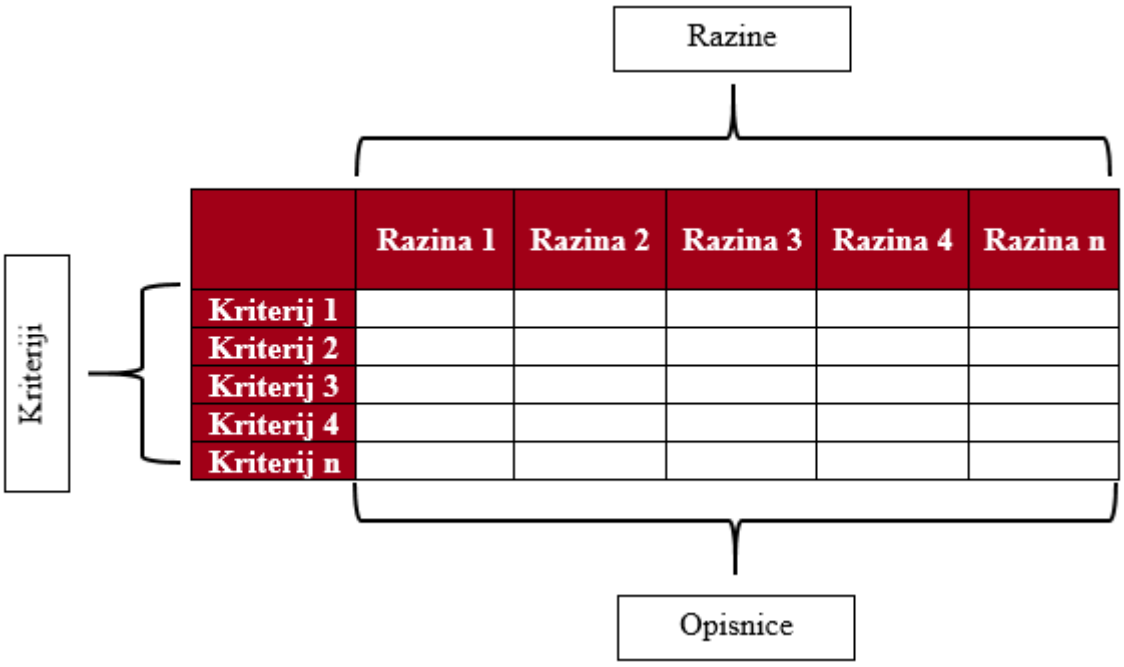

Slika 12: Sastavnice rubrike

Autorica Coil [105] navodi da nam rubrika pomaže da realno ocijenimo predmet istraživanja jer nam omogućava da budemo precizniji s očekivanjima i kriterijima koji su predmet procjene. Autorica navodi da nema pravila za koliko kriterija se preporučuje da budu sastavni dio rubrike, ali preporučuje se da se rubrika sastoji od četiri ili pet razina. U ovom istraživanju koristi se rubrika s pet razina zrelosti.

4.9. Kompozitni indeks

Kompozitni indeks koristi se u istraživanju društvenih pojava kada se mora razmotriti više varijabli kako bi se dobila složena ocjena ili razumjele različite dimenzije fenomena [109]. U istraživanju u sklopu ove doktorske disertacije kompozitni indeks koristi se kako bi se izvršila usporedba ranga visokih učilišta prema stupnju digitalne zrelosti [182]. Visoka učilišta koriste razne pokazatelje performansi (engl. *Performance Indicators*) kako bi pratili ključne procese kao što su istraživanje, poučavanje, usluge i financijski učinak.

Različiti autori navode u literaturi različite primjere primjene pokazatelja performansi u visokom učilištima. Autor Taylor [205] identificira razloge nezadovoljstva visokih učilišta s pokazateljima performansi te predlaže učinkovit način prikupljanja ulaznih podataka kako bi se poboljšala primjena pokazatelja performansi. Autori Badri i Abdulla [206] navode da visoka učilišta mogu primjenom metode AHP odrediti uspješnost članova fakulteta na temelju njihovog istraživačkog rada, poučavanja te odnosom prema zajednici i odnosom prema visokom učilištu.

Autor Suryadi [35] navodi da se uspješnost visokog učilišta može mjeriti korištenjem metode AHP. Autor Lukman [207] navodi da se visoka učilišta mogu rangirati na temelju pokazatelja performansi korištenjem istraživačkih, obrazovnih i indikatora okoline. Autori Asif i Raouf [208] predlažu listu dijagnostičkih pitanja kako bi se osigurala kontrola kvalitete na visokim učilištima. Autor Şencan [209] u radu istražuje postoji li statistički značajna razlika između prijedloga sveučilišnih administratora i prijedloga članova fakulteta vezano uz način koliko strogo treba pratiti pokazatelje performansi uspješnosti nastavnika u obrazovnom procesu. Autor You [210] u svojem radu identificira pokazatelje performansi korištenjem podataka dobivenih pomoću sustava za upravljanje učenjem LMS-a (engl. *Learning Management System*) za predviđanje dostignuća u online učenju. Grupa autora [211] prikazuju integrirani okvir analitika učenja za percepciju kvalitete visokih učilišta kroz troslojni model sadržaja, procesa i angažmana pokazatelja performansi.

Kreiranje kompozitnog indeksa provodi se u nekoliko koraka [212]:

1. Određivanje teorijskog okvira. Potrebno je stvoriti teorijski okvir koji pruža osnovu za odabir i kombinaciju pojedinih pokazatelja u smisleni kompozitni pokazatelj prema načelu prikladnosti za svrhu istraživanja i izgradnju složenih pokazatelja. Okvir treba jasno identificirati fenomen koji se mjeri i njegove sastavnice. Postupak je potrebno temeljiti na onome što je poželjno mjeriti, a ne na tome koji su pokazatelji dostupni.

Rezultat prvog koraka su jasno razumijevanje i definicija višedimenzionalnog fenomena koji se istražuje, popis kriterija za odabir osnovnih varijabli i uredno vođena dokumentacija.

2. Odabir podataka. Snage i slabosti složenih pokazatelja u velikoj mjeri proizlaze iz kvalitete sustava temeljne varijable. U idealnom slučaju, varijable bi trebale biti odabrane na temelju njihove važnosti, pouzdanosti podataka, pravovremenosti, pristupačnosti, itd. Kvaliteta i točnost složenih pokazatelja trebaju se razvijati paralelno s poboljšanjima u fazi prikupljanja podataka i razvoja pokazatelja. Rezultati drugog koraka su provjera kvalitete dostupnih pokazatelja, rasprava o prednostima i nedostacima svakog odabranog pokazatelja te izrađen sažetak tablice s podacima.
3. Dodavanje podataka koji su nedostajali. Postoje tri opće metode za rad s podacima koji nedostaju: odbacivanje slučaja, pojedinačno dodavanje ili višestruko dodavanje. Prva metoda koja se naziva kompletna analiza slučaja, jednostavno izostavlja nedostajuće zapise iz analize. Druga dva pristupa nedostajuće podatke smatraju dijelom analize i pokušavaju dodati vrijednosti bilo kroz jedno dodavanje, npr. srednja vrijednost, medijan, mod ili višestruko dodavanje npr. Markovljev lanac i Monte Carlo algoritam [213]. Rezultati trećeg koraka su kompletan skup podataka bez vrijednosti koje nedostaju, mjera pouzdanosti svake dodijeljene vrijednosti tako da se istraži utjecaj na dodavanja u kompozitnom indikatoru i dokumentirani i objašnjeni odabrani postupci dodavanja i rezultati.
4. Multivarijatna analiza koristi skup statističko-matematičkih postupaka pogodnih za analizu podataka promatranjem više varijabli pri čemu je svaka na svoj način važna. Rezultati: usporediti statistički određenu strukturu skupa podataka s teorijskim okvirom i razmotriti moguće razlike, primijeniti odgovarajuću multivarijatnu analizu (faktorska analiza, Analiza glavnih komponenata – PCA (engl. *Principal Component Analysis*), analizirati strukturu dobivenog skupa podataka s podacima iz teorijskog okvira i dokumentirati rezultate multivarijatne analize.
5. Normalizacija. Postupak normalizacije potrebno je provesti kako bi varijable bile usporedive. Potrebno je odabrati najprikladniji postupak normalizacije odnosno metodu koja odgovara teorijskom okviru i svojstvu podataka npr. rangiranje, standardizacija ili z-score metoda [213].
6. Određivanje težina i agregacija trebalo bi se odvijati u skladu s temeljnim teorijskim okvirom. Potrebno je uzeti u obzir povezanost među pokazateljima te dokumentirati i objasniti postupak određivanja težina i agregaciju odnosno korištene metode.

7. Robusnost i osjetljivost. U sedmom koraku potrebno je izvršiti procjenu stabilnosti kompozitnog pokazatelja, prepoznati sve moguće izvore nesigurnosti u razvoju te provesti analizu osjetljivosti zaključaka (pretpostavki) i utvrditi koji su izvori nesigurnosti utjecajniji na rezultate i/ili ocjenu.
8. Povratak stvarnim podacima provodi se u osmom koraku da kako bi se provjerila povezanost i kauzalitet (ukoliko je moguće) i da bi se utvrdilo dominira li pretjerano na kompozitnim pokazateljima nekoliko pokazatelja i da se objasni relativna važnost podkomponenata kompozitnog pokazatelja.
9. Povezivanje s varijablama. U predzadnjem, devetom koraku, potrebno je povezati kompozitni indikator (ili njegove dimenzije) s postojećim (jednostavnim ili kompozitnim) pokazateljima, povezati kompozitni pokazatelj s drugim relevantnim mjerama, uzimajući u obzir rezultate analize osjetljivosti te opisno obraditi rezultate.
10. Prezentacija i vizualizacija u posljednjem koraku: potrebno je odabrati prezentacijski alat i vizualizacijske tehnike koje komuniciraju najviše informacija.

Demonstracijski primjer kompozitnog indeksa prikazan je u *Tablici 8.*

Tablica 8: Demonstracijski primjer kompozitnog indeksa

Područja	Elementi	ANP	AHP	TW	LEVEL	LP	HEI SP
K1.	**K1.1.**	0,17	0,25	0,04	1	0,00	**0,00**
	K1.2	0,17	0,15	0,03	2	0,20	**0,01**
	K1.3	0,17	0,31	0,05	3	0,40	**0,02**
	K1.4	0,17	0,28	0,05	4	0,60	**0,03**
K2.	**K2.1**	0,49	0,18	0,09	1	0,00	**0,00**
	K2.2	0,49	0,14	0,07	1	0,00	**0,00**
	K2.3	0,49	0,13	0,06	2	0,20	**0,01**
	K2.4	0,49	0,17	0,08	3	0,40	**0,03**
	K2.5	0,49	0,09	0,04	5	1,00	**0,04**
	K2.6	0,49	0,1	0,05	3	0,40	**0,02**
	K2.7	0,49	0,1	0,05	3	0,40	**0,02**
	K2.8	0,49	0,08	0,04	2	0,20	**0,01**
K3.	**K3.1**	0,24	0,6	0,14	2	0,20	**0,03**
	K3.2	0,24	0,4	0,10	3	0,40	**0,04**
K4.	**K4.1**	0,11	0,32	0,04	5	1,00	**0,04**
	K4.2	0,11	0,37	0,04	5	1,00	**0,04**
	K4.3	0,11	0,3	0,03	5	1,00	**0,03**
						ML	**0,37**

Demonstracijski primjer sastoji se od četiri područja (K1., K2, K3. i K4.) koje se sastoje od 17 elemenata.

Težinske vrijednosti područja određene su metodom ANP. Težinske vrijednosti elemenata određene su metodom AHP. Ukupna vrijednost – TW (engl. *Total element Weight*) izračunata je kao umnožak težinskih koeficijenata ANP i AHP za svaki element [182], [214].

U rubrici (stupac LEVEL) su određena postignuća zrelosti po svakom elementu (procjena stručnjaka na ljestvici od 1 do 5). U sljedećem koraku se vrijednosti iz stupca LEVEL temeljem procjene stručnjaka transformiraju u vrijednosti prioriteta – LP (engl. *Level Prioritiy*).

Vrijednost stupca HEI SP dobiva se kao umnožak stupca TW i stupca LP. Ukupna vrijednost promatranog demonstracijskog primjera kompozitnog indeksa iznosi 0,37.

4.10. Metoda DEX

DEX (engl. *Decision EXpert*) [105] je metoda višekriterijskog odlučivanja koja je razvijena početkom 1980. na Institutu Jožef Štefan[3] u Ljubljani, a njezin razvoj i kontinuirano unaprjeđenje traje do danas. Metoda DEX je kvalitativna metoda za višekriterijsko odlučivanje koja pruža podršku donositeljima odluka prilikom procjene i donošenja odluka o odabiru alternativa korištenjem diskretnih atributa i funkcija temeljenih na pravilima [212].

Metoda DEX primjenjuje se u raznim područjima: energetika [215], poljoprivreda [216], [217], medicina [218].

Metoda DEX sastoji se od niza alternativnih odluka koje su ključne za procjenu i analizu. Alternativa je opisana skupom varijabli koje se nazivaju atributima i predstavljaju neko promatrano ili ocijenjeno svojstvo alternativa [108].

DEX je hijerarhijska metoda, to znači da su atributi organizirani u hijerarhiji koja predstavlja dekompoziciju problema odluke na pod-probleme. Smjer odozdo prema gore (engl. *bottom-up*) označava zavisnost, tako da atributi više razine ovise o nižim, odnosno elementarnim atributima. Najosnovniji atributi, nazvani osnovni atributi, pojavljuju se kao završni čvorovi hijerarhije i predstavljaju osnovne karakteristike koje se mogu promatrati. Atributi više razine koji ovise o jednoj ili više nižih vrijednosti nazivaju se združeni atributi koji predstavljaju

[3] https://www.ijs.si/ijsw/JSI

evaluaciju alternativa. Najviši čvorovi (obično postoji samo jedan takav čvor) nazivaju se korijeni i predstavljaju konačnu ocjenu alternativa [212].

Metoda DEX se pokazala vrlo uspješnom u situacijama kada je potrebno izraditi kompleksne modele odlučivanja u kojima postoji veliki broj atributa i/ili alternativa i/ili su podaci nepouzdani i/ili ne postoje.

DEX je kvalitativna metoda. Većina metoda za višekriterijsko odlučivanje je kvantitativna odnosno koriste numeričke varijable dok kvalitativne metode koriste simboličke [219]. Metoda DEX temelji se na jednostavnim pravilima: model je predstavljen hijerarhijskom dekompozicijom atributa gdje atributi na višoj razini zavise o atributu na nižoj razini odnosno model je predstavljen strukturom stabla gdje na najvišoj razini hijerarhije može postojati jedan ili više korijena (najčešće jedan); vrijednosti atributa definirane su kvalitativnim ljestvicama; vrijednosti atributa na nižem nivou hijerarhije, kroz proces agregacije elementarnim pravilima odlučivanja određuju vrijednost atributa na višem nivou hijerarhije; model garantira konzistentnost dobivenog rješenja.

Koraci u odlučivanju primjenom metode DEX [108]:

a) Strukturiranje DEX modela i definiranje kvalitativnih ljestvica vrijednosti atributa,
b) Definiranje pravila odlučivanja i unos alternativa,
c) Evaluacija alternativa i analiza rezultata.

Primjenom alata DEXi, u demonstracijskom primjeru, prikazana je primjena metode DEX na primjeru usporedbe dva VU. Strukturiranje DEX modela na način da je odabran ciljni atribut – *ODZVU* koji se grana na tri atributa *P1.. , P2.* i *P3.* koji se granaju na podatribute *E1.1, E1.2, E1.3, E2.1, E2.2, E3.1, E3.2* i *E3.3.* Za svaki element definirana je kvalitativna ljestvica. Ljestvica se sastoji od nekoliko elemenata koji se najčešće opisuju riječju poput "niska", srednja", "visoka", "vrlo visoka". U demonstracijskom primjeru to su riječi: „low“, „medium“, „high“, „very high“. Definiranje pravila odlučivanja vrši se na način da se za svaku kombinaciju ulaznih atributa na nižoj razini odrede vrijednost atributa na višoj razini. Vrijednost atributa ODZVU predstavlja konačnu ocjenu koja je alternativa ukupno najbolja, u demonstracijskom primjeru to je alternativa VU_2 čija je vrijednost *„high“*. Rezultati direktnog uspoređivanja alternativa u parovima i grupama prikazani na *Slici 13.*

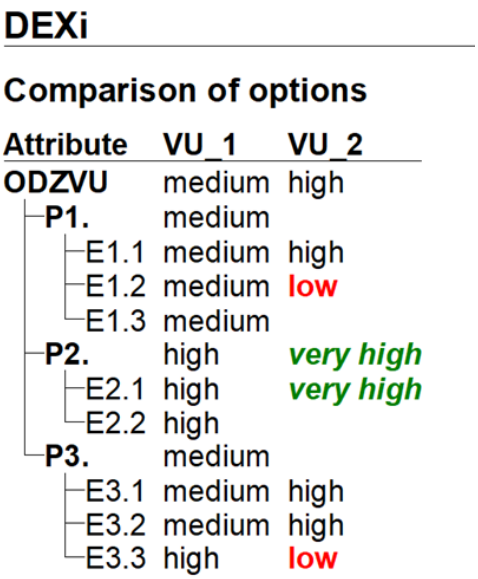

Slika 13: Analiza rezultata demonstracijskog primjera

5. Model za procjenu digitalne zrelosti

Visoko obrazovanje i njegova povezanost s istraživanjem i inovacijama predstavlja ključnu ulogu u osobnom i društvenom razvoju zajedno sa stvaranjem visoko kvalificiranih ljudskih potencijala koji su potrebni za stvaranje novih radnih mjesta, gospodarski rast i prosperitet. Visoko obrazovne ustanove su složene organizacije koje provode različite funkcije i razvijaju razne procedure kako bi ispunile svoje primarne obveze i dužnosti što predstavlja stalne izazove upravi i menadžmentu na svim razinama.

IKT omogućuju promjene u načinu učenja i poučavanja, međutim te promjene ne jamče podizanje kvalitete učenja i poučavanja. Kvalitetni visokoobrazovni sustav te istraživačka izvrsnost danas nisu mogući bez modernog i naprednog IKT-a koji je nezaobilazan temelj za nove metode i iskorake u istraživanjima, suradničko okruženje i skup alata koji omogućuju suradnju nastavnika, studenata i istraživača. Korištenje i integracija IKT-a u svakodnevni rad svih zaposlenika, učenje i poučavanje, znanstveno-istraživački rad, transfer tehnologije, razvoj IKT kulture doprinose razvoju digitalne zrelosti visokih učilišta (VU).

Razvoj ODZVU ima za cilj identificiranje područja i elemenata važnih za digitalnu zrelost VU-a i važnih prilikom strateškog planiranja o uvođenju IKT-a na VU-ima te prepoznavanje područja i elemenata ključnih za podizanje razine digitalne zrelosti VU *(Slika 14)*. IPDZVU omogućit će procjenu digitalne zrelosti VU-a po područjima i elementima identificiranima u ODZVU.

5.1. Razvoj Okvira za digitalnu zrelost visokih učilišta (ODZVU)

Na *Slici 14* prikazan je hodogram razvoja Okvira za digitalnu zrelost visokih učilišta (ODZVU). Kako bi se razvio ODZVU provedena je kvalitativna analiza strateških dokumenta i kvalitativna analiza postojećih okvira za digitalnu zrelost. Održane su dvije fokus grupe. Prva fokus grupe, čiji je cilj bio razvoj okvira za procjenu digitalne zrelosti za specifično područje – visoka učilišta, održana je u Varaždinu od 9. do 11. srpnja 2015., a druga, na kojoj su ispitanici zamoljeni da izdvoje koji ključni elementi, prema njihovom mišljenju, najbolje predstavljaju područja procjene digitalne zrelosti održana je u Splitu od 5. do 6. srpnja 2016. Evaluacija i revidiranje okvira od strane vanjskih eksperata rađena je u rujnu 2016. Delphi istraživanje provedeno je od 8. do 29. svibnja 2020. s ciljem specificiranja područja i elemenata unutar područja na temelju usuglašavanja stavova nezavisnih eksperata. Kako bi se specificirali

elementi unutar područja na temelju usuglašavanja stavova nezavisnih eksperata, od 1. do 21. srpnja 2020. provedeno je istraživanje metodom sortiranja karata. Temeljem izračuna pokazatelja valjanosti sadržaja za rezultate dobivene istraživanjima provedenim metodom Delphi i metodom sortiranja karata dobiven je ODZVU.

Istraživanja su detaljnije objašnjena u poglavljima: Poglavlje 5.1.1., Poglavlje 5.1.2. i Poglavlje 5.1.3.

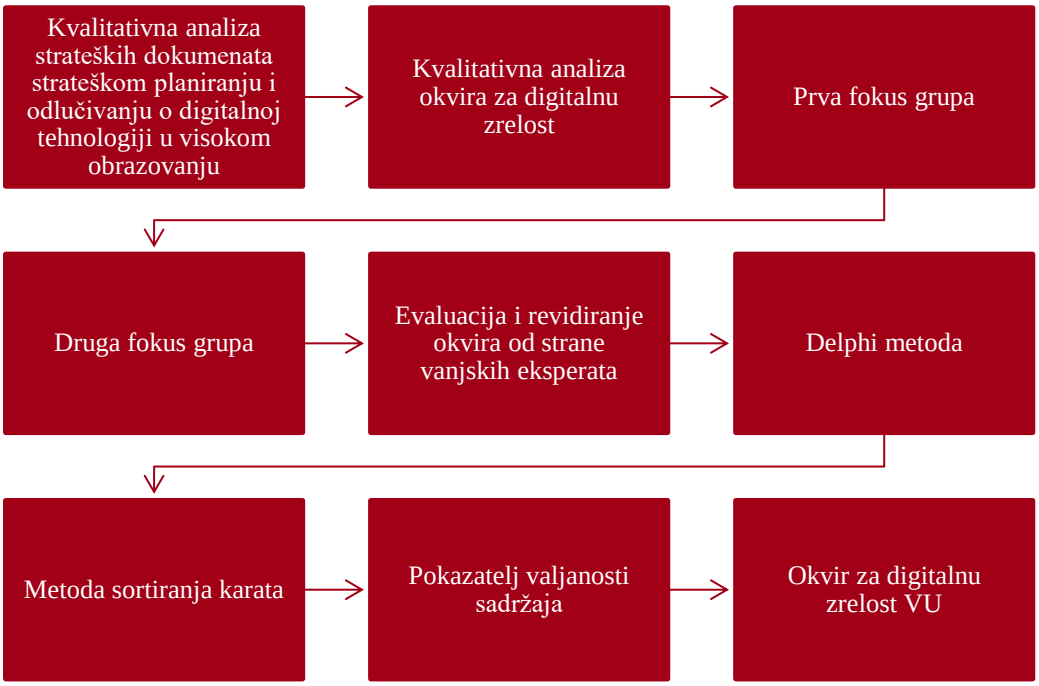

Slika 14: Hodogram razvoja Okvira za digitalnu zrelost visokih učilišta

5.1.1. Primjena metode fokus grupe u istraživanju

Metoda fokus grupa je kvalitativni oblik istraživanja koji uključuje grupnu diskusiju o nekoj zadanoj temi. Osnovni cilj fokus grupe je potaknuti dubinsku diskusiju kojom će se istražiti vrijednosti ili stavovi ispitanika prema nekom problemu ili temi. Informacije prikupljene ovom metodom u funkciji su konstrukcije i/ili testiranja modela koji najbolje oslikava istraživani problem. Metoda fokus grupe detaljno je objašnjena u Poglavlju 4.1.

Prva fokus grupa održana je u Varaždinu od 9. do 11. srpnja 2015. na kojoj je sudjelovao tim stručnjaka iz Belgije, Škotske i Hrvatske koji imaju ekspertizu upravljanja VU-om i/ili ekspertizu bavljenja digitalnom tehnologijom u VU. Općenito za fokus grupu bitna je uloga

moderatora koji vodi tijek razgovora. Razgovor traje od 90 do 120 minuta i unaprijed je kreiran u skladu s ciljevima istraživanja. Moderator vodi sudionike u raspravi koja teče od općeg prema posebnom, te se dolazi do relevantnog pitanja. U predmetnom istraživanju moderator fokus grupe bila je prof.dr.sc. Blaženka Divjak.

Kod fokus grupa važna je homogenost jer su tada sudionici otvoreniji, slobodniji, a rezultati fokus grupa interpretiraju se na grupnoj, a ne individualnoj razini, te je stoga važno da su sudionici međusobno slični. Svi članovi fokus grupe dijele interes za implementacijom IKT-a na visoka učilišta, ali u mnogim drugim aspektima skupina je bila heterogena (sveučilišni profesori, doktorandi, predstavnica Sveučilišnog računarskog centra SRCE te predstavnica Instituta za građevinarstvo Hrvatske - IGH[4]). Cilj prve fokus grupe bio je razvoj Okvira za procjenu digitalne zrelosti za specifično područje – visoka učilišta. Specifični cilj je prilagodba postojećih okvira za procjenu digitalne zrelosti za Okvir za procjenu digitalne zrelosti visokih učilišta.

Prva fokus grupa imala je 15 ispitanika (*N=15*). Jedanaest ispitanika (*N=11*) u istraživanju bili su eksperti s dvostrukom ekspertizom: ekspertiza upravljanja VU-om i ekspertiza bavljenja digitalnom tehnologijom u VU. Svih jedanaest ispitanika radilo je na pozicijama prorektora(ice), dekana(ice), prodekana(ice) ili na nekoj drugoj upravljačkoj funkciji na VU. Od jedanaest ispitanika njih šest (*N=6*) imalo je znanstveno-nastavno zvanje redovitog profesora, troje ispitanika imalo je znanstveno-nastavno zvanje izvanrednog profesora, jedan ispitanik imao je znanstveno-nastavno zvanje docenta i jedan ispitanik imao je zvanje znanstveno-nastavno zvanje suradnika. Od ukupnog broja ispitanika njih četiri (*N=4*) bili su polaznici doktorskog studija Informacijske znanosti Fakulteta organizacije i informatike, Sveučilište u Zagrebu.

Q1: Prema vašem mišljenju koja su ključna područja koje okvir za digitalnu zrelost visokih učilišta treba obuhvatiti?

> *Ispitanik 3: „Uprava VU treba djelovati u smjeru integracije IKT-a u poslovanje institucije.“*
>
> *Ispitanik 7: „Uprava VU također treba djelovati u smjeru integracije IKT-a učenju i poučavanju.“*

[4] Institut za građevinarstvo Hrvatske: https://www.igh.hr/

Ispitanik 1: „VU mora imati razvijenu strategiju integracije IKT-a na VU.“

Ispitanik 12: „VU treba planirati profesionalni razvoj svojih djelatnika.“

Ispitanik 9: „VU treba imati financijski plan ulaganja u IKT.“

Ispitanik 14: „Slažem se s navedenim, ali mi trebamo odrediti ključno područje, a ne sastavnice. Predlažem da prijedloge do sada navedene svrstamo u jedno područje – vodstvo i upravljanje.“

Ispitanik 2: „Potrebno je uključiti i planiranje.“

Ispitanici su se složili da jedno od područja bude „Vodstvo, planiranje i upravljanje“.

Ispitanik 5:“VU mora provoditi politiku osiguranja kvalitete primjene IKT-a.“

Ispitanik 3: „VU bi trebala imati procedure za vrednovanje rada djelatnika VU.“

Ispitanik 10: „VU treba imati procedure za praćenje rezultata znanstveno-nastavnog rada.„

Ispitanik 13: „Važno je osigurati politiku kvalitete na VU.“

Ispitanik 9: „VU treba pružiti povratne informacije studentima o njihovom napretku.“

Ispitanici su se složili da sve navedeno bude sastavni dio područja „Osiguranje kvalitete“.

Ispitanik 11: „Ne smijemo izostaviti znanstveno-istraživački rad.“

Ispitanik 15: „VU treba osigurati IKT podršku u znanstveno-istraživačkom radu.“

Ispitanik 4: „VU treba osigurati IKT podršku u znanstveno-istraživačkim projektima.“

Ispitanik 6: „Treba ulagati u kontinuirani profesionalni razvoj istraživača.“

Ispitanik 4: „Potrebno je poticati suradnju između istraživača.“

Ispitanik 8: „Potrebno je poticati istraživače u objavi znanstvenih radova.“

Ispitanici su se složili da sve navedeno bude sastavni dio područja „Znanstveno-istraživački rad uz podršku IKT-a“.

> *Ispitanik 3: „Predlažem da jedno od područja bude i transfer tehnologije i služenje društvu, kao rezultat istraživanja novih proizvoda, procesa ili usluga za kojim postoji potreba na tržištu.“*

Ispitanici su se složili da jedno od područja okvira za digitalnu zrelost VU bude „Transfer tehnologije i služenje društvu uz podršku IKT-a“.

> *Ispitanik 9: „VU treba poticati razvoj digitalnih kompetencija nastavnika.“*
>
> *Ispitanik 1: „VU treba poticati razvoj digitalnih kompetencija nastavnika i studenata.“*
>
> *Ispitanik 12: „VU treba podržavati inovacije u obrazovnom programu.“*
>
> *Ispitanik 5: „Treba poticati inovativne metode učenja i poučavanja.“*
>
> *Ispitanik 7: „Učenje mora biti dostupno bilo kada i bilo gdje.“*
>
> *Ispitanik 2: „VU treba omogućiti studentima i nastavnicima otvoreni kurikulum.“*
>
> *Ispitanik 15: „Ne smijemo zaboraviti podzastupljene skupine.“*
>
> *Ispitanik 10: „VU treba imati razvijen repozitorij kao centralno mjesto pohrane digitalnih dokumenata i obrazovnih sadržaja.“*

Ispitanici su se složili da sve navedeno bude sastavni dio područja „Učenje i poučavanje uz podršku IKT-a“.

> *Ispitanik 6: „VU treba se promovirati uz primjenu IKT-a, npr. mrežne stranice, društvene mreže….“*
>
> *Ispitanik 11: „Treba poticati razvoj digitalne pismenosti djelatnika.“*

Ispitanik 13: „Kod djelatnika VU treba razvijati samopouzdanje i motivaciju o važnosti promjene IKT-a.“

Ispitanik 14: „VU treba imati definirana pravila o primjeni etičkih standarda, autorskih prava i intelektualnog vlasništva.“

Ispitanici su se složili da sve navedeno bude sastavni dio područja „IKT kultura“.

Ispitanik 8: „Djelatnicima i studentima na VU potrebno je osigurati suvremenu IKT infrastrukturu.“

Ispitanik 3: „Potrebno je omogućiti pristup mreži unutar cijelog učilišta.“

Ispitanik 6: „Mrežna infrastruktura treba omogućiti brzi internet putem brže žične ili bežične mreže.“

Ispitanik 9: „Potrebno je osigurati IKT resurse znanstvenicima u njihovom znanstveno-istraživačkom radu.“

Ispitanik 11: „VU treba osigurati pouzdanu izvedbu, održavanje i interoperabilnost kako bi se omogućilo djelatnicima i studentima ne ometan pristup digitalnim tehnologijama.“

Ispitanik 5: „VU treba imati razvijen sustav informacijske sigurnosti.“

Ispitanici su se složili da sve navedeno bude sastavni dio područja „IKT infrastruktura“.

Tijekom interakcije između sudionika fokus grupe, a na temelju njihovog stručnog znanja i ekspertize te kvalitativne analize postojećih okvira za digitalnu zrelost dobiven je rezultat prve fokus grupe odnosno identificirano je sedam ključnih područja važnih za procjenu digitalne zrelosti visokih učilišta (*Slika 15).*

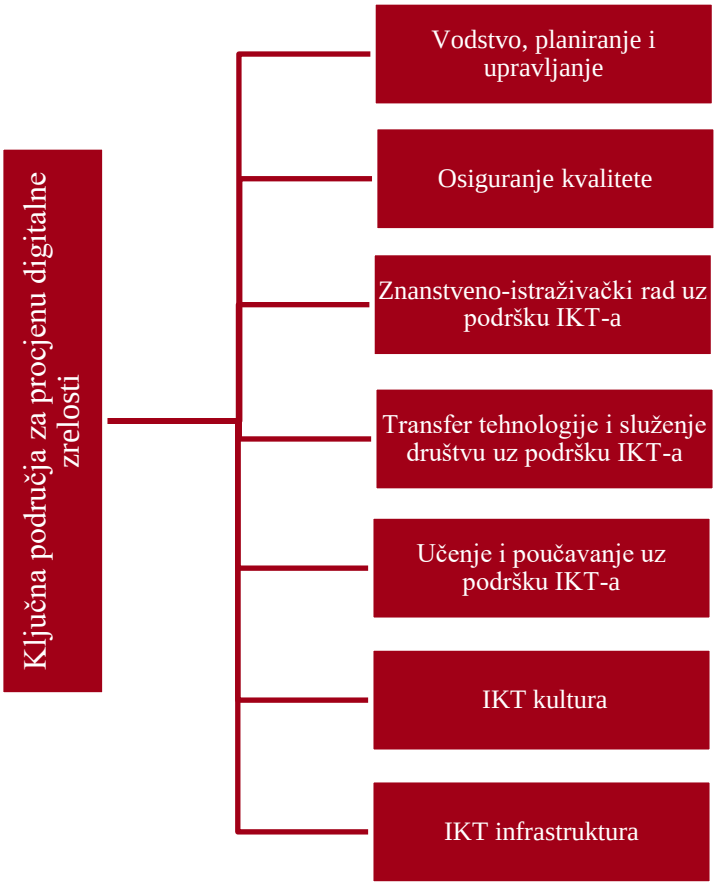

Slika 15: Rezultat prve fokus grupe

Druga fokus grupa održana je u Splitu od 5. do 6. srpnja 2016 i u njoj su sudjelovali ispitanici koji imaju ekspertizu upravljanja VU-om i ekspertizu bavljenja digitalnom tehnologijom u VU. Druga fokus grupa također je bila heterogena (sveučilišni profesori i doktorandi) i imala je deset ispitanika (*N=10*) od kojih su troje (*N=3*) polaznici doktorskog studija Informacijske znanosti Fakulteta organizacije i informatike Sveučilišta u Zagrebu. Na drugoj fokus grupi, koja je trajala 90 minuta, ispitanici su zamoljeni da izdvoje ključne elemente koji, prema njihovom mišljenju, najbolje predstavljaju područja procjene digitalne zrelosti. Moderator fokus grupe bila je prof.dr.sc. Blaženka Divjak. Sudionicima fokus grupe podijeljen je upitnik (*Tablica 9)* koji se sastojao od sedam ključnih područja. Svako područje opisano je pomoću elemenata koji su rezultat kvalitativne analize postojećih okvira za procjenu digitalne zrelosti. Elementi u svakom od predloženih područja zastupljeni su u jednom ili više analiziranih okvira za digitalnu zrelost (*Tablica 2*).

Tablica 9: Rezultati druge fokus grupe

Područja	Elementi i reference
Vodstvo, planiranje i upravljanje	Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama [86]
	Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima [72], [73], [86], [220]
	Upravljanje integracijom IKT-a u učenju i poučavanju na VU [72], [73], [86], [220]
	Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima [221]
	Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU [86]
	Planiranje usavršavanja zaposlenika VU u području primjene IKT-a [73], [86]
	Regulirani pristup IKT resursima [72], [86]
	Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU [221]
Osiguranje kvalitete	Politika osiguranja kvalitete primjene IKT-a na VU [222]
	Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU [222]
	Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a [222]
	Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a [222]
	Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a [222]
	Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU [222]
	Administrativna potpora za primjenu IKT-a [222]
Znanstveno-istraživački rad uz podršku IKT-a	Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova [221]
	Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima [221]
	Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu [223]
	Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja [221]
	Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu [72], [73], [75], [82], [86], [220]

	Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a [73], [75], [86]
Transfer tehnologije i služenje društvu uz podršku IKT-a	Suradnja VU s dionicima društva uz potporu IKT-a [224], [225]
	Umreženost istraživača i korisnika istraživanja uz potporu IKT-a [224], [225]
	Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda [224], [225]
	Šire digitalno okruženje (praćenje globalnih trendova u VO) [86], [72]
Učenje i poučavanje uz podršku IKT-a	*Osviještenost i sudjelovanje djelatnika u programima usavršavanja za razvoj digitalnih kompetencija* [72], [73], [82], [86], [220]
	Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU [73], [75], [82], [86], [220]
	Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika [75], [82], [86], [220]
	Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata [75], [82], [86], [220]
	Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju [73], [86], [220]
	Razvoj digitalne pismenosti i poticanje inovativnosti u primjeni IKT-a kod djelatnika VU [75], [86]
	Inovativne metode učenja i poučavanja uz pomoć IKT-a [73]
	Razvoj digitalnih kompetencija studenata [75], [86], [220]
	Dostupan repozitorij digitalnih obrazovnih sadržaja [75], [86]
	Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a [226]
	Upotreba analitika učenja u unapređenju učenja i poučavanja [227]
	Iskustva studenata o primjeni IKT-a [73], [75], [86], [220]
IKT kultura	Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata [73], [75], [86], [220]
	Samopouzdanje i motivacija djelatnika za primjenu IKT-a [73], [82], [86]
	Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata [73], [75], [86], [220]
	Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a [73], [75], [86]
	Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa [86], [224], [225]
	Politika VU u integraciji IKT-a i praćenju globalnih trendova [75], [86]

IKT infrastruktura	Planiranje i nabava IKT infrastrukture [72], [73], [75], [86], [220]
	Mrežna infrastruktura na VU [73], [75], [82], [86], [220]
	Raspoloživost IKT resursa za potporne službe [75], [86]
	Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU [86]
	Raspoloživost IKT resursa za znanstveno-istraživački rad [73], [82], [83], [220]
	Pristup IKT resursima za studente u nastavi i van nastave [73], [82], [86], [220]
	Pristup instaliranoj programskoj opremi [73], [82], [86], [220]
	Tehnička potpora i održavanje IKT resursa na VU [73], [75], [82], [86], [220]
	Sustav informacijske sigurnosti na VU [82], [86], [220]

Autorica je uz pomoć moderatorice prezentirala 52 elementa koji se najčešće pojavljuju u analiziranim okvirima za digitalnu zrelost. Ispitanici su izdvojili 42 elementa unutar 7 područja koja su definirana na prvoj fokus grupi za koje su smatrali na temelju svojeg stručnog znanja i ekspertize da trebaju biti sastavni dio ODZVU kojeg autorica razvija. U *Tablici 9* crnom bojom označeni su elementi za koje su ispitanici smatrali da su sastavni dio ODZVU-a, a crvenom bojom su označeni elementi koje su ispitanici smatrali redundantnim.

Područje „Vodstvo, planiranje i upravljanje“ – grupnom interakcijom donesen je zaključak da više od polovice ispitanika smatra da element „Regulirani pristup IKT resursima“ ne spada u navedeno područje, već u područje „IKT infrastruktura“. U području „IKT infrastruktura“ zastupljen je element „Sustav informacijske sigurnosti na VU“ koji ima isto ili slično značenje kao i navedeni element koji je stoga izuzet iz prijedloga okvira za digitalnu zrelost visokih učilišta.

Područje „Osiguranje kvalitete“ – grupnom interakcijom donesen je zaključak da više od polovice ispitanika smatra da element „Administrativna potpora za primjenu IKT-a“ ne spada u navedeno područje, već u područje „IKT infrastruktura“. U području „IKT infrastruktura“ zastupljen je element „Tehnička potpora i održavanje IKT resursa na VU“ koji imaju isto ili slično značenje kao i navedeni element koji je stoga izuzet iz prijedloga okvira za digitalnu zrelost visokih učilišta.

Područje „Transfer tehnologije i služenje društvu uz podršku IKT-a“ - grupnom interakcijom donesen je zaključak da više od polovice ispitanika smatra da element „Šire digitalno okruženje (praćenje globalnih trendova u VO)“ ne spada u navedeno područje, već u područje „Vodstvo, planiranje i upravljanje“. U području „Vodstvo, planiranje i upravljanje“ zastupljen je element „Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima“ koji imaju isto ili slično značenje kao i navedeni element koji je stoga izuzet iz prijedloga okvira za digitalnu zrelost visokih učilišta.

Područje „Učenje i poučavanje uz podršku IKT-a“ - grupnom interakcijom donesen je zaključak da više od polovice ispitanika smatra da sljedeća tri elementa „Osviještenost i sudjelovanje djelatnika u programima usavršavanja za razvoj digitalnih kompetencija“, „Razvoj digitalne pismenosti i poticanje inovativnosti u primjeni IKT-a kod djelatnika VU“ i „Inovativne metode učenja i poučavanja uz pomoć IKT-a“ imaju isto ili slično značenje kao i element „Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU“ unutar istog područja stoga su navedena tri elementa izuzeta iz prijedloga Okvira za digitalnu zrelost visokih učilišta. Element „Iskustva studenata u primjeni IKT-a“ također je izuzet iz prijedloga okvira za digitalnu zrelost visokih učilišta jer ima isto ili slično značenje kao i element „Razvoj digitalnih kompetencija studenata“ unutar istog područja.

Područje „IKT kultura“ - grupnom interakcijom donesen je zaključak da više od polovice ispitanika smatra da element „Politika VU u integraciji IKT-a i praćenju globalnih trendova“ ne spada u navedeno područje, već u područje „Vodstvo, planiranje i upravljanje“. U području „Vodstvo, planiranje i upravljanje“ zastupljen je element „Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima“ koji imaju isto ili slično značenje kao i navedeni element koji je stoga izuzet iz prijedloga okvira za digitalnu zrelost visokih učilišta.

Područje „IKT infrastruktura“ - grupnom interakcijom donesen je zaključak da više od polovice ispitanika smatra da sljedeća dva elementa „Mrežna infrastruktura na VU“ i „Pristup instaliranoj programskoj opremi“ imaju isto ili slično značenje kao i element „Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU“ unutar istog područja stoga su navedeni elementi izuzeti iz prijedloga okvira za digitalnu zrelost visokih učilišta.

Rezultatom kvalitativne analize okvira za procjenu digitalne zrelosti te rezultata istraživanja provedenog u dvije fokus grupe kreiran je prijedlog područja i elemenata ODZVU (*Tablica 9).*

5.1.2. Istraživanje metodom Delphi

Empirijsko istraživanje provedeno je metodom Delphi kroz jedan ciklus na uzorku od 57 eksperata (*N=57*) različitih sveučilišta iz Republike Hrvatske, Republike Slovenije, Belgije, Republike Srbije, Sjeverne Makedonije, Litve, Slovačke, Ujedinjenog Kraljevstva, Turske i SAD-a.

Kao što je ranije navedeno, cilj provođenja metode Delphi je specificiranje područja i elemenata unutar područja na temelju usuglašavanja stavova nezavisnih eksperata najčešće kroz više ciklusa. U istraživanju su sudjelovali eksperti koji imaju dvostruku ekspertizu: ekspertizu upravljanja VU-om i ekspertizu bavljenja digitalnom tehnologijom u VU. Istraživanje je provedeno primjenom metode Delphi koja uključuje kvantitativne metode za prikupljanje i analizu podataka. Postupak metode Delphi provodi se u najčešće tri ciklusa ili do postizanja potrebne razine suglasnosti eksperata (koji je u literaturi najčešće 70%) ili dok se ne dokaže da niti jedan ekspert više ne mijenja svoja rješenja već ostaje kod onih koje je već u prethodnim ciklusima predložio [137].

U Poglavlju 4.2. detaljno je opisana metoda Delphi te postupak njenog provođenja (*Slika 4).*

5.1.2.1. Provedba Delphi istraživanja

Metoda Delphi provedena je pomoću instrumenta istraživanja koji je razvijen na osnovu literature i rezultata empirijskog istraživanja tijekom fokus grupa (Poglavlje 5.1.1.).

Upitnik je sudionicima istraživanja dostavljen putem elektronske pošte, a izrađen je u alatu MS Excel (Prilog 1). U prvom stupcu upitnika navedeno je sedam područja ključnih za procjenu digitalne zrelosti VU, u drugom stupcu nabrojani su elementi koji su identificirani tijekom

druge fokus grupe (*Tablica 9)*. Ispitanici u istraživanja su odgovarali na dva pitanja: „*U kojoj mjeri se slažete da je element bitan za digitalnu zrelost visokih učilišta?*“ i „*U kojoj mjeri se slažete da je element smješten u ispravno područje (primjerice element Strateško planiranje integracije IKT-a VU u područje Vodstvo, planiranje i upravljanje)?*“. Upitnik se temelji na Likertovoj ljestvici procjenjivanja (*1 – uopće se ne slažem; 2 – uglavnom se ne slažem; 3 – niti se slažem niti se ne slažem; 4 – uglavnom se slažem; 5 – potpuno se slažem*).

Ispitanici su odgovorili na skup pojedinačnih pitanja: „*Navedite svoj stupanj obrazovanja*“, „*Imate li iskustva upravljanjem visokim učilištem (na razini uprave, zavoda, katedre, laboratorija i dr.)?*“, „*Koja je Vaša trenutna pozicija?*“ i „*Koje je vaše znanstveno-nastavno, nastavno ili suradničko zvanje?*“. Ispitanicima je također omogućen prostor za pisanje komentara kako bi još više doprinijeli ostvarivanju postavljenim ciljevima istraživanja. Upitnik je distribuiran ispitanicima u istraživanju na hrvatskom ili engleskom jeziku.

Za ocjenu sadržajne valjanosti odgovora ispitanika u istraživanju upotrijebljena je Lawsheova formula za CVR (*4.41*) gdje je *N* ukupan broj odgovora, a *n* broj ispitanika koji su ocijenili pojedini element s ocjenom 4 ili 5 (*4 – uglavnom se slažem; 5 – potpuno se slažem).*

CVR se izračunava za svaki pojedini element. Autor Lawshe [101] navodi da minimalna vrijednost koeficijenta CVR za više od 40 ispitanika iznosi 0,29. Samo oni elementi koji imaju veći ili jednak koeficijent minimalnom iznosu ostaju u daljnjem razmatranju.

Za svaki element izračunat je i stupanj suglasnosti ispitanika. Autor de Loe [228] suglasnost razlikuje na četiri razine:

- visoka suglasnost – kada je 70% sudionika istraživanja suglasno za pojedinu kategoriju,
- srednja (djelomična) suglasnost – kada je 60% sudionika istraživanja suglasno za pojedinu kategoriju,
- niska suglasnost - kada je 50% sudionika istraživanja suglasno za pojedinu kategoriju,
- bez suglasnosti - kada je manje od 50% sudionika istraživanja suglasno za pojedinu kategoriju.

Četiri razine suglasnosti prema [228] primijenjene su u ovom istraživanju.

a) Rezultati istraživanja na skup pojedinačnih pitanja

U prvom pitanju „*Navedite svoj stupanj obrazovanja*“ ispitanici su iz padajućeg izbornika mogli odabrati jedan od ponuđenih odgovora: SSS, VŠS, VSS, mr.sc., dr.art. i dr.sc. (*Slika 16*). Prema stupnju obrazovanja upitnik je ispunilo 50 ispitanika (*N=50*) ili 88% čiji je stupanj obrazovanja dr.sc., pet ispitanika (*N=5*) ili 9% čiji je stupanj obrazovanja VSS i dva ispitanika (*N=2*) ili 3% čiji je stupanj obrazovanja mr.sc.. Niti jedan od ispitanika nije imao stupanj obrazovanja SSS, VŠS ili dr.art..

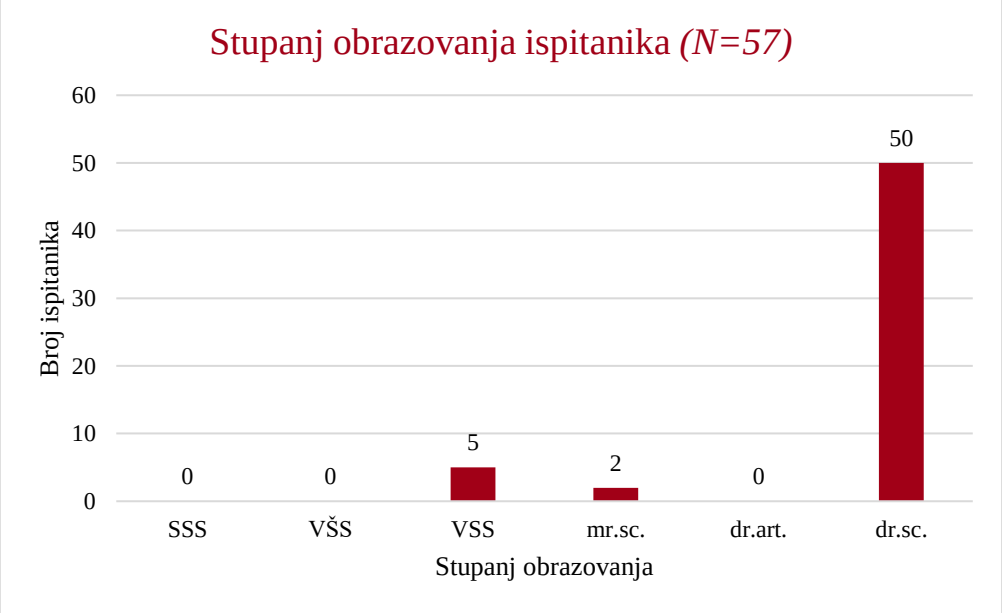

Slika 16: Stupanj obrazovanja ispitanika u prvom krugu Delphi istraživanja

U drugom pitanju „*Imate li iskustva upravljanjem visokim učilištem (na razini uprave, zavoda, katedre, laboratorija i dr.)?*“ svi ispitanici (*N=57*) su se izjasnili da imaju iskustva upravljanjem visokim učilištem.

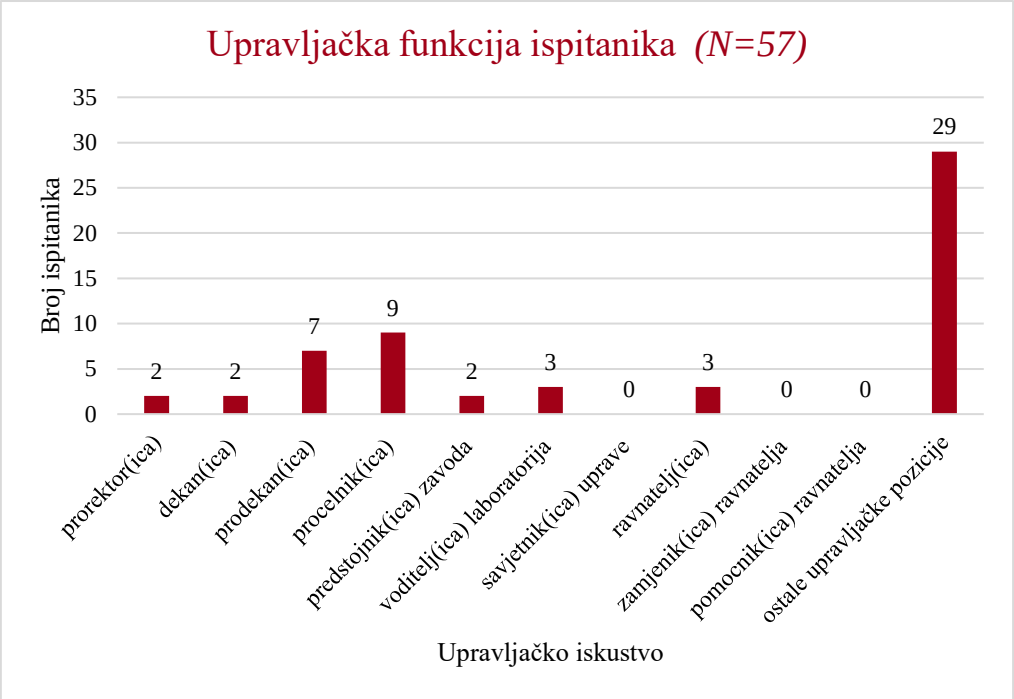

Slika 17: Upravljačka funkcija ispitanika u prvom krugu Delphi istraživanja

U trećem pitanju „*Koja je Vaša trenutna pozicija?*“ ispitanici su iz padajućeg izbornika mogli odabrati jedan od ponuđenih odgovora: prorektor(ica); dekan(ica); prodekan(ica); pročelnik(ica); predstojnik(ica) zavoda; voditelj(ica) laboratorija; savjetnik(ica) uprave; ravnatelj(ica); zamjenik(ica) ravnatelja; pomoćnik(ica) ravnatelja; ostale upravljačke pozicije. Od ukupnog broja ispitanika, njih 29 (*N=29*) ili 51% se izjasnilo da je trenutna njihova pozicija u upravljanju visokim učilištem na ostalim upravljačkim pozicijama, devet ispitanika (*N=9*) ili 16% izjasnilo se da je trenutna njihova pozicija u upravljanju visokim učilištem kao pročelnik ili pročelnica, sedam ispitanika (*N=7*) ili 12% ispitanika se izjasnilo da je trenutna njihova pozicija u upravljanju visokim učilištem kao prodekan ili prodekanica. Na poziciji voditelja ili voditeljice laboratorija nalazi se tri ispitanika (*N=3*) ili 5% ispitanika isto kao i na poziciji ravnatelja ili ravnateljice (*N=3*). Na poziciji prorektora ili prorektorice trenutno se nalaze dva ispitanika (*N=2*) ili 3% ispitanika, isto kao i na mjestu dekana ili dekanice (*N=2*) i predstojnika ili predstojnice zavoda (*N=2*). Među ispitanicima nitko se nije izjasnio da je savjetnik ili savjetnica uprave, zamjenik ili zamjenica ravnatelja te pomoćnik ili pomoćnica ravnatelja (*Slika 17*).

U posljednjem tj. četvrtom pitanju „*Koje je vaše znanstveno-nastavno, nastavno ili suradničko zvanje?*“ ispitanici su iz padajućeg izbornika mogli odabrati jedan od ponuđenih odgovora:

suradnik; asistent; poslijedoktorand; docent; izvanredni profesor; redovni profesor; redovni profesor u trajnom zvanju; predavač; ostalo. Od ukupnog broja ispitanika 18 ispitanika (*N=18*) ili 31% ispitanika ima zvanje izvanrednog profesora, 17 ispitanika (*N=17*) ili 30% ispitanika ima zvanje docenta, 13 ispitanika (*N=13*) ili 23% ispitanika ima zvanje redovitog profesora u trajnom zvanju. Od ukupnog broja ispitanika tri ispitanika (*N=3*) ili 5% imaju zvanje asistenta, isto kao i zvanje predavača. Po jedan ispitanik (*N=1*) ili 2% ispitanika izjasnilo se da imaju zvanje redovitog profesora, suradnika ili ostalo. Nitko od ispitanika nije se izjasnio da ima zvanje poslijedoktoranda (*Slika 18*).

Dobiveni rezultati pokazuju su da se radi o heterogenoj grupi s obzirom na zvanje ispitanika (dr.sc.; mr.sc.; VSS), upravljačku funkciju koju imaju u ustanovi (prorektor(ica); dekan(ica); prodekan(ica); pročelnik(ica); predstojnik(ica) zavoda; voditelj(ica) laboratorija; ravnatelj(ica); ostale upravljačke pozicije) te s obzirom na znanstveno-nastavno, nastavno ili suradničko zvanje (suradnik; asistent; docent; izvanredni profesor; redovni profesor; redovni profesor u trajnom zvanju; predavač; ostalo). Grupa je homogena s obzirom na iskustvo upravljanja visokim učilištem, tj. ispitanici u istraživanju izjasnili su se da imaju iskustvo upravljanja visokim učilištem.

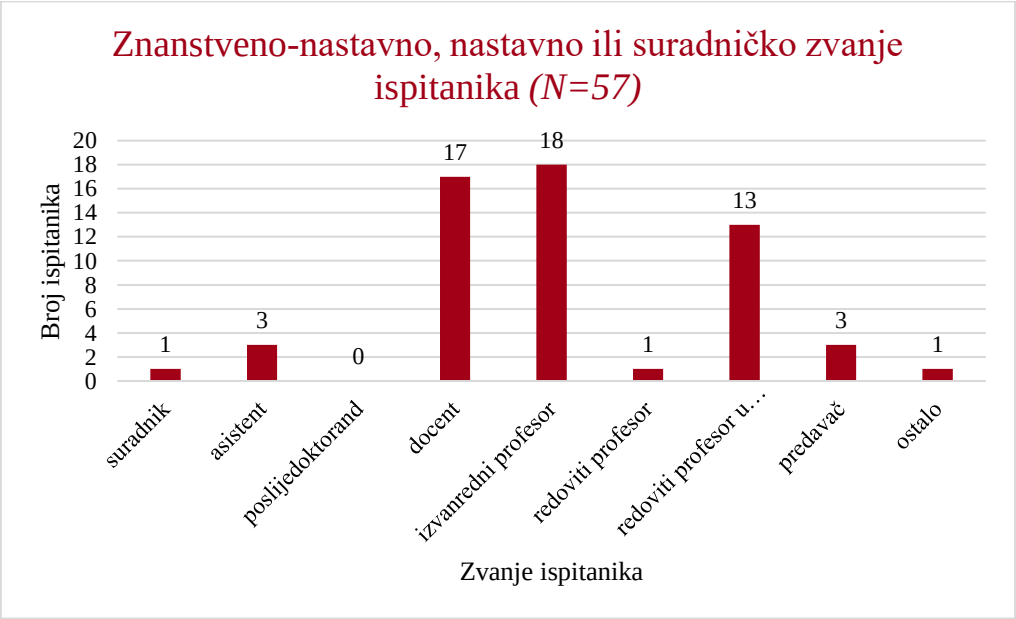

Slika 18: Znanstveno-nastavno, nastavno ili suradničko zvanje ispitanika u prvom krugu Delphi istraživanja

b) Rezultati istraživanja na pitanje „*U kojoj mjeri se slažete da je element bitan za digitalnu zrelost visokih učilišta?*“

U *Tablici 10* prikazani su rezultati istraživanja metodom Delphi za područje *Vodstvo, planiranje i upravljanje* koje se sastoji od sedam elemenata. Svih sedam elemenata ima CVR veći od 0,29 i svih sedam elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 10: Rezultati istraživanja metodom Delphi za područje: Vodstvo, planiranje i upravljanje

Elementi unutar područja Vodstvo, planiranje i upravljanje	CVR	Stupanj suglasnosti ispitanika
Upravljanje integracijom IKT-a u učenje i poučavanje na VU	0,93	96,49%
Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	0,86	92,98%
Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	0,86	92,98%
Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	0,82	91,23%
Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU	0,79	89,47%
Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	0,75	87,72%
Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	0,72	85,96%

U *Tablici 11* prikazani su rezultati istraživanja metodom Delphi za područje *Osiguranje kvalitete* koje se sastoji od šest elemenata. Pet elemenata ima CVR veći od 0,29 i pet elemenata ima stupanj suglasnosti ispitanika veći od 70% dok element *Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a* ima CVR 0,23 i stupanj suglasnosti ispitanika manji od 70% odnosno 61,40%.

U *Tablici 12* prikazani su rezultati istraživanja metodom Delphi za područje *Znanstveno-istraživački rad uz podršku IKT-a* koje se sastoji od šest elemenata. Svih šest elemenata ima CVR veći od 0,29 i svih šest elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 11: Rezultati istraživanja metodom Delphi za područje: Osiguranje kvalitete

Elementi unutar područja Osiguranje kvalitete	CVR	Stupanj suglasnosti ispitanika
Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a	0,68	84,21%
Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a	0,65	82,46%
Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU	0,61	80,70%
Politika osiguranja kvalitete primjene IKT-a na VU	0,58	78,95%
Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU	0,51	75,44%
Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a	0,23	61,40%

Tablica 12: Rezultati istraživanja metodom Delphi za područje: Znanstveno-istraživački rad uz podršku IKT-a

Elementi unutar područja Znanstveno-istraživački rad uz podršku IKT-a	CVR	Stupanj suglasnosti ispitanika
Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu	0,82	91,23%
Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima	0,82	91,23%
Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a	0,79	89,47%
Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu	0,68	84,21%
Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova	0,58	78,95%
Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja	0,54	77,19%

U *Tablici 13* prikazani su rezultati istraživanja metodom Delphi za područje *Transfer tehnologije i služenje društvu uz podršku IKT-a* koje se sastoji od tri elemenata. Sva tri elemenata imaju CVR veći od 0,29 i sva tri elemenata imaju stupanj suglasnosti ispitanika veći od 70%.

Tablica 13: Rezultati istraživanja metodom Delphi za područje: Transfer tehnologije i služenje društvu uz podršku IKT-a

Elementi unutar područja Transfer tehnologije i služenje društvu uz podršku IKT-a	CVR	Stupanj suglasnosti ispitanika
Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda	0,75	87,72%
Umreženost istraživača i korisnika istraživanja uz potporu IKT-a	0,68	84,21%
Suradnja VU s dionicima društva uz potporu IKT-a	0,51	75,44%

U *Tablici 14* prikazani su rezultati istraživanja metodom Delphi za područje *Učenje i poučavanje uz podršku IKT-a* koje se sastoji od osam elemenata. Svih osam elemenata ima CVR veći od 0,29 i svih osam elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 14: Rezultati istraživanja metodom Delphi za područje: Učenje i poučavanje uz podršku IKT-a

Elementi unutar područja Učenje i poučavanje uz podršku IKT-a	CVR	Stupanj suglasnosti ispitanika
Razvoj digitalnih kompetencija studenata	0,93	96,49%
Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU	0,89	94,74%
Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika	0,86	92,98%
Upotreba analitika učenja u unapređenju učenja i poučavanja	0,86	92,98%
Dostupan repozitorij digitalnih obrazovnih sadržaja	0,75	87,72%
Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata	0,75	87,72%
Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju	0,68	84,21%
Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a	0,58	78,95%

U *Tablici 15* prikazani su rezultati istraživanja metodom Delphi za područje *IKT kultura* koje se sastoji od pet elemenata. Svih pet elemenata ima CVR veći od 0,29 i svih pet elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 15: Rezultati istraživanja metodom Delphi za područje: IKT kultura

Elementi unutar područja IKT kultura	CVR	Stupanj suglasnosti ispitanika
Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata	0,82	91,23%
Samopouzdanje i motivacija djelatnika za primjenu IKT-a	0,79	89,47%
Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata	0,75	87,72%
Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a	0,72	85,96%
Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa	0,68	84,21%

U *Tablici 16* prikazani su rezultati istraživanja metodom Delphi za područje *IKT infrastruktura* koje se sastoji od sedam elemenata. Svih sedam elemenata ima CVR veći od 0,29 i svih sedam elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 16: Rezultati istraživanja metodom Delphi za područje: IKT infrastruktura

Elementi unutar područja IKT infrastruktura	CVR	Stupanj suglasnosti ispitanika
Pristup IKT resursima za studente u nastavi i van nastave	0,93	96,49%
Sustav informacijske sigurnosti na VU	0,93	96,49%
Planiranje i nabava IKT infrastrukture	0,89	94,74%
Raspoloživost IKT resursa za znanstveno-istraživački rad	0,86	92,98%
Tehnička potpora i održavanje IKT resursa na VU	0,86	92,98%
Raspoloživost IKT resursa za potporne službe	0,79	89,47%
Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU	0,75	87,72%

U *Tablici 17* prikazani su rezultati istraživanja metodom Delphi za pitanje „*U kojoj mjeri se slažete da je element bitan za digitalnu zrelost visokih učilišta?*“. Ispitanici su u istraživanju trebali odrediti stupanj suglasnosti u kojoj mjeri je pojedini element važan za područje ODZVU unutar kojeg se nalazi. U šest od sedam definiranih područja nije bilo promjena. U području Osiguranje kvalitete ispitanici nisu smatrali važnim element *Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a* (CVR = 0,23 i stupanj suglasnosti ispitanika iznosi 61,40%).

Tablica 17: Rezultati istraživanja metodom Delphi za pitanje „U kojoj mjeri se slažete da je element bitan za digitalnu zrelost visokih učilišta?“

Područje	Početni broj elemenata	CVR	Stupanj suglasnosti ispitanika	Broj elemenata nakon CVR testa
Vodstvo, planiranje i upravljanje	7	0,82	90,98%	7
Osiguranje kvalitete	6	0,54	77,19%	5
Znanstveno-istraživački rad uz podršku IKT-a	6	0,71	85,38%	6
Transfer tehnologije i služenje društvu uz podršku IKT-a	3	0,65	77,19%	3
Učenje i poučavanje uz podršku IKT-a	8	0,79	90,98%	8
IKT kultura	5	0,75	87,72%	5
IKT infrastruktura	7	0,86	92,98%	7
UKUPNO	**42**	**0,73**	**86,06%**	**41**

c) Rezultati istraživanja na pitanje „*U kojoj mjeri se slažete da je element smješten u ispravno područje (primjerice element Strateško planiranje integracije IKT-a VU u područje Vodstvo, planiranje i upravljanje)?*“

U *Tablici 18* prikazani su rezultati istraživanja metodom Delphi za područje *Vodstvo, planiranje i upravljanje* koje se sastoji od sedam elemenata. Svih sedam elemenata ima CVR veći od 0,29 i svih sedam elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 18: Rezultati istraživanja metodom Delphi za područje: Vodstvo, planiranje i upravljanje

Elementi unutar područja Vodstvo, planiranje i upravljanje	CVR	Stupanj suglasnosti ispitanika
Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	0,89	94,74%
Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	0,82	91,23%
Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	0,75	87,72%
Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	0,72	85,96%
Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	0,68	84,21%
Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU	0,65	82,46%
Upravljanje integracijom IKT-a u učenje i poučavanje na VU	0,58	78,95%

U *Tablici 19* prikazani su rezultati istraživanja metodom Delphi za područje *Osiguranje kvalitete* koje se sastoji od šest elemenata. Svih šest elemenata ima CVR veći od 0,29 i svih šest elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 19: Rezultati istraživanja metodom Delphi za područje: Osiguranje kvalitete

Elementi unutar područja Osiguranje kvalitete	CVR	Stupanj suglasnosti ispitanika
Politika osiguranja kvalitete primjene IKT-a na VU	0,79	89,47%
Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a	0,65	82,46%
Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU	0,75	87,72%
Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU	0,68	84,21%
Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a	0,75	87,72%
Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a	0,61	80,70%

U *Tablici 20* prikazani su rezultati istraživanja metodom Delphi za područje *Znanstveno-istraživački rad uz podršku IKT-a* koje se sastoji od šest elemenata. Svih šest elemenata ima CVR veći od 0,29 i svih šest elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 20: Rezultati istraživanja metodom Delphi za područje: Znanstveno-istraživački rad uz podršku IKT-a

Elementi unutar područja Znanstveno-istraživački rad uz podršku IKT-a	CVR	Stupanj suglasnosti ispitanika
Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova	0,75	87,72%
Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu	0,75	87,72%
Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima	0,89	94,74%
Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja	0,82	91,23%
Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu	0,68	84,21%
Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a	0,82	91,23%

U *Tablici 21* prikazani su rezultati istraživanja metodom Delphi za područje *Transfer tehnologije i služenje društvu uz podršku IKT-a* koje se sastoji od tri elemenata. Sva tri elemenata imaju CVR veći od 0,29 i sva tri elemenata imaju stupanj suglasnosti ispitanika veći od 70%.

Tablica 21: Rezultati istraživanja metodom Delphi za područje: Transfer tehnologije i služenje društvu uz podršku IKT-a

Elementi unutar područja Transfer tehnologije i služenje društvu uz podršku IKT-a	CVR	Stupanj suglasnosti ispitanika
Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda	0,72	85,96%
Suradnja VU s dionicima društva uz potporu IKT-a	0,58	78,95%
Umreženost istraživača i korisnika istraživanja uz potporu IKT-a	0,58	78,95%

U *Tablici 22* prikazani su rezultati istraživanja metodom Delphi za područje *Učenje i poučavanje uz podršku IKT-a* koje se sastoji od osam elemenata. Svih osam elemenata ima CVR veći od 0,29 i svih osam elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 22: Rezultati istraživanja metodom Delphi za područje: Učenje i poučavanje uz podršku IKT-a

Elementi unutar područja Učenje i poučavanje uz podršku IKT-a	CVR	Stupanj suglasnosti ispitanika
Dostupan repozitorij digitalnih obrazovnih sadržaja	0,82	91,23%
Razvoj digitalnih kompetencija studenata	0,89	94,74%
Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika	0,82	91,23%
Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata	0,93	96,49%
Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU	0,89	94,74%
Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a	0,89	94,74%
Upotreba analitika učenja u unapređenju učenja i poučavanja	0,82	91,23%
Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju	0,65	82,46%

U *Tablici 23* prikazani su rezultati istraživanja metodom Delphi za područje *IKT kultura* koje se sastoji od pet elemenata. Svih pet elemenata ima CVR veći od 0,29 i svih pet elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 23: Rezultati istraživanja metodom Delphi za područje: IKT kultura

Elementi unutar područja IKT kultura	CVR	Stupanj suglasnosti ispitanika
Samopouzdanje i motivacija djelatnika za primjenu IKT-a	0,89	94,74%
Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata	0,75	87,72%
Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata	0,86	92,98%
Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa	0,75	87,72%
Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a	0,82	91,23%

U *Tablici 24* prikazani su rezultati istraživanja metodom Delphi za područje *IKT infrastruktura* koje se sastoji od sedam elemenata. Svih sedam elemenata ima CVR veći od 0,29 i svih sedam elemenata ima stupanj suglasnosti ispitanika veći od 70%.

Tablica 24: Rezultati istraživanja metodom Delphi za područje: IKT infrastruktura

Elementi unutar područja IKT infrastruktura	CVR	Stupanj suglasnosti ispitanika
Tehnička potpora i održavanje IKT resursa na VU	0,61	80,70%
Sustav informacijske sigurnosti na VU	0,75	87,72%
Raspoloživost IKT resursa za potporne službe	0,79	89,47%
Pristup IKT resursima za studente u nastavi i van nastave	0,89	94,74%
Raspoloživost IKT resursa za znanstveno-istraživački rad	0,86	92,98%
Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU	0,93	96,49%
Planiranje i nabava IKT infrastrukture	0,93	96,49%

Rezultati istraživanja metodom Delphi za pitanje „*U kojoj mjeri se slažete da je element smješten u ispravno područje (primjerice element Strateško planiranje integracije IKT-a VU u područje Vodstvo, planiranje i upravljanje)?*“ prikazani su u *Tablici 25*. Broj elemenata nakon

izračuna CVR-a ostaje nepromijenjen u odnosu na početni broj elemenata predloženog ODZVU. Stupanj suglasnosti ispitanika za svih 42 elementa je veći od 70%.

Tablica 25: Rezultati istraživanja metodom Delphi za pitanje „U kojoj mjeri se slažete da je element smješten u ispravno područje?“

Područje	Početni broj elemenata	CVR	Stupanj suglasnosti ispitanika	Broj elemenata nakon CVR testa
Vodstvo, planiranje i upravljanje	7	0,78	89,44%	7
Osiguranje kvalitete	6	0,79	89,49%	6
Znanstveno-istraživački rad uz podršku IKT-a	6	0,77	88,33%	6
Transfer tehnologije i služenje društvu uz podršku IKT-a	3	0,78	89,09%	3
Učenje i poučavanje uz podršku IKT-a	8	0,77	88,48%	8
IKT kultura	5	0,78	88,96%	5
IKT infrastruktura	7	0,78	88,96%	7
UKUPNO	**42**	**0,78**	**88,96%**	**42**

Rezultati Delphi istraživanja za pitanja „*U kojoj mjeri se slažete da je element bitan za digitalnu zrelost visokih učilišta?*“ i „*U kojoj mjeri se slažete da je element smješten u ispravno područje (primjerice element Strateško planiranje integracije IKT-a VU u područje Vodstvo, planiranje i upravljanje)?*“ pokazuju da su ispitanici u istraživanju u prvom pitanju imali dvojbu oko važnosti u području Osiguranje kvalitete kod elementa *Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a* čiji je CVR 0,23 i stupanj suglasnosti ispitanika 61,40%. U drugom pitanju isti element ima CVR 0,61 i stupanj suglasnosti ispitanika 80,70%.

Dobiveni rezultati pokazali su da je konsenzus postignut u prvom krugu istraživanja jer se više od 70% ispitanika usuglasilo oko važnosti elemenata unutar sedam predloženih područja [137]. Iz navedenoga proizlazi da nema potrebe za provođenje drugog ciklusa Delphi istraživanja.

5.1.3. Istraživanje metodom sortiranja karata

Nakon provedenog empirijskog istraživanja metodom Delphi slijedilo je istraživanje metodom sortiranja karata. Metoda sortiranja karata je teoretski utemeljen i kvantitativan alat za ispitivanje mišljenja i stavova. Ispitanici u istraživanju su eksperti koji su relevantni za problem istraživanja. U predmetnom istraživanju to su eksperti koji imaju dvostruku ekspertizu: upravljanje VU-om i bavljenje digitalnom tehnologijom u VU. Autor Brown [145] naglašava da je minimalan broj sudionika potreban za istraživanje onoliki koji će omogućiti da se u istraživanju utvrdi postojanje čimbenika za uspoređivanje jedne varijable (u ovom radu elemenata) s drugom. Kod određivanja sudionika istraživanja metodom sortiranja karata nije važan broj sudionika već je važno da ispitanici imaju različite perspektive na problem istraživanja. Autor Brown [145] navodi da se ne preporučuje veliki broj ispitanika jer dolazi do redundantnosti kod interpretiranja problema istraživanja.

Istraživanje je provedeno na uzorku od 31 eksperta (*N=31*) s različitih sveučilišta iz Republike Hrvatske, Republike Slovenije i Republike Bosne i Hercegovine.

U istraživanju se koristi metoda zatvorenog sortiranje karata (*Slika 6).* Cilj provođenja metode sortiranja karata je specificiranje elemenata unutar područja na temelju usuglašavanja stavova nezavisnih eksperata. U istraživanju su sudjelovali eksperti koji imaju dvostruku ekspertizu: ekspertizu upravljanja VU-om i ekspertizu bavljenja digitalnom tehnologijom na VU odnosno eksperti koji imaju iskustvo u primjeni digitalnih tehnologija, iskustvo u sudjelovanju ili vođenju projekata u području digitalnih tehnologija, iskustvo bavljenja stručno i(ili) znanstveno digitalnim tehnologijama te iskustvo na upravljačkim funkcijama. Eksperti koji su sudjelovali u istraživanju su prema stupnju obrazovanja doktori znanosti, docenti, izvanredni profesori i redovni profesori, a prema znanstveno-nastavnom, nastavnom ili suradničkom zvanju su dekan(ica), prodekan(ica), nastavnik(ica) i asistent(ica). Eksperti koji su sudjelovali u istraživanju primjenom metode sortiranja karata nisu sudjelovali u istraživanju primjenom metode Delphi (Poglavlje 5.1.3.).

U Poglavlju 4.3. detaljno je opisana metoda sortiranja karata te postupak njenog provođenja *(Slika 5, Slika 6).*

5.1.3.1. Provedba metode sortiranja karata

Metoda sortiranja karata provedena je pomoću instrumenta istraživanja koji je razvijen na osnovu literature, rezultata empirijskog istraživanja fokus grupa i rezultata provedbe Delphi istraživanja (Poglavlje 5.1.1. i Poglavlje 5.1.2.).

Upitnik se sudionicima istraživanja dostavio putem elektronske pošte, a izrađen je u alatu MS Excel (Prilog 2). Istraživanje je provedeno u periodu od 1.-21.7.2020. U prvom stupcu upitnika navedena su četrdeset i dva elementa za procjenu digitalne zrelosti VU. Ispitanici u istraživanju odgovorili su na pitanje: „*Prema Vašoj procjeni, kojem od sedam predloženih područja Okvira za digitalnu zrelost visokih učilišta pripada pojedini element?*“ odabirom iz padajućeg izbornika jednog od 7 područja ODZVU-a (*1 – Vodstvo, planiranje i upravljanje; 2 – Osiguranje kvalitete; 3 – Znanstveno-istraživački rad uz podršku IKT-a; 4 – Transfer tehnologije i služenje društvu uz podršku IKT-a; 5 – Učenje i poučavanje uz podršku IKT-a; 6 - IKT kultura; 7 - IKT infrastruktura*).

Ispitanici su odgovorili i na skup pojedinačnih pitanja: „*Navedite svoj stupanj obrazovanja*“, „*Imate li iskustva upravljanjem visokim učilištem (na razini uprave, katedre i dr.)*“, „*Koja je Vaša trenutna pozicija?*“ i „*Primjenjujete li IKT u svom radu?*“. Ispitanicima je također omogućen prostor za pisanje komentara kako bi još više doprinijeli ostvarivanju postavljenim ciljevima istraživanja. Upitnik se distribuirao ispitanicima u istraživanju na hrvatskom ili engleskom jeziku.

Za ocjenu sadržajne valjanosti odgovora ispitanika u istraživanju upotrijebljena je Lawsheova formula za CVR (*4.41*) gdje je *N* ukupan broj odgovora, a *n* je broj ispitanika koji su pojedinom elementu pridružili jedno od sedam predloženih područja (*1 – Vodstvo, planiranje i upravljanje; 2 – Osiguranje kvalitete; 3 – Znanstveno-istraživački rad uz podršku IKT-a; 4 – Transfer tehnologije i služenje društvu uz podršku IKT-a; 5 – Učenje i poučavanje uz podršku IKT-a; 6 - IKT kultura; 7 - IKT infrastruktura).*

CVR se izračunava za svaki pojedini element. Minimalna vrijednost koeficijenta CVR za 31 ispitanika iznosi 0,33 [101]. Samo oni elementi koji imaju CVR veći ili jednak minimalnom iznosu ostaju u daljnjem razmatranju kao i oni elementi čiji je stupanj suglasnosti ispitanika veći od 50%.

a) Rezultati istraživanja na skup pojedinačnih pitanja

U prvom pitanju „*Navedite svoj stupanj obrazovanja*“ ispitanici (*N=31*) su iz padajućeg izbornika mogli odabrati jedan od ponuđenih odgovora: dr.sc., prof.dr.sc., izv.prof.dr.sc., doc.dr.sc. i dr.art. (*Slika 19*). Prema stupnju obrazovanja upitnik je ispunilo 14 ispitanika (*N=14*) ili 45% čiji je stupanj obrazovanja dr.sc., deset ispitanika (*N=10*) ili 32% čiji je stupanj obrazovanja prof.dr.sc., šest ispitanika (*N=6*) ili 19% čiji je stupanj obrazovanja izv.prof.dr.sc. i jedan ispitanik (*N=1*) ili 3% čiji je stupanj obrazovanja doc.dr.sc. Niti jedan od ispitanika nije imao stupanj obrazovanja dr.art.

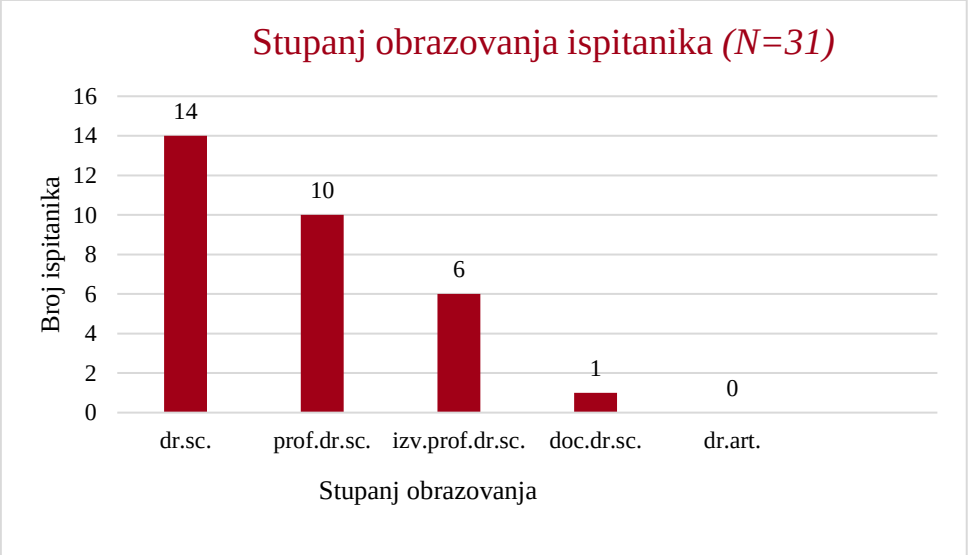

Slika 19: Stupanj obrazovanja ispitanika u istraživanju metodom sortiranja karata

U drugom pitanju „*Imate li iskustva upravljanjem visokim učilištem (na razini uprave, katedre i dr.)* svi ispitanici (*N=31*) su se izjasnili da imaju iskustva upravljanjem visokim učilištem.

U trećem pitanju „*Koja je Vaša trenutna pozicija?*“ ispitanici su iz padajućeg izbornika mogli odabrati jedan od ponuđenih odgovora: dekan(ica); prodekan(ica); nastavnik(ica); asistent(ica) i ostalo (*Slika 20*). Od ukupnog broja ispitanika, njih dvanaest (*N=12*) ili 39% se izjasnilo da je trenutna njihova pozicija nastavnik(ica). Na ostalim pozicijama nalazi se sedam ispitanika (*N=7*) ili 23% ispitanika. Šest ispitanika (*N=6*) ili 19% izjasnilo se da je trenutna njihova pozicija prodekan(ica), pet ispitanika (*N=5*) ili 16% ispitanika se izjasnilo da je trenutna njihova pozicija asistent(ica), jedan ispitanik (*N=1*) se izjasnio da je trenutna njegova pozicija dekana(ice) što je 3% od ukupnog broja ispitanika.

Slika 20: Znanstveno-nastavno, nastavno ili suradničko zvanje ispitanika u istraživanju metodom sortiranja karata

U četvrtom pitanju „*Primjenjujete li IKT u svom radu?*“ svi ispitanici (*N=31*) su se izjasnili da primjenjuju IKT u svome radu.

b) Rezultati istraživanja na pitanje „*Prema Vašoj procjeni, kojem od sedam predloženih područja Okvira za digitalnu zrelost visokih učilišta pripada pojedini element?*“

U *Tablici 26* prikazani su rezultati istraživanja metodom sortiranja karata za elemente koje su eksperti procijenili da su sastavni dio područja *Vodstvo, planiranje i upravljanje*. Sedam elemenata ima CVR veći od 0,33 i svih sedam elemenata ima stupanj suglasnosti ispitanika veći od 50%.

Tablica 26: Rezultati istraživanja metodom sortiranja karata za područje: Vodstvo, planiranje i upravljanje

Elementi unutar područja Vodstvo, planiranje i upravljanje	CVR	Stupanj suglasnosti ispitanika
Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	0,87	93,55%
Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	0,81	90,32%
Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	0,74	87,10%
Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	0,55	77,42%
Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	0,42	70,97%
Upravljanje integracijom IKT-a u učenju i poučavanju na VU	0,35	67,74%
Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU	0,35	67,74%

U *Tablici 27* prikazani su rezultati istraživanja metodom sortiranja karata za elemente koje su eksperti procijenili da su sastavni dio područja *Osiguranje kvalitete*. Šest elemenata ima CVR veći od 0,33 i šest elemenata ima stupanj suglasnosti ispitanika veći od 50%.

Tablica 27: Rezultati istraživanja metodom sortiranja karata za područje: Osiguranje kvalitete

Elementi unutar područja Osiguranje kvalitete	CVR	Stupanj suglasnosti ispitanika
Politika osiguranja kvalitete primjene IKT-a na VU	0,87	93,55%
Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU	0,74	87,10%
Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a	0,68	83,87%
Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a	0,42	70,97%
Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a	0,35	67,74%
Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU	0,35	67,74%

U *Tablici 28* prikazani su rezultati istraživanja metodom sortiranja karata za elemente koje su eksperti procijenili da su sastavni dio područja *Znanstveno-istraživački rad uz podršku IKT-a*. Šest elemenata ima CVR veći od 0,33 i svih šest elemenata ima stupanj suglasnosti ispitanika veći od 50%.

Tablica 28: Rezultati istraživanja metodom sortiranja karata za područje: Znanstveno-istraživački rad uz podršku IKT-a

Elementi unutar područja Znanstveno-istraživački rad uz podršku IKT-a	CVR	Stupanj suglasnosti ispitanika
Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova	0,74	87,10%
Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a	0,55	77,42%
Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima	0,48	74,19%
Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu	0,48	74,19%
Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu	0,42	70,97%
Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja	0,42	70,97%

U *Tablici 29* prikazani su rezultati istraživanja metodom sortiranja karata za elemente koje su eksperti procijenili da su sastavni dio područja *Transfer tehnologije i služenje društvu uz podršku IKT-a*. Tri elementa imaju CVR veći od 0,33 i sva tri elemenata imaju stupanj suglasnosti ispitanika veći od 50%.

Tablica 29: Rezultati istraživanja metodom sortiranja karata za područje: Transfer tehnologije i služenje društvu uz podršku IKT-a

Elementi unutar područja Transfer tehnologije i služenje društvu uz podršku IKT-a	CVR	Stupanj suglasnosti ispitanika
Suradnja VU s dionicima društva uz potporu IKT-a	0,74	87,10%
Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda	0,35	67,74%
Umreženost istraživača i korisnika istraživanja uz potporu IKT-a	0,35	67,74%

U *Tablici 30* prikazani su rezultati istraživanja metodom sortiranja karata za elemente koje su eksperti procijenili da su sastavni dio područja *Učenje i poučavanje uz podršku IKT-a*. Osam elemenata ima CVR veći od 0,33 i svih osam elemenata ima stupanj suglasnosti ispitanika veći od 50%.

Tablica 30: Rezultati istraživanja metodom sortiranja karata za područje: Učenje i poučavanje uz podršku IKT-a

Elementi unutar područja Učenje i poučavanje uz podršku IKT-a	CVR	Stupanj suglasnosti ispitanika
Razvoj digitalnih kompetencija studenata	0,61	80,65%
Upotreba analitika učenja u unapređenju učenja i poučavanja	0,55	77,42%
Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a	0,48	74,19%
Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika	0,42	70,97%
Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU	0,35	67,74%
Dostupan repozitorij digitalnih obrazovnih sadržaja	0,35	67,74%
Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata	0,35	67,74%
Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju	0,35	67,74%

U *Tablici 31* prikazani su rezultati istraživanja metodom sortiranja karata za elemente koje su eksperti procijenili da su sastavni dio područja *IKT kultura*. Pet elemenata ima CVR veći od 0,33 i svih pet elementa imaju stupanj suglasnosti ispitanika veći od 50%.

Tablica 31: Rezultati istraživanja metodom sortiranja karata za područje: IKT kultura

Elementi unutar područja IKT kultura	CVR	Stupanj suglasnosti ispitanika
Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa	0,42	70,97%
Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a	0,42	70,97%
Samopouzdanje i motivacija djelatnika za primjenu IKT-a	0,35	67,74%
Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata	0,35	67,74%
Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata	0,35	67,74%

U *Tablici 32* prikazani su rezultati istraživanja metodom sortiranja karata za elemente koje su eksperti procijenili da su sastavni dio područja *IKT infrastruktura*. Sedam elemenata ima CVR veći od 0,33 i svih sedam elemenata ima stupanj suglasnosti ispitanika veći od 50%.

Tablica 32: Rezultati istraživanja metodom sortiranja karata za područje: IKT infrastruktura

Elementi unutar područja IKT infrastruktura	CVR	Stupanj suglasnosti ispitanika
Tehnička potpora i održavanje IKT resursa na VU	0,94	96,77%
Pristup IKT resursima za studente u nastavi i van nastave	0,55	77,42%
Sustav informacijske sigurnosti na VU	0,55	77,42%
Raspoloživost IKT resursa za potporne službe	0,48	74,19%
Planiranje i nabava IKT infrastrukture	0,42	70,97%
Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU	0,42	70,97%
Raspoloživost IKT resursa za znanstveno-istraživački rad	0,35	67,74%

U *Tablici 33* prikazani su rezultati istraživanja metodom sortiranja karata za pitanje „*Prema Vašoj procjeni, kojem od sedam predloženih područja Okvira za digitalnu zrelost visokih učilišta pripada pojedini element?*“. Ispitanici su u istraživanju trebali odrediti u koje područje ODZVU-a pojedini element pripada. Nakon provedene metode sortiranja karata u daljnjem istraživanju ostaje svih 42 elementa jer je kod svakog elementa CVR bio veći od 0,33 i stupanj suglasnosti ispitanika bio veći od 50%.

Tablica 33: Rezultati istraživanja metodom sortiranja karata za pitanje „Prema Vašoj procjeni, kojem od sedam predloženih područja Okvira za digitalnu zrelost visokih učilišta pripada pojedini element?“

Područje	Početni broj elemenata	CVR	Stupanj suglasnosti ispitanika	Broj elemenata nakon CVR testa
Vodstvo, planiranje i upravljanje	7	0,59	79,26%	7
Osiguranje kvalitete	6	0,57	78,49%	6
Znanstveno-istraživački rad uz podršku IKT-a	6	0,52	75,81%	6
Transfer tehnologije i služenje društvu uz podršku IKT-a	3	0,48	74,19%	3
Učenje i poučavanje uz podršku IKT-a	8	0,44	71,77%	8
IKT kultura	5	0,38	69,03%	5
IKT infrastruktura	7	0,53	76,50%	7
UKUPNO	**42**	**0,50**	**75,01%**	**42**

Dobiveni rezultati pokazuju da je konsenzus postignut u prvom krugu istraživanja jer se više od 70% ispitanika usuglasilo oko važnosti elemenata unutar sedam predloženih područja [137]. Iz navedenoga proizlazi da nema osnove za provođenje drugog ciklusa istraživanja metodom sortiranja karata.

5.1.4. Okvir za digitalnu zrelost visokih učilišta - rezultati istraživanja

Rezultati istraživanja pokazuju da nije došlo do razlike u stavovima ispitanika prilikom provedbe istraživanja metodom Delphi i istraživanja metodom sortiranja karata. Odnosno nakon provedbe metode Delphi, metodom sortiranja karata s drugom nezavisnom skupinom eksperata provjerena je valjanost područja i elemenata ODZVU-a usuglašenih kroz metodu Delphi. Istraživanja su provedena u dva različita/nezavisna skupa eksperata, predstavnika različitih visokih učilišta iz Republike Hrvatske i iz inozemstva. Cilj primjene ove dvije metode bila je provjera valjanosti okvira odnosno hipoteze **H1** i ostvarenje cilja istraživanja **C1**.

Potvrđena je hipoteza **H1:** Razvijeni Okvir za digitalnu zrelost visokih učilišta bit će valjan.

Primjenom kvalitativnih i kvantitativnih metoda istraživanja ostvaren je cilj istraživanja **C1**: Razviti Okvir za digitalnu zrelost visokog učilišta.

Razvijeni ODZVU sastoji se od 7 područja i 42 elementa (*Tablica 34*).

Tablica 34: Okvir za digitalnu zrelost visokih učilišta

Područje	Elementi
Vodstvo, planiranje i upravljanje	Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama
	Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima
	Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU
	Planiranje usavršavanja zaposlenika VU u području primjene IKT-a
	Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima
	Upravljanje integracijom IKT-a u učenje i poučavanje na VU
	Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU
Osiguranje kvalitete	Politika osiguranja kvalitete primjene IKT-a na VU
	Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a
	Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU
	Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU
	Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a
	Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a
Znanstveno-istraživački rad uz podršku IKT-a	Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova
	Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu
	Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima

	Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja
	Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu
	Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a
Transfer tehnologije i služenje društvu uz podršku IKT-a	Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda
	Suradnja VU s dionicima društva uz potporu IKT-a
	Umreženost istraživača i korisnika istraživanja uz potporu IKT-a
Učenje i poučavanje uz podršku IKT-a	Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU
	Razvoj digitalnih kompetencija studenata
	Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a
	Dostupan repozitorij digitalnih obrazovnih sadržaja
	Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika
	Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata
	Upotreba analitika učenja u unapređenju učenja i poučavanja
	Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju
IKT kultura	Samopouzdanje i motivacija djelatnika za primjenu IKT-a
	Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata
	Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata
	Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa
	Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a
IKT infrastruktura	Planiranje i nabava IKT infrastrukture
	Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU
	Raspoloživost IKT resursa za znanstveno-istraživački rad
	Raspoloživost IKT resursa za potporne službe
	Pristup IKT resursima za studente u nastavi i van nastave
	Tehnička potpora i održavanje IKT resursa na VU
	Sustav informacijske sigurnosti na VU

Detaljniji opisi elemenata po područjima dani su u nastavku.

5.1.4.1. Područje ODZVU: Vodstvo, planiranje i upravljanje

Vodstvo, planiranje i upravljanje kao područje ODZVU-a temelji se na postojanju strateških dokumenata integracije IKT-a na razini cijelog visokog učilišta te usklađenost strateških dokumenata na nacionalnim smjernicama i globalnim trendovima. Ovo područje ističe važnost integracije IKT-a na VU koja uključuje opremanje VU IKT resursima, integraciju IKT-a u učenje i poučavanje, istraživanje i razvoj te poslovanje ustanove.

Područje Vodstvo, planiranje i upravljanje se sastoji od sedam elemenata čije opisnice su prikazane u *Tablici 35*.

Tablica 35: Opisnice elemenata područja ODZVU: Vodstvo, planiranje i upravljanje

Elementi	Opisnice elemenata
Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	Strateško planiranje je proces stvaranja i razvoja strateškog plana poslovanja, određivanja dugoročnih ciljeva organizacije i utvrđivanja najboljih načina za ostvarivanje tih ciljeva. Postojanje strateških dokumenata koji obuhvaćaju integraciju IKT-a u učenju i poučavanju i koji su usklađeni s nacionalnim smjernicama. Čimbenici koji potiču djelotvorno učenje, uključujući integraciju i organizacijsku upotrebu IKT-a jasno su ugrađeni u misiji, viziji i/ili strategiji razvoja VU. Strateški plan, vizija i misija VU sadrže jasne prioritete i mjerljive ciljeve za učinkovitu integraciju IKT-a u cjelini.
Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	Postojanje strateških dokumenata koji obuhvaćaju integraciju IKT-a VU i koji su usklađeni s globalnim trendovima. Visoko učilište provodi politike vezane uz promoviranje zaštite autorskog prava, intelektualnog vlasništva te praćenju globalnih trendova integracije IKT-a. Globalni trendovi integracije IKT-a odnose se na poticanje istraživanja, razvoja i inovacija na VU.
Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	Visoko učilište planira, prati i evaluira financijska ulaganja u IKT. Potencijal IKT-a u učenju i poučavanju jasno je naznačen modernizacijom postojećih obrazovnih usluga i pružanjem novih mogućnosti u obrazovanju na VU zajedno s pripadajućim pokazateljima učinkovitosti integracije IKT-a na VU na svim razinama.
Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	Visoko učilište ulaže u kontinuirani i sveobuhvatni profesionalni razvoj svojih zaposlenika (ne samo nastavnog osoblja) na svim razinama kako bi se razvili i integrirali novi oblici učenja i poučavanja te ostvarili ishodi učenja integracijom IKT-a. Zaposlenici se potiču u pohađanju akreditiranih/certificiranih edukacija koje pridonose njihovom profesionalnom razvoju i razvoju VU.
Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	Visoko učilište ima implementiran informacijski sustav za potporu poslovnim procesima na VU. Računovodstvene informacije unutar ustanove su međusobno povezane te su povezane s ministarstvom. Računalni programi za potporu

	nastavi i za potporu vlastite djelatnosti povezani su s računovodstvom i međusobno.
Upravljanje integracijom IKT-a u učenje i poučavanje na VU	Upravljanje integracijom IKT-a u učenju i poučavanju na VU podržano je od strane uprave. Uprava VU planira i provodi opremanje IKT resursima, integraciju IKT-a u učenje i poučavanje, razvoj digitalnih kompetencija zaposlenika i studenata te osiguranje IKT podrške.
Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU	Upravljanje integracijom IKT-a u znanstveno istraživački rad na VU podržano je od strane uprave VU. Uprava VU planira i provodi opremanje IKT resursima u znanstveno-istraživački rad planiranjem, nabavom (osiguranjem sredstava), primjenom, edukacijom zaposlenika, osiguranjem IKT podrške, ali i praćenjem efektivnog iskorištavanja IKT-a u ostvarenju cilja.

5.1.4.2. Područje ODZVU: Osiguranje kvalitete

Osiguranje kvalitete kao područje ODZVU-a naglašava važnost procedura praćenja napredovanja studenata kroz studij uz podršku IKT-a te važnost praćenja i periodičke revizije kvalitete studijskih programa s aspekta primjene IKT-a. Također, ovo područje naglašava važnost kontinuiranog praćenja rezultata primjene IKT-a u svrhu osiguranja kvalitete VU.

Područje Osiguranje kvalitete se sastoji od šest elemenata čije su opisnice prikazane u *Tablici 36.*

Tablica 36: Opisnice elemenata područja ODZVU: Osiguranje kvalitete

Elementi	Opisnice elemenata
Politika osiguranja kvalitete primjene IKT-a na VU	Visoko učilište provodi politiku osiguranja kvalitete primjene IKT-a kao dio dokumenta strateškog upravljanja. Politika osiguranja kvalitete primjene IKT-a uključuje planiranje, uspostavu, mjerenja i analize te kontinuirano poboljšanje primjene IKT kako bi odgovaralo zahtjevima kvalitete koje postavlja VU.
Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a	Visoko učilište ima definirane i objavljene propise koji pokrivaju sve faze "životnog ciklusa" studenata, npr. upis, napredovanje, priznanja i certifikati. Učilište koristi analitike učenja i dubinske analize podataka (engl. *data mining*). VU potiče zaposlenike da iskoriste IKT kako bi studentima pružili povratne informacije o njihovom napretku na suvremeni način npr. korištenjem e-portfelja.
Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-	Visoko učilište ima definirane smjernice i preporuke za napredovanje u zvanju zaposlenika. Ustanova koristi IKT kako bi proširila formativne procjene koje uključuju znanje, ali i

nastavnom radu u svrhu osiguranja kvalitete VU	vještine i kompetencije (posebice digitalne kompetencije) te upotrebljava analitike učenja i dubinske analize podataka (engl. *data mining*).
Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU	Visoko učilište ima procedure za utvrđivanje potreba, razvoja i nabave hardvera i softvera (IKT resursa) te ima procedure vezane uz primjenu IKT resursa. Procedure obuhvaćaju analizu potreba, planiranje proračuna i plan nabave IKT resursa.
Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a	Visoko učilište ima uspostavljene procedure za periodički pregled i izvještavanje o rezultatima, kvaliteti i utjecaju implementacije IKT-a obrazovne programe te ažuriranje programa sukladno razvoju novih tehnoloških i pedagoških trendova.
Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a	Visoko učilište ima uspostavljene procedure prikupljanja podataka koji se odnose na pojedinačni profesionalni napredak i postignuća zaposlenika; podaci se skupljaju i analiziraju na razini učilišta.

5.1.4.3. Područje ODZVU: Znanstveno-istraživački rad uz podršku IKT-a

Znanstveno-istraživački rad uz podršku IKT-a kao područje ODZVU-a temelji se na upotrebi IKT-a u pripremi i objavi znanstveno-istraživačkih radova. Područje naglašava važnost sustava potpore istraživačima na početku karijere, ali važnost kontinuiranog usavršavanja istraživača u primjeni IKT-a u znanstveno-istraživačkom radu. Također, ovo područje ističe važnost podrške IKT-a u upravljanju znanstveno-istraživačkim radom te važnost podrške VU-a u stvaranju partnerstva u provođenju zajedničkih IKT istraživanja kroz umreženost i suradnju istraživača u znanstveno-istraživačkom radu uz podršku IKT-a.

Područje Znanstveno-istraživački rad uz podršku IKT-a se sastoji od šest elemenata čije su opisnice prikazane u *Tablici 37*.

Tablica 37: Opisnice elemenata područja ODZVU: Znanstveno-istraživački rad uz podršku IKT-a

Elementi	Opisnice elemenata
Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova	Visoko učilište ima politike vezane uz upotrebu IKT-a prilikom objave stručnih i znanstvenih članaka zaposlenika i studenata na konferencijama i u časopisima.
Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu	Visoko učilište ima razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu pomoću relevantnih digitalnih alata i platformi; dijeljenje internih znanja i resursa, pristup bazama publikacija, suradnja unutar projektnih timova. Podrška i djelatnosti Centra potpore nastavnicima ili Centra za razvoj IKT alata i sustava, odnosno Centra za projekte i sl.
Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima	VU osigurava IKT podršku u pripremi i upravljanju znanstveno-istraživačkog rada te IKT podršku projektima koje učilište prijavljuje ili provodi (baza članaka, IS sustavi poput baze projekata).
Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja	Visoko učilište potiče povezivanje obrazovnih institucija u svrhu stvaranje partnerstva i zajedničkih IKT istraživanja te redovito prati takve natječaje i inicira projektne ideje.
Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu	Visoko učilište ulaže u kontinuirani profesionalni razvoj istraživača u primjeni IKT-a u znanstveno-istraživačkom radu, te pohađanju edukacija koje pridonose njihovom profesionalnom razvoju i razvoju VU.
Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a	Visoko učilište se zalaže za suradnju i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a. Suradnja istraživača oslanja se na zajedničku mrežnu infrastrukturu i pristup zajedničkim resursima - poput računala, udaljenih instrumenata, baza podataka i softverskih alata i aplikacija.

5.1.4.4. Područje ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a

Transfer tehnologije i služenje društvu uz podršku IKT-a kao područje ODZVU-a temelji se na primijenjenim istraživanjima uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda. Primijenjeno istraživanje je teorijski ili pokusni rad poduzet radi otkrivanja novih znanja i usmjeren prije svega na ostvarivanje praktičnog cilja poput razvoja nove tehnologije ili proizvoda. Ovo područje naglašava važnost suradnje VU s dionicima društva uz potporu IKT-a te važnost umreženosti istraživača.

Područje Transfer tehnologije i služenje društvu uz podršku IKT-a sastoji se od tri elementa čije su opisnice prikazane u *Tablici 38.*

Tablica 38: Opisnice elemenata područja ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a

Elementi	Opisnice elemenata
Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda	Visoko učilište potiče i usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a s ciljem unapređenja razvoja i inovacija, suradnje između gospodarstva i znanstveno-istraživačkog sektora te aktivnosti razvoja i transfera tehnologija.
Suradnja VU s dionicima društva uz potporu IKT-a	Visoko učilište potiče i usmjerava zaposlenike i studente na suradnju s poslodavcima, gospodarstvenicima, lokalnom zajednicom (lice u lice, online ili kombinacija jednog i drugog) u svrhu savjetovanja ili buduće suradnje.
Umreženost istraživača i korisnika istraživanja uz potporu IKT-a	Visoko učilište se zalaže za suradnju i razmjenu znanja uz potporu IKT-a putem partnerstva s drugim obrazovnim institucijama, privatnim i javnim sektorom te širom zajednicom kao korisnicima istraživanja.

5.1.4.5. Područje ODZVU: Učenje i poučavanje uz podršku IKT-a

Učenje i poučavanje uz podršku IKT-a kao područje ODZVU-a temelji se na važnosti razvoja digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika i studenata. Potrebno je naglasiti da ovo područje ističe važnost sveprisutnog učenja, otvorenog kurikuluma uz primjenu IKT-a, upotrebu analitika učenja za unapređenje učenja i poučavanja te važnost dostupnosti repozitorija digitalnih obrazovnih sadržaja čija izrada, pohrana i upotreba se potiče i kod nastavnika i kod studenata. Također, ovo područje ističe važnost personalizacije i potpore podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju.

Područje Učenje i poučavanje uz podršku IKT-a sastoji se od osam elemenata čije su opisnice prikazane u *Tablici 39.*

Tablica 39: Opisnice elemenata područja ODZVU: Učenje i poučavanje uz podršku IKT-a

Elementi	Opisnice elemenata
Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU	Zaposlenici VU su svjesni mogućnosti te planiraju usavršavanje digitalnih kompetencija pri agencijama zaduženim za stručno usavršavanje i sličnim institucijama te kontinuirano usavršavaju i razvijaju svoje digitalne kompetencije i sudjeluju u projektima vezanim uz razvoj digitalnih kompetencija.
Razvoj digitalnih kompetencija studenata	Visoko učilište redovito potiče, razvija i ocjenjuje primjenu IKT-a od strane studenata u različitim okruženjima učenja te kroz programe obrazovanja. VU potiče studente da budu kreatori specifičnih i međukurikularnih digitalnih sadržaja koji se koriste u formalnih i neformalnih obrazovnim programima.
Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a	Visoko učilište omogućava fleksibilan pristup edukaciji jer je učenje dostupno bilo kada i bilo gdje. VU omogućava studentima i zaposlenicima otvoreni kurikulum te niz digitalnih tehnologija za učenje, alate, aplikacije, sadržaje i usluge kojima mogu pristupiti bilo gdje i bilo kada (npr. u formalnim i neformalnim okruženjima). BYOD mogućnosti na VU.
Dostupan repozitorij digitalnih obrazovnih sadržaja	Visoko učilište ima definirana pravila kako bi osiguralo da su svi dionici organizacije dobro informirani o pravima intelektualnog vlasništva i autorskim pravima pri nabavi, korištenju ili stvaranju digitalnog sadržaja. VU ima razvijeno centralno mjesto pohrane digitalnih dokumenata i obrazovnih sadržaja (repozitorij).
Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika	Visoko učilište podržava inovacije u obrazovnim programa koji potiču primjenu IKT-a na način da se nastavnici mogu razvijati i primjenjivati svoje prethodno znanje, istraživanje i vještine te se mogu baviti izazovima izrade, pohrane i upotrebe digitalnih sadržaja. Dostupan BYOD na VU.
Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata	Visoko učilište podržava inovacije u obrazovnim programa koji potiču primjenu IKT-a na način da se studenti mogu razvijati i primjenjivati svoje prethodno znanje, istraživanje i vještine te se mogu baviti izazovima izrade, pohrane i upotrebe digitalnih sadržaja. Dostupan BYOD na VU.
Upotreba analitika učenja u unapređenju učenja i poučavanja	Visoko učilište ima definiran proces mjerenja, prikupljanja i izvještavanja o studentima i njihovom napretku radi optimizacije učenja, poboljšanja budućih procesa učenja ili dodatnih konzultacija/intervencija od strane zaposlenika. Prikupljanje, analiza podataka o iskustvu studenata i uspješnosti poučavanja te upotreba rezultata u unapređenju učenja i poučavanja.
Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju	Visoko učilište ima pristup i smjernice za primjenu pomoćne IKT-a i odgovarajućih digitalnih sadržaja diljem ustanove kako bi se odgovorilo na potrebe podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju.

5.1.4.6. Područje ODZVU: IKT kultura

IKT kultura kao područje ODZVU-a temelji se na važnosti samopouzdanja i motivacije djelatnika za primjenu IKT-a gdje je mrežna prisutnost VU-a i upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata sastavni dio IKT kulture nastavnika i studenata. Također ovo područje navodi važnost primjene smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa od strane zaposlenika i studenata te primjenu etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a. Područje IKT kultura sastoji se od pet elemenata čije su opisnice prikazane u *Tablici 40.*

Tablica 40: Opisnice elemenata područja ODZVU: IKT kultura

Elementi	Opisnice elemenata
Samopouzdanje i motivacija djelatnika za primjenu IKT-a	Visoko učilište ima procese koji osiguravaju da zaposlenici budu sigurni i digitalno kompetentni integrirajući IKT u svakodnevni rad (učenje, poučavanje, komunikacija, administracija). Od iznimne je važnosti za zaposlenike poštivanje pravila sigurnosti te svijest o mogućim rizicima i jasno razumijevanje odgovornog ponašanja.
Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata	Visoko učilište aktivno promiče i očekuje angažman zaposlenika i studenata na mrežnim stranicama, portalima i zajednicama prakse profesionalnih zajednica koje promiču izvrsnost, kvalitetu i dostupnost obrazovnog sadržaja i znanja o implementaciji tehnologija digitalnog učenja u različitim kontekstima. Kroz takav angažman, zaposlenici i studenti mogu pristupiti i doprinijeti istraživanju i širem sustavu učenja i poučavanja.
Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata	Visoko učilište potiče online sustav komunikacije i izvještavanja zaposlenika i studenata putem elektroničke pošte, društvenih mreža, sustava za upravljanje učenjem, foruma te drugih online usluga ustanove. Mrežne stranice i stranice socijalnih mreža se redovito ažuriraju.
Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa	Visoko učilište ima smjernice i preporuke za regulirani pristup te odgovornu i sigurnu primjenu IKT resursa u vlasništvu učilišta, u vlasništvu zaposlenika i studenata, za sigurno korištenje internetom što pridonosi bržem i sigurnijem učenju, poučavanju i poslovanju. VU ima osiguranu podršku u primjeni IKT infrastrukture i BYOD mogućnosti.
Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a	Visoko učilište ima pravila koja se odnose na licence za sadržaj (npr. e-knjige, časopise), softver, aplikacije, platforme i ostale obrazovne resurse koji potječu od komercijalnih izdavača / davatelja usluga. Pravila promoviraju zaštitu autorskog prava i intelektualnog vlasništva kod zaposlenika i studenata.

5.1.4.7. Područje ODZVU: IKT infrastruktura

IKT infrastruktura kao područje ODZVU-a temelji se prvenstveno na važnosti planiranja i nabave IKT infrastrukture te njezinoj raspoloživosti za ostvarenje ciljeva VU, raspoloživosti za studente na nastavi i van nastave, raspoloživosti za znanstveno-istraživački rad i raspoloživosti za potporne službe. Također, ovo područje naglašava važnost tehničke potpore i održavanja IKT resursa na VU te naglašava važnost sustava informacijske sigurnosti na VU. Područje IKT infrastruktura sastoji se od sedam elemenata čije su opisnice prikazane u *Tablici 41*.

Tablica 41: Opisnice elemenata područja ODZVU: IKT infrastruktura

Elementi	Opisnice elemenata
Planiranje i nabava IKT infrastrukture	Visoko učilište planira, provodi i revidira nabavu IKT infrastrukture kako bi se omogućilo ostvarenje ciljeva VU.
Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU	Visoko učilište omogućava digitalno okruženje i informacijski sustav koji je stalno dostupan zaposlenicima i studentima u svrhu postizanja ishoda učenja i obrazovnih ciljeva VU. Zaposlenicima i studentima omogućena je suvremena IKT infrastruktura, online resursi za učenje, VLE, LMS, laboratoriji, virtualne zajednice prakse i sl. Pristup mreži omogućen je unutar cijelog VU.
Raspoloživost IKT resursa za znanstveno-istraživački rad	Visoko učilište omogućava znanstvenicima IKT resurse u njihovom znanstveno-istraživačkom radu. VU infrastrukturno omogućava znanstvenicima uspješno korištenje vlastite opreme unutar cijelog VU.
Raspoloživost IKT resursa za potporne službe	Visoko učilište omogućava suvremenu IKT infrastrukturu za potporne službe. Pristup mreži omogućen je unutar cijelog VU.
Pristup IKT resursima za studente u nastavi i van nastave	Visoko učilište omogućava studentima IKT opremu u njihovom svakodnevnom pohađanju nastave (učenje, poučavanje, komunikacija) te pristup digitalnim sadržajima. VU infrastrukturno omogućava studentima uspješno korištenje vlastite opreme unutar cijele ustanove.
Tehnička potpora i održavanje IKT resursa na VU	Tehnička i korisnička podrška VU planirana je i integrirana u IKT infrastrukturu kako bi se osigurala pouzdana izvedba, održavanje i interoperabilnost te omogućilo zaposlenicima i studentima neometan pristup digitalnim tehnologijama, sadržajima i uslugama VU. Stupanj i način tehničke podrške može biti definiran interno ili vanjskim pružateljima usluga.
Sustav informacijske sigurnosti na VU	Visoko učilište ima odgovarajuće politike, postupke i zaštitne mjere kako bi osigurala zaštita privatnosti pojedinca, povjerljivost i sigurna uporaba IKT infrastrukture i podataka za učenje. Zaštitne mjere uključuju zakonske obveze vezane uz zaštitu podataka i licence te formalne smjernice za osoblje i studente o privatnosti, povjerljivosti i sigurnosti u mrežnim okruženjima; aktivno se prati informacijska imovina i implementiraju zaštitne mjere u odnosu na procijenjene rizike i odabrane strategije upravljanja rizikom.

5.2. Instrument za procjenu digitalne zrelosti visokih učilišta

Istraživanje razvoja metrike za procjenu razine digitalne zrelosti visokih učilišta provedeno je u tri faze.

U prvoj fazi razvoja metrike za procjenu razine digitalne zrelosti visokih učilišta istraživanje je provedeno primjenom kombinacije metoda AHP i ANP (DEMATEL-ANP) za izračun težinskih koeficijenata područja i elemenata, na temelju procjena eksperata, a stabilnost dobivenih rezultata provjerena je primjenom analize osjetljivosti.

U drugoj fazi istraživanja primijenjeno je istraživanje upotrebom rubrike u kojoj su za svaki od 42 elementa ODZVU-a definirane izjave koje opisuju svaku od pet razina zrelosti (Digitalno neosviješteno VU; Digitalno početno VU; Digitalno osnaženo VU; Digitalno sposobno VU i Digitalno zrelo VU).

U trećoj fazi istraživanja integrirani su rezultati prve dvije faze preko kompozitnog indeksa koji se u ovom istraživanju koristi kako bi se izvršila usporedba ranga visokih učilišta prema razini digitalne zrelosti.

U akademskoj godini 2019./2020. u Republici Hrvatskoj studiralo je 161.627 studenata na 119 visokih učilišta. U istraživanju u sklopu ove doktorske disertacije sudjelovala su 33 visoka učilišta na kojima je studiralo 60.551 studenata ili 37% od ukupnog broja studenata u akademskoj godini 2019/2020.

U istraživanju su sudjelovala visoka učilišta iz područja biomedicine i zdravstva, biotehničkih znanosti, društvenih znanosti, humanističkih znanosti, interdisciplinarnih područja znanosti, prirodnih znanosti, tehničkih znanosti te umjetničkog područja. Prema vrsti ustanove, od 33 visokih učilišta koja su sudjelovala u istraživanju, 26 ustanova ima status ustanova sveučilišta (25 ustanova javnih sveučilišta i jedna ustanova privatnog sveučilište), pet je veleučilišta (dva javna veleučilišta i tri privatna veleučilišta) i dvije ustanove imaju status privatne visoke škole. U istraživanju su sudjelovali eksperti koji imaju dvostruku ekspertizu: ekspertizu upravljanja VU-om i ekspertizu bavljenja digitalnom tehnologijom u VU odnosno eksperti koji svojom ekspertizom mogu doprinijeti ostvarenju cilja istraživanja. Drugim riječima, ispitanici u istraživanju imaju iskustvo u primjeni IKT-a, sudjelovali su ili vodili projekt u području IKT-a, bave se stručno i(ili) znanstveno digitalnim tehnologijama, bili su ili jesu na upravljačkim funkcijama u VU. Istraživanje je provedeno od lipnja do listopada 2021. Uživo su održane tri radionice na Ekonomskom fakultetu Sveučilišta u Splitu 23. i 24. lipnja 2021. na kojima je

sudjelovalo 14 eksperata sa sedam visokih učilišta. Ostatak radionica održao se online korištenjem alata Google Meets. Radionice su prosječno trajale 1 sat i 30 minuta.

5.2.1. Sudionici u istraživanju

Empirijsko istraživanje provedeno je na uzorku od 66 eksperata (*N=66*) s 33 visokih učilišta iz Republike Hrvatske odnosno po dvoje eksperta sa svakog visokog učilišta. U istraživanju razvoja metrike za procjenu razine digitalne zrelosti VU, prema stupnju obrazovanja u istraživanju je sudjelovalo 56 ispitanika (*N=56*) ili 85% čiji je stupanj obrazovanja dr.sc. i deset ispitanika (*N=10*) ili 15% čiji je stupanj obrazovanja VSS. Niti jedan od ispitanika nije imao stupanj obrazovanja SSS, VŠS, mr.sc. ili dr.art. (*Slika 21*).

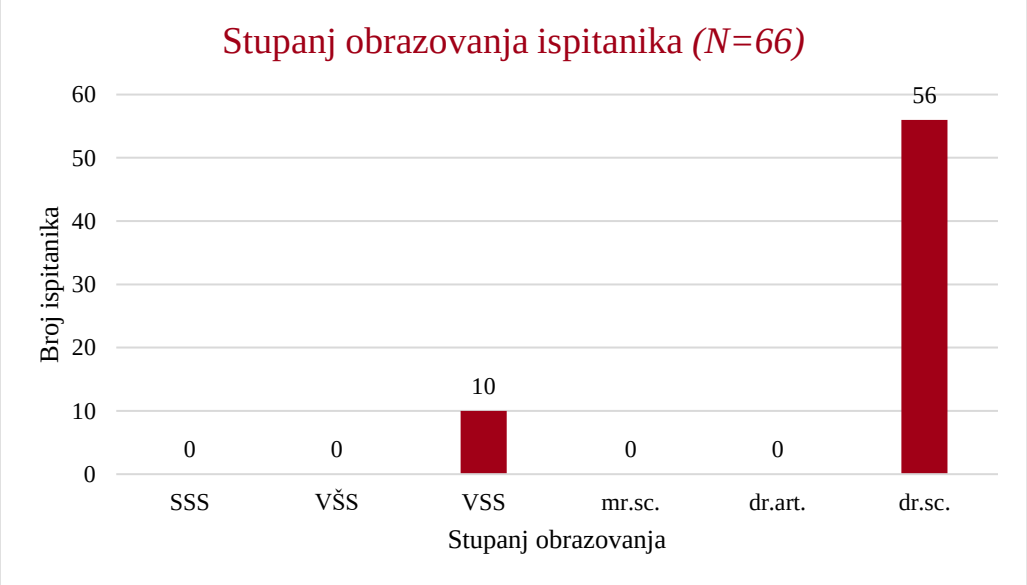

Slika 21: Stupanj obrazovanja ispitanika u istraživanju

Od ukupnog broja ispitanika 16 ispitanika (*N=16*) ili 24% ispitanika ima zvanje docenta, 13 ispitanika (*N=13*) ili 20% ispitanika ima zvanje izvanrednog profesora. Od ukupnog broja ispitanika 11 ispitanika *(N=11)* ili 17% ispitanika ima zvanje redovitog profesora u trajnom zvanju. Isti broj, devet ispitanika *(N=9)* ili 13,5% ispitanika ima zvanje asistenta isto kao i zvanje predavača *(N=9)*. Od ukupnog broja ispitanika osam *(N=8)* ili 12% ispitanika ima zvanje redovitog profesora (*Slika 22*).

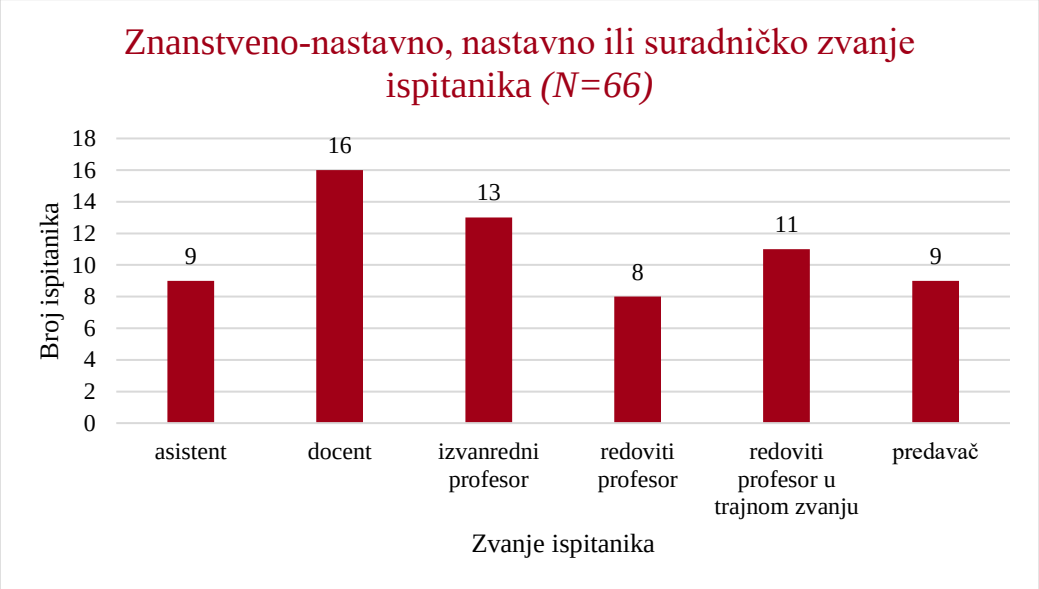

Slika 22: Zvanje ispitanika u istraživanju

Od ukupnog broja ispitanika 18 ispitanika (*N=18*) ili 27% ima iskustvo na upravljačkoj funkciji visokog učilišta na poziciji prodekana(ice). Isti broj ispitanika, 13 ispitanika (*N=13*) ili 20% ima iskustvo na upravljačkoj funkciji visokog učilišta na poziciji ostalih upravljačkih funkcija i na poziciji voditelj(ica) službe, odbora, projekata, studija. Od ukupnog broja ispitanika devet ispitanika (*N=9*) ili 14% ima iskustvo na upravljačkoj funkciji visokog učilišta na poziciji dekana(ice). S iskustvom na upravljačkoj poziciji visokog učilišta pročelnika(ice) nalazi se šest ispitanika (*N=6*) ili 9% ispitanika isto kao i na upravljačkoj funkciji predstojnika(ice) zavoda, odsjeka (*N=6*). Na poziciji prorektora ili prorektorice upravljačko iskustvo ima jedan ispitanik (*N=1*) ili 1% ispitanika (*Slika 23*).

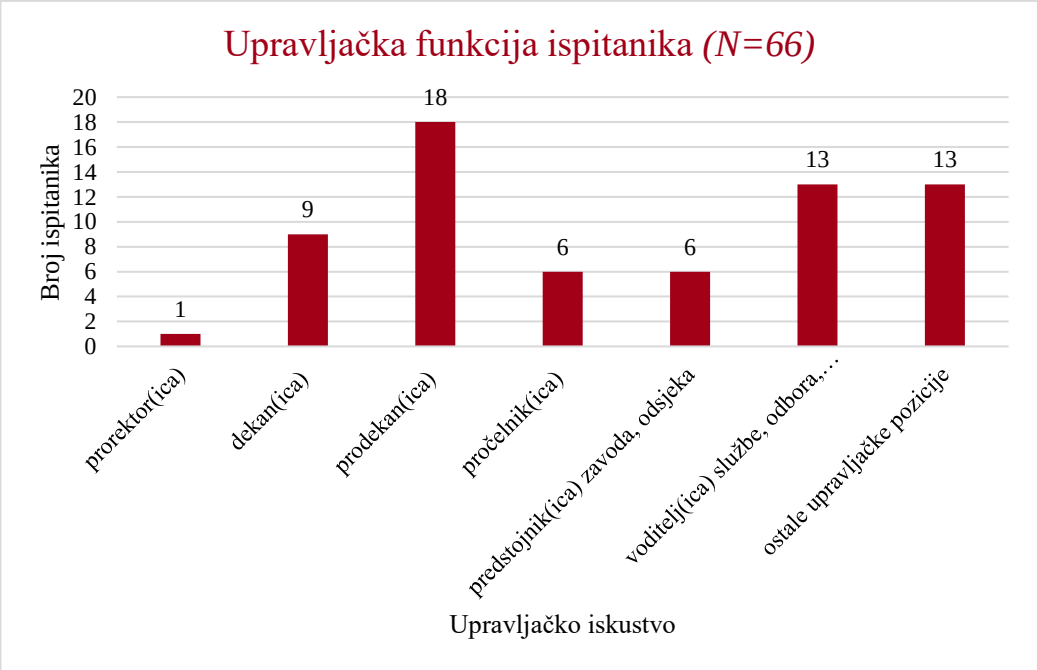

Slika 23: Upravljačka funkcija ispitanika

5.2.2. Određivanje težinskih koeficijenata područja ODZVU

Primjenom metode DEMATEL-ANP (Poglavlje 4.6. i Poglavlje 4.7.) te primjenom grupnog odlučivanja ispitanika u istraživanju *(N=66)* dobiveni su težinski koeficijenti područja digitalne zrelosti koji su potrebni za procjenu konačne razine zrelosti nekog VU-a. Metoda ANP je nadogradnja metode AHP i omogućava stvaranje mreža. Metoda ANP sadrži strukturu povratnih informacija koja omogućuje mrežno definiranje problema. U tome se razlikuje od metode AHP jer ne predstavlja linearnu hijerarhiju već modelira utjecaje između elemenata mreže. Metoda DEMATEL je korištena kako bi se analizirale i formirale veze uzroka i posljedica između područja ili derivirale međuzavisnosti između područja.

Istraživanje je provedeno pomoću tablica u Prilogu 3. Prilog 3 je bio implementiran kroz MS Excel datoteku koja se zvala dematel.xlsx. Metodom DEMATEL ispituju se utjecaji među područjima ODZVU (*1_Vodstvo, planiranje i upravljanje*; *2_Osiguranje kvalitete*; *3_Znanstveno-istraživački rad uz podršku IKT-a*; *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*; *5_Učenje i poučavanje uz podršku IKT-a*; *6_IKT kultura* i *7_IKT infrastruktura*) (*Tablica 34*) na ljestvici od 0-4. Svaki sudionik u istraživanju *(N=66)* trebao je odrediti stupanj utjecaja jednog područja ODZVU-a u odnosu na drugo područje ODZVU-a za svaki par područja ODZVU-a. Stupanj utjecaja vrednuje se od 0, 1, 2, 3 i 4 odnosno „0 -nema utjecaja“, „1 - nizak utjecaj“, „2 - srednji utjecaj“, „3 - visok utjecaj“ i „4 - vrlo jak utjecaj“. Rezultati dobiveni primjenom metode DEMATEL su ulaz u model razvijen metodom ANP. Nakon provedenog istraživanja na uzorku od 66 ispitanika *(N=66)* s 33 visoka učilišta u Republici Hrvatskoj dobiveni su rezultati koji su analizirani grupno kao sinteza rezultata sudionika u istraživanju.

Korak 1. Agregirana matrica

Tablica 42: Određivanje težinskih koeficijenata područja ODZVU - agregirana matrica

Agregirana matrica	1_VPU	2_OK	3_ZIR	4_TTSD	5_UP	6_IKTK	7_IKTI
1_VPU	0	3,6364	3,2576	3,1667	3,3182	3,1061	3,6061
2_OK	3,1364	0	2,7727	2,5303	3,0758	2,5455	2,5606
3_ZIR	2,6061	2,6667	0	3,1061	2,8182	2,6818	3,0303
4_TTSD	2,5303	2,5303	2,7879	0	2,7424	2,7576	2,8182
5_UP	2,5152	3,0455	2,6515	2,7576	0	2,9848	3,1364
6_IKTK	2,6667	2,7424	2,8788	2,8636	3,1212	0	2,9697
7_IKTI	3,1212	2,8939	3,2727	3,2121	3,5000	2,9697	0

Korak 2. Težinska supermatrica

Tablica 43: Određivanje težinskih koeficijenata područja ODZVU - Težinska supermatrica

Težinska supermatrica	1_VPU	2_OK	3_ZIR	4_TTSD	5_UP	6_IKTK	7_IKTI
1_VPU	0	0,2076	0,1849	0,1796	0,1786	0,1822	0,1990
2_OK	0,1892	0	0,1574	0,1435	0,1656	0,1493	0,1413
3_ZIR	0,1572	0,1522	0	0,1761	0,1517	0,1573	0,1672
4_TTSD	0,1527	0,1445	0,1582	0	0,1476	0,1618	0,1555
5_UP	0,1517	0,1739	0,1505	0,1564	0	0,1751	0,1731
6_IKTK	0,1609	0,1566	0,1634	0,1624	0,1680	0	0,1639
7_IKTI	0,1883	0,1652	0,1857	0,1821	0,1884	0,1742	0

Korak 3. Potenciranje težinske supermatrice (jedna od iteracija potenciranja težinske supermatrice)

Tablica 44: Određivanje težinskih koeficijenata područja ODZVU - Potenciranje težinske supermatrice

Ponderiranje težinske supermatrice	1_VPU	2_OK	3_ZIR	4_TTSD	5_UP	6_IKTK	7_IKTI
1_VPU	0,1896	0,1466	0,1547	0,1561	0,1570	0,1551	0,1490
2_OK	0,1224	0,1595	0,1332	0,1376	0,1306	0,1361	0,1394
3_ZIR	0,1355	0,1367	0,1605	0,1298	0,1372	0,1356	0,1322
4_TTSD	0,1299	0,1325	0,1285	0,1537	0,1317	0,1272	0,1293
5_UP	0,1412	0,1330	0,1409	0,1386	0,1638	0,1327	0,1329
6_IKTK	0,1365	0,1380	0,1358	0,1362	0,1343	0,1626	0,1358
7_IKTI	0,1449	0,1537	0,1464	0,1480	0,1453	0,1507	0,1814

Korak 4. Granična supermatrica dobivena je potenciranjem ponderirane matrice u 4 ciklusa, odnosno dok matrica nije konvergirala u oblik iz kojeg se daju iščitati težinski koeficijenti područja (elementi svakog retka matrice moraju biti jednaki).

Tablica 45: Određivanje težinskih koeficijenata područja ODZVU - Granična supermatrica

Granična supermatrica	1_VPU	2_OK	3_ZIR	4_TTSD	5_UP	6_IKTK	7_IKTI
1_VPU	0,1588	0,1588	0,1588	0,1588	0,1588	0,1588	0,1588
2_OK	0,1366	0,1366	0,1366	0,1366	0,1366	0,1366	0,1366
3_ZIR	0,1381	0,1381	0,1381	0,1381	0,1381	0,1381	0,1381
4_TTSD	0,1330	0,1330	0,1330	0,1330	0,1330	0,1330	0,1330
5_UP	0,1404	0,1404	0,1404	0,1404	0,1404	0,1404	0,1404
6_IKTK	0,1398	0,1398	0,1398	0,1398	0,1398	0,1398	0,1398
7_IKTI	0,1532	0,1532	0,1532	0,1532	0,1532	0,1532	0,1532

Rezultati primjene metode DEMATEL-ANP su težinski koeficijenti područja ODZVU prikazani su u *Tablici 46* i na *Slici 24*.

Tablica 46: Težinski koeficijenti područja ODZVU

Područja okvira za digitalnu zrelost visokih učilišta	Težinski koeficijenti područja
1_Vodstvo, planiranje i upravljanje	0,1588
2_Osiguranje kvalitete	0,1366
3_Znanstveno-istraživački rad uz podršku IKT-a	0,1381
4_Transfer tehnologije i služenje društvu uz podršku IKT-a	0,1330
5_Učenje i poučavanje uz podršku IKT-a	0,1404
6_IKT kultura	0,1398
7_IKT infrastruktura	0,1532

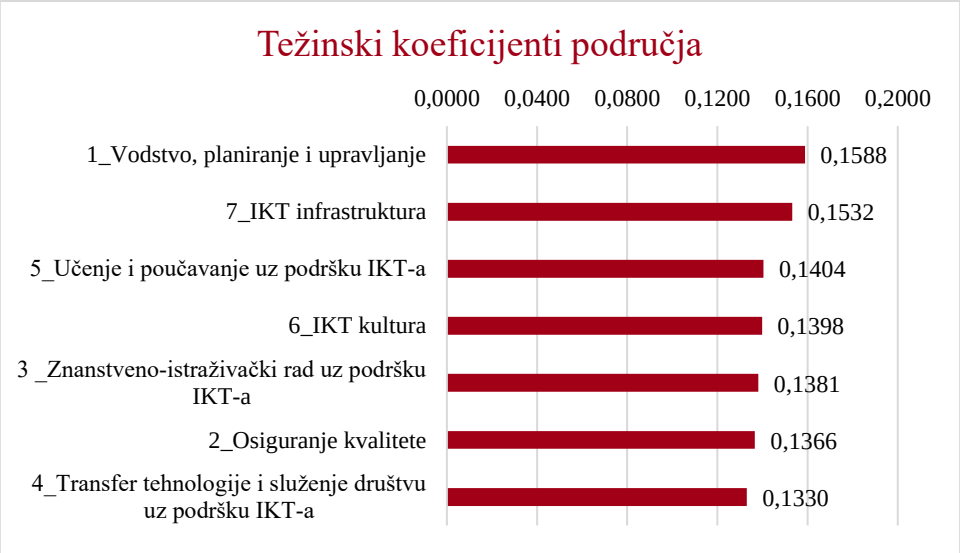

Slika 24: Težinski koeficijenti područja ODZVU

U interpretaciji rezultata važno je naglasiti da najveći težinski koeficijent ODZVU ima područje *1_Vodstvo, planiranje i upravljanje* s težinskim koeficijentom područja 0,1588. Područje *7_IKT infrastruktura* ima drugi najveći težinski koeficijent područja 0,1532. Treći najveći koeficijent područja ima područje *5_Učenje i poučavanje uz podršku IKT-a* s težinskim koeficijentom područja 0,1404. Četvrto područje po važnosti je područje *6_IKT kultura* s težinskim koeficijentom područja 0,1398. Peto područje po važnosti je *3_Znanstveno-istraživački rad uz podršku IKT-a* s težinskim koeficijentom područja 0,1381. Šesto područje po važnosti je područje *2_Osiguranje kvalitete* s težinskim koeficijentom područja 0,1366. Najmanji težinski koeficijent ODZVU ima područje *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* s težinskim koeficijentom područja 0,1330.

Zanimljivo je da su ispitanici u istraživanju znatno važnijim (za 0,0128) ocijenili utjecaj područja koje ima drugi najveći težinski koeficijent područja ODZVU *7_IKT infrastruktura* u odnosu na područje *5_Učenje i poučavanje uz podršku IKT-a* koje ima treći najveći težinski koeficijent područja. Potrebno je istaknuti i vrlo malu prednost od 0,0006 području ODZVU *5_Učenje i poučavanje uz podršku IKT-a* koje ima treći najveći težinski koeficijent područja u odnosu na područje *6_IKT kultura* koje ima četvrti najveći koeficijent područja ODZVU.

5.2.3. Određivanje težinskih koeficijenata elemenata ODZVU

Primjenom metode AHP i primjenom grupnog odlučivanja ispitanika u istraživanju dobiveni su težinski koeficijenti elemenata digitalne zrelosti koji su potrebni za procjenu konačne razine zrelosti nekog VU-a. Metoda AHP detaljno je objašnjena u Poglavlju 4.5.

Istraživanje je provedeno pomoću tablica (Prilog 4) uspoređivanjem u parovima. U uspoređivanju u parovima koristi se Saatyjeva ljestvica relativne važnosti koja sadrži 9 stupnjeva. Stupnjem na Saatyjevoj ljestvici opisuje se odnos između dva elementa. Ako su dva elementa jednako važna, na Saatyjevoj ljestvici taj odnos opisujemo brojkom 1. Ostale vrijednosti ukazuju na dominaciju jednog elementa nad drugim i ovisno o tome koliko je ta dominacija jaka koristimo brojeve 3 - slaba dominacija, 5 - jaka dominacija, 7 - dokazana dominacija i 9- apsolutna dominacija. Također, mogu se koristiti i međuvrijednosti 2, 4, 6, 8. U svakom retku usporedbe ispitanici su stavili "x" na odgovarajuće mjesto, sukladno njihovoj procjeni važnosti pojedinog elementa iz para koji se uspoređivao. Ispitanici su upozoreni na važnost tranzitivnosti na Saatyevoj ljestvici (ukoliko se tranzitivnost naruši, usporedbe nisu konzistentne i ne smatraju se valjanima). Mjera CR (omjer konzistencije) opisuje koliko je narušeno pravilo tranzitivnosti u matrici usporedbe. CR ne smije biti veći od 0.1 [167]. U ćeliji CR ispitanici su u realnom vremenu mogli pratiti konzistentnost usporedbi. Također, ispitanici u istraživanju mogli su u stupcu "Prioriteti" pratiti u realnom vremenu konačne prioritete elemenata koje su uspoređivali.

Prilog 4 je bio implementiran kroz MS Excel datoteku koja se zvala ahp.xlsx odnosno na njenim radnim listovima: VPU, OK, ZIR, TTSD, UP, IKTK i IKTI.

Nakon provedenog istraživanja na uzorku od 66 ispitanika *(N=66)* s 33 visoka učilišta u Republici Hrvatskoj dobiveni su rezultati koji su analizirani grupno kao sinteza rezultata sudionika u istraživanju.

5.2.3.1. Rezultati istraživanja za elemente područja ODZVU: Vodstvo, planiranje i upravljanje

Rezultati istraživanja za područje ODZVU: Vodstvo, planiranje i upravljanje koje se sastoji od 7 elemenata prikazani su u *Tablici 47*. Element *6. Upravljanje integracijom IKT-a u učenje i poučavanje na VU* ima najveći težinski koeficijent elementa 0,1734. Element *7. Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU* ima drugi najveći težinski koeficijent

elementa 0,1709, a nešto manji odnosno treći najveći težinski koeficijent elementa 0,1704 ima element *4. Planiranje usavršavanja zaposlenika VU u području primjene IKT-a*. Četvrti element s najvećim težinskim koeficijentom je element *3. Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU* koji ima težinski koeficijent elementa 0,1542. Peti element po važnosti je element *5. Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima* koji ima težinski koeficijent elementa 0,1490. Šesti element po važnosti je element *2. Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima* koji ima težinski koeficijent elementa 0,0961. Element *1. Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama* ima najmanji težinski koeficijent elementa 0,0861. Zanimljivo je da su rezultati istraživanja pokazali da ispitanici u istraživanju smatraju najmanje važnima elemente koji su od strateške važnosti (strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama ili usklađenost s globalnim trendovima), dok elementi koji su vezani uz integraciju IKT-a u učenje i poučavanje te znanstveno-istraživački rad na VU imaju najveći težinski koeficijent.

Tablica 47: Težinski koeficijenti elemenata područja ODZVU: Vodstvo, planiranje i upravljanje

Elementi područja Vodstvo, planiranje i upravljanje	Težinski koeficijenti elemenata
1. Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	0,0861
2. Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	0,0961
3. Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	0,1542
4. Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	0,1704
5. Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	0,1490
6. Upravljanje integracijom IKT-a u učenje i poučavanje na VU	0,1734
7. Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU	0,1709

5.2.3.2. Rezultati istraživanja za elemente područja ODZVU: Osiguranje kvalitete

Rezultati istraživanja za područje ODZVU: Osiguranje kvalitete koje se sastoji od 6 elemenata prikazani su u *Tablici 48.* Element *5. Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a* ima najveći težinski koeficijent elementa 0,1969. Sljedeći element s najvećim težinskim koeficijentom elementa 0,1682 je element *2. Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a*. Element *6. Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a* je treći po važnosti i ima težinski koeficijent elementa 0,1631. Četvrti element po važnosti je element *3. Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU* i ima težinski koeficijent elementa 0,1604. Peti element po važnosti je element *4. Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU* ima težinski koeficijent elementa 0,1596. Najmanji težinski koeficijent elementa 0,1517 ima element *1. Politika osiguranja kvalitete primjene IKT-a na VU*. Rezultati istraživanja za područje Osiguranje kvalitete pokazali su da ispitanici u istraživanju smatraju praćenje i periodičke revizije kvalitete studijskih programa i napredovanja studenata kroz studij uz podršku IKT-a znatno važnijim od politike osiguranja kvalitete primjene IKT-a na VU koja je za ispitanike najmanje važna unutar promatranog područja.

Tablica 48: Težinski koeficijenti elemenata područja ODZVU: Osiguranje kvalitete

Elementi područja Osiguranje kvalitete	Težinski koeficijenti elemenata
1. Politika osiguranja kvalitete primjene IKT-a na VU	0,1517
2. Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a	0,1682
3. Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU	0,1604
4. Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU	0,1596
5. Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a	0,1969
6. Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a	0,1631

5.2.3.3. Rezultati istraživanja za elemente područja ODZVU: Znanstveno-istraživački rad uz podršku IKT-a

Rezultati istraživanja za područje ODZVU: Znanstveno-istraživački rad uz podršku IKT-a koje se sastoji od 6 elemenata prikazani su u *Tablici 49*. Element *5. Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu* ima najveći težinski koeficijent elementa 0,2191. Drugi po važnosti je element *4. Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja* koji ima težinski koeficijent elementa 0,1728, a njega slijedi element *6. Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a* koji ima težinski koeficijent elementa 0,1710. Četvrti element po važnosti je element *3. Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima* koji ima težinski koeficijent 0,1608. Najmanje težinske koeficijente elemenata unutar promatranog područja imaju element *1. Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova* s težinskim koeficijentom elementa 0,1407 i element *2. Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu* koji ima težinski koeficijent elementa 0,1357. Rezultati istraživanja za područje Znanstveno-istraživački rad uz podršku IKT-a pokazali su da ispitanici u istraživanju smatraju najvažnijim kontinuirano usavršavanje istraživača u primjeni IKT-a dok najmanju važnost daju sustavu potpore istraživačima na početku karijere u primjeni IKT-a.

Tablica 49: Težinski koeficijenti elemenata područja ODZVU: Znanstveno-istraživački rad uz podršku IKT-a

Elementi područja Znanstveno-istraživački rad uz podršku IKT-a	Težinski koeficijenti elemenata
1. Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova	0,1407
2. Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu	0,1357
3. Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima	0,1608
4. Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja	0,1728
5. Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu	0,2191
6. Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a	0,1710

5.2.3.4. Rezultati istraživanja za elemente područja ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a

Rezultati istraživanja za područje ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a koje se sastoji od 3 elementa prikazani su u *Tablici 50*. Najveći težinski koeficijent elementa 0,4107 unutar promatranog područja ima element *1. Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda*. Drugi element po važnosti je element *3. Umreženost istraživača i korisnika istraživanja uz potporu IKT-a* koji ima težinski koeficijent 0,3154. Najmanji težinski koeficijent elementa 0,2738 ima element *2. Suradnja VU s dionicima društva uz potporu IKT-a*. Rezultati istraživanja za područje Transfer tehnologije i služenje društvu uz podršku IKT-a pokazali su da ispitanici u istraživanju daju značajnu prednost primijenjenim istraživanju uz primjenu IKT-a u odnosu na suradnju VU s dionicima društva.

Tablica 50: Težinski koeficijenti elemenata područja ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a

Elementi područja Transfer tehnologije i služenje društvu uz podršku IKT-a	Težinski koeficijenti elemenata
1. Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda	0,4107
2. Suradnja VU s dionicima društva uz potporu IKT-a	0,2738
3. Umreženost istraživača i korisnika istraživanja uz potporu IKT-a	0,3154

5.2.3.5. Rezultati istraživanja za elemente područja ODZVU: Učenje i poučavanje uz podršku IKT-a

Rezultati istraživanja za područje ODZVU: Učenje i poučavanje uz podršku IKT-a koje se sastoji od 8 elemenata prikazani su u *Tablici 51*. Element *1. Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU* ima najveći težinski koeficijent elementa 0,2041. Drugi i treći elementi po važnosti su *2. Razvoj digitalnih kompetencija studenata* i *5. Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika* koji imaju težinske koeficijente elementa 0,1486 i 0,1390. Vrlo mala razlika u težinskim koeficijentima elemenata je između četvrtog, petog i šestog elementa. Četvrti element po važnosti *4. Dostupan repozitorij digitalnih obrazovnih sadržaja* ima težinski koeficijent elementa 0,1063. Peti element po važnosti je element *7. Upotreba analitika učenja u unapređenju učenja i poučavanja* i ima težinski koeficijent elementa 0,1059, a šesti element po važnosti je element *3. Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a* koji ima težinski koeficijent elementa 0,1046. Sedmi element po važnosti je element *6. Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata* koji ima težinski koeficijent elementa 0,0977. Najmanju važnost ima element *8. Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju* koji ima težinski koeficijent elementa 0,0938. Rezultati istraživanja za ovo područje pokazali su da ispitanici u istraživanju smatraju da je za ovo područje najvažniji razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU, a da im je najmanje važna izrada, pohrana i upotreba digitalnih sadržaja od strane studenata, te personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju.

Tablica 51: Težinski koeficijenti elemenata područja ODZVU: Učenje i poučavanje uz podršku IKT-a

Elementi područja Učenje i poučavanje uz podršku IKT-a	Težinski koeficijenti elemenata
1. Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU	0,2041
2. Razvoj digitalnih kompetencija studenata	0,1486
3. Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a	0,1046
4. Dostupan repozitorij digitalnih obrazovnih sadržaja	0,1063
5. Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika	0,1390
6. Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata	0,0977
7. Upotreba analitika učenja u unapređenju učenja i poučavanja	0,1059
8. Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju	0,0938

5.2.3.6. Rezultati istraživanja za elemente područja ODZVU: IKT kultura

Rezultati istraživanja za područje ODZVU: IKT kultura koje se sastoji od 5 elemenata prikazani su u *Tablici 52.* Najveći težinski koeficijent 0,2597 ima element *3. Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata*. Drugi težinski element po važnosti je element *5. Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a* koji ima težinski koeficijent elementa 0,1956. Treći element po važnosti je element *1. Samopouzdanje i motivacija djelatnika za primjenu IKT-a* koji ima težinski koeficijent elementa 0,1911. Element *2. Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata* je četvrti element po važnosti i ima težinski koeficijent elementa 0,1832. Najmanju važnost ima element *4. Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa* koji ima težinski koeficijent elementa 0,1704. Rezultati istraživanja unutar područja IKT kultura pokazali su da je ispitanicima u istraživanju najvažnija upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata, dok najmanju važnost pridodaju primjeni smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa.

Tablica 52: Težinski koeficijenti elemenata područja ODZVU: IKT kultura

Elementi područja IKT kultura	Težinski koeficijenti elemenata
1. Samopouzdanje i motivacija djelatnika za primjenu IKT-a	0,1911
2. Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata	0,1832
3. Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata	0,2597
4. Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa	0,1704
5. Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a	0,1956

5.2.3.7. Rezultati istraživanja za elemente područja ODZVU: IKT infrastruktura

Rezultati istraživanja za područje ODZVU-a IKT infrastruktura koje se sastoji od 7 elemenata prikazani su u *Tablici 53.* Element *3. Raspoloživost IKT resursa za znanstveno-istraživački rad* ima najveći težinski koeficijent elementa 0,1892 unutar promatranog područja. Sljedeći po važnosti je element *5. Pristup IKT resursima za studente u nastavi i van nastave* koji ima težinski koeficijent elementa 0,1734. Treći element po važnosti je element *2. Raspoloživa IKT infrastruktura VU* omogućava ostvarenje ciljeva VU i ima težinski koeficijent elementa 0,1414. Četvrti element po važnosti je element *6. Tehnička potpora i održavanje IKT resursa na VU* koji ima težinski koeficijent elementa 0,1347. Element *7. Sustav informacijske sigurnosti na VU* je peti element po važnosti koji ima težinski koeficijent elementa 0,1274. Šesti element po važnosti je element *4. Raspoloživost IKT resursa za potporne službe* i ima težinski koeficijent elementa 0,1202. Element *1. Planiranje i nabava IKT infrastrukture* ima najmanju važnost s težinskim koeficijentom elementa 0,1137. Zanimljivo je da su rezultati istraživanja za područje IKT infrastruktura pokazali da je ispitanicima u istraživanju najvažnija raspoloživost i pristup IKT resursima za znanstveno-istraživački rad i za studente u nastavi i van nastave, dok im je najmanje važna raspoloživost IKT resursa za potporne službe te planiranje i nabava IKT infrastrukture.

Tablica 53: Težinski koeficijenti elemenata područja ODZVU: IKT infrastruktura

Elementi područja IKT infrastruktura	Težinski koeficijenti elemenata
1. Planiranje i nabava IKT infrastrukture	0,1137
2. Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU	0,1414
3. Raspoloživost IKT resursa za znanstveno-istraživački rad	0,1892
4. Raspoloživost IKT resursa za potporne službe	0,1202
5. Pristup IKT resursima za studente u nastavi i van nastave	0,1734
6. Tehnička potpora i održavanje IKT resursa na VU	0,1347
7. Sustav informacijske sigurnosti na VU	0,1274

5.2.4. Težinski koeficijenti područja i težinski koeficijenti elemenata ODZVU – rezultati

Postupak određivanja težinskih koeficijenata područja i elemenata detaljno je opisan u Poglavlju 5.2.2. i Poglavlju 5.2.3. Zajednički rezultati težinskih koeficijenata područja i težinskih koeficijenata njihovih elemenata prikazani su u *Tablici 54.*

Tablica 54: Težinski koeficijenti područja i težinski koeficijenti elemenata ODZVU

Područje	Elementi	Težinski koeficijenti područja	Težinski koeficijenti elemenata
Vodstvo, planiranje i upravljanje	1. Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	0,1588	0,0861
	2. Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	0,1588	0,0961
	3. Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	0,1588	0,1542
	4. Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	0,1588	0,1704
	5. Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	0,1588	0,1490
	6. Upravljanje integracijom IKT-a u učenje i poučavanje na VU	0,1588	0,1734
	7. Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU	0,1588	0,1709
Osiguranje kvalitete	1. Politika osiguranja kvalitete primjene IKT-a na VU	0,1366	0,1517
	2. Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a	0,1366	0,1682
	3. Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU	0,1366	0,1604
	4. Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU	0,1366	0,1596
	5. Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a	0,1366	0,1969
	6. Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a	0,1366	0,1631
Znanstveno - istraživački rad uz podršku IKT-a	1. Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova	0,1381	0,1407
	2. Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu	0,1381	0,1357
	3. Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima	0,1381	0,1608
	4. Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja	0,1381	0,1728
	5. Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu	0,1381	0,2191

	6. Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a	0,1381	0,1710
Transfer tehnologije i služenje društvu uz podršku IKT-a	1. Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda	0,1330	0,4107
	2. Suradnja VU s dionicima društva uz potporu IKT-a	0,1330	0,2738
	3. Umreženost istraživača i korisnika istraživanja uz potporu IKT-a	0,1330	0,3154
Učenje i poučavanje uz podršku IKT-a	1. Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU	0,1404	0,2041
	2. Razvoj digitalnih kompetencija studenata	0,1404	0,1486
	3. Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a	0,1404	0,1046
	4. Dostupan repozitorij digitalnih obrazovnih sadržaja	0,1404	0,1063
	5. Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika	0,1404	0,1390
	6. Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata	0,1404	0,0977
	7. Upotreba analitika učenja u unapređenju učenja i poučavanja	0,1404	0,1059
	8. Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju	0,1404	0,0938
IKT kultura	1. Samopouzdanje i motivacija djelatnika za primjenu IKT-a	0,1398	0,1911
	2. Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata	0,1398	0,1832
	3. Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata	0,1398	0,2597
	4. Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa	0,1398	0,1704
	5. Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a	0,1398	0,1956
IKT infrastruktura	1. Planiranje i nabava IKT infrastrukture	0,1532	0,1137
	2. Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU	0,1532	0,1414
	3. Raspoloživost IKT resursa za znanstveno-istraživački rad	0,1532	0,1892
	4. Raspoloživost IKT resursa za potporne službe	0,1532	0,1202
	5. Pristup IKT resursima za studente u nastavi i van nastave	0,1532	0,1734
	6. Tehnička potpora i održavanje IKT resursa na VU	0,1532	0,1347
	7. Sustav informacijske sigurnosti na VU	0,1532	0,1274

5.2.5. Razine zrelosti ODZVU

Istraživanje upotrebom rubrike (Poglavlje 4.8.) provedeno je u tri osnovna koraka *(Slika 12)*: definiranje područja i elemenata koji su predmet procjene; definiranje razina zrelosti prema kojima se kriteriji ocjenjuju te definiranje opisnica kriterija za svaku razinu.

5.2.5.1. Definiranje područja i elemenata

Prvi korak u istraživanju upotrebom rubrike, definiranje područja i elemenata, objašnjen je u Poglavlju 5.1.4. i prikazan u *Tablici 34*. ODZVU sastoji se od 7 područja i 42 elementa.

5.2.5.2. Definiranje razina zrelosti

Svako područje ODZVU prikazanih u *Tablici 34* opisano je kroz pet razina zrelosti: 1 – Digitalno neosviješteno (engl. *digital unaware*), 2 – Digitalno početno (engl. *digital initial*), 3 – Digitalno osnaženo (engl. *digitally empowered*), 4 – Digitalno sposobno (engl. *digitally capable*) i 5 – Digitalno zrelo (engl. *digitally mature*). U nastavku je detaljni opis razina zrelosti prema područjima ODZVU-a koji se temelji na elementima unutar svakog od područja.

Razina 1: Digitalno neosviješteno

Vodstvo, planiranje i upravljanje

Na VU ne postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU. VU ne planira financijsko ulaganje u primjenu IKT resursa za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove niti ima razvijen plan usavršavanja djelatnika VU u području digitalnih kompetencija. VU nema implementiran IS za potporu poslovnim procesima VU niti postoji praksa prikupljanja poslovno relevantnih podataka i njihova obrada. Uprava VU ne planira i ne provodi opremanje IKT resursima u znanstveno-istraživački rad.

Osiguranje kvalitete

VU ne provodi politiku osiguranja kvalitete primjene IKT-a kao dio dokumenta strateškog upravljanja. VU nema usvojene procedure i praćenje upisa studenata, njihovog napredovanja kroz studij, završavanja studija uz podršku IKT-a; nema uspostavljene smjernice i preporuke za kontinuirano praćenje rezultata znanstveno-nastavnog rada, nastavnika i zaposlenika; nema uspostavljene procedure za praćenje i periodičku reviziju studijskih programa s aspekta primjene IKT-a te nema uspostavljene procedure prikupljanja podataka koji se odnose na

pojedinačni profesionalni napredak i postignuća nastavnog, istraživačkog, administrativnog i tehničkog osoblja.

Znanstveno-istraživački rad uz podršku IKT-a

VU ne planira niti ima definirane politike vezane uz upotrebu IKT-a u pripremi i objavi znanstvenih radova i nema razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu. VU ne osigurava podršku u pripremi i upravljanju znanstveno-istraživačkom radu i projektima, ne potiče partnerstva za provođenje zajedničkih IKT istraživanja i ne planira niti ulaže u usavršavanje istraživača u primjeni IKT-a u znanstveno- istraživačkom radu i ne zalaže se za suradnju i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a.

Transfer tehnologije i služenje društvu uz podršku IKT-a

VU ne potiče i ne usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a, ne zalaže se za suradnju s dionicima društva i ne zalaže se za suradnju i razmjenu znanja istraživača i korisnika istraživanja.

Učenje i poučavanje uz podršku IKT-a

VU ne omogućava zaposlenicima i studentima fleksibilan pristup edukaciji jer učenje nije dostupno bilo kada i bilo gdje niti postoji dostupan repozitorij digitalnih obrazovnih sadržaja. Nitko od nastavnika VU-a nije svjestan mogućnosti usavršavanja digitalnih kompetencija, nitko od nastavnika VU u svom poučavanju ne provodi aktivnosti koje pridonose razvoju digitalnih kompetencija studenata niti u svom poučavanju ne primjenjuje već pripremljene dostupne digitalne sadržaje i nitko od zaposlenika visokog učilišta nije svjestan mogućnosti primjene pomoćne IKT-a kako bi se odgovorilo na potrebe podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju. Nitko od studenata VU u svom učenju ne primjenjuje već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođava kontekstu i aktivnostima učenja. VU nema definiran proces mjerenja, prikupljanja i izvještavanja o studentima i njihovom napretku.

IKT kultura

VU nema smjernice i preporuke za regulirani pristup i sigurnu primjenu IKT resursa, ne provodi kontrolu primjene etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a nije prisutno na mreži (mrežne stranice, portali, društvene mreže). Nitko od nastavnika VU ne koristi online sustav komunikacije niti odabire primjerenu IKT tehnologiju u poučavanju.

IKT infrastruktura

VU ne planira nabavu IKT infrastrukture za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove. Gotovo niti jedna predavaonica na VU ne raspolaže s prezentacijskim (interaktivnim) uređajima (projektorima, pametnim pločama ili ekranima) te prijenosnim uređajima (prijenosna računala, tableti, mobiteli) ili stolnim računalima. VU ne omogućava studentima, znanstvenicima i zaposlenicima IKT resurse niti je osigurana tehnička potpora niti održavanje opreme i nisu za to osigurana sredstva. VU nema razvijen sustav informacijske sigurnosti.

Razina 2: Digitalno početno

Vodstvo, planiranje i upravljanje

Na VU započet je proces izrade strateškog dokumenta integracije IKT-a na VU, ali niti na ovoj razini digitalne zrelosti, VU nema plan financijskog ulaganja u IKT resurse za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove već se ono provodi po potrebi. VU nema razvijen plan usavršavanja zaposlenika VU u području primjene IKT-a već se usavršavanje zaposlenika vrši po potrebi. Manje od polovice zaposlenika u planiranje nastavnog procesa uključuje IKT s ciljem unaprjeđenja načina učenja i poučavanja; istraživanja i razvoja te usmjeravanja nastave u skladu s ishodima učenja te svoj plan redovito preispituje i s tim u skladu i revidira. VU nema implementiran IS za potporu poslovnim procesima VU, ali postoji praksa prikupljanja poslovno relevantnih podataka i njihova obrada. Uprava VU ne planira i ne provodi integraciju IKT-a u učenje i poučavanje niti planira i ne provodi opremanje IKT resursima u znanstveno-istraživački rad već se ono provodi po potrebi.

Osiguranje kvalitete

VU ne provodi politiku osiguranja kvalitete primjene IKT-a kao dio dokumenta strateškog upravljanja već se politika osiguranja kvalitete provodi po potrebi. VU ima djelomično definirane i objavljene propise koji pokrivaju sve faze "životnog ciklusa" studenata. VU nema uspostavljene procedure za praćenje i periodičku reviziju studijskih programa s aspekta primjene IKT i nema uspostavljene procedure prikupljanja podataka koji se odnose na pojedinačni profesionalni napredak i postignuća nastavnog, istraživačkog, administrativnog i tehničkog osoblja, ali pojedini zaposlenici (uprava) imaju dostupne na primjeren način obrađene podatke o profesionalnom napretku zaposlenika.

Znanstveno-istraživački rad uz podršku IKT-a

VU nema definirane politike u pripremi i objavi znanstvenih radova nego se ona provodi po potrebi kada uključuje primjenu IKT-a. VU ima djelomično razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu, djelomično potiče partnerstva za provođenje zajedničkih IKT istraživanja i djelomično se zalaže za suradnju, ali ne i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a. VU ne osigurava podršku IKT-a u pripremi i upravljanju znanstveno-istraživačkom radu i projektima i ne planira usavršavanje istraživača već se usavršavanje u primjeni IKT-a u znanstveno- istraživačkom radu provodi po potrebi.

Transfer tehnologije i služenje društvu uz podršku IKT-a

VU djelomično potiče, ali ne usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a, djelomično se zalaže za suradnju i razmjenu znanja istraživača i korisnika istraživanja i ne zalaže se za suradnju s dionicima društva.

Učenje i poučavanje uz podršku IKT-a

VU djelomično omogućava zaposlenicima i studentima fleksibilan pristup edukaciji jer učenje nije dostupno bilo kada i bilo gdje. Na VU postoji djelomično dostupan repozitorij digitalnih obrazovnih sadržaja za nastavnike. Manje od polovice nastavnika VU-a je svjesno mogućnosti usavršavanja digitalnih kompetencija, manje od polovice nastavnika VU u svom poučavanju provodi aktivnosti koje pridonose razvoju digitalnih kompetencija studenata i manje od polovice nastavnika je svjesno mogućnosti primjene pomoćne IKT-a kako bi se odgovorilo na potrebe podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju. VU ima djelomično definiran proces mjerenja, prikupljanja i izvještavanja o studentima i njihovom napretku. Manje od polovice nastavnika i studenata VU u svom učenju i poučavanju primjenjuje već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođava kontekstu i aktivnostima učenja i poučavanja.

IKT kultura

Manje od polovice djelatnika VU ima dovoljno samopouzdanja i motivacije, temeljenog na usavršavanju digitalnih kompetencija, za svoje poučavanje odabrati primjerenu IKT tehnologiju i sadržaj, te ih primjenjuje u poučavanju, a nekolicina nastavnika VU koristi online sustav komunikacije na osnovnoj razini korespondencije i komunikacije. VU ne planira

smjernice i preporuke za regulirani pristup i sigurnu primjenu IKT resursa, već to radi prema potrebi te djelomično provodi kontrolu primjene etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a. VU je u procesu izrade mrežne stranice, portala ili profila na društvenim mrežama.

IKT infrastruktura

VU nema plan nabave ulaganja u IKT infrastrukturu za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove već se ono provodi po potrebi. VU djelomično omogućava studentima, znanstvenicima i djelatnicima IKT resurse. Manje od polovice predavaonica na VU raspolaže s prezentacijskim (interaktivnim) uređajima, prijenosnim uređajima ili stolnim računalima. Ostali periferni uređaji su dostupni kao zajednički resursi samo djelatnicima. Na VU nije razvijen sustav informacijske sigurnosti, ali se koristi minimalni skup zaštitnih mjera kako bi se osigurala zaštita privatnosti pojedinca, povjerljivost i sigurna uporaba IKT infrastrukture i podataka za učenje. Tehnička potpora i održavanje IKT resursa temelji se na dobrovoljnoj pomoći pojedinih djelatnika i za to nema osiguranih sredstava.

Razina 3: Digitalno osnaženo

Vodstvo, planiranje i upravljanje

Na VU djelomično postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU, ali nisu usklađeni s nacionalnim smjernicama i globalnim trendovima. VU ima plan financijskog ulaganja u IKT resurse za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove koji je djelomično usklađen s potrebama VU i čija se realizacija periodički prati. VU planira i provodi usavršavanje zaposlenika VU u području primjene IKT-a, ali je planiranje na individualnoj razini. VU ima djelomično implementiran IS za potporu poslovnim procesima VU i postoji praksa prikupljanja poslovno relevantnih podataka i njihova obrada. Uprava VU neplanski provodi integraciju IKT-a u učenje i poučavanje i opremanje IKT resursima u znanstveno-istraživački rad.

Osiguranje kvalitete

VU djelomično provodi politiku osiguranja kvalitete primjene IKT-a kao zaseban dokument, ali ne kao dio dokumenta strateškog upravljanja. VU ima definirane i objavljene propise koji pokrivaju sve faze "životnog ciklusa" studenata. VU ima djelomično uspostavljene procedure prikupljanja podataka koji se odnose na pojedinačni profesionalni napredak i postignuća

nastavnog, istraživačkog, administrativnog i tehničkog osoblja, ali nema mogućnosti analiziranja prikupljenih podataka.

Znanstveno-istraživački rad uz podršku IKT-a

VU djelomično planira i provodi upotrebu IKT-a u pripremi i objavi znanstvenih radova koje se provode na individualnoj razini, djelomično osigurava podršku IKT-a u pripremi i upravljanju u znanstveno-istraživačkom radu i projektima, djelomično planira i ulaže u usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu i djelomično se zalaže za suradnju i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a. VU ima razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu pomoću relevantnih digitalnih alata i platformi te potiče povezivanje obrazovnih institucija u svrhu stvaranja partnerstva i zajedničkih IKT istraživanja, ali ne prati redovito takve natječaje niti inicira projektne ideje.

Transfer tehnologije i služenje društvu uz podršku IKT-a

VU djelomično potiče i usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a. VU se djelomično zalaže za suradnju s dionicima i djelomično se zalaže za suradnju i razmjenu znanja istraživača i korisnika istraživanja uz potporu IKT-a.

Učenje i poučavanje uz podršku IKT-a

VU omogućava fleksibilan pristup edukaciji jer je učenje dostupno bilo kada i bilo gdje, ali VU ne omogućava studentima i zaposlenicima otvoreni kurikulum. Više od polovice nastavnika VU je svjesno mogućnosti usavršavanja digitalnih kompetencija pri agencijama zaduženim za stručno usavršavanje i sličnim institucijama i više od polovice nastavnika VU u svom poučavanju provodi aktivnosti koje pridonose razvoju digitalnih kompetencija studenata i više od polovice zaposlenika VU je svjesno mogućnosti primjene pomoćne IKT-a kako bi se odgovorilo na potrebe podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju. Na VU postoji djelomično dostupan repozitorij digitalnih obrazovnih sadržaja za nastavnike i studente. Više od polovice nastavnika i studenata VU u svom učenju i poučavanju primjenjuje već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođava kontekstu i aktivnostima učenja i poučavanja, a manje od polovice samostalno izrađuje digitalne sadržaje koje koristi u učenju i poučavanju. VU ima definiran proces mjerenja i prikupljanja podataka o

studentovom napretku, ali studenti nemaju povratnu informaciju odnosno ne dobivaju izvještaj o individualnom napretku.

IKT kultura

Više od polovice djelatnika VU ima dovoljno samopouzdanja i motivacije, temeljenog na usavršavanju digitalnih kompetencija za svoje poučavanje odabrati primjerenu IKT tehnologiju i sadržaj te ih primjenjuje u poučavanju, a više od polovice nastavnika VU koristi online sustav komunikacije na osnovnoj razini korespondencije i komunikacije. VU ima djelomično razvijene smjernice i preporuke za regulirani pristup te sigurnu primjenu IKT resursa u vlasništvu učilišta, djelatnika i studenata i VU provodi kontrolu primjene etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a i nema razvijena pravila koja promoviraju zaštitu autorskih prava i intelektualnog vlasništva kod djelatnika i studenata. VU ima aktivnu i ažurnu mrežnu stranicu, portal ili profil na društvenim mrežama s osnovnim informacijama o VU, predmetima i aktivnostima.

IKT infrastruktura

Na VU provode se aktivnosti planiranja i nabave IKT infrastrukture za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove koji je usklađen s potrebama VU. Više od polovice predavaonica na VU opremljeno je projektorom, dok je manje od polovice njih opremljeno prijenosnim ili tablet uređajima i pametnim pločama ili pametnim ekranima. Ostali periferni uređaju su dostupni kao zajednički resursi samo djelatnicima. VU omogućava studentima i znanstvenicima IKT resurse u njihovom radu, ali bez mogućnosti korištenja vlastite opreme i omogućava zaposlenicima potpornih službi raspoloživost IKT resursa. Na VU postoji djelomično razvijen sustav informacijske sigurnosti dok tehničku potporu i održavanje IKT resursa na VU prema potrebi vrše vanjski pružatelji usluga, ali ne postoji ugovorena usluga i nisu unaprijed osigurana sredstva za te potrebe.

Razina 4: Digitalno sposobno

Vodstvo, planiranje i upravljanje

Na VU postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU te su usklađeni s nacionalnim smjernicama i globalnim trendovima. VU ima plan financijskog ulaganja u IKT resurse za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove koji je usklađen s potrebama VU. VU planski ulaže u kontinuirani i sveobuhvatni profesionalni razvoj svojih

zaposlenika u području primjene IKT-a te ima implementiran IS za potporu poslovnim procesima VU. Uprava VU planira i provodi integraciju IKT-a u učenje i poučavanje te provodi opremanje IKT resursima na razini VU za potrebe učenja i poučavanja i za potrebe znanstveno-istraživačkog rada.

Osiguranje kvalitete

VU provodi politiku osiguranja kvalitete primjene IKT-a kao dio dokumenta strateškog upravljanja. VU ima definirane i objavljene propise koji pokrivaju sve faze "životnog ciklusa" studenata. VU potiče zaposlenike da iskoriste IKT kako bi studentima pružili povratne informacije o njihovom napretku na suvremeni način npr. korištenjem e-portfelja, ali ne koristi analitike učenja i dubinske analize podataka (engl. *data mining*). VU ima uspostavljene smjernice i preporuke za napredovanje u zvanju nastavnika, napredovanje u zvanju zaposlenika; ima uspostavljene procedure za periodički pregled i izvještavanje o rezultatima, kvaliteti i utjecaju implementacije IKT-a na obrazovne programe te ima uspostavljene procedure prikupljanja podataka koji se odnose na pojedinačni profesionalni napredak i postignuća nastavnog, istraživačkog, administrativnog i tehničkog osoblja, ali podaci nisu međusobno povezani na razini učilišta.

Znanstveno-istraživački rad uz podršku IKT-a

VU ima politike vezane uz upotrebu IKT-a prilikom objave stručnih i znanstvenih članaka zaposlenika na konferencijama i u stručnim časopisima, ali ne i objave radova studenata. VU ima razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu pomoću relevantnih digitalnih alata i platformi. VU osigurava IKT podršku u pripremi i upravljanju znanstveno-istraživačkog rada i projekata, potiče povezivanje obrazovnih institucija u svrhu stvaranja partnerstva i zajedničkih IKT istraživanja te redovito prati takve natječaje i zalaže za suradnju i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a. VU kratkoročno planira i ulaže u profesionalni razvoj istraživača u primjeni IKT-a u znanstveno-istraživačkom radu kao i pohađanju edukacija koje pridonose njihovom profesionalnom razvoju i razvoju VU.

Transfer tehnologije i služenje društvu uz podršku IKT-a

VU potiče i usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a s ciljem unapređenja razvoja i inovacija te potiče i usmjerava zaposlenike i studente na suradnju uz potporu IKT-a s dionicima. VU se zalaže za

suradnju i razmjenu znanja istraživača putem umreženosti istraživača i korisnika istraživanja (dionika) uz potporu IKT-a putem partnerstva s drugim obrazovnim institucijama.

Učenje i poučavanje uz podršku IKT-a

VU omogućava fleksibilan pristup edukaciji jer je učenje dostupno bilo kada i bilo gdje te postoji dostupan repozitorij digitalnih obrazovnih sadržaja za nastavnike. Visoko učilište omogućava studentima i zaposlenicima otvoreni kurikulum. Gotovo svi nastavnici visokog učilišta (VU) su svjesni mogućnosti usavršavanja digitalnih kompetencija pri agencijama zaduženim za stručno usavršavanje i gotovo svi nastavnici VU u svom poučavanju provode aktivnosti koje pridonose razvoju digitalnih kompetencija studenata. Gotovo svi zaposlenici VU su svjesni mogućnosti primjene pomoćne IKT-a kako bi se odgovorilo na potrebe podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju. VU ima definiran proces mjerenja, prikupljanja i izvještavanja o studentima i njihovom napretku. Gotovo svi nastavnici i studenti VU u svom učenju i poučavanju primjenjuju već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođavaju kontekstu i aktivnostima učenja i poučavanja.

IKT kultura

Gotovo svi djelatnici VU ima dovoljno samopouzdanja i motivacije, temeljenog na usavršavanju digitalnih kompetencija, za svoje poučavanje odabrati primjerenu IKT tehnologiju i sadržaj, te ih primjenjuje u poučavanju, a više od polovice nastavnika VU koristi odgovarajuće komunikacijske kanale i informacijske sustave za uspostavu komunikacije i izvještavanje između nastavnika studenata i šire zajednice. VU ima smjernice i preporuke, regulirani pristup kao i sigurnu primjenu IKT resursa u vlasništvu učilišta, djelatnika i studenata za sigurno korištenje internetom što pridonosi bržem i sigurnijem učenju, poučavanju i poslovanju, ali nema osiguranu podršku za BYOD mogućnosti. VU provodi kontrolu primjene etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a i ima pravila koja se odnose na licence za programsku opremu i sadržaj. VU ima aktivnu i ažurnu mrežnu stranicu, portal ili profil na društvenim mrežama koji mogu biti prilagođeni različitim vrstama mobilnih uređaja u čiju izradu i ažuriranje su uključeni i djelatnici.

IKT infrastruktura

VU ima plan nabave IKT infrastrukture za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove. Periodički se prati realizacija plana nabave IKT infrastrukture. Više od

polovice predavaonica na VU opremljeno je projektorom, dok je manje od polovice njih opremljeno prijenosnim ili tablet uređajima i pametnim pločama ili pametnim ekranima. Ostali periferni uređaju su dostupni kao zajednički resursi djelatnicima i studentima. VU omogućava znanstvenicima IKT resurse u njihovom znanstveno-istraživačkom radu. Učilište infrastrukturno omogućava znanstvenicima uspješno korištenje vlastite opreme unutar cijelog učilišta. VU omogućava studentima IKT opremu u njihovom svakodnevnom pohađanju nastave (učenje, poučavanje, komunikacija) te pristup digitalnim sadržajima. Učilište infrastrukturno omogućava studentima djelomično korištenje vlastite opreme unutar ustanove. Na VU postoji razvijen sustav informacijske sigurnosti, identificirana je informacijska imovina te su primijenjene zaštitne mjere kako bi se osigurala zaštita privatnosti pojedinca, povjerljivost i sigurna upotreba IKT infrastrukture i podataka za učenje prema raspoloživim resursima. Tehnička potpora i održavanje IKT resursa na VU vrši vanjski davatelj usluga, njegova obveza je regulirana i za to su osigurana sredstva ili unutar VU postoji Centar za informatičku podršku djelatnicima i studentima.

Razina 5: Digitalno zrelo

Vodstvo, planiranje i upravljanje

Na VU postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU koji su usklađeni s nacionalnim smjernicama i globalnim trendovima. Postoji periodička evaluacija učinaka u kontekstu definiranih dugoročnih ciljeva primjene IKT-a. VU ima plan financijskog ulaganja u IKT resurse za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove koji je usklađen s potrebama VU. Redovito se prati realizacija financijskog ulaganja kao i evaluacija financijskog ulaganja. VU planski ulaže u kontinuirani i sveobuhvatni profesionalni razvoj svojih zaposlenika (ne samo nastavnog osoblja) na svim razinama u području primjene IKT-a. Zaposlenici se potiču u pohađanju akreditiranih/certificiranih edukacija koje pridonose njihovom profesionalnom razvoju i razvoju VU. VU ima implementiran IS za potporu poslovnim procesima VU-a koji služi za pripremu informacijske podloge za poslovno odlučivanje. Upravljanje integracijom IKT-a u učenju i poučavanju na VU podržano je od strane uprave. Uprava VU planira i provodi opremanje IKT resursima, integraciju IKT-a u učenje i poučavanje, znanstveno-istraživački rad, razvoj digitalnih kompetencija zaposlenika i studenata te osiguranje IKT podrške.

Osiguranje kvalitete

VU provodi politiku osiguranja kvalitete primjene IKT-a kao dio dokumenta strateškog upravljanja. Politika osiguranja kvalitete primjene IKT-a uključuje planiranje, uspostavu, mjerenja i analize te kontinuirano poboljšanje primjene IKT kako bi odgovaralo zahtjevima kvalitete koje postavlja VU. VU ima definirane i objavljene propise koji pokrivaju sve faze "životnog ciklusa" studenata. VU ima uspostavljene smjernice i preporuke za napredovanje u zvanju nastavnika i ima uspostavljene smjernice i preporuke za napredovanje u zvanju zaposlenika. VU ima uspostavljene procedure za periodički pregled i izvještavanje o rezultatima, kvaliteti i utjecaju implementacije IKT-a na obrazovne programe i ima uspostavljene procedure prikupljanja podataka koji se odnose na pojedinačni profesionalni napredak i postignuća djelatnika; podaci se skupljaju i analiziraju na razini učilišta.

Znanstveno-istraživački rad uz podršku IKT-a

VU ima politike vezane uz upotrebu IKT-a prilikom objave stručnih i znanstvenih članaka zaposlenika i studenata na konferencijama i u stručnim časopisima te ima razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu pomoću relevantnih digitalnih alata i platformi, dijeljenje internih znanja i resursa, pristup bazama publikacija, suradnja unutar projektnih timova. VU osigurava IKT podršku u pripremi i upravljanju znanstveno-istraživačkog rada; potiče povezivanje obrazovnih institucija u svrhu stvaranja partnerstva i zajedničkih IKT istraživanja te redovito prati takve natječaje i inicira projektne ideje; dugoročno planira i ulaže u kontinuirani profesionalni razvoj istraživača u primjeni IKT-a u znanstveno-istraživačkom radu te se zalaže za suradnju i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a.

Transfer tehnologije i služenje društvu uz podršku IKT-a

VU potiče i usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a s ciljem unapređenja razvoja i inovacija, suradnje između gospodarstva i znanstveno-istraživačkog sektora te aktivnosti razvoja i transfera tehnologija te se zalaže za suradnju i razmjenu znanja uz potporu IKT-a putem partnerstva s drugim obrazovnim institucijama, privatnim i javnim sektorom te širom zajednicom kao korisnicima istraživanja.

Učenje i poučavanje uz podršku IKT-a

VU omogućava fleksibilan pristup edukaciji jer je učenje dostupno bilo kada i bilo gdje te im omogućava otvoreni kurikulum i repozitorij digitalnih obrazovnih sadržaja za nastavnike i studente. VU ima definirana pravila kako bi osiguralo da su svi dionici organizacije dobro informirani o pravima intelektualnog vlasništva i autorskim pravima pri nabavi, korištenju ili stvaranju digitalnog sadržaja. VU redovito potiče, razvija i ocjenjuje primjenu IKT-a od strane studenata u različitim okruženjima učenja te kroz programe obrazovanja. Nastavnici VU-a su svjesni mogućnosti te planiraju usavršavanja digitalnih kompetencija pri agencijama zaduženim za stručno usavršavanje i sličnim institucijama te kontinuirano usavršavaju i razvijaju svoje digitalne kompetencije i sudjeluju u projektima vezanim uz razvoj digitalnih kompetencija. VU ima definiran proces mjerenja, prikupljanja i izvještavanja o studentima i njihovom napretku radi optimizacije učenja, poboljšanja budućih procesa učenja ili dodatnih konzultacija/intervencija od strane nastavnika. VU ima pristup i smjernice za primjenu pomoćne IKT-a i odgovarajućih digitalnih sadržaja diljem ustanove kako bi se odgovorilo na potrebe podzastupljenih skupina primjenom IKT-a u učenju i poučavanju.

IKT kultura

VU ima procese koji osiguravaju da zaposlenici budu sigurni i digitalno kompetentni integrirajući IKT u svakodnevni rad (učenje, poučavanje, komunikacija, administracija). Od iznimne je važnosti za djelatnike poštivanje pravila sigurnosti te svijest o mogućim rizicima i jasno razumijevanje odgovornog ponašanja. VU potiče online sustav komunikacije i izvještavanja nastavnika i studenata putem elektroničke pošte, društvenih mreža, sustava za upravljanje učenjem, foruma te drugih online usluga ustanove. Mrežne stranice i stranice socijalnih mreža se redovito ažuriraju. VU ima smjernice i preporuke za regulirani pristup te odgovornu i sigurnu primjenu IKT resursa u vlasništvu učilišta, djelatnika i studenata. VU ima osiguranu podršku u primjeni IKT infrastrukture i BYOD mogućnosti te ima pravila koja se odnose na licence za programsku opremu i sadržaj te pravila koja promoviraju zaštitu autorskog prava i intelektualnog vlasništva kod djelatnika i studenata, primjenu etičkih standarda i opću uredbu o zaštiti osobnih podataka.

IKT infrastruktura

VU ima plan nabave ulaganja u IKT infrastrukturu za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove koji je usklađen s potrebama VU. Redovito se prati realizacija plana nabave IKT infrastrukture. Djelatnicima i studentima omogućena je suvremena IKT

infrastruktura, online resursi za učenje, VLE, LMS, laboratoriji, virtualne zajednice prakse i sl. Pristup mreži omogućen je unutar cijelog učilišta. VU omogućava znanstvenicima IKT resurse u njihovom znanstveno-istraživačkom radu. Učilište infrastrukturno omogućava znanstvenicima uspješno korištenje vlastite opreme unutar cijelog učilišta i omogućava im pristup bazama podataka, softverskim alatima i aplikacijama. VU omogućava studentima IKT opremu u njihovom svakodnevnom pohađanju nastave (učenje, poučavanje, komunikacija) te pristup digitalnim sadržajima. Učilište infrastrukturno omogućava studentima uspješno korištenje vlastite opreme unutar cijele ustanove. Tehnička i korisnička podrška VU planirana je i integrirana u IKT infrastrukturu kako bi se osigurala pouzdana izvedba, održavanje i interoperabilnost te omogućilo djelatnicima i studentima neometan pristup digitalnim tehnologijama, sadržajima i uslugama učilišta. VU ima odgovarajuće politike, postupke i zaštitne mjere kako bi se osigurala zaštita privatnosti pojedinca, povjerljivost i sigurna uporaba IKT infrastrukture i podataka za učenje.

5.2.5.3. Definiranje opisnica

Svaki element ODZVU prikazanih u *Tablici 34* opisan je kroz pet razina zrelosti: 1 – Digitalno neosviješteno, 2 – Digitalno početno, 3 – Digitalno osnaženo, 4 – Digitalno sposobno i 5 – Digitalno zrelo. U nastavku se nalazi detaljni opis razina zrelosti prema elementima unutar pojedinih područja ODZVU-a.

U *Tablici 55* prikazane su opisnice elemenata područja ODZVU: Vodstvo, planiranje i upravljanje za svaku od pet razina zrelosti.

Tablica 55: Opisnice elemenata područja ODZVU: Vodstvo, planiranje i upravljanje

Element	Digitalno neosviješteno	Digitalno početno	Digitalno osnaženo	Digitalno sposobno	Digitalno zrelo
Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	Na visokom učilištu ne postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU. U misiji, viziji i/ili strategiji razvoja VU ne postoje čimbenici koji potiču upotrebu IKT-a na VU. Strateški plan, vizija i misija VU ne sadrže jasne prioritete i mjerljive ciljeve za učinkovitu integraciju IKT-a na VU.	Na visokom učilištu ne postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU. U misiji, viziji i/ili strategiji razvoja VU postoje čimbenici koji uključuju integraciju i organizacijsku upotrebu IKT-a. Strateški plan, vizija i misija VU ne sadrže jasne prioritete i mjerljive ciljeve za učinkovitu integraciju IKT-a u VU.	Na visokom učilištu djelomično postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU. U misiji, viziji i/ili strategiji razvoja VU postoje čimbenici koji uključuju integraciju i organizacijsku upotrebu IKT-a. Strateški plan, vizija i misija VU ne sadrže jasne prioritete i mjerljive ciljeve za učinkovitu integraciju IKT-a u VU.	Na visokom učilištu postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU te su usklađeni s nacionalnim smjernicama. U misiji, viziji i/ili strategiji razvoja VU postoje čimbenici koji uključuju integraciju i organizacijsku upotrebu IKT-a. Strateški plan, vizija i misija VU sadrže jasne prioritete i mjerljive ciljeve za učinkovitu integraciju IKT-a na VU, ali ne postoji periodička evaluacija učinaka u kontekstu definiranih dugoročnih ciljeva primjene IKT-a.	Na visokom učilištu postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU te su usklađeni s nacionalnim smjernicama. Čimbenici koji potiču integraciju i organizacijsku upotrebu IKT-a jasno su ugrađeni u misiji, viziji i/ili strategiji razvoja VU. Strateški plan, vizija i misija VU sadrže jasne prioritete i mjerljive ciljeve za učinkovitu integraciju IKT-a u cjelini. Postoji periodička evaluacija učinaka u kontekstu definiranih dugoročnih ciljeva primjene IKT-a.

Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	Na visokom učilištu ne postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU.	Na visokom učilištu započet je proces izrade strateškog dokumenta integracije IKT-a na VU.	Na visokom učilištu djelomično postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU te nisu usklađeni s nacionalnim smjernicama i globalnim trendovima.	Na visokom učilištu postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU te su usklađeni s nacionalnim smjernicama i globalnim trendovima.	Na visokom učilištu postoje strateški dokumenti koji obuhvaćaju integraciju IKT-a na VU te su usklađeni s nacionalnim smjernicama i globalnim trendovima. Postoji periodička evaluacija učinaka u kontekstu definiranih dugoročnih ciljeva primjene IKT-a.
Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	Visoko učilište ne planira financijsko ulaganje u primjenu IKT resursa za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove.	Visoko učilište nema plan financijskog ulaganja u IKT resurse za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove već se ono provodi po potrebi.	Visoko učilište ima plan financijskog ulaganja u IKT resurse za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove koji je djelomično usklađen s potrebama VU. Periodički se prati realizacija financijskog ulaganja.	Visoko učilište ima plan financijskog ulaganja u IKT resurse za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove koji je usklađen s potrebama VU. Redovito se prati realizacija financijskog ulaganja.	Visoko učilište ima plan financijskog ulaganja u IKT resurse za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove koji je usklađen s potrebama VU. Redovito se prati realizacija financijskog ulaganja kao i evaluacija financijskog ulaganja.
Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	Visoko učilište nema razvijen plan usavršavanja djelatnika VU u području digitalnih kompetencija.	Visoko učilište nema razvijen plan usavršavanja zaposlenika VU u području primjene IKT-a već se usavršavanje zaposlenika vrši po potrebi. Manje od polovice zaposlenika u planiranje nastavnog procesa uključuje IKT s ciljem unaprjeđenja načina učenja i poučavanja; istraživanja i razvoja te usmjeravanja nastave u skladu s ishodima učenja te svoj plan redovito	Visoko učilište planira i provodi usavršavanje zaposlenika VU u području primjene IKT-a, ali je planiranje na individualnoj razini. Više od polovice zaposlenika u planiranje nastavnog procesa uključuje IKT s ciljem unaprjeđenja načina učenja i poučavanja; istraživanja i razvoja te usmjeravanja nastave u skladu s ishodima učenja te svoj plan redovito	Visoko učilište planski ulaže u kontinuirani i sveobuhvatni profesionalni razvoj svojih zaposlenika u području primjene IKT-a. Gotovo svi zaposlenici u planiranje nastavnog procesa uključuju IKT s ciljem unaprjeđenja načina učenja i poučavanja; istraživanja i razvoja te usmjeravanja nastave u skladu s ishodima učenja te svoj plan redovito preispituju	Visoko učilište planski ulaže u kontinuirani i sveobuhvatni profesionalni razvoj svojih zaposlenika (ne samo nastavnog osoblja) na svim razinama u području primjene IKT-a. Zaposlenici se potiču u pohađanju akreditiranih /certificiranih edukacija koje pridonose njihovom profesionalnom razvoju i razvoju VU. Gotovo svi zaposlenici u planiranje nastavnog procesa uključuju IKT s ciljem unaprjeđenja

		preispituje i s tim u skladu i revidira.	preispituje i s tim u skladu i revidira.	i s tim u skladu i revidira.	načina učenja i poučavanja; istraživanja i razvoja te usmjeravanja nastave u skladu s ishodima učenja te svoj plan redovito preispituju i s tim u skladu i revidiraju.
Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	Visoko učilište nema implementiran informacijski sustav za potporu poslovnim procesima VU niti postoji praksa prikupljanja poslovno relevantnih podataka i njihova obrada.	Visoko učilište nema implementiran informacijski sustav za potporu poslovnim procesima VU, ali postoji praksa prikupljanja poslovno relevantnih podataka i njihova obrada.	Visoko učilište ima djelomično implementiran informacijski sustav za potporu poslovnim procesima VU i postoji praksa prikupljanja poslovno relevantnih podataka i njihova obrada.	Visoko učilište ima implementiran informacijski sustav za potporu poslovnim procesima VU. Postoji praksa prikupljanja poslovno relevantnih podataka i njihova obrada u svrhu informiranja donositelja odluka.	Visoko učilište ima implementiran informacijski sustav za potporu poslovnim procesima VU. IS za potporu poslovnim procesima služi za pripremu informacijske podloge za poslovno odlučivanje i zahtijeva integraciju aktivnosti: prikupljanje poslovno relevantnih podataka; obradu (procesiranje) tih podataka, tj. njihovu pretvorbu u poslovno relevantne informacije i ispostavljanje (diseminaciju) informacije donositeljima poslovnih odluka.
Upravljanje integracijom IKT-a u učenje i poučavanje na VU	Uprava visokog učilišta ne planira i ne provodi integraciju IKT-a u učenje i poučavanje. Uprava ne prepoznaje potencijal IKT-a u učenju i poučavanju. Na VU nema modernizacije postojećih obrazovnih usluga, ne pružaju se novi oblici obrazovanja i ne koriste	Uprava visokog učilišta ne planira i ne provodi integraciju IKT-a u učenje i poučavanje. Uprava ne prepoznaje potencijal IKT-a u učenju i poučavanju; ne planira opremanje VU resursima za potrebe učenja i poučavanja već se ono provodi po potrebi.	Uprava visokog učilišta neplanski provodi integraciju IKT-a u učenje i poučavanje. Uprava povremeno prepoznaje potencijal IKT-a u učenju i poučavanju, provodi opremanje IKT resursima dok se integracija IKT-a ne planira niti provodi na	Uprava visokog učilišta planira i provodi integraciju IKT-a u učenje i poučavanje. Uprava prepoznaje potencijal IKT-a u učenju i poučavanju, provodi opremanje IKT resursima na razini VU.	Upravljanje integracijom IKT-a u učenju i poučavanju na visokom učilištu podržano je od strane uprave. Uprava VU planira i provodi opremanje IKT resursima, integraciju IKT-a u učenje i poučavanje, razvoj digitalnih kompetencija

	računalni programi za potporu u nastavi.		razini VU već je na individualnoj razini.		zaposlenika i studenata te osiguranje IKT podrške.
Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU	Uprava visokih učilišta ne planira i ne provodi opremanje IKT resursima u znanstveno-istraživački rad planiranjem, nabavom (osiguranjem sredstava), primjenom, edukacijom zaposlenika, osiguranjem IKT podrške.	Uprava visokih učilišta ne planira i ne provodi opremanje IKT resursima u znanstveno-istraživački rad planiranjem, nabavom (osiguranjem sredstava), primjenom, edukacijom zaposlenika, osiguranjem IKT podrške već se ono provodi po potrebi.	Uprava visokih učilišta neplanski provodi opremanje IKT resursima u znanstveno-istraživački rad planiranjem, nabavom (osiguranjem sredstava), primjenom, edukacijom zaposlenika, osiguranjem IKT podrške.	Uprava visokih učilišta planira i provodi opremanje IKT resursima u znanstveno-istraživački rad planiranjem, nabavom (osiguranjem sredstava), primjenom IKT-a, edukacijom zaposlenika, osiguranjem IKT podrške. Upravljanje integracijom IKT-a u znanstveno istraživački rad je na individualnoj razini.	Upravljanje integracijom IKT-a u znanstveno istraživački rad na VU podržano je od strane uprave VU. Uprava VU planira i provodi opremanje IKT resursima u znanstveno-istraživački rad planiranjem, nabavom (osiguranjem sredstava), primjenom, edukacijom djelatnika, osiguranjem IKT podrške, ali i praćenjem efektivnog iskorištavanja IKT-a u ostvarenju cilja.

U *Tablici 56* prikazane su opisnice elemenata područja ODZVU: Osiguranje kvalitete za svaku od pet razina zrelosti.

Tablica 56: Opisnice elemenata područja ODZVU: Osiguranje kvalitete

Elementi	Digitalno neosviješteno	Digitalno početno	Digitalno osnaženo	Digitalno sposobno	Digitalno zrelo
Politika osiguranja kvalitete primjene IKT-a na VU	Visoko učilište ne provodi politiku osiguranja kvalitete primjene IKT-a kao dio dokumenta strateškog upravljanja.	Visoko učilište ne provodi politiku osiguranja kvalitete primjene IKT-a kao dio dokumenta strateškog upravljanja već se politika osiguranja kvalitete provodi po potrebi.	Visoko učilište djelomično provodi politiku osiguranja kvalitete primjene IKT-a kao zaseban dokument, ali ne kao dio dokumenta strateškog upravljanja.	Visoko učilište provodi politiku osiguranja kvalitete primjene IKT-a kao dio dokumenta strateškog upravljanja. Politika osiguranja kvalitete IKT-a uključuje planiranje i uspostavu, ali ne i mjerenje, analizu primjene IKT-a na VU.	Visoko učilište provodi politiku osiguranja kvalitete primjene IKT-a kao dio dokumenta strateškog upravljanja. Politika osiguranje kvalitete primjene IKT-a uključuje planiranje, uspostavu, mjerenja i analize te kontinuirano poboljšanje primjene IKT kako bi odgovaralo zahtjevima kvalitete koje postavlja VU.
Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a	Visoko učilište nema usvojene procedure i praćenje upisa studenata, njihovog napredovanja kroz studij, završavanja studija uz podršku IKT-a.	Visoko učilište ima djelomično definirane i objavljene propise koji pokrivaju sve faze "životnog ciklusa" studenata, npr. upis, napredovanje, priznanja i certifikati uz podršku IKT-a.	Visoko učilište ima definirane i objavljene propise koji pokrivaju sve faze "životnog ciklusa" studenata, npr. upis, napredovanje, priznanja i certifikati uz podršku IKT-a.	Visoko učilište ima definirane i objavljene propise koji pokrivaju sve faze "životnog ciklusa" studenata, npr. upis, napredovanje, priznanja i certifikati uz podršku IKT-a. VU potiče zaposlenike da iskoriste IKT kako bi studentima pružili povratne informacije o njihovom napretku na suvremeni način npr. korištenjem e-portfelja, ali ne koristi analitike	Visoko učilište ima definirane i objavljene propise koji pokrivaju sve faze "životnog ciklusa" studenata, npr. upis, napredovanje, priznanja i certifikati uz podršku IKT-a. VU koristi analitike učenja i dubinske analize podataka (engl. *data mining*). VU potiče zaposlenike da iskoriste IKT kako bi studentima pružili povratne informacije o njihovom napretku na

				učenja i dubinske analize podataka (engl. *data mining*).	suvremeni način npr. korištenjem e-portfelja.
Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU	Visoko učilište nema uspostavljene smjernice i preporuke za kontinuirano praćenje rezultata znanstveno-nastavnog rada i napredovanja nastavnika u svrhu osiguranja kvalitete VU.	Visoko učilište prati rezultate znanstveno-nastavnog rada i napredovanje nastavnika pri čemu ne koristi smjernice, preporuke i IKT za kontinuirano praćenje nastavnika u svrhu osiguranja kvalitete VU.	Visoko učilište ima djelomično uspostavljene smjernice i preporuke za napredovanje u zvanju nastavnika, pri čemu koristi IKT kako bi se proširila formativna procjena nastavnika u svrhu osiguranja kvalitete VU.	Visoko učilište ima uspostavljene smjernice i preporuke za napredovanje u zvanju nastavnika. Ustanova koristiti IKT kako bi proširila formativne procjene koje uključuju znanje, ali i vještine i kompetencije (posebice digitalne kompetencije) u svrhu osiguranja kvalitete VU, ali ne koristi analitike učenja i dubinske analize podataka (engl. *data mining*).	Visoko učilište ima uspostavljene smjernice i preporuke za napredovanje u zvanju nastavnika. Ustanova koristiti IKT kako bi proširila formativne procjene koje uključuju znanje, ali i vještine i kompetencije (posebice digitalne kompetencije) u svrhu osiguranja kvalitete VU te upotrebljava analitike učenja i dubinske analize podataka (engl. *data mining*).
Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU	Visoko učilište nema uspostavljene smjernice i preporuke za kontinuirano praćenje rezultata primjene IKT resursa zaposlenika VU u svrhu osiguranja kvalitete VU.	Visoko učilište periodički prati rezultate i napredovanje zaposlenika pri čemu ne koristi smjernice, preporuke i IKT za kontinuirano praćenje zaposlenika u svrhu osiguranja kvalitete VU.	Visoko učilište ima djelomično uspostavljene smjernice i preporuke za napredovanje zaposlenika, pri čemu koristi IKT kako bi se proširila formativna procjena zaposlenika u svrhu osiguranja kvalitete VU.	Visoko učilište ima uspostavljene smjernice i preporuke za napredovanje u zvanju zaposlenika. Ustanova koristiti IKT kako bi proširila formativne procjene koje uključuju znanje, ali i vještine i kompetencije (posebice digitalne kompetencije) u svrhu osiguranja kvalitete VU, ali ne koristi analitike učenja i dubinske analize podataka (engl. *data mining*).	Visoko učilište ima uspostavljene smjernice i preporuke za napredovanje u zvanju zaposlenika. Ustanova koristiti IKT kako bi proširila formativne procjene koje uključuju znanje, ali i vještine i kompetencije (posebice digitalne kompetencije) u svrhu osiguranja kvalitete VU te upotrebljava analitike učenja i dubinske analize podataka (engl. *data mining*).

Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a	Visoko učilište nema uspostavljene procedure za praćenje i periodičku reviziju studijskih programa s aspekta primjene IKT-a.	Visoko učilište nema uspostavljene procedure za praćenje i periodičku reviziju studijskih programa s aspekta primjene IKT-a, ali pojedini zaposlenici (uprava) imaju dostupne na primjeren način obrađene podatke o rezultatima implementacije IKT-a.	Visoko učilište ima djelomično uspostavljene procedure za praćenje i periodičku reviziju studijskih programa s aspekta primjene IKT-a te po potrebi mogućnost izvještavanja o rezultatima implementacije IKT-a.	Visoko učilište ima uspostavljene procedure za periodički pregled i izvještavanje o rezultatima, kvaliteti i utjecaju implementacije IKT-a na obrazovne programe, ali se obrazovni programi ne ažuriraju sukladno razvoju novih tehnoloških i pedagoških trendova.	Visoko učilište ima uspostavljene procedure za periodički pregled i izvještavanje o rezultatima, kvaliteti i utjecaju implementacije IKT-a na obrazovne programe te ažuriranje programa sukladno razvoju novih tehnoloških i pedagoških trendova.
Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a	Visoko učilište nema uspostavljene procedure prikupljanja podataka koji se odnose na pojedinačni profesionalni napredak i postignuća nastavnog, istraživačkog, administrativnog i tehničkog osoblja.	Visoko učilište nema uspostavljene procedure prikupljanja podataka koji se odnose na pojedinačni profesionalni napredak i postignuća nastavnog, istraživačkog, administrativnog i tehničkog osoblja, ali pojedini zaposlenici (uprava) imaju dostupne na primjeren način obrađene podatke o profesionalnom napretku zaposlenika.	Visoko učilište ima djelomično uspostavljene procedure prikupljanja podataka koji se odnose na pojedinačni profesionalni napredak i postignuća nastavnog, istraživačkog, administrativnog i tehničkog osoblja, ali nema mogućnosti analiziranja prikupljenih podataka.	Visoko učilište ima uspostavljene procedure prikupljanja podataka koji se odnose na pojedinačni profesionalni napredak i postignuća nastavnog, istraživačkog, administrativnog i tehničkog osoblja, ali podaci nisu međusobno povezani na razini učilišta.	Visoko učilište ima uspostavljene procedure prikupljanja podataka koji se odnose na pojedinačni profesionalni napredak i postignuća djelatnika, podaci se skupljaju i analiziraju na razini učilišta.

U *Tablici 57* prikazane su opisnice elemenata područja ODZVU: Znanstveno-istraživački rad uz podršku IKT-a za svaku od pet razina zrelosti.

Tablica 57: Opisnice elemenata područja ODZVU: Znanstveno-istraživački rad uz podršku IKT-a

Elementi	Digitalno neosviješteno	Digitalno početno	Digitalno osnaženo	Digitalno sposobno	Digitalno zrelo
Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova	Visoko učilište ne planira niti ima definirane politike vezane uz upotrebu IKT-a u pripremi i objavi znanstvenih radova.	Visoko učilište nema definirane politike u pripremi i objavi znanstvenih radova već se ona provodi po potrebi kada uključuje primjenu IKT-a.	Visoko učilište djelomično planira i provodi upotrebu IKT-a u pripremi i objavi znanstvenih radova koje se provodi na individualnoj razini.	Visoko učilište ima politike vezane uz upotrebu IKT-a prilikom objave stručnih i znanstvenih članaka zaposlenika na konferencijama i u stručnim časopisima, ali ne i objave radova studenata.	Visoko učilište ima politike vezane uz upotrebu IKT-a prilikom objave stručnih i znanstvenih članaka zaposlenika i studenata na konferencijama i u stručnim časopisima.
Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu	Visoko učilište nema razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu.	Visoko učilište ima djelomično razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu.	Visoko učilište ima razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu pomoću relevantnih digitalnih alata i platformi.	Visoko učilište ima razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu pomoću relevantnih digitalnih alata i platformi te omogućuje i dijeljenje internih znanja i resursa, pristup bazama publikacija, suradnja unutar projektnih timova bez podrške Centra potpore nastavnicima ili Centra za razvoj IKT alata i sustava.	Visoko učilište ima razvijen sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu pomoću relevantnih digitalnih alata i platformi, dijeljenje internih znanja i resursa, pristup bazama publikacija, suradnja unutar projektnih timova. VU omogućava podršku uz pomoć djelatnosti Centra potpore nastavnicima ili Centra za razvoj IKT alata i sustava, odnosno Centra za projekte i sl.

Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima	Visoko učilište ne osigurava podršku u pripremi i upravljanju znanstveno-istraživačkom radu i projektima.	Visoko učilište ne osigurava podršku IKT-a u pripremi i upravljanju znanstveno-istraživačkom radu i projektima.	Visoko učilište djelomično osigurava podršku IKT-a u pripremi i upravljanju znanstveno-istraživačkom radu i projektima.	Visoko učilište osigurava IKT podršku u pripremi i upravljanju znanstveno-istraživačkog rada i projekata, ali ne i IKT podršku projektima koje učilište prijavljuje ili provodi (baza članaka, IS sustavi poput baze projekata).	Visoko učilište osigurava IKT podršku u pripremi i upravljanju znanstveno-istraživačkog rada te IKT podršku projektima koje učilište prijavljuje ili provodi (baza članaka, IS sustavi poput baze projekata).
Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja	Visoko učilište ne potiče partnerstva za provođenje zajedničkih IKT istraživanja.	Visoko učilište djelomično potiče partnerstva za provođenje zajedničkih IKT istraživanja.	Visoko učilište potiče povezivanje obrazovnih institucija u svrhu stvaranja partnerstva i zajedničkih IKT istraživanja ali ne prati redovito takve natječaje niti inicira projektne ideje.	Visoko učilište potiče povezivanje obrazovnih institucija u svrhu stvaranja partnerstva i zajedničkih IKT istraživanja te redovito prati takve natječaje, ali ne inicira projektne ideje.	Visoko učilište potiče povezivanje obrazovnih institucija u svrhu stvaranja partnerstva i zajedničkih IKT istraživanja te redovito prati takve natječaje i inicira projektne ideje.
Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu	Visoko učilište ne planira niti ulaže u usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu.	Visoko učilište ne planira usavršavanje istraživača već se usavršavanje u primjeni IKT-a u znanstveno-istraživačkom radu provodi po potrebi.	Visoko učilište djelomično planira i ulaže u usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu (provodi po potrebi na individualnoj razini).	Visoko učilište kratkoročno planira i ulaže u profesionalni razvoj istraživača u primjeni IKT-a u znanstveno-istraživačkom radu te pohađanju edukacija koje pridonose njihovom profesionalnom razvoju i razvoju VU.	Visoko učilište dugoročno planira i ulaže u kontinuirani profesionalni razvoj istraživača u primjeni IKT-a u znanstveno-istraživačkom radu te pohađanju edukacija koje pridonose njihovom profesionalnom razvoju i razvoju VU.

Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a	Visoko učilište ne zalaže se za suradnju i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a.	Visoko učilište djelomično se zalaže za suradnju, ali ne i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a.	Visoko učilište djelomično se zalaže za suradnju i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a.	Visoko učilište se zalaže za suradnju i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a. Suradnja istraživača oslanja se na zajedničku mrežnu infrastrukturu, ali ne i pristup zajedničkim resursima.	Visoko učilište se zalaže za suradnju i razmjenu znanja istraživača putem umreženosti uz podršku IKT-a. Suradnja istraživača oslanja se na zajedničku mrežnu infrastrukturu i pristup zajedničkim resursima - poput računala, udaljenih instrumenata, baza podataka i softverskih alata i aplikacija.

U *Tablici 58* prikazane su opisnice elemenata područja ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a za svaku od pet razina zrelosti.

Tablica 58: Opisnice elemenata područja ODZVU: Transfer tehnologije i služenje društvu uz podršku IKT-a

Elementi	Digitalno neosviješteno	Digitalno početno	Digitalno osnaženo	Digitalno sposobno	Digitalno zrelo
Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda	Visoko učilište ne potiče i ne usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a.	Visoko učilište djelomično potiče ali ne usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a.	Visoko učilište djelomično potiče i usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a.	Visoko učilište potiče i usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a s ciljem unapređenja razvoja i inovacija.	Visoko učilište potiče i usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a s ciljem unapređenja razvoja i inovacija, suradnje između gospodarstva i znanstveno-istraživačkog sektora te aktivnosti razvoja i transfera tehnologija.
Suradnja VU s dionicima društva uz potporu IKT-a	Visoko učilište ne zalaže se za suradnju s dionicima društva (poslodavci, lokalna zajednica).	Visoko učilište ne zalaže se za suradnju s dionicima društva (poslodavci, lokalna zajednica) uz potporu IKT-a.	Visoko učilište djelomično se zalaže za suradnju s dionicima (poslodavci, lokalna zajednica) uz potporu IKT-a.	Visoko učilište potiče i usmjerava zaposlenike i studente na suradnju uz potporu IKT-a s poslodavcima i lokalnom zajednicom u svrhu savjetovanja.	Visoko učilište potiče i usmjerava zaposlenike i studente na suradnju uz potporu IKT-a s poslodavcima i lokalnom zajednicom (lice u lice, online ili kombinacija jednog i drugog) u svrhu savjetovanja ili buduće suradnje.

Umreženost istraživača i korisnika istraživanja uz potporu IKT-a	Visoko učilište ne zalaže se za suradnju i razmjenu znanja istraživača i korisnika istraživanja.	Visoko učilište djelomično se zalaže za suradnju, ali ne i razmjenu znanja istraživača i korisnika istraživanja uz potporu IKT-a.	Visoko učilište djelomično se zalaže za suradnju i razmjenu znanja istraživača i korisnika istraživanja uz potporu IKT-a.	Visoko učilište se zalaže za suradnju i razmjenu znanja istraživača putem umreženosti istraživača i korisnika istraživanja (dionika) uz potporu IKT-a putem partnerstva s drugim obrazovnim institucijama.	Visoko učilište se zalaže za suradnju i razmjenu znanja uz potporu IKT-a putem partnerstva s drugim obrazovnim institucijama, privatnim i javnim sektorom te širom zajednicom kao korisnicima istraživanja.

U *Tablici 59* prikazane su opisnice elemenata područja ODZVU: Učenje i poučavanje uz podršku IKT-a za svaku od pet razina zrelosti.

Tablica 59: Opisnice elemenata područja ODZVU: Učenje i poučavanje uz podršku IKT-a

Elementi	Digitalno neosviješteno	Digitalno početno	Digitalno osnaženo	Digitalno sposobno	Digitalno zrelo
Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU	Nitko od nastavnika visokog učilišta nije svjestan mogućnosti usavršavanja digitalnih kompetencija pri agencijama zaduženim za stručno usavršavanje i sličnim institucijama, niti je završio neki od programa usavršavanja pri spomenutim agencijama/institucijama.	Manje od polovice nastavnika visokog učilišta je svjesno mogućnosti usavršavanja digitalnih kompetencija pri agencijama zaduženim za stručno usavršavanje i sličnim institucijama te je završilo neki od programa usavršavanja pri spomenutim agencijama/institucijama.	Više od polovice nastavnika visokog učilišta je svjesno mogućnosti usavršavanja digitalnih kompetencija pri agencijama zaduženim za stručno usavršavanje i sličnim institucijama te je završilo neki od programa usavršavanja pri spomenutim agencijama/institucijama.	Gotovo svi nastavnici visokog učilišta su svjesni mogućnosti usavršavanja digitalnih kompetencija pri agencijama zaduženim za stručno usavršavanje i sličnim institucijama te su završili neki od programa usavršavanja pri spomenutim agencijama/institucijama. Više od polovice nastavnika se kontinuirano usavršava i razvija inovativne metode učenja i poučavanja.	Nastavnici visokog učilišta su svjesni mogućnosti te planiraju usavršavanja digitalnih kompetencija pri agencijama zaduženim za stručno usavršavanje i sličnim institucijama te kontinuirano usavršavaju i razvijaju svoje digitalne kompetencije i sudjeluju u projektima vezanim uz razvoj digitalnih kompetencija. Više od polovice nastavnika se kontinuirano usavršava i razvija inovativne metode učenja i poučavanja.
Razvoj digitalnih kompetencija studenata	Nitko od nastavnika visokog učilišta u svom poučavanju ne provodi aktivnosti koje pridonose razvoju digitalnih kompetencija studenata.	Manje od polovice nastavnika VU u svom poučavanju provodi aktivnosti koje pridonose razvoju digitalnih kompetencija studenata.	Više od polovice nastavnika VU u svom poučavanju provodi aktivnosti koje pridonose razvoju digitalnih kompetencija studenata te ih manje od polovice prepoznaje potrebu da se na razini visokog učilišta (VU) sustavno pristupa planiranju i provođenju	Gotovo svi nastavnici VU u svom poučavanju provode aktivnosti koje pridonose razvoju digitalnih kompetencija studenata te ih više od polovice prepoznaje potrebu da se na razini visokog učilišta (VU) sustavno pristupa planiranju i provođenju	Visoko učilište redovito potiče, razvija i ocjenjuje primjenu IKT-a od strane studenata u različitim okruženjima učenja te kroz programe obrazovanja. VU potiče studente da budu kreatori specifičnih i međukurikularnih digitalnih sadržaja koji se koriste u

			takvih aktivnosti kroz učenje i poučavanje.	takvih aktivnosti kroz učenje i poučavanje.	formalnih i neformalnih obrazovnim programima.
Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a	Visoko učilište ne omogućava zaposlenicima i studentima fleksibilan pristup edukaciji jer učenje nije dostupno bilo kada i bilo gdje.	Visoko učilište djelomično omogućava zaposlenicima i studentima fleksibilan pristup edukaciji jer učenje nije dostupno bilo kada i bilo gdje.	Visoko učilište omogućava fleksibilan pristup edukaciji jer je učenje dostupno bilo kada i bilo gdje, ali VU ne omogućava studentima i zaposlenicima otvoreni kurikulum.	Visoko učilište omogućava fleksibilan pristup edukaciji jer je učenje dostupno bilo kada i bilo gdje. Visoko učilište omogućava studentima i zaposlenicima otvoreni kurikulum.	Visoko učilište omogućava fleksibilan pristup edukaciji jer je učenje dostupno bilo kada i bilo gdje. VU omogućava studentima i zaposlenicima otvoreni kurikulum te niz digitalnih tehnologija za učenje, alate, aplikacije, sadržaje i usluge kojima mogu pristupiti bilo gdje / bilo kada (npr. u formalnim i neformalnim okruženjima). BYOD mogućnosti u visokom učilištu.
Dostupan repozitorij digitalnih obrazovnih sadržaja	Na visokom učilištu ne postoji dostupan repozitorij digitalnih obrazovnih sadržaja.	Na visokom učilištu postoji djelomično dostupan repozitorij digitalnih obrazovnih sadržaja za nastavnike.	Na visokom učilištu postoji djelomično dostupan repozitorij digitalnih obrazovnih sadržaja za nastavnike i studente.	Na visokom učilištu postoji dostupan repozitorij digitalnih obrazovnih sadržaja za nastavnike.	Na visokom učilištu postoji dostupan repozitorij digitalnih obrazovnih sadržaja za nastavnike i studente.
Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika	Nitko od nastavnika visokog učilišta u svom poučavanju ne primjenjuje već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođava kontekstu i aktivnostima učenja i poučavanja.	Manje od polovice nastavnika visokog učilišta u svom poučavanju primjenjuje već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođava kontekstu i aktivnostima učenja i poučavanja.	Više od polovice nastavnika visokog učilišta u svom poučavanju primjenjuje već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođava kontekstu i aktivnostima učenja i poučavanja i manje od polovice ih samostalno izrađuje digitalne sadržaje koje koristi u poučavanju.	Gotovo svi nastavnici visokog učilišta u svom poučavanju primjenjuju već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođavaju kontekstu i aktivnostima učenja i poučavanja. Više od polovice ih samostalno izrađuje digitalne sadržaje koje koristi u poučavanju, a manje od polovice u okviru svog	Visoko učilište ima definirana pravila kako bi osiguralo da su svi dionici organizacije dobro informirani o pravima intelektualnog vlasništva i autorskim pravima pri nabavi, korištenju ili stvaranju digitalnog sadržaja. VU ima razvijeno centralno mjesto pohrane digitalnih dokumenata i

				poučavanja raznim aktivnostima potiče i studente na izradu digitalnih sadržaja.	obrazovnih sadržaja (repozitorij).
Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata	Nitko od studenata visokog učilišta u svom učenju ne primjenjuje već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođava kontekstu i aktivnostima učenja.	Manje od polovice studenata visokog učilišta u svom učenju primjenjuje već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođava kontekstu i aktivnostima učenja.	Više od polovice studenata visokog učilišta u svom učenju primjenjuje već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođava kontekstu i aktivnostima učenja, a manje od polovice samostalno izrađuje digitalne sadržaje koje koristi u učenju.	Gotovo svi studenti visokog učilišta u svom učenju primjenjuju već pripremljene dostupne digitalne sadržaje ili ih po potrebi prilagođavaju kontekstu i aktivnostima učenja i poučavanja. Više od polovice ih samostalno izrađuje digitalne sadržaje koje koriste u učenju.	Visoko učilište ima definirana pravila kako bi osiguralo da su svi dionici organizacije dobro informirani o pravima intelektualnog vlasništva i autorskim pravima pri nabavi, korištenju ili stvaranju digitalnog sadržaja. VU ima razvijeno centralno mjesto pohrane digitalnih dokumenata i obrazovnih sadržaja (repozitorij).
Upotreba analitika učenja u unapređenju učenja i poučavanja	Visoko učilište nema definiran proces mjerenja, prikupljanja i izvještavanja o studentima i njihovom napretku.	Visoko učilište ima djelomično definiran proces mjerenja, prikupljanja i izvještavanja o studentima i njihovom napretku radi optimizacije učenja.	Visoko učilište ima definiran proces mjerenja i prikupljanja podataka o studentovom napretku, ali studenti nemaju povratnu informaciju odnosno ne dobivaju izvještaj o individualnom napretku.	Visoko učilište ima definiran proces mjerenja, prikupljanja i izvještavanja o studentima i njihovom napretku radi optimizacije učenja, poboljšanja budućih procesa učenja ili dodatnih konzultacija/intervencija od strane nastavnika, ali se ne prikupljaju i analiziraju podaci o iskustvu studenata i uspješnosti poučavanja.	Visoko učilište ima definiran proces mjerenja, prikupljanja i izvještavanja o studentima i njihovom napretku radi optimizacije učenja, poboljšanja budućih procesa učenja ili dodatnih konzultacija/intervencija od strane nastavnika. Prikupljaju se i analiziraju podaci o iskustvima studenata i uspješnosti poučavanja te se rezultati upotrebljavaju za unapređenje učenja i poučavanja na VU.

Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju	Nitko od zaposlenika visokog učilišta nije svjestan mogućnosti primjene pomoćne IKT-a kako bi se odgovorilo na potrebe podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju.	Manje od polovice zaposlenika visokog učilišta je svjesno mogućnosti primjene pomoćne IKT-a kako bi se odgovorilo na potrebe podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju.	Više od polovice zaposlenika visokog učilišta je svjesno mogućnosti primjene pomoćne IKT-a kako bi se odgovorilo na potrebe podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju.	Gotovo svi zaposlenici visokog učilišta su svjesni mogućnosti primjene pomoćne IKT-a kako bi se odgovorilo na potrebe podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju.	Visoko učilište ima pristup i smjernice za primjenu pomoćne IKT-a i odgovarajućih digitalnih sadržaja diljem ustanove kako bi se odgovorilo na potrebe podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju.

U *Tablici 60* prikazane su opisnice elemenata područja ODZVU: IKT kultura za svaku od pet razina zrelosti.

Tablica 60: Opisnice elemenata područja ODZVU: IKT kultura

Elementi	Digitalno neosviješteno	Digitalno početno	Digitalno osnaženo	Digitalno sposobno	Digitalno zrelo
Samopouzdanje i motivacija djelatnika za primjenu IKT-a	Nitko od djelatnika visokog učilišta nema dovoljno samopouzdanja i motivacije, temeljenog na usavršavanju digitalnih kompetencija, odabrati za svoje poučavanje primjerenu IKT tehnologiju i sadržaj, niti ih primjenjuje u poučavanju.	Manje od polovice djelatnika visokog učilišta ima dovoljno samopouzdanja i motivacije, temeljenog na usavršavanju digitalnih kompetencija, odabrati za svoje poučavanje primjerenu IKT tehnologiju i sadržaj, te ih primjenjuje u poučavanju.	Više od polovice djelatnika visokog učilišta ima dovoljno samopouzdanja i motivacije, temeljenog na usavršavanju digitalnih kompetencija, odabrati za svoje poučavanje primjerenu IKT tehnologiju i sadržaj, te ih primjenjuje u poučavanju.	Gotovo svi djelatnici visokog učilišta imaju dovoljno samopouzdanja i motivacije, temeljenog na usavršavanju digitalnih kompetencija, odabrati za svoje poučavanje primjerenu IKT tehnologiju i sadržaj, te ih primjenjuje u poučavanju.	Visoko učilište ima procese koji osiguravaju da zaposlenici budu sigurni i digitalno kompetentni integrirajući IKT u svakodnevni rad (učenje, poučavanje, komunikacija, administracija). Od iznimne je važnosti za djelatnike poštivanje pravila sigurnosti te svijest o mogućim rizicima i jasno razumijevanje odgovornog ponašanja.

Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata	Visoko učilište nije prisutno na mreži (mrežne stranice, portali, društvene mreže).	Visoko učilište je u procesu izrade mrežne stranice, portala ili profila na društvenim mrežama.	Visoko učilište ima aktivnu i ažurnu mrežnu stranicu, portal ili profil na društvenim mrežama s osnovnim informacijama o VU, predmetima i aktivnostima.	Visoko učilište ima aktivnu i ažurnu mrežnu stranicu, portal ili profil na društvenim mrežama. VU je aktivno i u zajednicama prakse profesionalnih zajednica koje promiču izvrsnost, kvalitetu i dostupnost obrazovnog sadržaja.	Visoko učilište aktivno promiče i očekuje angažman djelatnika i studenata na mrežnim stranicama, portalima i zajednicama prakse profesionalnih zajednica koje promiču izvrsnost, kvalitetu i dostupnost obrazovnog sadržaja i znanja o implementaciji tehnologija digitalnog učenja u različitim kontekstima. Kroz takav angažman, djelatnici i studenti mogu pristupiti i doprinijeti istraživanju i širem ekosustavu učenja.
Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata	Nitko od nastavnika visokog učilišta ne koristi online sustav komunikacije, stoga komunikacija može jedino biti usmena (licem u lice) ili putem telefona.	Nekolicina nastavnika visokog učilišta koristi online sustav komunikacije na osnovnoj razini korespondencije i komunikacije.	Više od polovice nastavnika visokog učilišta koristi online sustav komunikacije te je moguća uspostava komunikacije i osnovnog izvještavanja između nastavnika i studenata.	Više od polovice nastavnika visokog učilišta koristi odgovarajuće komunikacijske kanale i informacijske sustave za uspostavu komunikacije i izvještavanje između nastavnika studenata i šire zajednice.	Visoko učilište potiče online sustav komunikacije i izvještavanja nastavnika i studenata putem elektroničke pošte, društvenih mreža, sustava za upravljanje učenjem, foruma te drugih online usluga ustanove. Mrežne stranice i stranice socijalnih mreža se redovito ažuriraju.
Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa	Visoko učilište nema smjernice i preporuke za regulirani pristup i sigurnu primjenu IKT resursa.	Visoko učilište ne planira smjernice i preporuke za regulirani pristup i sigurnu primjenu IKT resursa, već to radi prema potrebi.	Visoko učilište ima djelomično razvijene smjernice i preporuke za regulirani pristup te sigurnu primjenu IKT resursa u vlasništvu	Visoko učilište ima smjernice i preporuke za regulirani pristup i sigurnu primjenu IKT resursa u vlasništvu učilišta; djelatnika i studenata, za sigurno korištenje internetom što	Visoko učilište ima smjernice i preporuke za regulirani pristup te odgovornu i sigurnu primjenu IKT resursa u vlasništvu učilišta, djelatnika i studenata, za sigurno korištenje

			učilišta, djelatnika i studenata.	pridonosi bržem i sigurnijem učenju, poučavanju i poslovanju, ali nema osiguranu podršku za BYOD mogućnosti.	internetom što pridonosi bržem i sigurnijem učenju, poučavanju i poslovanju. VU ima osiguranu podršku u primjeni IKT infrastrukture i BYOD mogućnosti.
Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a	Visoko učilište ne provodi kontrolu primjene etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a.	Visoko učilište djelomično provodi kontrolu primjene etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a.	Visoko učilište provodi kontrolu primjene etičkih standarda, opće uredbe o zaštiti podataka (GDPR), prava i intelektualnog vlasništva u području IKT-a i nema razvijena pravila koja promoviraju zaštitu autorskih prava i intelektualnog vlasništva kod djelatnika i studenata.	Visoko učilište ima pravila koja se odnose na licence za programsku opremu i sadržaj (npr. e-knjige, časopise), aplikacije, platforme i ostale obrazovne resurse koji potječu od komercijalnih izdavača / davatelja usluga te pravila koja promoviraju zaštitu autorskog prava i intelektualnog vlasništva kod djelatnika i studenata.	Visoko učilište ima pravila koja se odnose na licence za programsku opremu i sadržaj (npr. e-knjige, časopise), aplikacije, platforme i ostale obrazovne resurse koji potječu od komercijalnih izdavača / davatelja usluga te pravila koja promoviraju zaštitu autorskog prava i intelektualnog vlasništva kod djelatnika i studenata, primjenu etičkih standarda i opću uredbu o zaštiti osobnih podataka.

U *Tablici 61* prikazane su opisnice elemenata područja ODZVU: IKT infrastruktura

Tablica 61: Opisnice elemenata područja ODZVU: IKT infrastruktura

Elementi	Digitalno neosviješteno	Digitalno početno	Digitalno osnaženo	Digitalno sposobno	Digitalno zrelo
Planiranje i nabava IKT infrastrukture	Visoko učilište ne planira nabavu IKT infrastrukture za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove.	Visoko učilište nema plan nabave ulaganja u IKT infrastrukturu za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove već se ono provodi po potrebi.	Na visokom učilištu provode se aktivnosti planiranja i nabave IKT infrastrukture za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove koji je usklađen s potrebama VU.	Visoko učilište ima plan nabave IKT infrastrukture za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove. Periodički se prati realizacija plana nabave IKT infrastrukture.	Visoko učilište ima plan nabave ulaganja u IKT infrastrukturu za učenje i poučavanje; istraživanje i razvoj te poslovanje ustanove koji je usklađen s potrebama VU. Redovito se prati realizacija plana nabave IKT infrastrukture.
Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU	Gotovo niti jedna predavaonicama na visokom učilištu ne raspolaže s prezentacijskim (interaktivnim) uređajima (projektorima, pametnim pločama ili ekranima) te prijenosnim uređajima (prijenosna računala, tableti, mobiteli) ili stolnim računalima.	Manje od polovice predavaonica na visokom učilištu ne raspolaže s prezentacijskim (interaktivnim) uređajima (projektorima, pametnim pločama ili ekranima) te prijenosnim uređajima (prijenosna računala, tableti, mobiteli) ili stolnim računalima. Ostali periferni uređaju (npr. pisači, skeneri, kamere i slično) su dostupni kao zajednički resursi samo djelatnicima.	Više od polovice predavaonica na visokom učilištu opremljeno je projektorom, dok je manje od polovice njih opremljeno prijenosnim ili tablet uređajima i pametnim pločama ili pametnim ekranima. Ostali periferni uređaju (npr. pisači, skeneri, kamere i slično) su dostupni kao zajednički resursi samo djelatnicima.	Više od polovice predavaonica na visokom učilištu opremljeno je projektorom, dok je manje od polovice njih opremljeno prijenosnim ili tablet uređajima i pametnim pločama ili pametnim ekranima. Ostali periferni uređaju (npr. pisači, skeneri, kamere i slično) su dostupni kao zajednički resursi djelatnicima i studentima.	Visoko učilište raspolaže predavaonicama s prezentacijskim (interaktivnim) uređajima (projektorima, pametnim pločama ili ekranima) te prijenosnim uređajima (prijenosna računala, tableti, mobiteli) ili stolnim računalima. Djelatnicima i studentima omogućena je suvremena IKT infrastruktura, online resursi za učenje, VLE, LMS, laboratoriji, virtualne zajednice prakse i sl. Pristup mreži omogućen je unutar cijelog učilišta.

Raspoloživost IKT resursa za znanstveno-istraživački rad	Visoko učilište ne omogućava znanstvenicima IKT resurse u njihovom znanstveno-istraživačkom radu.	Visoko učilište djelomično omogućava znanstvenicima IKT resurse u njihovom znanstveno-istraživačkom radu. IKT oprema dostupna je kao zajednički resurs djelatnicima.	Visoko učilište omogućava znanstvenicima IKT resurse u njihovom znanstveno-istraživačkom radu, bez mogućnosti korištenja vlastite opreme. .	Visoko učilište omogućava znanstvenicima IKT resurse u njihovom znanstveno-istraživačkom radu. Učilište infrastrukturno omogućava znanstvenicima uspješno korištenje vlastite opreme unutar cijelog učilišta.	Visoko učilište omogućava znanstvenicima IKT resurse u njihovom znanstveno-istraživačkom radu. Učilište infrastrukturno omogućava znanstvenicima uspješno korištenje vlastite opreme unutar cijelog učilišta i omogućava im pristup bazama podataka, softverskim alatima i aplikacijama.
Raspoloživost IKT resursa za potporne službe	Visoko učilište ne omogućava zaposlenicima potpornih službi raspoloživost IKT resursa.	Visoko učilište djelomično omogućava zaposlenicima potpornih službi raspoloživost IKT resursa.	Visoko učilište omogućava zaposlenicima potpornih službi raspoloživost IKT resursa.	Visoko učilište ima plan nabave IKT infrastrukture za poslovanje ustanove odnosno potpornih službi VU. Periodički se prati realizacija plana nabave IKT infrastrukture.	Visoko učilište ima plan nabave IKT infrastrukture za poslovanje ustanove odnosno potpornih službi VU. Kontinuirano se prati realizacija plana nabave IKT infrastrukture kako bi se ostvarili ciljevi VU.
Pristup IKT resursima za studente u nastavi i van nastave	Visoko učilište ne omogućava studentima IKT resurse u nastavi i van nastave.	Visoko učilište djelomično omogućava studentima IKT resurse u nastavi. IKT oprema dostupna je kao zajednički resurs studentima.	Visoko učilište omogućava studentima IKT resurse u nastavi, bez mogućnosti korištenja vlastite opreme.	Visoko učilište omogućava studentima IKT opremu u njihovom svakodnevnom pohađanju nastave (učenje, poučavanje, komunikacija) te pristup digitalnim sadržajima. Učilište infrastrukturno omogućava studentima djelomično korištenje vlastite opreme unutar ustanove.	Visoko učilište omogućava studentima IKT opremu u njihovom svakodnevnom pohađanju nastave (učenje, poučavanje, komunikacija) te pristup digitalnim sadržajima. Učilište infrastrukturno omogućava studentima uspješno korištenje vlastite opreme unutar cijele ustanove.

Tehnička potpora i održavanje IKT resursa na VU	Na visokom učilištu nije osigurana tehnička potpora niti održavanje opreme i nisu za to osigurana sredstva.	Tehnička potpora i održavanje IKT resursa na visokom učilištu temelji se na dobrovoljnoj pomoći pojedinih djelatnika i za to nema osiguranih sredstava.	Tehnička potpora i održavanje IKT resursa na visokom učilištu prema potrebi vrši vanjski pružatelj usluga, ali ne postoji ugovorena usluga i nisu unaprijed osigurana sredstva za te potrebe.	Tehnička potpora i održavanje IKT resursa na visokom učilištu vrši vanjski davatelj usluga, njegova obveza je regulirana i za to su osigurana sredstva ili unutar VU postoji Centar za informatičku podršku djelatnicima i studentima.	Tehnička i korisnička podrška visokog učilišta planirana je i integrirana u IKT infrastrukturu kako bi se osigurala pouzdana izvedba, održavanje i interoperabilnost te omogućilo djelatnicima i studentima neometan pristup digitalnim tehnologijama, sadržajima i uslugama učilišta. Stupanj i način tehničke podrške može biti definiran interno ili vanjskim pružateljima usluga.
Sustav informacijske sigurnosti na VU	Visoko učilište nema razvijen sustav informacijske sigurnosti.	Na visokom učilištu nije razvijen sustav informacijske sigurnosti, ali se koristi minimalni skup zaštitnih mjera kako bi se osigurala zaštita privatnosti pojedinca, povjerljivost i sigurna uporaba IKT infrastrukture i podataka za učenje.	Na visokom učilištu postoji djelomično razvijen sustav informacijske sigurnosti, identificirana je informacijska imovina te su primijenjene zaštitne mjere kako bi se osigurala zaštita - privatnost pojedinca, povjerljivost i sigurna upotreba IKT infrastrukture i podataka za učenje prema raspoloživim resursima.	Na visokom učilištu postoji razvijen sustav informacijske sigurnosti, identificirana je informacijska imovina te su primijenjene zaštitne mjere kako bi se osigurala zaštita - privatnost pojedinca, povjerljivost i sigurna upotreba IKT infrastrukture i podataka za učenje prema raspoloživim resursima. Postoji svijest o manjkavostima u sustavu i planski se saniraju sigurnosne manjkavosti.	Visoko učilište ima odgovarajuće politike, postupke i zaštitne mjere kako bi se osigurala zaštita privatnosti pojedinca, povjerljivost i sigurna uporaba IKT infrastrukture i podataka za učenje. Zaštitne mjere uključuje zakonske obveze vezane uz zaštitu podataka i licence te formalne smjernice za osoblje i studente o privatnosti, povjerljivosti i sigurnosti u mrežnim okruženjima, aktivno se prati informacijska imovina i implementiraju zaštitne mjere u odnosu na procijenjene rizike i odabrane strategije upravljanja rizikom.

5.2.5.4. Rezultati istraživanja razina digitalne zrelosti visokih učilišta upotrebom rubrike

Rubrika je organizirana tako da prikazuje kriterije (Poglavlje 5.2.5.1.) kojima se mjeri kvaliteta ostvarene razine zrelosti. Kriteriji su postavljeni na nekoliko razina (Poglavlje 5.2.5.2.). Razine sadrže opise za svaki nivo napretka. Kriteriji izvedbe jasno navode razinu očekivane izvedbe za svaku numeričku vrijednost u rubrici (Poglavlje 5.2.5.3.). U ovom istraživanju koristi se rubrika s pet razina zrelosti za svaki od 42 elementa unutar 7 područja ODZVU.

Istraživanje je provedeno pomoću tablica u Prilogu 5. Prilog 5 je implementiran kroz MS Excel datoteku koja se zvala rubrika.xlsx na čijim su radnim listovima: VPU, OK, ZIR, TTSD, UP, IKTK i IKTI dani su opisi razina zrelosti za svaki element unutar 7 područja ODZVU (*Tablica 55* - *Tablica 61*). Svako područje opisano je na zasebnom radnom listu. Opisi razina zrelosti služe kao pokazatelji značajki pojedinih razina zrelosti za svaki od elemenata unutar pojedinog područja. Na svakom od navedenih sedam radnih listova u stupcu H ispitanici su iz padajućeg izbornika određivali razinu zrelosti pojedinog elementa na ljestvici od 1-5, (1-Digitalno neosviješteno VU, 2-Digitalno početno VU, 3-Digitalno osnaženo VU, 4-Digitalno sposobno VU i 5-Digitalno zrelo VU) za koju su smatrali da odgovara razini zrelosti na njihovom VU.

Rubrika je korištena da se dobiju vrijednosti prioriteta - LP (engl. *Level Priority*) svakog elementa koji su dio kompozitnog indeksa.

5.2.6. Kompozitni indeks

Kompozitni indeks omogućava integraciju rezultata prethodnih faza u sveobuhvatni model za procjenu digitalne zrelosti visokih učilišta. Rezultati prethodnih faza dobiveni su korištenjem AHP metode, DEMATEL-ANP metode te rezultata dobivenih istraživanjem pomoću rubrike [182]. Težinske vrijednosti područja određene su metodom DEMATEL-ANP (Poglavlje 5.2.2.). Težinske vrijednosti elemenata određene su metodom AHP (Poglavlje 5.2.3.). Ukupna vrijednost – TEW (engl. *Total Element Weight*) izračunata je kao umnožak težinskih vrijednosti dobivenih metodama DEMATEL-ANP i AHP za svaki element.

Ispitanici su procjenjivali zrelost po svakom elementu za svoje VU (Poglavlje 5.2.5.4.). Rezultati procjena upisivani su u stupac HEI-LEVEL (*Tablica 62)* za potrebe određivanja ukupne zrelosti VU.

Razine zrelosti iz stupca HEI-LEVEL transformirane su linearno u prioritete HEI-LP *(*engl. *Level Prioritiy*). Razina 1 dobila je prioritet 0, Razina 2 dobila je prioritet 0,25, Razina 3 dobila je prioritet 0,5, Razina 4 dobila je prioritet 0,75 te Razina 5 koja je dobila prioritet 1.

Potom je moguće procijeniti razinu zrelosti elementa za VU, HEI-TEP *(*engl. *Total Element Priority*) kao umnožak ukupne težine elementa (stupac TEW) i vrijednosti prioriteta za VU (stupac HEI-LP). Digitalna zrelost visokog učilišta – HEI-ML (engl. *Maturity Level*) dobiva se kao suma svih vrijednosti stupca HEI-TEP. U nastavku je prikazan rezultat digitalne zrelosti visokog učilišta prema izboru autorice (*Tablica 62*).

U razvoju IPDZVU-a korištene su kvalitativne i kvantitativne metode istraživanja:

- metode za višekriterijsko odlučivanje AHP i DEMATEL-ANP za određivanje težinskih koeficijenata područja i elemenata ODZVU-a,
- metoda za strukturiranje problema odlučivanja DEMATEL za analizu i formiranje veze uzroka i posljedica između područja ili derivirale međuzavisnosti između područja,
- rubrika za definiranje izjava koje opisuju svaku od pet razina zrelosti,
- kompozitni indeks za rangiranje VU-a prema razinama zrelosti.

Primjenom kvalitativnih i kvantitativnih metoda istraživanja ostvaren je cilj istraživanja **C2:** Razviti instrument za procjenu digitalne zrelosti visokog učilišta.

Tablica 62: Struktura kompozitnog indeksa na primjeru rezultata istraživanja na odabranom VU

Područje	Elementi	ANP Težinski koeficijent područja	AHP Težinski koeficijent elemenata	TEW Ukupna težina elemenata	HEI-LEVEL Procjena iz rubrike Ispitanik 1	HEI-LP Vrijednosti prioriteta	HEI-TEP Razina zrelosti elemenata
Vodstvo, planiranje i upravljanje	Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	0,1588	0,0861	0,0137	4	0,75	0,0103
	Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	0,1588	0,0961	0,0153	3	0,5	0,0076
	Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	0,1588	0,1542	0,0245	5	1	0,0245
	Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	0,1588	0,1704	0,0271	4	0,75	0,0203
	Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	0,1588	0,1490	0,0237	3	0,5	0,0118
	Upravljanje integracijom IKT-a u učenje i poučavanje na VU	0,1588	0,1734	0,0275	4	0,75	0,0207
	Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU	0,1588	0,1709	0,0271	4	0,75	0,0204
Osiguranje kvalitete	Politika osiguranja kvalitete primjene IKT-a na VU	0,1366	0,1517	0,0207	5	1	0,0207
	Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a	0,1366	0,1682	0,0230	3	0,5	0,0115
	Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU	0,1366	0,1604	0,0219	3	0,5	0,0110
	Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU	0,1366	0,1596	0,0218	3	0,5	0,0109
	Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a	0,1366	0,1969	0,0269	4	0,75	0,0202
	Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a	0,1366	0,1631	0,0223	4	0,75	0,0167
Znanstveno-istraživački	Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova	0,1381	0,1407	0,0194	3	0,5	0,0097

rad uz podršku IKT-a	Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu	0,1381	0,1357	0,0187	3	0,5	0,0094
	Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima	0,1381	0,1608	0,0222	4	0,75	0,0167
	Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja	0,1381	0,1728	0,0239	5	1	0,0239
	Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu	0,1381	0,2191	0,0303	5	1	0,0303
	Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a	0,1381	0,1710	0,0236	3	0,5	0,0118
Transfer tehnologije i služenje društvu uz podršku IKT-a	Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda	0,1330	0,4107	0,0546	3	0,5	0,0273
	Suradnja VU s dionicima društva uz potporu IKT-a	0,1330	0,2738	0,0364	3	0,5	0,0182
	Umreženost istraživača i korisnika istraživanja uz potporu IKT-a	0,1330	0,3154	0,0420	2	0,25	0,0105
Učenje i poučavanje uz podršku IKT-a	Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU	0,1404	0,2041	0,0287	4	0,75	0,0215
	Razvoj digitalnih kompetencija studenata	0,1404	0,1486	0,0209	3	0,5	0,0104
	Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a	0,1404	0,1046	0,0147	3	0,5	0,0073
	Dostupan repozitorij digitalnih obrazovnih sadržaja	0,1404	0,1063	0,0149	5	1	0,0149
	Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika	0,1404	0,1390	0,0195	4	0,75	0,0146
	Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata	0,1404	0,0977	0,0137	3	0,5	0,0069
	Upotreba analitika učenja u unapređenju učenja i poučavanja	0,1404	0,1059	0,0149	2	0,25	0,0037
	Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju	0,1404	0,0938	0,0132	3	0,5	0,0066
IKT kultura	Samopouzdanje i motivacija djelatnika za primjenu IKT-a	0,1398	0,1911	0,0267	4	0,75	0,0200
	Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata	0,1398	0,1832	0,0256	4	0,75	0,0192
	Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata	0,1398	0,2597	0,0363	4	0,75	0,0272
	Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa	0,1398	0,1704	0,0238	3	0,5	0,0119

	Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a	0,1398	0,1956	0,0274	3	0,5	0,0137
IKT infrastruktura	Planiranje i nabava IKT infrastrukture	0,1532	0,1137	0,0174	5	1	0,0174
	Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU	0,1532	0,1414	0,0217	5	1	0,0217
	Raspoloživost IKT resursa za znanstveno-istraživački rad	0,1532	0,1892	0,0290	4	0,75	0,0217
	Raspoloživost IKT resursa za potporne službe	0,1532	0,1202	0,0184	5	1	0,0184
	Pristup IKT resursima za studente u nastavi i van nastave	0,1532	0,1734	0,0266	5	1	0,0266
	Tehnička potpora i održavanje IKT resursa na VU	0,1532	0,1347	0,0206	4	0,75	0,0155
	Sustav informacijske sigurnosti na VU	0,1532	0,1274	0,0195	4	0,75	0,0146
					HEI-ML Ukupna razina zrelosti VU		**0,6781**

6. Digitalna zrelost visokih učilišta u Republici Hrvatskoj – rezultati istraživanja

Rezultati istraživanja digitalne zrelosti VU u RH koje je provedeno u sklopu ove doktorske disertacije prikazano je u Poglavlju 6.1. i Poglavlju 6.2.

Ispitanici u istraživanju procjenjivali su digitalnu zrelost svojeg VU pomoću rubrike koja se sastoji od sedam područja. Područja se sastoje od 42 elementa koji su opisani za svaku od pet razina zrelosti: 1 – Digitalno neosviješteno, 2 – Digitalno početno, 3 – Digitalno osnaženo, 4 – Digitalno sposobno i 5 – Digitalno zrelo. Najveća moguća digitalna zrelost predstavlja digitalnu zrelost VU kada je svaki od 42 elementa u rubrici procijenjen kao 5_Digitalno zrelo. Najveća moguća digitalna zrelost prema predloženom instrumentu za područje 1_Vodstvo, planiranje i upravljanje iznosi 0,1588. Najveća moguća digitalna zrelost prema predloženom instrumentu za područje 2_Osiguranje kvalitete iznosi 0,1366. Najveća moguća digitalna zrelost prema predloženom instrumentu za područje 3 _Znanstveno-istraživački rad uz podršku IKT-a iznosi 0,1381. Najveća moguća digitalna zrelost prema predloženom instrumentu za područje 4_Transfer tehnologije i služenje društvu uz podršku IKT-a iznosi 0,1330. Najveća moguća digitalna zrelost prema predloženom instrumentu za područje 5_Učenje i poučavanje uz podršku IKT-a iznosi 0,1404. Najveća moguća digitalna zrelost prema predloženom instrumentu za područje 6_IKT kultura iznosi 0,1398. Najveća moguća digitalna zrelost prema predloženom instrumentu za područje 7_IKT infrastruktura iznosi 0,1532.

6.1. Digitalna zrelost VU

Digitalna zrelost VU mjeri se pomoću kompozitnog indeksa koji je prikazan u *Tablici 62*. U nastavku slijedi analiza digitalne zrelosti 33 VU u RH koji su sudjelovali u istraživanju (struktura VU objašnjena je u poglavlju 5.2. Instrument za procjenu digitalne zrelosti visokih učilišta). U grafikonu je plavom bojom označena najveća moguća razina zrelosti za svako područje predloženog instrumenta. Crvenom bojom označene su razine zrelosti za analizirano visoko učilište.

Digitalna zrelost VU_1 prikazana je na *Slici 25*. VU_1 je digitalno zrelo u tri područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a, 7_IKT infrastruktura* te *6_IKT kultura*. Područja *2_Osiguranje kvalitete* i *3_Znanstveno-istraživački rad uz podršku IKT-a* područja su kod kojih je potrebno tek malo unaprijediti kako bi bila digitalno zrela. Zanimljivo

je da su područja *5_Učenje i poučavanje uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje* najmanje zrela za promatrano VU te je potrebno kroz niz aktivnosti ova dva područja podići na veću razinu zrelosti.

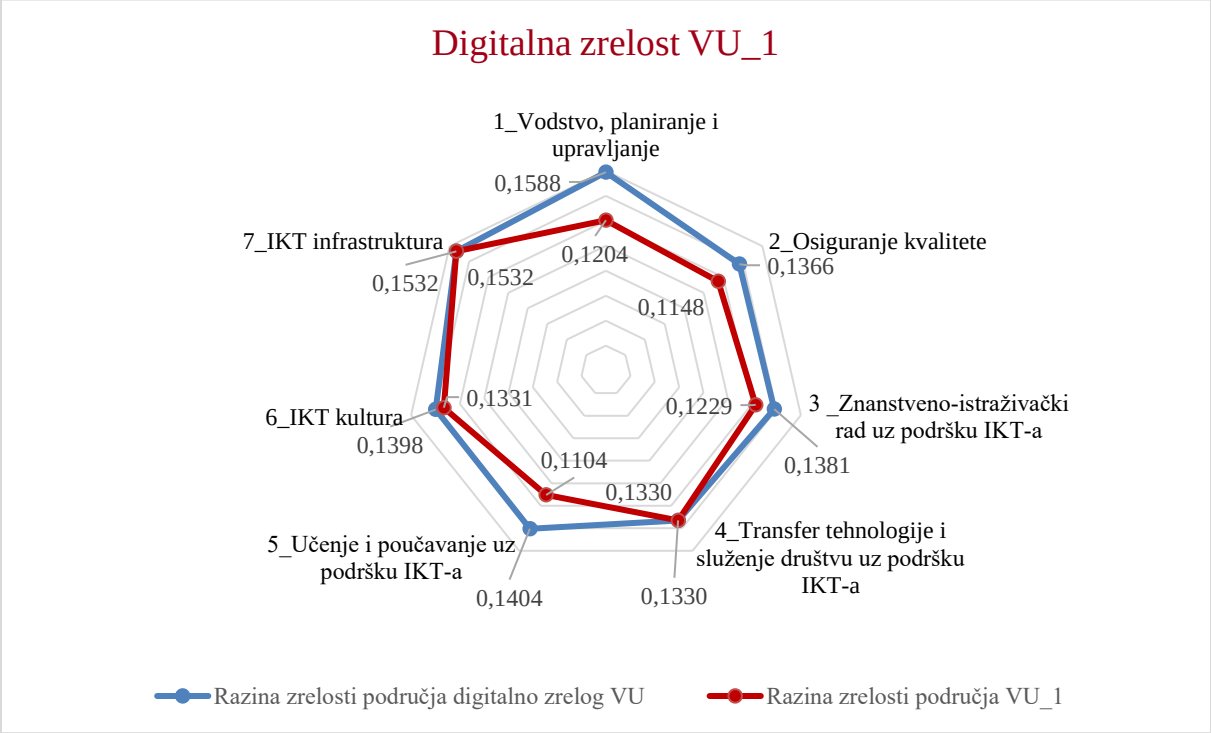

Slika 25: Digitalna zrelost VU_1

Digitalna zrelost VU_4 prikazana je na *Slici 26*. VU_4 najveću digitalnu zrelost ima u područjima *6_IKT kultura* i *1_Vodstvo, planiranje i upravljanje*. U svim područjima (uključujući i navedena dva koja imaju najveću digitalnu zrelost) potrebno je provesti mnogo aktivnosti kako bi se unaprijedila digitalna zrelost pojedinog područja, a samim time i digitalna zrelost VU.

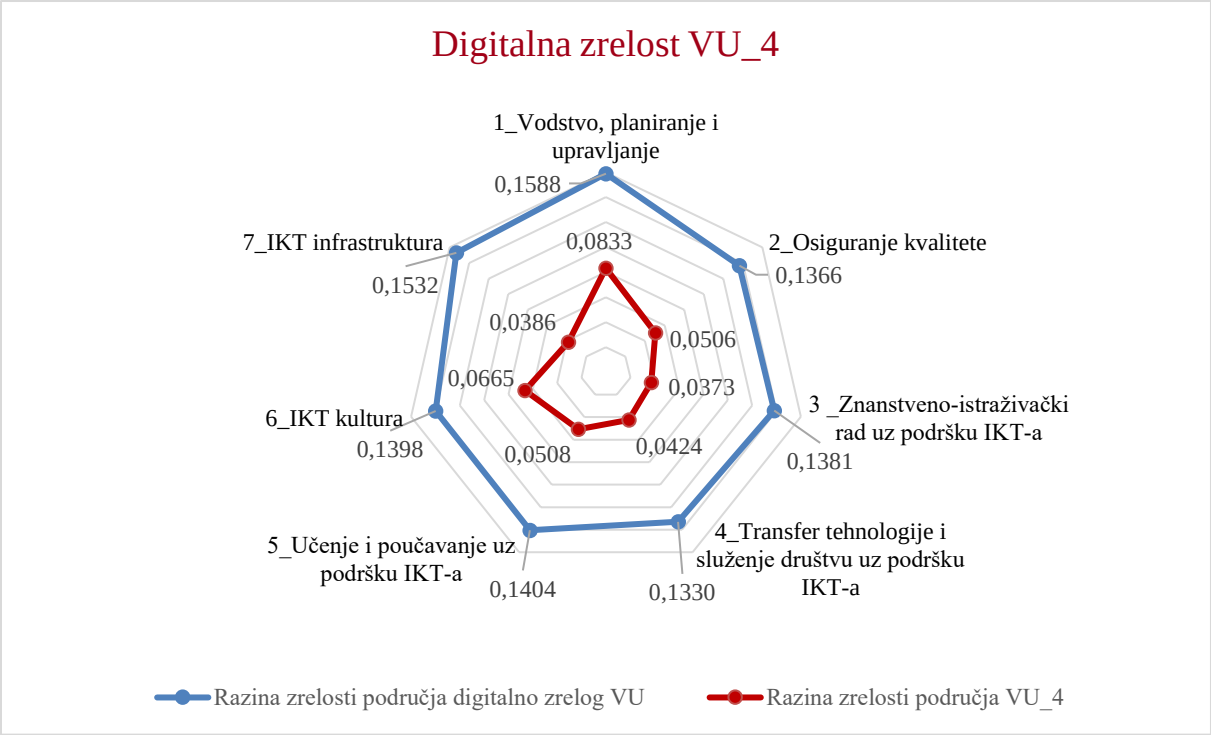

Slika 26: Digitalna zrelost VU_4

Digitalna zrelost VU_33 prikazana je na *Slici 27*. VU_33 najveću digitalnu zrelost ima u području *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*, zatim slijede područja *5_Učenje i poučavanje uz podršku IKT-a, 1_Vodstvo, planiranje i upravljanje, 3_Znanstveno-istraživački rad uz podršku IKT-a* i *7_IKT infrastruktura i 6_IKT kultura.* Područje *2_Osiguranje kvalitete* je jedino područje koje nije digitalno zrelo te ga je potrebno unaprijediti kako bi postigli veću razinu digitalne zrelosti.

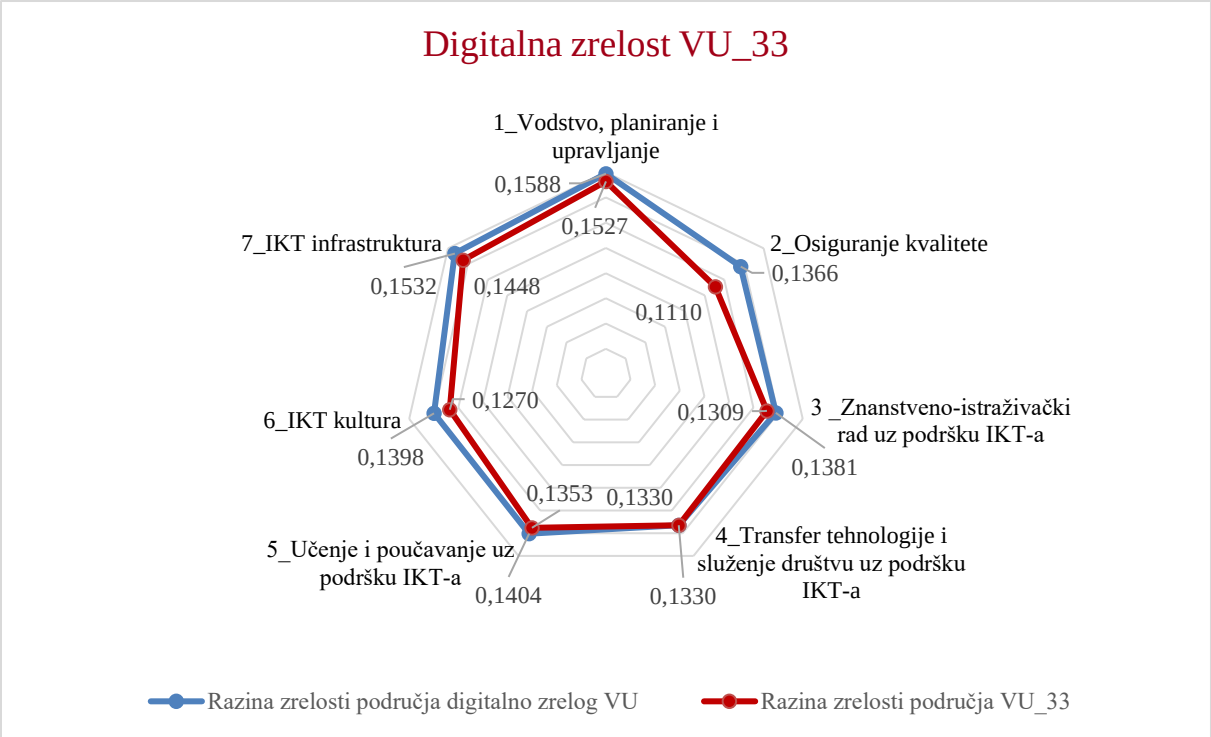

Slika 27: Digitalna zrelost VU_33

Digitalna zrelost svih visokih učilišta koja su sudjelovala u istraživanju prikazana je i interpretirana u Prilogu 6: Digitalna zrelost VU.

Zbirna analiza rezultata digitalne zrelosti 33 visoka učilišta pokazala (*Slika 28*) je da najveći broj 46% ili (*N=15*) VU ima najveću digitalnu zrelost u području *7_IKT infrastruktura*. 30% VU ili (*N=10*) VU ima najveću digitalnu zrelost u području *6_IKT kultura*. Zanimljivo je da 9% VU ili (*N=3*) VU ima najveću digitalnu zrelost u području *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*, a samo 6% VU ili (*N=2*) VU ima najveću digitalnu zrelost u području *1_Vodstvo, planiranje i upravljanje*. 3% VU ili (*N=1*) VU ima najveću digitalnu zrelost u područjima *2_Osiguranje kvalitete*, *3_Znanstveno-istraživački rad uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a*.

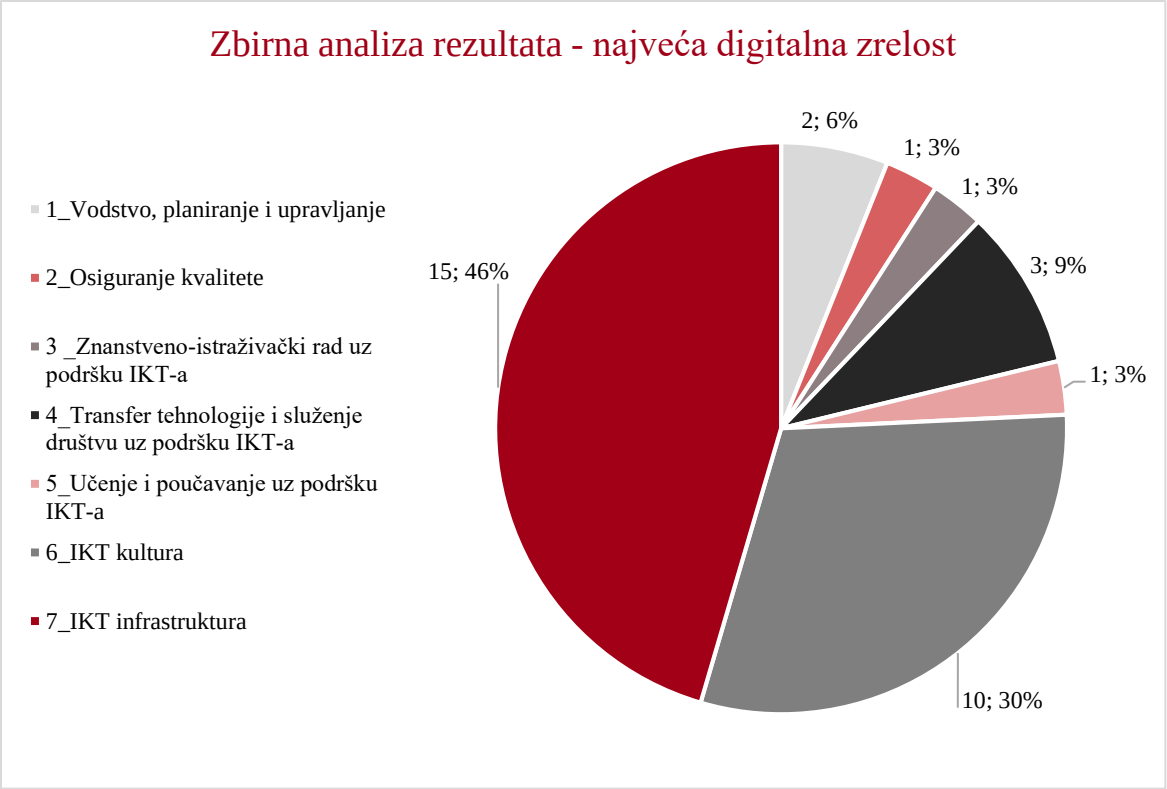

Slika 28: Zbirna analiza rezultata - najveća digitalna zrelost

Od ukupnog broja VU koja su sudjelovala u istraživanju 37% VU ili (*N=12*) VU ima drugu najveću digitalnu zrelost u području *7_IKT infrastruktura*. Drugu najveću digitalnu zrelost u području *6_IKT kultura* ima 21% VU ili (*N=7*) VU. Drugu najveću digitalnu zrelost u području *1_Vodstvo, planiranje i upravljanje* ima 12% VU ili (*N=4*) VU. Drugu najveću digitalnu zrelost u područjima *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a* ima 9% ili (*N=3*) VU. Drugu najveću digitalnu zrelost u područjima *2_Osiguranje kvalitete* odnosno *3_Znanstveno-istraživački rad uz podršku IKT-a* ima 6% VU ili (*N=2*) VU.

Analizom prve dvije najveće razine digitalne zrelosti proizlazi da 41% VU ima najveću digitalnu zrelost u području *7_IKT infrastruktura*. Najveću digitalnu zrelost u području *6_IKT kultura* ima 26% VU. Najveću digitalnu zrelost u područjima *1_Vodstvo, planiranje i upravljanje* i *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* ima 9% VU. Najveću digitalnu zrelost u području *5_Učenje i poučavanje uz podršku IKT-a* ima 6% VU. Najveću digitalnu zrelost u područjima *2_Osiguranje kvalitete* i *3_Znanstveno-istraživački rad uz podršku IKT-a* ima 4% VU.

Nadalje, zbirna analiza rezultata digitalne zrelosti 33 visoka učilišta pokazala je da najveći broj 24% ili (*N=8*) VU ima drugu najmanju digitalnu zrelost u područjima *2_Osiguranje kvalitete i 5_Učenje i poučavanje uz podršku IKT-a*. Drugu najmanju digitalnu zrelost u području *3_Znanstveno-istraživački rad uz podršku IKT-a* ima 21% VU ili (*N=7*) VU. Drugu najmanju digitalnu zrelost u području *1_Vodstvo, planiranje i upravljanje* ima 18% VU ili (*N=6*) VU. Drugu najmanju digitalnu zrelost u području *7_IKT infrastruktura* ima 6% VU ili (*N=2*) VU. Drugu najmanju digitalnu zrelost u područjima *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *6_IKT kultura* ima 3% VU ili (*N=1*).

Najmanju digitalnu zrelost u području *2_Osiguranje kvalitete* ima 31% ili (*N=10*) VU (*Slika 29*). Najmanju digitalnu zrelost u području *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* ima 27% VU ili (*N=9*) VU. Najmanju digitalnu zrelost u području *1_Vodstvo, planiranje i upravljanje* ima 15% VU ili (*N=5*) VU. Najmanju digitalnu zrelost u području *5_Učenje i poučavanje uz podršku IKT-a* ima 12% VU ili (*N=4*) VU. Najmanju digitalnu zrelost u području *3_Znanstveno-istraživački rad uz podršku IKT-a* ima 9% VU ili (*N=3*) VU. Najmanju digitalnu zrelost u područjima *7_IKT infrastruktura.* i *6_IKT kultura* ima 3% VU ili (*N=1*) VU.

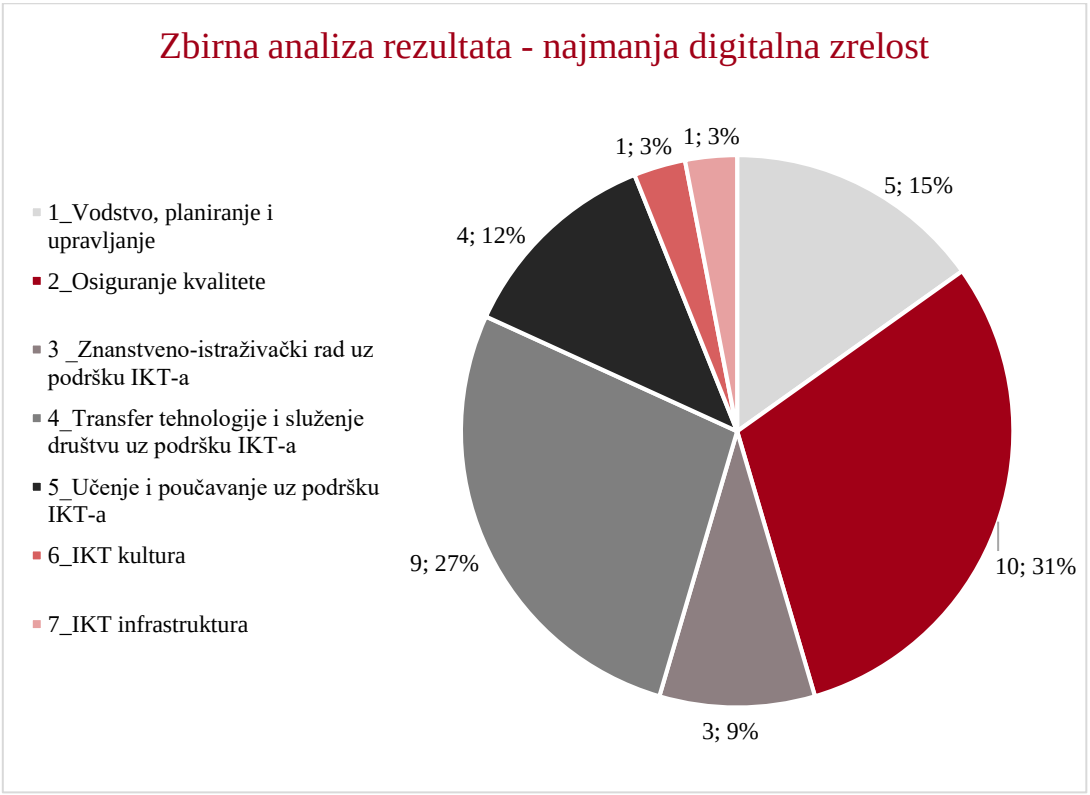

Slika 29: Zbirna analiza rezultata - najmanja digitalna zrelost

Analizom zadnje dvije najmanje razine digitalne zrelosti proizlazi da 27% VU ima najmanju digitalnu zrelost u području *2_Osiguranje kvalitete.* Najmanju digitalnu zrelost u području *5_Učenje i poučavanje uz podršku IKT-a* ima 18% VU. Najmanju digitalnu zrelost u području *1_Vodstvo, planiranje i upravljanje* ima 17% VU. Najmanju digitalnu zrelost u područjima *3_Znanstveno-istraživački rad uz podršku IKT-a* i *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* ima 15% VU. Najmanju digitalnu zrelost u područjima *6_IKT kultura* i *7_IKT infrastruktura* ima 3% VU.

U nastavku slijedi analiza digitalne zrelosti visokih učilišta prema znanstvenim područjima. Analizom prve dvije najveće razine digitalne zrelosti proizlazi da 44% VU iz područja **društvenih znanosti** ima najveću digitalnu zrelost u području *7_IKT infrastruktura*. Iz područja društvenih znanosti 22% VU ima najveću digitalnu zrelost u području *6_IKT kultura*. Iz područja društvenih znanosti 11% VU ima najveću digitalnu zrelost u područjima *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a.* Iz područja društvenih znanosti 6% VU ima najveću digitalnu zrelost u područjima *1_Vodstvo, planiranje i upravljanje* i *3_Znanstveno-istraživački rad uz podršku IKT-a.* Zanimljivo je da niti jedno VU iz područja društvenih znanosti nema najveću digitalnu zrelost u području *2_Osiguranje kvalitete.*

Analizom zadnje dvije najmanje razine digitalne zrelosti proizlazi da 39% VU iz područja **društvenih znanosti** ima najmanju digitalnu zrelost u području *2_Osiguranje kvalitete.* Zanimljivo je da 22% VU iz područja društvenih znanosti ima najmanju digitalnu zrelost u području *5_Učenje i poučavanje uz podršku IKT-a.* Iz područja društvenih znanosti 11% VU ima najmanju digitalnu zrelost u područjima *1_Vodstvo, planiranje i upravljanje, 3_Znanstveno-istraživački rad uz podršku IKT-a* i *4_Transfer tehnologije i služenje društvu uz podršku IKT-a.* Iz područja društvenih znanosti 6% VU ima najmanju digitalnu zrelost u području *6_IKT kultura.* Niti jedno VU iz područja društvenih znanosti nema najmanju digitalnu zrelost u području *7_IKT infrastruktura.*

Analizom prve dvije najveće razine digitalne zrelosti proizlazi da 50% VU iz područja **prirodnih znanosti** ima najveću digitalnu zrelost u područjima *7_IKT infrastruktura i 6_IKT kultura*. Zanimljivo je da niti jedno VU iz područja prirodnih znanosti nema najveću digitalnu zrelost u preostalim područjima *1_Vodstvo, planiranje i upravljanje, 2_Osiguranje kvalitete, 3_Znanstveno-istraživački rad uz podršku IKT-a, 4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a.*

Analizom zadnje dvije najmanje razine digitalne zrelosti proizlazi da 33% VU iz područja **prirodnih znanosti** ima najmanju digitalnu zrelost u područjima *1_Vodstvo, planiranje i upravljanje* i *2_Osiguranje kvalitete.* Iz područja prirodnih znanosti 17% VU ima najmanju digitalnu zrelost u područjima *4_Transfer tehnologije* i *5_Učenje i poučavanje uz podršku IKT-a.* Niti jedno VU iz područja prirodnih znanosti nema najmanju digitalnu zrelost u područjima *3_Znanstveno-istraživački rad uz podršku IKT-a, 4_Transfer tehnologije i služenje društvu uz podršku IKT-a, 6_IKT kultura* i *7_IKT infrastruktura.*

Analizom prve dvije najveće razine digitalne zrelosti proizlazi da 40% VU iz područja **tehničkih znanosti** ima najveću digitalnu zrelost u području *7_IKT infrastruktura*. Iz područja tehničkih znanosti 20% VU ima najveću digitalnu zrelost u području *6_IKT kultura*. Iz područja tehničkih znanosti 10% VU ima najveću digitalnu zrelost u područjima *1_Vodstvo, planiranje i upravljanje, 2_Osiguranje kvalitete, 4_Transfer tehnologije i služenje društvu uz podršku IKT-a i 5_Učenje i poučavanje uz podršku IKT-a.* Zanimljivo je da niti jedno VU iz područja tehničkih znanosti nema najveću digitalnu zrelost u području *3_Znanstveno-istraživački rad uz podršku IKT-a.*

Analizom zadnje dvije najmanje razine digitalne zrelosti proizlazi da 30% VU iz područja **tehničkih znanosti** ima najmanju digitalnu zrelost u područjima *1_Vodstvo, planiranje i upravljanje* i *2_Osiguranje kvalitete.* Iz područja tehničkih znanosti 10% VU ima najmanju digitalnu zrelost u područjima *3_Znanstveno-istraživački rad uz podršku IKT-a, 4_Transfer tehnologije i služenje društvu uz podršku IKT-a, 5_Učenje i poučavanje uz podršku IKT-a* i *7_IKT infrastruktura.* Niti jedno VU iz područja tehničkih znanosti nema najmanju digitalnu zrelost u području *6_IKT kultura.*

Analizom prve dvije najveće razine digitalne zrelosti proizlazi da 50% VU iz područja **biomedicine i zdravstva** ima najveću digitalnu zrelost u području *1_Vodstvo, planiranje i upravljanje.* Iz područja biomedicine i zdravstva 25% VU ima najveću digitalnu zrelost u područjima *6_IKT kultura* i *7_IKT infrastruktura*. Niti jedno VU iz područja biomedicine i zdravstva nema najveću digitalnu zrelost u područjima *2_Osiguranje kvalitete, 3_Znanstveno-istraživački rad uz podršku IKT-a, 4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a.*

Analizom zadnje dvije najmanje razine digitalne zrelosti proizlazi da 50% VU iz područja **biomedicine i zdravstva** ima najmanju digitalnu zrelost u području *2_Osiguranje kvalitete.* Iz

područja biomedicine i zdravstva. 25% VU ima najmanju digitalnu zrelost u područjima, *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a.* Niti jedno VU iz područja biomedicine i zdravstva nema najmanju digitalnu zrelost u područjima *1_Vodstvo, planiranje i upravljanje*, *3_Znanstveno-istraživački rad uz podršku IKT-a, 6_IKT kultura* i *7_IKT infrastruktura.*

Analizom prve dvije najveće razine digitalne zrelosti proizlazi da 50% VU iz područja **biotehničkih znanosti** ima najveću digitalnu zrelost u područjima *6_IKT kultura* i *7_IKT infrastruktura*. Niti jedno VU iz područja biotehničkih znanosti nema najveću digitalnu zrelost u području *1_Vodstvo, planiranje i upravljanje, 2_Osiguranje kvalitete, 3_Znanstveno-istraživački rad uz podršku IKT-a, 4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a.*

Analizom zadnje dvije najmanje razine digitalne zrelosti proizlazi da 25% VU iz područja **biotehničkih znanosti** ima najmanju digitalnu zrelost u područjima *2_Osiguranje kvalitete, 3_Znanstveno-istraživački rad uz podršku IKT-a, 4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a.* Niti jedno VU iz područja biotehničkih znanosti nema najmanju digitalnu zrelost u područjima *1_Vodstvo, planiranje i upravljanje, 6_IKT kultura* i *7_IKT infrastruktura.*

Analizom prve dvije najveće razine digitalne zrelosti proizlazi da 25% VU iz **umjetničkog područja** ima najveću digitalnu zrelost u područjima, *4_Transfer tehnologije i služenje društvu uz podršku IKT-a, 6_IKT kultura* i *7_IKT infrastruktura*. Niti jedno VU iz umjetničkog područja nema najveću digitalnu zrelost u području, *2_Osiguranje kvalitete, 3_Znanstveno-istraživački rad uz podršku IKT-a,* i *5_Učenje i poučavanje uz podršku IKT-a.*

Analizom zadnje dvije najmanje razine digitalne zrelosti proizlazi da 50% VU iz **umjetničkog područja** ima najmanju digitalnu zrelost u području *3_Znanstveno-istraživački rad uz podršku IKT-a.* Iz umjetničkog područja 25% VU ima najmanju digitalnu zrelost u područjima *1_Vodstvo, planiranje i upravljanje* i *7_IKT infrastruktura.* Niti jedno VU iz umjetničkog područja nema najmanju digitalnu zrelost u područjima, *2_Osiguranje kvalitete, 4_Transfer tehnologije i služenje društvu uz podršku IKT-a, 5_Učenje i poučavanje uz podršku IKT-a* i *6_IKT kultura.*

Rezultati zbirne analize pokazali su da VU koja su sudjelovala u istraživanju najveću razinu digitalne zrelosti imaju u područjima *6_IKT kultura* i *7_IKT infrastruktura.* Od ukupnog broja

VU kod njih 66% navedena područja imaju prve dvije najveće razine digitalne zrelosti. Ostalih pet područja: *1_Vodstvo, planiranje i upravljanje, 2_Osiguranje kvalitete, 3_Znanstveno-istraživački rad uz podršku IKT-a, 4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a* potrebno je unaprijediti kako bi se podigla ukupna razina digitalne zrelosti VU.

6.2. Digitalna zrelost područja ODZVU

Digitalna zrelost područja ODZVU *1_Vodstvo, planiranje i upravljanje* prikazana je na *Slici 30.* Kod dva VU (VU_8 i VU_29) ili 6% od ukupnog broja VU područje *1_Vodstvo, planiranje i upravljanje* ima najveću digitalnu zrelost u odnosu na ostalih 6 područja ODZVU-a (Prilog 6 *Slika 6.8* i *Slika 6.29*). Više od polovice VU područje *1_Vodstvo, planiranje i upravljanje* zanemaruje u odnosu na ostalih 6 područja ODZVU-a što je vidljivo iz grafikona na *Slici 30.* Kod 5 VU (VU_1, VU_9, VU_10, VU_30 i VU_31) ili 15% od ukupnog broja VU područje *1_Vodstvo, planiranje i upravljanje* ima najmanju digitalnu zrelost u odnosu na ostala područja ODZVU-a.

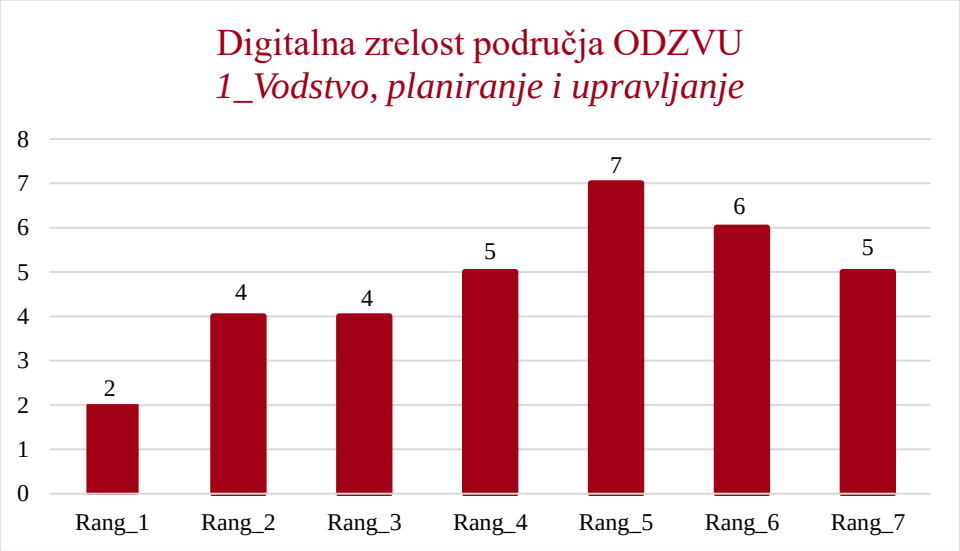

Slika 30: Digitalna zrelost područja ODZVU 1_Vodstvo, planiranje i upravljanje

Digitalna zrelost područja ODZVU *2_Osiguranje kvalitete* prikazana je na *Slici 31.* Kod samo jednog VU (VU_5) ili 3% od ukupnog broja VU područje *2_Osiguranje kvalitete* ima najveću digitalnu zrelost u odnosu na ostala područja ODZVU-a. Kod više od 75% VU-a područje *2_Osiguranje kvalitete* nalazi se unutar posljednjih tri područja digitalne zrelosti područja ODZVU u odnosu na ostala područja ODZVU-a što je vidljivo iz grafikona na *Slici 31.* Kod 10 VU (VU_2, VU_6, VU_7, VU_17, VU_23, VU_24, VU_25, VU_32 i VU_33) ili 15% od ukupnog broja VU područje *2_Osiguranje kvalitete* ima najmanju digitalnu zrelost u odnosu na ostala područja ODZVU-a.

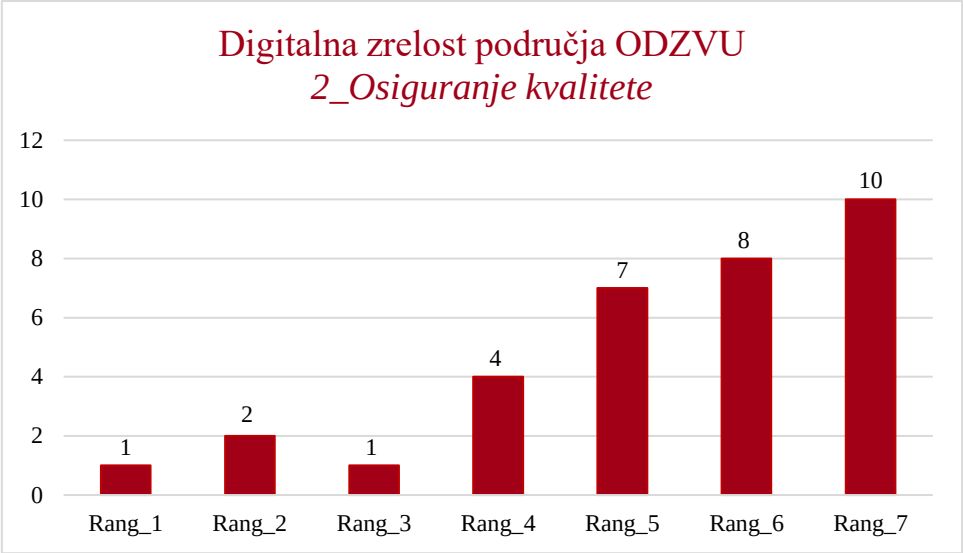

Slika 31: Digitalna zrelost područja ODZVU 2_Osiguranje kvalitete

Digitalna zrelost područja ODZVU *3_Znanstveno-istraživački rad uz podršku IKT-a* prikazana je na *Slici 32*. Kod samo jednog VU (VU_20) ili 3% od ukupnog broja VU područje *3_Znanstveno-istraživački rad uz podršku IKT-a* ima najveću digitalnu zrelost u odnosu na ostala područja ODZVU-a. Kod 28% VU-a područje *3_Znanstveno-istraživački rad uz podršku IKT-a* nalazi se unutar prva tri područja digitalne zrelosti područja u odnosu na ostala područja ODZVU-a. Kod 3 VU ili 9% od ukupnog broja VU područje 3_Znanstveno-istraživački rad uz podršku IKT-a ima najmanju digitalnu zrelost u odnosu na ostala područja ODZVU-a.

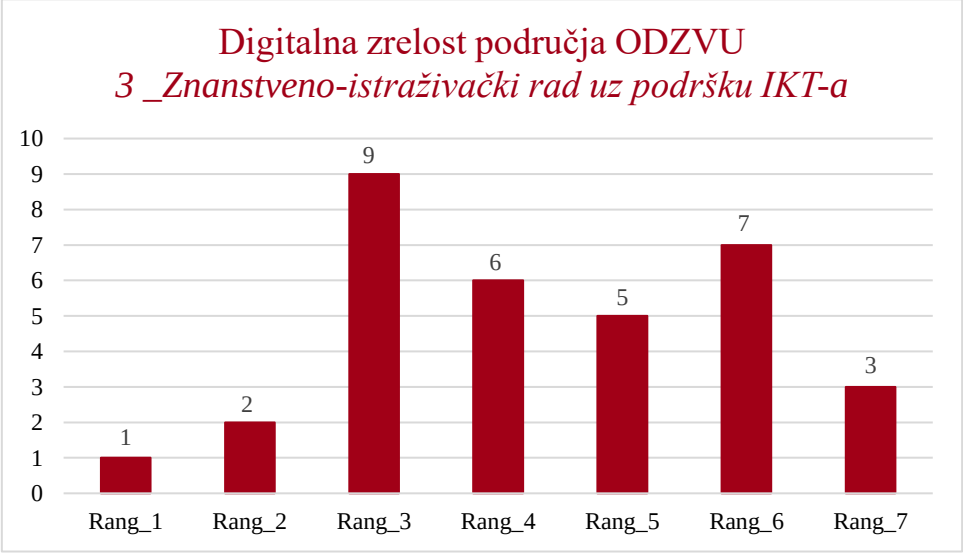

Slika 32: Digitalna zrelost područja ODZVU 3_Znanstveno-istraživački rad uz podršku IKT-a

Digitalna zrelost područja ODZVU *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* prikazana je na *Slici 33.* Kod tri VU (VU_9, VU_10 i VU_33) ili 9% od ukupnog broja VU područje *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* ima najveću digitalnu zrelost u odnosu na ostala područja ODZVU-a. Kod 10 VU (VU_8, VU_11, VU_12, VU_14, VU_16, VU_18, VU_19, VU_21, VU_22 i VU_27) ili 31% od ukupnog broja VU područje *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* ima najmanju digitalnu zrelost u odnosu na ostala područja ODZVU-a.

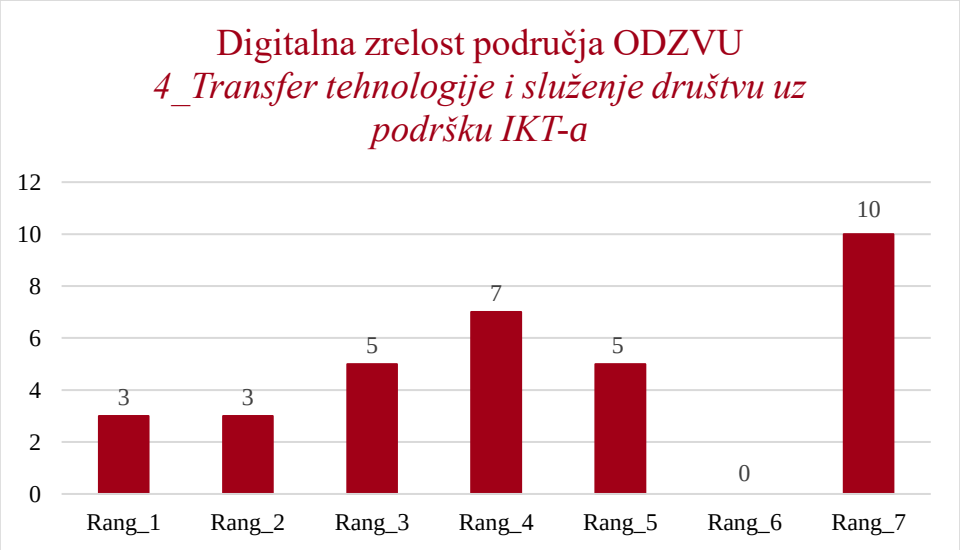

Slika 33: Digitalna zrelost područja ODZVU 4_Transfer tehnologije i služenje društvu uz podršku IKT-a

Digitalna zrelost područja ODZVU 5_Učenje i poučavanje uz podršku IKT-a prikazana je na *Slici 34.* Kod jednog VU (VU_6) ili 3% od ukupnog broja VU područje 5_Učenje i poučavanje uz podršku IKT-a ima najveću digitalnu zrelost u odnosu na ostala područja ODZVU-a. Najveći broj VU, njih 8 (VU_1, VU_2, VU_12, VU_16, VU_24, VU_25, VU_27 i VU_30) ili 25% VU ima drugu najmanju digitalnu zrelost u području 5_Učenje i poučavanje uz podršku IKT-a u odnosu na ostala područja ODZVU-a. Kod 4 VU (VU_3, VU_15, VU_20 i VU_29) ili 12% od ukupnog broja VU područje 5_Učenje i poučavanje uz podršku IKT-a ima najmanju digitalnu zrelost u odnosu na ostala područja ODZVU-a.

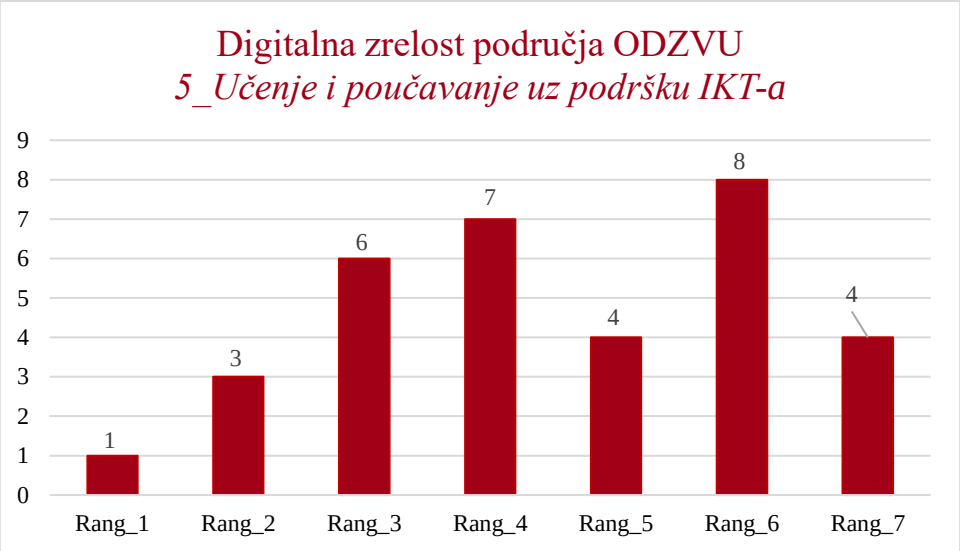

Slika 34: Digitalna zrelost područja ODZVU 5_Učenje i poučavanje uz podršku IKT-a

Digitalna zrelost područja ODZVU *6_IKT kultura* prikazana je na *Slici 35.* Kod 9 VU (VU_4, VU_11, VU_12, VU_13, VU_14, VU_15, VU_16 i VU_17) ili 28% od ukupnog broja VU područje *6_IKT kultura* ima najveću digitalnu zrelost u odnosu na ostala područja ODZVU-a. Kod više od 75% VU područje 6_IKT kultura je unutar prva tri područja digitalne zrelosti u odnosu na ostala područja ODZVU. Kod niti jednog VU područje *6_IKT kultura* nema najmanju digitalnu zrelost u odnosu na ostala područja ODZVU-a.

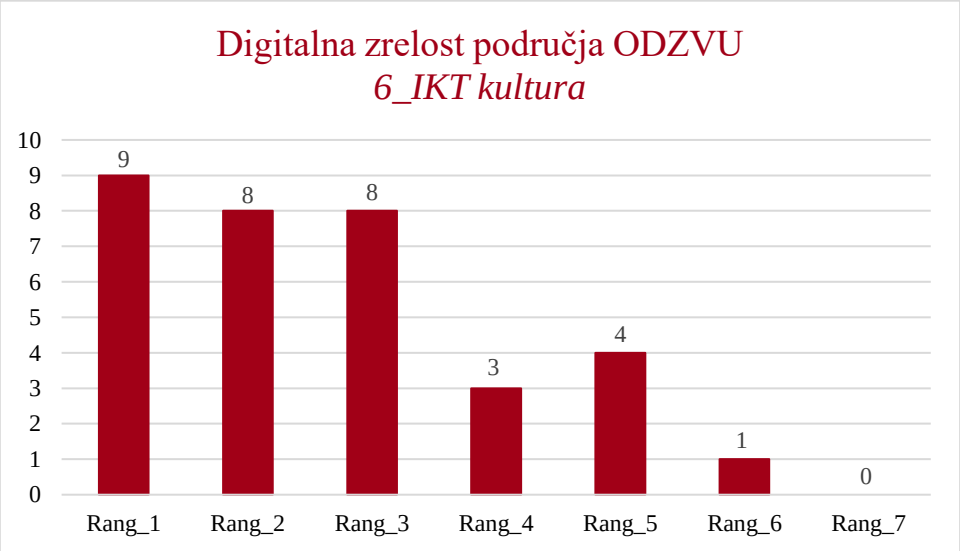

Slika 35: Digitalna zrelost područja ODZVU 6_IKT kultura

Digitalna zrelost područja ODZVU *7_IKT infrastruktura* prikazana je na *Slici 36.* Kod 15 VU (VU_2, VU_3, VU_7, VU_18, VU_19, VU_21, VU_22, VU_23, VU_24, VU_25, VU_26, VU_27, VU_28, VU_31 i VU_32) ili 46% od ukupnog broja VU područje *7_IKT infrastruktura* ima najveću digitalnu zrelost u odnosu na ostala područja ODZVU-a. Kod 82% VU područje *7_IKT infrastruktura* je unutar prva dva područja digitalne zrelosti u odnosu na ostala područja ODZVU. Kod samo jednog VU (VU_4) područje *7_IKT infrastruktura* ima najmanju digitalnu zrelost u odnosu na ostala područja ODZVU-a.

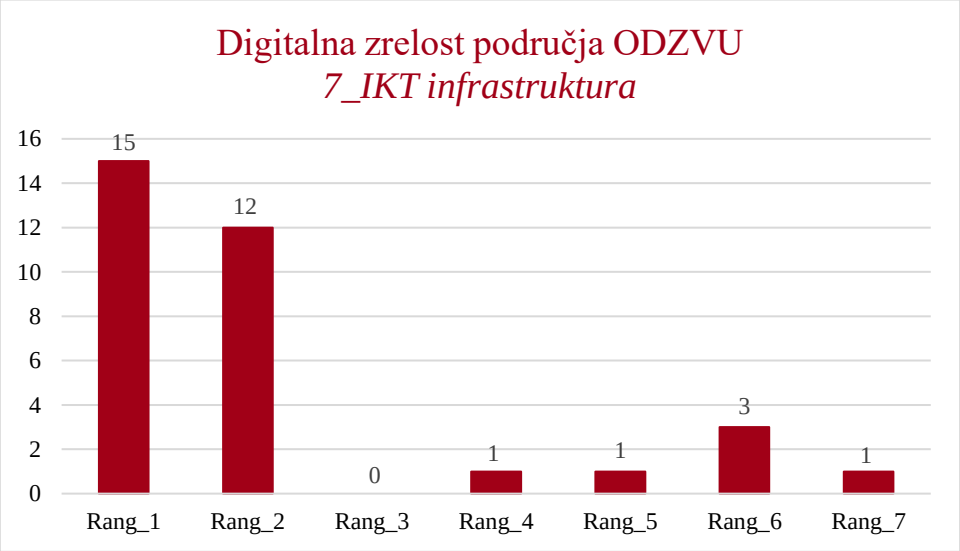

Slika 36: Digitalna zrelost područja ODZVU 7_IKT infrastruktura

Područja *7_IKT infrastruktura* i *6_IKT kultura* su područja koja imaju najveću digitalnu zrelost u odnosu na ostala područja ODZVU ako promatramo zbirno Rang_1 i Rang_2. Zatim slijede; *1_Vodstvo, planiranje i upravljanje* i *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* te *5_Učenje i poučavanje uz podršku IKT-a*. Najmanju digitalnu zrelost imaju područja *2_Osiguranje kvalitete* i *3_Znanstveno-istraživački rad uz podršku IKT-a*. Područje *2_Osiguranje kvalitete* ima i najmanju digitalnu zrelost u odnosu na ostala područja ODZVU ako promatramo zbirno Rang_6 i Rang_7.

Temeljem prikupljenih podataka samovrednovanjem i primjenom razvijene metrike za procjenu digitalne zrelosti VU izvršena je procjena razina digitalne zrelosti VU-a. Primjenom kompozitnog indeksa omogućena je usporedba ranga VU-a prema razini digitalne zrelosti i procjena digitalne zrelosti prema područjima ODZVU-a. Primjenom kvalitativnih i kvantitativnih metoda istraživanja ostvaren je cilj istraživanja **C3:** Procijeniti razinu digitalne zrelosti nekoliko visokih učilišta.

Analiza digitalne zrelosti VU prema znanstvenim područjima pokazala je da VU iz područja društvenih znanosti i tehničkih znanosti imaju najveću digitalnu zrelost u području *7_IKT infrastruktura.* Visoka učilišta iz područja prirodnih znanosti i biotehničkih znanosti imaju najveću digitalnu zrelost u područjima *6_IKT kultura* i *7_IKT infrastruktura*. Visoka učilišta iz umjetničkog područja najveću digitalnu zrelost imaju u područjima *4_Transfer tehnologije i služenje društvu uz podršku IKT-a, 6_IKT kultura* i *7_IKT infrastruktura*. Zanimljivo je da visoka učilišta iz područja biomedicine i zdravstva imaju najveću digitalnu zrelost u području *1_Vodstvo, planiranje i upravljanje*. Zajedničko svim VU osim onih iz umjetničkog područja je da najmanju digitalnu zrelost imaju u području *2_Osiguranje kvalitete* dok VU iz umjetničkog područja imaju najmanju digitalnu zrelost u području *3_Znanstveno-istraživački rad uz podršku IKT-a*. Ovo je očekivano, jer se znanstvena istraživanja rjeđe provode u umjetničkom području, nego u drugim područjima.

Okvir za digitalnu zrelost visokih učilišta i Instrument za procjenu digitalne zrelosti visokih učilišta mogu se primjenjivati na različite vrste visokih učilišta: sveučilišta (javna sveučilišta i privatna sveučilišta), veleučilišta (javna veleučilišta i privatna veleučilišta) i visoke škole (javne visoke škole i privatne visoke škole). Primjena *Okvira* i *Instrumenta* nad svima njima omogućava u teoriji rangiranje tih učilišta, ali s obzirom na njihove karakteristike to nije poželjno raditi.

Primjenom *Okvira* i *Instrumenta* visoka učilišta mogu procijeniti trenutnu razinu digitalne zrelosti po područjima i elementima definiranim u Okviru, ali isto tako primjenom Instrumenta mogu vidjeti u kojim područjima je potrebno djelovati kako bi postigli veću razinu digitalne zrelosti svojeg visokog učilišta. Okvir za digitalnu zrelost visokih učilišta sadrži identificirana i validirana područja i elemente digitalne zrelosti koji su temelj za strateško planiranje primjene digitalnih tehnologija, podizanja razine digitalne zrelosti VU-a kao i definiranja strateških ciljeva te njihove operacionalizacije koja može biti sadržana u akcijskom planu VU-a.

7. Evaluacija

Evaluacija IPDZVU-a izvršena je primjenom analize osjetljivosti preko Spearmanovog koeficijenta korelacije ranga, primjenom pouzdanosti procjene između ispitanika te izračunom postotkom suglasnosti ispitanika.

7.1. Analiza osjetljivosti preko Spearmanovog koeficijenta korelacije ranga

Spearmanov koeficijent korelacije r_s ili koeficijent ranga korelacije pokazuje u kojoj su mjeri promjene vrijednosti jedne varijable povezane s promjenama vrijednosti druge varijable [229]. Spearmanov koeficijent korelacije zasniva se na rangu podataka, a ne na vrijednosti podatka. Računa se tako da se svakom podatku u nizu odredi rang u odnosu na njegovu vrijednost na način da će podatak s najvećom vrijednošću imati rang jedan, a podatak s najmanjom vrijednošću rang n, gdje je n broj podataka. Rangovi se dodjeljuju u oba skupa podataka. Formula za izračun Spearmanovog koeficijenta korelacije je (*7.1.1*):

$$r_s = 1 - 6 \sum_{i=1}^{n} \frac{d_i^2}{n(n^2 - 1)} \qquad (7.1.1)$$

r_s - Spearmanov koeficijent korelacije

d_i - razlika između rangova prve i druge varijable razlika rangova

n - broj podataka u nizu

Interpretacija Spearmanova koeficijenta korelacije prema autoricama Prion i Hearling [230]:

• nikakva ili neznatna povezanost - od 0.00 do ±0.20

• slaba povezanost - od ±0.21 do ±0.40

• umjerena povezanost - od ±0.41 do ±0.60

• jaka povezanost - od ±0.61 do ±0.80

• vrlo jaka povezanost - od ±0.81 do ±1.00

U okviru ove doktorske disertacije ispitano je utječe li mala promjena u ulaznim podacima (+/−5% u težinskim koeficijentima područja ODZVU) na konačni poredak alternativa i koliko. Provedba analize osjetljivosti predstavlja ispitivanje osjetljivosti izlaznih varijabli - konačni poredak alternativa temeljem promjena ulaznih varijabli - težinski koeficijenti područja

ODZVU i odgovarajućih usporedbi. U primjeni analize osjetljivosti ispitano je da li mala promjena u ulaznim procjenama (težinski koeficijenti područja ODZVU) utječe na konačni poredak i prioritete alternativa i koliko. Ako male promjene ulaznih varijabli utječu na promjenu poretka alternativa (pogotovo prvo-rangirane alternative), tada tu alternativu ne bismo smjeli proglasiti odlukom bez neke dodatne analize.

U prvom koraku izračunate su vrijednosti za svaku kombinaciju promjena na ulaznim podacima: Vodstvo, planiranje i upravljanje – promjena −5% (VPU −5%), Vodstvo, planiranje i upravljanje +5% (VPU +5%), Osiguranje kvalitete −5% (OK −5%), Osiguranje kvalitete +5% (OK +5%), Znanstveno-istraživački rad uz podršku IKT-a −5% (ZIR −5%), Znanstveno-istraživački rad uz podršku IKT-a +5% (ZIR +5%), Transfer tehnologije i služenje društvu uz podršku IKT-a −5% (TT −5%), Transfer tehnologije i služenje društvu uz podršku IKT-a +5% (TT +5%), Učenje i poučavanje uz podršku IKT-a −5% (UP −5%), Učenje i poučavanje uz podršku IKT-a +5% (UP +5%), IKT kultura −5% (IKTK −5%), IKT kultura +5% (IKTK +5%), IKT infrastruktura −5% (IKTI −5%), IKT infrastruktura +5% (IKTI +5%).

U drugom koraku u izračunavanju Spearmanova koeficijenta korelacije ranga slijedilo je pridruživanje ranga originalnoj vrijednosti i to tako da se najvećoj vrijednosti pridružio rang 1, sljedećoj manjoj rang 2 sve do najmanje vrijednosti kojoj je pridružen rang 33. Na isti način, u ovom koraku, slijedilo je i pridruživanje ranga za 14 kombinacija promjena na ulaznim podacima iz prvog koraka (*Tablica 63*).

U trećem koraku izračunao se Spearmanov koeficijent korelacije ranga za svaku od 14 kombinacija parova iz *Tablice 63.*

Tablica 63: Spearmanov koeficijent korelacije ranga - rangiranje alternativa

Alternativa	Rang alternativa	VPU − 5%	VPU + 5%	OK − 5%	OK + 5%	ZIR − 5%	ZIR + 5%	TT − 5%	TT + 5%	UP − 5%	UP + 5%	IKTK − 5%	IKTK + 5%	IKTI − 5%	IKTI + 5%
VU_1	**3**	3	3	3	3	3	3	3	2	3	3	3	3	3	3
VU_2	**15**	15	15	15	16	15	16	16	15	16	15	15	15	15	15
VU_3	**22**	22	22	22	22	22	22	22	22	22	22	22	22	22	22
VU_4	**33**	33	33	33	33	33	33	33	33	33	33	33	33	33	33
VU_5	**23**	23	23	23	23	23	23	23	23	23	23	23	23	23	23
VU_6	**18**	20	18	18	20	19	18	20	18	20	17	18	20	17	20
VU_7	**12**	11	12	10	12	11	11	11	11	11	11	12	11	12	10
VU_8	**21**	21	21	21	21	21	21	21	21	21	21	21	21	21	21
VU_9	**32**	32	32	32	32	32	32	32	32	32	32	32	32	32	32
VU_10	**7**	7	9	9	7	7	9	9	7	9	7	9	9	7	9
VU_11	**27**	27	27	27	27	27	27	27	27	27	27	27	27	27	27
VU_12	**20**	19	20	20	18	20	19	18	20	19	20	19	19	19	19
VU_13	**4**	4	6	6	4	4	8	6	4	6	6	6	4	4	6
VU_14	**29**	29	29	29	29	29	29	29	29	29	29	29	29	29	29
VU_15	**19**	18	19	19	19	18	20	19	19	18	19	20	16	20	18
VU_16	**2**	2	2	2	2	2	2	2	3	2	2	2	2	2	2
VU_17	**28**	28	28	28	28	28	28	28	28	28	28	28	28	28	28
VU_18	**5**	5	4	4	5	5	4	4	5	4	4	4	5	5	4
VU_19	**5**	5	4	4	5	5	4	4	5	4	4	4	5	5	4
VU_20	**16**	16	17	16	17	17	15	17	16	15	18	16	18	16	17
VU_21	**14**	14	13	14	13	13	14	13	14	14	13	13	14	14	13
VU_22	**25**	26	25	26	24	26	25	24	26	26	24	25	25	24	26

VU_23	**30**	30	30	30	30	30	30	30	30	30	30	30	30	30	30
VU_24	**8**	8	7	7	8	8	6	8	8	7	9	7	7	8	7
VU_25	**9**	9	8	8	9	9	7	7	9	8	8	8	8	9	8
VU_26	**26**	25	26	25	26	25	26	26	25	25	26	26	26	26	25
VU_27	**17**	17	16	17	15	16	17	15	17	17	16	17	17	18	16
VU_28	**24**	24	24	24	25	24	24	25	24	24	25	24	24	25	24
VU_29	**11**	12	10	12	11	12	12	12	12	12	12	11	12	11	12
VU_30	**13**	13	14	13	14	14	13	14	13	13	14	14	13	13	14
VU_31	**31**	31	31	31	31	31	31	31	31	31	31	31	31	31	31
VU_32	**10**	10	11	11	10	10	10	10	10	10	10	10	10	10	11
VU_33	**1**	1	1	1	1	1	1	1	1	1	1	1	1	1	1

U *Tablici 64* prikazani su rezultati usporedbe Spearmanovim koeficijentom korelacije ranga za par: Rang alternativa i Ranga alternativa VPU − 5%. Na isti način izrađena je usporedba za preostalih 13 parova.

Tablica 64: Spearmanov koeficijent korelacije ranga za par: Rang alternativa i Ranga alternativa VPU -5%

Alternativa	Rangiranje alternativa	Rangiranje alternativa VPU − 5%	Razlika rangova *d*	*d*d*	Spearmanov koeficijent
VU_1	3	3	0	0	0
VU_2	15	15	0	0	0
VU_3	22	22	0	0	0
VU_4	33	33	0	0	0
VU_5	23	23	0	0	0
VU_6	18	20	− 2	4	0,00011141
VU_7	12	11	1	1	2,7852E− 05
VU_8	21	21	0	0	0
VU_9	32	32	0	0	0
VU_10	7	7	0	0	0
VU_11	27	27	0	0	0
VU_12	20	19	1	1	2,7852E− 05
VU_13	4	4	0	0	0
VU_14	29	29	0	0	0
VU_15	19	18	1	1	2,7852E− 05
VU_16	2	2	0	0	0
VU_17	28	28	0	0	0
VU_18	5	5	0	0	0
VU_19	5	5	0	0	0
VU_20	16	16	0	0	0
VU_21	14	14	0	0	0
VU_22	25	26	− 1	1	2,7852E− 05
VU_23	30	30	0	0	0
VU_24	8	8	0	0	0
VU_25	9	9	0	0	0
VU_26	26	25	1	1	2,7852E− 05
VU_27	17	17	0	0	0
VU_28	24	24	0	0	0
VU_29	11	12	− 1	1	2,7852E− 05
VU_30	13	13	0	0	0
VU_31	31	31	0	0	0
VU_32	10	10	0	0	0
VU_33	1	1	0	0	0
					0,9983

U *Tablici 65* prikazani su rezultati Spearmanovog koeficijenta korelacije ranga za svih 14 kombinacija nastalih promjenom ulaznih podataka za +/− 5%.

Tablica 65: Zbirni rezultati usporedbe Spearmanovog koeficijenta korelacije ranga

Red broj	Usporedbe ranga	Spearmanov koeficijent korelacije ranga
1	Usporedba ranga alternativa i ranga alternativa VPU -5%	0,9983
2	Usporedba ranga alternativa i ranga alternativa VPU +5%	0,9970
3	Usporedba ranga alternativa i ranga alternativa OK -5%	0,9967
4	Usporedba ranga alternativa i ranga alternativa OK +5%	0,9970
5	Usporedba ranga alternativa i ranga alternativa ZIR -5%	0,9983
6	Usporedba ranga alternativa i ranga alternativa ZIR +5%	0,9940
7	Usporedba ranga alternativa i ranga alternativa TT -5%	0,9943
8	Usporedba ranga alternativa i ranga alternativa TT +5%	0,9990
9	Usporedba ranga alternativa i ranga alternativa UP -5%	0,9960
10	Usporedba ranga alternativa i ranga alternativa UP +5%	0,9967
11	Usporedba ranga alternativa i ranga alternativa IKTK -5%	0,9973
12	Usporedba ranga alternativa i ranga alternativa IKTK +5%	0,9957
13	Usporedba ranga alternativa i ranga alternativa IKTI -5%	0,9990
14	Usporedba ranga alternativa i ranga alternativa IKTI +5%	0,9950

Vrijednosti Spearmanovog koeficijenta korelacije za svaki par kombinacija je visoka i iznosi >0.99 te možemo zaključiti da između svakog od 14 parova kombinacije postoji vrlo visoka povezanost što je prikazano u *Tablici 65*.

Provedbom analize osjetljivosti i varijacijom važnosti svih kriterija za 5% u svim kombinacijama, nije došlo do nikakve promjene u rangiranju alternativa, te zaključujemo da je dobiveni rezultat stabilan.

7.2. Pouzdanost procjene između ispitanika

Pouzdanost se odnosi na dosljednost ispitanikovih odgovora pri istovjetnom ili sličnom pitanju, a istraživači nastoje odgovoriti na pitanje mjeri li skup promatranih varijabla (čestica) isti konstrukt [231]. Pouzdanost među ocjenjivačima je stupanj u kojem se dva ili više ocjenjivača (promatrača ili ispitivača) slažu. Pouzdanost među ocjenjivačima može se ocijeniti korištenjem niza različitih statistika, npr. Cohen kappa, postotak suglasnosti, intraklasni koeficijent korelacije.

Pouzdanost procjene između procjenitelja/ocjenjivača/ispitanika je zapravo suglasnost u procjenama, a mjeri se pouzdanost procjena preko toga da se računa koliko se procjenitelji slažu u svojim procjenama ili da li procjenitelji daju slične odgovore na slična pitanja. U istraživanju u okviru ove doktorske disertacije mjeri se pouzdanost procjene između ispitanika za svaki par ispitanika sa istog VU koji su procjenjivali razine digitalne zrelosti svojeg VU u istraživanju pomoću rubrike.

7.2.1. Cohen kappa koeficijent pouzdanosti

Cohen kappa koeficijent (κ) koristi se za mjerenje pouzdanosti između ispitanika kod kvalitativnih istraživanja [232]. Cohen kappa koeficijent je robusnija mjera pouzdanosti između ispitanika od postotka suglasnosti između ispitanika jer uzima u obzir broj opcija odgovora, broj ispitanika i vjerojatnost da je neka od suglasnosti ispitanika posljedica slučajnosti. Formula za izračun Cohen kappa koeficijenta (7.2.1):

$$\kappa = \frac{p_o - p_e}{1 - p_e} \tag{7.2.1}$$

κ - Cohen kappa koeficijent

p_o - relativni uočeni dogovor među ocjenjivačima

p_e - hipotetska vjerojatnost slučajnog dogovora

Interpretacija Cohen kappa koeficijenta pouzdanosti [233]:

- nikakva pouzdanost – < 0,00
- neznatna pouzdanost – od 0,00 do 0,20
- lagana pouzdanost – od 0,21 do 0,40
- umjerena pouzdanost – od 0,41 do 0,60
- značajna pouzdanost – od 0,61 do 0,80
- vrlo visoka pouzdanost – od 0,81 do 1,00

U okviru ove doktorske disertacije ispitana je pouzdanost procjene između ispitanika, na procjenu razine zrelosti njihovog VU, izračunom Cohen kappa koeficijenta pouzdanosti za svaki par ispitanika s istog VU, odnosno po dvoje ispitanika s 33 VU. U *Tablici 66* prikazan je izračun za dvoje ispitanika s jednog VU prema izboru autorice.

Tablica 66: Cohen kappa koeficijent pouzdanosti za dvoje ispitanika

VU_33	1-Digitalno neosviješteno	2-Digitalno početno VU	3-Digitalno osnaženo VU	4-Digitalno sposobno VU	5-Digitalno zrelo VU	Ukupno
1 - Digitalno neosviješteno VU						0
2 - Digitalno početno VU						0
3 - Digitalno osnaženo VU					1	1
4 - Digitalno sposobno VU				8	1	9
5 - Digitalno zrelo VU				5	27	32
Ukupno	0	0	0	13	29	**42**
Slaganje procjenjivača	0	0	0	8	27	**35**
Pretpostavljena vjerojatnost slaganja	0,00	0,00	0,00	1,71	20,57	**22,29**
Cohen kappa	**0,6449**					

U *Tablici 67* prikazani su rezultati izračuna Cohen kappa koeficijenta pouzdanosti procjene za sve parove ispitanika, sudionika u istraživanju.

Tablica 67: Cohen kappa koeficijent pouzdanosti za sve ispitanike u istraživanju

Visoko učilište	Cohen kappa
VU_1	0,6319
VU_2	0,4983
VU_3	0,4481
VU_4	0,7432
VU_5	0,6182
VU_6	0,6557
VU_7	0,6277
VU_8	0,6351
VU_9	0,8103
VU_10	0,6216
VU_11	0,6438
VU_12	0,6354
VU_13	0,6703
VU_14	0,6241
VU_15	0,8562
VU_16	0,6420
VU_17	0,4533
VU_18	0,8519
VU_19	0,6730
VU_20	0,6889
VU_21	0,7657
VU_22	0,8906
VU_23	0,6353
VU_24	0,6758
VU_25	0,8077
VU_26	0,6513
VU_27	0,8308
VU_28	0,6109
VU_29	0,6283
VU_30	0,6202
VU_31	0,7656
VU_32	0,8660
VU_33	0,6449

Rezultati u *Tablici 67* prikazuju da je kod 7 parova ispitanika ili 21,21% od ukupnog broja ispitanika koeficijent pouzdanosti između ispitanika vrlo visok (VU_22 − 0,8906; VU_32 − 0,8660; VU_15 − 0,8562; VU_18 − 0,8519; VU_27 − 0,8308; VU_9 − 0,8103 i VU_25 − 0,8077). Nadalje, kod 23 para ispitanika ili 69,70% od ukupnog broja ispitanika koeficijent pouzdanosti između ispitanika je značajan (VU_21 − 0,7657; VU_31 − 0,7656; VU_4 − 0,7432; VU_20 − 0,6889; VU_24 − 0,6758; VU_19 − 0,6730; VU_13 − 0,6703; VU_6 − 0,6557;

VU_26 − 0,6513; VU_33 − 0,6449; VU_11 − 0,6438; VU_16 − 0,6420; VU_12 − 0,6354; VU_23 − 0,6353; VU_8 − 0,6351; VU_1 − 0,6319; VU_29 − 0,6283; VU_7 − 0,6277; VU_14 − 0,6241; VU_10 − 0,6216; VU_30 − 0,6202; VU_5 − 0,6182 i VU_28 − 0,6109). Samo kod 3 para ispitanika ili 9,09% od ukupnog broja ispitanika koeficijent pouzdanosti između ispitanika je umjeren (VU_2 − 0,4983; VU_17 − 0,4533 i VU_3 − 0,4481).

Pouzdanost ispitivača mjerena Cohen kappa koeficijentom iznosila je 0,6795 što ukazuje na značajnu pouzdanost između ispitanika.

7.2.2. Postotak suglasnosti između ispitanika

Stupanj suglasnosti ispitanika u procjene razine zrelosti za svako VU koje je predstavljalo po dvoje ispitanika, prikazan je u *Tablici 68*.

Rezultati prikazani u tablici prikazuju da kod po dvoje ispitanika s 4 VU ili kod 12% od ukupnog broja ispitanika stupanj suglasnosti oko procjene razine zrelosti iznosi više od 90,00% (VU_22 − 92,86%; VU_15 − 90,48%; VU_18 − 90,48% i VU_32 − 90,48%). Stupanj suglasnosti oko procjene razine zrelosti iznosi od 80,00% do 90,00% pri dvoje ispitanika s 8 VU ili kod 24,24% od ukupnog broja ispitanika (VU_9 − 88,10%; VU_25 − 88,10%; VU_27 − 88,10%; VU_4 − 83,33%; VU_19 − 83,33%; VU_21 − 83,33%; VU_31 − 83,33% i VU_33 − 83,33%). Stupanj suglasnosti oko procjene razine zrelosti iznosi od 70,00% do 80,00% pri dvoje ispitanika sa 17 VU ili kod 51,52% od ukupnog broja ispitanika (VU_1 − 78,57%; VU_8 − 78,57%; VU_16 − 78,57%; VU_20 − 78,57%; VU_24 − 78,57%; VU_29 − 78,57%; VU_5 − 76,19%; VU_7 − 76,19%; VU_10 − 76,19%; VU_13 − 76,19%; VU_6 − 73,81%; VU_11 − 73,81%; VU_12 − 73,81%; VU_14 − 73,81%; VU_26 − 73,81%; VU_23 − 71,43% i VU_30 − 71,43%). Stupanj suglasnosti oko procjene razine zrelosti iznosi od 60,00% do 70,00% pri dvoje ispitanika s 3 VU ili kod 9,09% od ukupnog broja ispitanika (VU_28 − 68,29%; VU_2 − 66,67% i VU_17 − 60,47%). Najmanji stupanj suglasnosti između ispitanika je samo na jednom VU ili kod 3,03% od ukupnog broja ispitanika i iznosi 52,38%.

Tablica 68: Stupanj suglasnosti ispitanika oko procjene razine zrelosti VU

Visoko učilište	Stupanj suglasnosti ispitanika oko procjene razine zrelosti
VU_1	78,57%
VU_2	66,67%
VU_3	52,38%
VU_4	83,33%
VU_5	76,19%
VU_6	73,81%
VU_7	76,19%
VU_8	78,57%
VU_9	88,10%
VU_10	76,19%
VU_11	73,81%
VU_12	73,81%
VU_13	76,19%
VU_14	73,81%
VU_15	90,48%
VU_16	78,57%
VU_17	60,47%
VU_18	90,48%
VU_19	83,33%
VU_20	78,57%
VU_21	83,33%
VU_22	92,86%
VU_23	71,43%
VU_24	78,57%
VU_25	88,10%
VU_26	73,81%
VU_27	88,10%
VU_28	68,29%
VU_29	78,57%
VU_30	71,43%
VU_31	83,33%
VU_32	90,48%
VU_33	83,33%

Evaluacija IPDZVU-a provela se na uzorku od 33 VU-a kako bi se provjerila pouzdanost IPDZVU-a. Postupak samovrednovanja je proveden od strane dva ispitanika po svakom VU. Ispitanici koji su sudjelovali u postupku samovrednovanja su isti ispitanici koji su sudjelovali u istraživanju pomoću rubrike odnosno ispitanici koji imaju iskustvo u primjeni IKT-a, iskustvo sudjelovanja ili vođenja projekta iz tog područja, iskustvo stručnog i(ili) znanstvenog bavljenja digitalnim tehnologijama te da jesu ili su bili na upravljačkim funkcijama na visokom učilištu. Pouzdanost IPDZVU-a je provjerena primjenom Spearmanovog koeficijenta korelacije ranga te izračunom pouzdanosti procjene između ispitanika, primjenom Cohen kappa koeficijenta pouzdanosti i primjenom postotka suglasnosti između ispitanika. Cilj primjene ovih metoda bila je provjera pouzdanosti IPDZVU odnosno hipoteze **H2**.

Potvrđena je hipoteza **H2**: Razvijeni instrument za mjerenje digitalne zrelosti visokih učilišta bit će pouzdan.

8. Zaključak

U zaključku će se opisati najvažniji rezultati istraživanja. Osim toga objasnit će se znanstveni doprinos istraživanja i društveni doprinos istraživanja. Naposljetku, u zaključku će se opisati ograničenja istraživanja.

a) Realizacija ciljeva istraživanja

Realizacija cilja vezanog uz razvoj okvira za digitalnu zrelost visokog učilišta

U sklopu provedenog istraživanja izvršena je analiza literature koja je uključila izvore o strateškom planiranju i odlučivanju o IKT-u u visokom obrazovanju te izvore postojećih okvira za procjenu digitalne zrelosti obrazovnih institucija. Detaljan pregled analize literature prikazan je u poglavljima: Poglavlje 2.1., Poglavlje 2.2. i Poglavlje 2.3.

Na temelju rezultata kvalitativne analize literature te korištenjem metode fokus grupa, metode Delphi i metode sortiranja karata razvijen je Okvir za digitalnu zrelost visokih učilišta koji se sastoji od 7 područja i 42 elementa. Time je realiziran prvi cilj ovog istraživanja (Poglavlje 5.1.).

Realizacija cilja vezanog uz razvoj instrumenta za procjenu digitalne zrelosti visokog učilišta

U sklopu provedenog istraživanja razvijen je Instrument za procjenu digitalne zrelosti visokih učilišta kombiniranjem različitih kvalitativnih i kvantitativnih metoda istraživanja. Te metode su: (1) metoda DEMATEL-ANP koja je korištena za izračun težinskih koeficijenata područja ODZVU-a, (2) metoda AHP koja je korištena za izračun težinskih koeficijenata elemenata ODZVU-a, (3) rubrika za definiranje opisnica pet razina zrelosti i (4) kompozitni indeks koji je korišten za agregiranje težinskih koeficijenata područja, težinskih koeficijenata elemenata i kvantitativnih vrijednosti opisnica razina zrelosti.

Dakle, primjenom kvalitativnih i kvantitativnih metoda istraživanja razvijen je instrument za procjenu digitalne zrelosti visokih učilišta. Time je realiziran drugi cilj ovog istraživanja (Poglavlje 5.2.).

Realizacija cilja vezanog uz procjenu razina digitalne zrelosti nekoliko visokih učilišta

U sklopu provedenog istraživanja temeljem prikupljenih podataka, samovrednovanjem i primjenom razvijene metrike za procjenu digitalne zrelosti VU izvršena je procjena digitalne zrelosti VU-a na 33 VU iz RH. Primjenom kompozitnog indeksa omogućena je usporedba rangova VU-a prema razini digitalne zrelosti.

Primjenom kvalitativnih i kvantitativnih metoda istraživanja izvršena je procjena razina digitalne zrelosti nekoliko VU. Time je realiziran treći cilj ovog istraživanja (Poglavlje 6.).

b) Odgovor na hipoteze istraživanja

Hipoteza H1: ***Razvijeni okvir za digitalnu zrelost visokih učilišta bit će valjan*** **se potvrđuje**

Rezultati istraživanja pokazali su da nema razlike u stavovima ispitanika o sadržaju i strukturi razvijenog Okvira za digitalnu zrelost visokih učilišta prilikom provedbe istraživanja metodom Delphi i istraživanja metodom sortiranja karata. Odnosno nakon provedbe metode Delphi, metodom sortiranja karata s nezavisnom skupinom eksperata i primjenom pokazatelja valjanosti sadržaja provjerena je valjanost područja i elemenata ODZVU-a usuglašenih kroz metodu Delphi. Istraživanja su provedena s dva različita/nezavisna skupa eksperata, predstavnika različitih visokih učilišta iz Republike Hrvatske i iz inozemstva (Poglavlje 2. i Poglavlje 5.1.).

Hipoteza H2: ***Razvijeni Instrument za mjerenje digitalne zrelosti visokih učilišta bit će pouzdan*** **se potvrđuje**

Evaluacija Instrumenta za mjerenje digitalne zrelosti visokih učilišta provela se na uzorku od 33 VU-a kako bi se provjerila njegova pouzdanost. Postupak samovrednovanja je proveden od strane dva ispitanika po svakom VU. Pouzdanost Instrumenta provjerena je primjenom Spearmanovog koeficijenta korelacije ranga te izračunom pouzdanosti procjene između ispitanika. Izračunati koeficijent korelacije ranga (Spearmanov koeficijent korelacije ranga) za svaki par kombinacija je visok i iznosi >0,99 što dovodi do zaključka da između svakog od 14 parova kombinacije postoji vrlo visoka povezanost. Provedbom analize osjetljivosti i varijacijom važnosti svih kriterija za 5% u svim kombinacijama, nije došlo do nikakve promjene u rangiranju alternativa, te zaključujemo da je dobiveni rezultat stabilan. Izračunata pouzdanost procjene ispitanika mjerena Cohen kappa koeficijentom iznosila je 0,6795 što

ukazuje na značajnu pouzdanost između ispitanika, a rezultati postotka suglasnosti između ispitanika su pokazali da kod 12% ispitanika od ukupnog broja ispitanika stupanj suglasnosti oko procjene razine zrelosti iznosi više od 90,00%, da kod 24,24% ispitanika od ukupnog broja ispitanika stupanj suglasnosti oko procjene razine zrelosti iznosi od 80,00% do 90,00% te kod 51,5% ispitanika od ukupnog broja ispitanika stupanj suglasnosti oko procjene razine zrelosti iznosi od 70,00% do 80,00%.

8.1. Znanstveni doprinos

U skladu s postavljenim ciljevima istraživanja i hipotezama u nastavku slijedi opis znanstvenog doprinosa kao rezultata ciklusa rigoroznosti znanosti o dizajniranju:

> *1. Teorija iz područja zrelosti, modela zrelosti, digitalne zrelosti, okvira za procjenu digitalne zrelosti, strateškog planiranja i odlučivanja u visokom obrazovanju*

Kvalitativna analiza literature započela je analizom literature vezanom uz odlučivanje o informacijsko-komunikacijskoj tehnologiji na visokim učilištima (Poglavlje 2.1.). Analiza je uključila pregled i sistematizaciju literature o pojmu odlučivanja (devet izvora) i vrstama poslovnih odluka te strateškom odlučivanju o informacijsko-komunikacijskoj tehnologiji na visokim učilištima (26 izvora).

U drugom koraku kvalitativna analiza literature obuhvatila je pregled i sistematizaciju literature vezanu uz digitalnu zrelost (20 izvora) i modele zrelosti. Analizirano je i sistematizirano, prema izboru autorice, šest modela postizanja zrelosti u obrazovnom sektoru.

U trećem koraku kvalitativnom analizom literature identificirana su 23 okvira za procjenu digitalne zrelosti obrazovnih institucija. Svaki od identificiranih okvira analiziran je prema sljedećim karakteristikama: postojanje pratećeg instrumenta; područja, elementi i opisnici okvira; implementirani razvojni pristupi; područja primjene i primjeri njihovih najboljih praksi. Model zrelosti potreban je kako bi se utvrdila postojeća razina zrelosti poslovnih procesa u poduzeću. Rezultati evaluacije trebali bi pomoći u daljnjem razvoju i unapređenju upravljanja procesima u organizaciji.

Procjena zrelosti kao i podizanje razina zrelosti je dugotrajan proces i zahtijeva određene napore i od strane menadžmenta i od strane ostalih dionika uključenih u proces poslovanja, ali to je

nužan uvjet za razvoj organizacije u smislu modernog pristupa upravljanja poduzećem ili institucijom. Analizom literature zaključeno je da su razvijeni modeli zrelosti u obrazovanju usmjereni na kvalitetu e-učenja i online tečajeva, kurikulum, poboljšanje obrazovnih vještina i znanja profesora, na angažman studenta prve godine te samoprocjenu obrazovnih ustanova i proces planiranja. Analizirani modeli postizanja zrelosti u obrazovnom sektoru većinom ne uključuju strateško planiranje, transfer tehnologije, osiguranje kvalitete ili znanstveno-istraživački rad u visokom obrazovanju. Kvalitativnom analizom literature zaključeno je da ne postoji sveobuhvatni koncept ispitivanja digitalne zrelosti visokih učilišta, već su postojeći okviri generički okviri ili okviri koji imaju primjenu u osnovnim i srednjim školama. Pregled postojećeg stanja koji je obuhvatio okvire digitalne zrelosti obrazovnih institucija, polazna je točka za provođenje istraživanja razvoja Okvira za digitalnu zrelost visokih učilišta i Instrumenta za procjenu digitalne zrelosti visokih učilišta.

2. Teorijski Okvir za procjenu digitalne zrelosti visokih učilišta

Eksperti koji su sudjelovali u istraživanjima u sklopu ove doktorske disertacije imali su dvostruku ekspertizu: ekspertizu upravljanja VU-om i ekspertizu bavljenja digitalnom tehnologijom u VU.

U razvoju Okvira za digitalnu zrelost visokih učilišta istraživanje se provodilo u dvije radionice fokus grupe u kojima je sudjelovalo 25 eksperata (poglavlje 5.1.1. Primjena metode fokus grupe u istraživanju). Nadalje, istraživanje se provodilo metodom Delphi u kojem je sudjelovalo 57 eksperata (poglavlje 5.1.2. Istraživanje metodom Delphi) i metodom sortiranja karata u kojem je sudjelovao 31 ekspert (poglavlje 5.1.3. Istraživanje metodom sortiranja karata). Na temelju znanja eksperata razvijen je Okvir za digitalnu zrelost visokih učilišta s identificiranih 7 područja i 42 elementa. Rezultati istraživanja pokazali su da nije došlo do razlike u stavovima ispitanika o sadržaju i strukturi razvijenog Okvira za digitalnu zrelost visokih učilišta prilikom provedbe istraživanja metodom Delphi i istraživanja metodom sortiranja karata. Odnosno nakon provedbe metode Delphi, metodom sortiranja karata s nezavisnom skupinom eksperata provjerena je valjanost područja i elemenata ODZVU-a usuglašenih kroz metodu Delphi. Primjenom ove dvije metode potvrđena je hipoteza **H1** da će razvijeni Okvir za digitalnu zrelost visokih učilišta biti valjan.

3. Razvijena metrika za određivanje važnosti područja i elemenata identificiranih kao relevantnih u određivanju digitalne zrelosti VU

U razvoju Instrumenta za procjenu digitalne zrelosti visokih učilišta također su sudjelovali eksperti sa dvostrukom ekspertizom.

U prvoj fazi razvoja metrike za procjenu razine digitalne zrelosti visokih učilišta istraživanje je provedeno primjenom kombinacije metoda AHP i ANP (DEMATEL-ANP) za izračun težinskih koeficijenata područja i težinskih koeficijenata elemenata, na temelju procjena eksperata (66 eksperata), a stabilnost dobivenih rezultata provjerena je primjenom analize osjetljivosti.

U drugoj fazi istraživanja primijenjeno je istraživanje upotrebom rubrike (sudjelovalo 66 eksperata) u kojoj su za svaki od 42 elementa ODZVU-a definirane izjave koje opisuju svaku od pet razina zrelosti (Digitalno neosviješteno VU; Digitalno početno VU; Digitalno osnaženo VU; Digitalno sposobno VU i Digitalno zrelo VU).

U trećoj fazi istraživanja integrirani su rezultati prve dvije faze preko kompozitnog indeksa koji se u ovom istraživanju koristio kako bi se izvršila usporedba ranga visokih učilišta prema razini digitalne zrelosti.

Evaluacija IPDZVU-a provela se na uzorku od 33 VU-a kako bi se provjerila pouzdanost IPDZVU-a. Postupak samovrednovanja je proveden od strane dva ispitanika po svakom VU. Ispitanici koji su sudjelovali u postupku samovrednovanja su isti ispitanici koji su sudjelovali u istraživanju pomoću rubrike odnosno ispitanici koji imaju iskustvo u primjeni IKT-a, iskustvo sudjelovanja ili vođenja projekta iz tog područja, iskustvo stručnog i(ili) znanstvenog bavljenja digitalnim tehnologijama te da jesu ili su bili na upravljačkim funkcijama na visokom učilištu. Pouzdanost IPDZVU-a je provjerena primjenom Spearmanovog koeficijenta korelacije ranga te izračunom dosljednosti procjenjivača pouzdanosti procjene između ispitanika. Primjenom ovih metoda potvrđena je hipoteza **H2** da će razvijeni instrument za mjerenje digitalne zrelosti visokih učilišta biti pouzdan.

8.2. Društveni doprinos

Društveni je doprinos u diseminaciji i korištenju Okvira za digitalnu zrelost visokih učilišta i Instrumenta za procjenu digitalne zrelosti visokih učilišta na visokim učilištima u Republici Hrvatskoj te podizanja svijesti o primjeni navedenog Okvira i Instrumenta. Njihovom primjenom visoka učilišta mogu procijeniti trenutnu razinu digitalne zrelosti po područjima i elementima definiranim u Okviru, ali isto tako primjenom Instrumenta mogu vidjeti u kojim područjima je potrebno djelovati kako bi postigli veću razinu digitalne zrelosti svojeg visokog učilišta. Okvir za digitalnu zrelost visokih učilišta sadrži identificirana i validirana područja i elemente digitalne zrelosti koji su temelj za strateško planiranje primjene digitalnih tehnologija, podizanja razine digitalne zrelosti kao i definiranja strateških ciljeva te njihove operacionalizacije koja može biti sadržana u akcijskom planu VU-a.

Završna faza u procesu znanstvenog istraživanja prema znanosti o dizajniranju je diseminacija artefakta. U toj završnoj fazi procesa odrađene su tek početne aktivnosti. Glavna diseminacijska aktivnost je publiciranje radova. U tom smislu, ovaj rad je najkompletniji diseminacijski element za Okvir za digitalnu zrelost visokog učilišta i Instrument za procjenu digitalne zrelosti visokog učilišta.

8.3. Ograničenja istraživanja

Prepoznata su sljedeća ograničenja istraživanja:

- U RH trenutno djeluje 119 visokih učilišta sa statusom ustanove. U istraživanju u sklopu ove doktorske disertacije sudjelovala su 33 visoka učilišta što je 27,7% od ukupnog broja visokih učilišta u Republici Hrvatskoj. Za potrebe daljnjih istraživanja takvo bi se istraživanje trebalo provesti u suradnji s Agencijom za znanost i visoko obrazovanje kako bi se istraživanjem obuhvatio što veći broj visokih učilišta te se utvrdile razlike, ali i napredak u odnosu na postojeće istraživanje.
- U istraživanju u sklopu ove doktorske disertacije bila su uključena po dva eksperta sa svakog od 33 visoka učilišta. Za potrebe daljnjih istraživanja potrebno je uključiti više ispitanika sa istog visokog učilišta, odnosno mogla bi se uvesti i mogućnost grupnog odlučivanja o ispunjavanju pojedinih kriterija.

- U fazi određivanja težinskih koeficijenata elemenata metodom AHP i težinskih koeficijenata područja metodom DEMATEL-ANP bilo je potrebno izdvojiti više od 90 minuta za usporedbu elemenata u parovima što smanjuje koncentraciju ispitanika.

Naposljetku, istraživanje provedeno u okviru ove doktorske disertacije rezultiralo je identifikacijom područja i elemenata koji su relevantni za digitalnu zrelost visokih učilišta, razvijena je metrika za određivanje važnosti područja i elemenata identificiranih kao relevantnih u određivanju digitalne zrelosti visokih učilišta i dizajniran je način procjene zrelosti visokih učilišta prema definiranim područjima i elementima. Po prvi puta je primijenjen model za procjenu digitalne zrelosti visokih učilišta koji se sastoji od Okvira za digitalnu zrelost visokih učilišta i Instrumenta za mjerenje digitalne zrelosti visokih učilišta. Instrument koji je razvijen sastoji se od definiranih:

- težinskih koeficijenata područja sadržanih u Okviru za digitalnu zrelost visokih učilišta,
- težinskih koeficijenata elemenata sadržanih u Okviru za digitalnu zrelost visokih učilišta,
- razina digitalne zrelosti visokih učilišta sadržanih u rubrici.

Sve navedeno je integrirano u kompozitni indeks čijom primjenom se određuje sveobuhvatna digitalna zrelost visokih učilišta.

Istraživanje provedeno u okviru ove doktorske disertacije, rezultiralo je originalnim znanstvenim doprinosom koji se sastoji u sistematizaciji okvira za digitalnu zrelost, kreiranju modela zrelosti time i povećanju znanja iz područja digitalne zrelosti; razvoju okvira za digitalnu zrelost visokih učilišta i razvoju instrumenta za mjerenje digitalne zrelosti visokih učilišta.

Popis literature

[1] Agencija za znanost i visoko obrazovanje, 'Visoka učilišta u Republici Hrvatskoj', 2022. [Online]. Available: https://www.azvo.hr/hr/visoko-obrazovanje/visoka-ucilista. [Accessed: 20-Jan-2022].

[2] S. Sarkar, 'The Role of Information and Communication Technology (ICT) in Higher Education for the 21st Century', *Sci. Probe*, vol. 1, no. 1, pp. 30–41, 2012.

[3] Ministarstvo znanosti obrazovanja i sporta, 'Strategija obrazovanja, znanosti i tehnologije', Zagreb, 2014.

[4] V. Kirinić and M. Kozina, 'Maturity Assessment of Strategy Implementation in Higher Education Institution', in *Central European Conference on Information and Intelligent Systems*, 2016, pp. 169–176.

[5] R. E. Johnson, 'Components, frameworks, patterns', *ACM SIGSOFT Softw. Eng. Notes*, vol. 22, no. 3, pp. 10–17, May 1997, doi: 10.1145/258368.258378.

[6] P. Nilsen, 'Making sense of implementation theories, models and frameworks', *Implement. Sci.*, vol. 10, no. 1, p. 53, Dec. 2015, doi: 10.1186/s13012-015-0242-0.

[7] C. Frankfort-Nachmias and D. Nachmias, *Research Methods in the Social Sciences*. London: Taylor & Francis Ltd, 1996.

[8] D. Moher, A. Liberati, J. Tetzlaff, and D. G. Altman, 'Preferred reporting items for systematic reviews and meta-analyses (PRISMA) statement and publication bias', *Int. J. Surg.*, vol. 8, no. 5, pp. 336–341, 2010, doi: 10.1016/j.jcms.2010.11.001.

[9] H. Weihrich and H. Koontz, *Menadžment*. Zagreb: MATE, 1994.

[10] P. Sikavica, B. Bebek, H. Skoko, and D. Tipurić, *Poslovno odlučivanje*. Zagreb: Informator, 1999.

[11] V. Srića, *Inventivni menadžer: putokazi za hrvatski gospodarski preporod*. Zagreb: Croman : MEP Consult, 1995.

[12] H. Weihrich and H. Koontz, *Menadžment*. Zagreb: Mate, 1998.

[13] R. L. Daft, *Organization Theory and Design*, 7th ed. Cincinnati, Ohio: South-Western College Publishing, 2001.

[14] J. L. Pierce and R. B. Dunham, *Managing*. Scott Foresman & Co, 1990.

[15] S. Petar and L. Babogredac, *Pametna odluka - vrste i tehnike poslovnog odlučivanja*. Zagreb: Školska knjiga, 2013.

[16] J. F. Yates, *Poslovno odlučivanje*. Zagreb: Mate, 2012.

[17] P. Sikavica, T. Hunjak, N. Begičević Ređep, and T. Hernaus, *Poslovno odlučivanje*. Zagreb: Školska knjiga, 2014.

[18] R. L. Daft, *Management*, 11th ed. South-Western: Cengage Learning, 2013.

[19] N. Kadoić, 'Strateško planiranje i odlučivanje u informacijskim i komunikacijskim znanostima', in *6. Kongres hrvatskih arhivista: Na pragu 3. desetljeća 21. stoljeća - inkluzivnost kao uvjet*, 2021, pp. 227–252.

[20] L. Luić, ‘Strateško planiranje i upravljanje školom’, Hrvatska akademska i istraživačka mreža – CARNET, Zagreb, 2018.

[21] B. Divjak and N. Begičević Ređep, ‘Strategic Decision Making Cycle in Higher Education: Case Study of E-learning’, in *International Conference on E-learning 2015*, 2015, pp. 19–26.

[22] A. R. Ahmad, A. Farley, and M. Farley, ‘Strategic Planning In Higher Education Institutions’, in *Proceedings International Conference of Technology Management, Business and Entrepreneurship 2012*, 2012, pp. 439–446.

[23] J. S. Taylor, M. D. L. Machado, and M. W. Peterson, ‘Leadership and strategic management: Keys to institutional priorities and planning’, *Eur. J. Educ.*, vol. 43, no. 3, pp. 369–386, 2012.

[24] F. Newman and L. Couturier, ‘Trading public good in the higher education market’, London, 2002.

[25] T. Moja, ‘Institutional challenges and implications for HEIS: Transformation, mission and vision for the 21st century’, in *Higher Education in the World 3: New Challenges and Emerging Roles for Human and Social Development*, Palgrave MacMillan, 2007.

[26] J. Kettunen, ‘A conceptual framework to help evaluate the quality of institutional performance’, *Qual. Assur. Educ.*, vol. 16, no. 4, pp. 322–332, Sep. 2008, doi: 10.1108/09684880810906472.

[27] J. U. Ahmed, K. U. Ahmed, M. A. S. Shimul, and R. Zuñiga, ‘Managing Strategies for Higher Education Institutions in the UK’, *High. Educ. Futur.*, vol. 2, no. 1, pp. 32–48, Jan. 2015, doi: 10.1177/2347631114558189.

[28] D. A. Raluca and S. V. Alecsandru, ‘Strategic planning at the level of Higher Education Institution elements used peer-review under responsibility of the 8 th International Strategic Management Conference’, *Procedia-Social Behav. Sci.*, vol. 58, pp. 1–10, 2012, doi: 10.1016/j.sbspro.2012.09.972.

[29] H. Rolfe, ‘University strategy in an age of uncertainty: The effect of higher education funding on old and new universities’, *High. Educ. Q.*, vol. 57, no. 1, pp. 24–47, Jan. 2003, doi: 10.1111/1468-2273.00233.

[30] F. Strehl, S. Reisinger, and M. Kalatschan, ‘Funding Systems and Their Effects on Higher Education Systems Country Study - Austria’, 2006.

[31] M. A. Hassanien, ‘Strategic Planning in Higher Education, a Need for Innovative Model’, *J. Educ. Soc. Behav. Sci.*, vol. 23, no. 2, pp. 1–11, 2017, doi: 10.9734/JESBS/2017/37428.

[32] R. Whittington, P. Regnér, D. Angwin, G. Johnson, and K. Scholes, *Exploring Strategy, Text and Cases*, 12th ed. Pearson Education, 2019.

[33] L. Zechlin, ‘Strategic planning in higher education’, in *International Encyclopedia of Education*, Elsevier Ltd, 2010, pp. 256–263.

[34] S. M. Savic, M. S. Stankovic, and G. L. Janackovic, ‘Hybrid Model for e-Learning Quality Evaluation’, *Int. J. Emerg. Technol. Learn.*, vol. 7, no. S1, Feb. 2012, doi: 10.3991/ijet.v7is1.1905.

[35] K. Suryadi, ‘Framework of Measuring Key Performance Indicators for Decision

Support in Higher Education Institution', *J. Appl. Sci. Res.*, vol. 2, no. 12, pp. 1689–1695, 2007.

[36] R. Wongsathan, A. Khaothawirat, and W. Khuankaew, 'The prioritization for higher education institutions performance criteria with Fuzzy Analytical Hierarchy Process', in *IEEE International Conference on Fuzzy Systems*, 2014, pp. 1395–1401, doi: 10.1109/FUZZ-IEEE.2014.6891531.

[37] N. F. Pan, 'Fuzzy AHP approach for selecting the suitable bridge construction method', *Fuzzy AHP approach Sel. suitable Bridg. Constr. method*, pp. 958–965, 2008.

[38] D. Chattrfee, 'Study of Fuzzy-Ahp Model to Search the Criterion in the Evaluation of the Best Technical Institutions: A Case Study', *Int. J. Eng. Sci. Tech*, vol. 2, no. 7, pp. 2499–2510, 2010.

[39] C. Tongchuay and P. Praneetpolgrang, 'Application of Fuzzy Logic in Knowledge Quality Assessment for Knowledge Management Systems in the Context of Institutions of Higher Education', *J. Inf. Sci. Tech., vol.*, vol. 1, pp. 43–53, 2010.

[40] V. T. Lokare and P. M. Jadhav, 'Using the AHP and TOPSIS methods for decision making in best course selection after HSC', in *2016 International Conference on Computer Communication and Informatics, ICCCI 2016*, 2016, pp. 1–6, doi: 10.1109/ICCCI.2016.7479937.

[41] A. Yıldızbaşı and B. Daneshvar Rouyendegh, 'Multi-criteria decision making approach for evaluation of the performance of computer programming languages in higher education', *Comput. Appl. Eng. Educ.*, vol. 26, no. 6, pp. 1992–2001, Nov. 2018, doi: 10.1002/cae.21961.

[42] L. D. M. Sanchez, M. F. L. Almeida, R. F. Calili, and D. R. Louzada, 'Multicriteria decision methods applied to the selection and hierarchy of campus sustainability indicators of a Higher Education Institution', *J. Phys. Conf. Ser.*, vol. 1065, 2018, doi: 10.1088/1742-6596/1065/19/192003.

[43] N. Begičević, 'Višekriterijski modeli odlučivanja u strateškom planiranju uvođenja e-učenja. Disertacija, University of Zagreb, Faculty of organization and informatics, 2008.

[44] N. Kadoić, N. Begičević Ređep, and B. Divjak, 'Structuring e-Learning Multi-Criteria Decision Making Problems', in *Proceedings of 40th Jubilee International Convention, MIPRO 2017*, 2017, pp. 811–817, doi: 10.23919/MIPRO.2017.7973514.

[45] B. Divjak, 'Challenges of Strategic Decision-Making within Higher Education and Evaluation of the Strategic Decisions', in *Central European Conference on Information and Intelligent Systems*, 2016, pp. 41–46.

[46] J. V. Carvalho, R. H. Pereira, and A. Rocha, 'Maturity models of education information systems and technologies: A systematic literature review', in *Iberian Conference on Information Systems and Technologies, CISTI*, 2018, vol. 2018-June, pp. 1–7, doi: 10.23919/CISTI.2018.8399339.

[47] S. C. Bacchini, *The Cambridge Dictionary of English Grammar*, vol. 28, no. 8. Emerald Group Publishing Limited, 2014.

[48] V. Aceituno, 'ISM3 - Information Security Management Maturity Model', Madrid, 2007.

[49] D. Proença and J. Borbinha, ‘Maturity Models for Information Systems - A State of the Art’, *Procedia Comput. Sci.*, vol. 100, pp. 1042–1049, Jan. 2016, doi: 10.1016/J.PROCS.2016.09.279.

[50] I. Pihir, K. Tomičić-Pupek, and J. Kolarić, ‘Business Process Modeling and Process Oriented Application in Implementation or Development of New Information System’, in *Economic and Social Development, 20th International Scientific Conference on Economic and Social Development*, 2017, pp. 610–619.

[51] P. B. Crosby, *Quality is Free. The Art of Making Quality Certain.* New York, USA: McGraw-Hill, New York, 1979.

[52] M. C. Paulk, B. Curtis, M. B. Chrissis, and C. V Weber, ‘The Capability Maturity Model for Software’, 1993.

[53] A. P. Goncalves Filho and P. Waterson, ‘Maturity models and safety culture: A critical review’, *Saf. Sci.*, vol. 105, pp. 192–211, Jun. 2018, doi: 10.1016/j.ssci.2018.02.017.

[54] L. Gastaldi *et al.*, ‘Measuring the maturity of business intelligence in healthcare: Supporting the development of a roadmap toward precision medicine within ISMETT hospital’, *Technol. Forecast. Soc. Change*, vol. 128, pp. 84–103, Mar. 2018, doi: 10.1016/j.techfore.2017.10.023.

[55] J. A. Vivares, W. Sarache, and J. E. Hurtado, ‘A maturity assessment model for manufacturing systems’, *J. Manuf. Technol. Manag.*, vol. 29, no. 5, pp. 746–767, Aug. 2018, doi: 10.1108/JMTM-07-2017-0142.

[56] J. Alfaro, A. Ortiz, and R. Poler, ‘Performance measurement system for business processes’, *Prod. Plan. Control*, vol. 18, no. 8, pp. 641–654, Dec. 2007, doi: 10.1080/09537280701599772.

[57] A. C. Fernandes *et al.*, ‘Towards an approach to assess Supply Chain Quality Management maturity’, in *2017 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, 2017, pp. 1445–1449, doi: 10.1109/IEEM.2017.8290132.

[58] N. González, F. Marle, and J. C. Bocquet, ‘Measuring project maturity: Example in a French automotive organization’, in *Proceedings of ICED 2007, the 16th International Conference on Engineering Design*, 2007, pp. 677–678.

[59] L. Chen and R. Nath, ‘Business analytics maturity of firms: an examination of the relationships between managerial perception of IT, business analytics maturity and success’, *Inf. Syst. Manag.*, vol. 35, no. 1, pp. 62–77, Dec. 2017, doi: 10.1080/10580530.2017.1416948.

[60] B. Lak and J. Rezaeenour, ‘Maturity assessment of social customer knowledge management (SCKM) using fuzzy expert system’, *J. Bus. Econ. Manag.*, vol. 19, no. 1, pp. 192–212, May 2018, doi: 10.3846/16111699.2018.1427620.

[61] J. Gochermann and I. Nee, ‘The Idea Maturity Model — A Dynamic Approach to Evaluate Idea Maturity’, *Int. J. Innov. Technol. Manag.*, vol. 16, no. 05, p. 1950030, Aug. 2019, doi: 10.1142/S0219877019500305.

[62] S. Geyer and B. Krumay, ‘Development of a Social Media Maturity Model -- A Grounded Theory Approach’, in *2015 48th Hawaii International Conference on System Sciences*, 2015, pp. 1859–1868, doi: 10.1109/HICSS.2015.224.

[63] M. B. Chrissis, M. Konrad, S. Shrum, and M. B. Chrissis, *CMMI for development : guidelines for process integration and product improvement*. Addison-Wesley, 2011.

[64] Project Management Institute., *Organizational project management maturity model (OPM3)*. Project Management Institute, 2013.

[65] K. El Emam, J.-N. Drouin, and W. Melo, *SPICE : the theory and practice of software process improvement and capability determination*. IEEE Computer Society Press, 1998.

[66] S. Marshall, 'Development and Evolution of an E-Learning Maturity Model', in *12th International Conference on Technology Supported Learning and Training*, 2006, pp. 291–294.

[67] K. Nelson, J. Clarke, I. Stoodley, and T. Creagh, 'Using a Capability Maturity Model to build on the generational approach to student engagement practices', *High. Educ. Res. Dev.*, vol. 34, no. 2, pp. 351–367, Mar. 2015, doi: 10.1080/07294360.2014.956694.

[68] C. L. Thong, Y. Y. Jusoh, R. Abdullah, and N. H. Alwi, 'Application of Curriculum Design Maturity Model at Private Institution of Higher Learning in Malaysia: A Case Study', Springer, Dordrecht, 2013, pp. 579–590.

[69] C.-Y. Chen, P.-C. Chen, and P.-Y. Chen, 'Teaching quality in higher education: An introductory review on a process-oriented teaching-quality model', *Total Qual. Manag. Bus. Excell.*, vol. 25, no. 1–2, pp. 36–56, Feb. 2014, doi: 10.1080/14783363.2011.637789.

[70] D. Gu, J. Chen, and W. Pu, 'Online course quality maturity model based on evening university and correspondence education(OCQMM)', in *2011 IEEE 3rd International Conference on Communication Software and Networks, ICCSN 2011*, 2011, pp. 5–9, doi: 10.1109/ICCSN.2011.6013763.

[71] M. Solar, J. Sabattin, and V. Parada, 'A Maturity Model for Assessing the Use of ICT in School Education', *Educ. Technol. Soc.*, vol. 16, no. 1, pp. 1176–3647, 2013.

[72] Ae-MoYS, 'Assessing the e-maturity of your school', 2011. [Online]. Available: http://e-mature.ea.gr/. [Accessed: 14-May-2018].

[73] E-learning Roadmap, 'The E-learning Roadmap'. [Online]. Available: https://player.slideplayer.com/19/5912446/#. [Accessed: 14-May-2018].

[74] M. Hunya, 'Self-evaluation on ICT usage at Hungarian schools', in *10th IFIP World Conference on Computer Education, WCCE 2013*, 2013, pp. 194–199.

[75] ePOBMM, 'The ePortfolios & Open Badges Maturity Matrix', 2013. [Online]. Available: http://www.eportfolio.eu/matrix. [Accessed: 14-May-2018].

[76] FCMM, 'Future classroom maturity model', 2010. [Online]. Available: http://fcl.eun.org/hr/toolset2. [Accessed: 14-May-2018].

[77] HEInnovative, 'HEInnovative', 2013. [Online]. Available: https://heinnovate.eu/. [Accessed: 14-May-2018].

[78] JISC, 'Jisc strategic ICT toolkit', 2010. [Online]. Available: https://www.jisc.ac.uk/guides/managing-course-information. [Accessed: 14-May-2018].

[79] LIKA, ‘Ledning, infrastruktur, kompetens, användning’, 2013. [Online]. Available: http://www.iktpedagogerna.se/lika-it-tempen-pa-skolan/. [Accessed: 14-May-2018].

[80] Microsoft IF&SRT, ‘Microsoft Innovation framework & self-reflection tool’, 2009. [Online]. Available: http://www.is-toolkit.com/self_reflection.html. [Accessed: 14-May-2018].

[81] NAACE SRF, ‘Naace Self-review Framework (SRF)’, 2012. [Online]. Available: https://www.naace.co.uk/si-srf.html. [Accessed: 14-May-2018].

[82] OPEKA, ‘Opeka - System Design’, 2012. [Online]. Available: http://opeka.fi/Opeka-SystemDesign-1.0.pdf. [Accessed: 14-May-2018].

[83] S. Bocconi, P. Kampylis, and Y. Punie, ‘Up-scaling creative classrooms in Europe’, Genova, Italy, 2012.

[84] SCHOOL MENTOR, ‘The Norwegian centre for ICT in education’, 2014. [Online]. Available: https://iktsenteret.no/sites/iktsenteret.no/files/ikt_ministerbrosjyre_eng.pdf. [Accessed: 14-May-2018].

[85] Venstress, ‘Scholen op de kaart’, 2008. [Online]. Available: https://www.scholenopdekaart.nl/. [Accessed: 14-May-2018].

[86] A. Ferrari, Y. Punie, and B. N. Brečko, ‘DIGCOMP: A Framework for Developing and Understanding Digital Competence in Europe’, European Union, 2013.

[87] R. Vuorikari, Y. Punie, S. Carretero, and L. Van Den Brande, ‘DigComp 2.0: The Digital Competence Framework for Citizens’, European Union, 2016.

[88] S. Carretero, R. Vuorikari, and Y. Punie, ‘DigComp 2.1: The Digital Competence Framework for Citizens with eight proficiency levels and examples of use’, 2017.

[89] P. Kampylis, Y. Punie, and J. Devine, ‘Promoting effective digital-age learning : a European framework for digitally-competent educational organisations.’, Joint Research Centre, European Union, 2015, 2015.

[90] C. Redecker, ‘European Framework for the Digital Competence of Educators DigCompEdu’, Luxembourg: Publications Office of the European Union, 2017.

[91] A. I. Santos, Y. Punie, and J. Castaño Muñoz, ‘Framework for Higher Education Institutions Opening up Education’, 2016, doi: 10.2791/293408.

[92] European Commission, ‘Self-reflection tool for digitally capable schools (SELFIE)’, EU Science Hub, 2018.

[93] N. Begičević Ređep and I. Balaban, ‘Okvir za digitalnu zrelost i procjena digitalne zrelosti škola u Hrvatskoj’, in *Proceedings of the 40th MIPRO International Convention on Computers in Education*, 2017, pp. 717–722.

[94] N. Begičević Ređep, I. Balaban, B. Žugec, M. Klačmer Čalopa, and B. Divjak, ‘Framework for Digitally Mature Schools’, in *European Distance and E-Learning Network,* 2017, pp. 360–371.

[95] I. Balaban, N. Begicevic Redjep, and M. Klacmer Calopa, ‘The Analysis of Digital Maturity of Schools in Croatia’, *Int. J. Emerg. Technol. Learn.*, vol. 13, no. 06, pp. 4–15, May 2018.

[96] HolonIQ, ‘Higher Education Digital Capability Framework’. [Online]. Available: https://www.digitalcapability.org/. [Accessed: 15-Dec-2021].

[97] V. Đurek, N. Begičević Ređep, and B. Divjak, ‘Digital Maturity Framework for Higher Education Institutions’, in *Conference Proceedings Central European Conference on Information and Intelligent Systems 2017*, 2017, pp. 99–106.

[98] T. Hines, ‘An evaluation of two qualitative methods (focus group interviews and cognitive maps) for conducting research into entrepreneurial decision making’, *Qual. Mark. Res. An Int. J.*, vol. 3, no. 1, pp. 7–16, 2000.

[99] S. Watts and P. Stenner, ‘Doing Q methodology: theory, method and interpretation’, *Qual. Res. Psychol.*, vol. 2, pp. 67–91, 2005, doi: 10.1191/1478088705qp022oa.

[100] M. J. Clayton, ‘Delphi: A Technique to Harness Expert Opinion for Critical Decision-Making Tasks in Education., Educational Psychology: An International Journal of Experimental Educational Psychology, 1997’, *Educ. Psychol. An Int. J. Exp. Educ. Psychol.*, vol. 17, no. 4, pp. 373–386, 1997.

[101] C. H. Lawshe, ‘No Title quantitative approach to content validity’, *Pers. Psychol.*, vol. 28, no. 4, pp. 563–575, 1975.

[102] L. G. Kilem, *Handbook of inter-rater reliability, 4th edition*, 4th ed. Gaithersburg, MD: Advance Analytics, LLC, 2014.

[103] A. R. Hevner, S. T. March, J. Park, and S. Ram, ‘Design science in information system research’, *Des. Sci. IS Res. MIS Q.*, vol. 28, no. 1, pp. 75–105, 2004.

[104] L. A. Knight, ‘Using rubrics to assess information literacy’, *Ref. Serv. Rev.*, vol. 34, no. 1, pp. 43–55, Jan. 2006, doi: 10.1108/00907320610640752.

[105] C. Coil, *Successful teaching in the differentiated classroom*, Pap/Com ed. Pieces of Learning: Pieces of Learning, 2007.

[106] N. Kadoić, B. Divjak, and N. Begičević Ređep, ‘Integrating the DEMATEL with the analytic network process for effective decision-making’, *Cent. Eur. J. Oper. Res.*, vol. 27, no. 3, pp. 653–678, 2019.

[107] T. L. Saaty and L. G. Vargas, *Models, Methods, Concepts & Applications of the Analytic Hierarchy Process*, vol. 175. Boston, MA: Springer US, 2012.

[108] M. Bohanec, M. Žnidaršič, V. Rajkovič, I. Bratko, and B. Zupan, ‘DEX Methodology: Three Decades of Qualitative Multi-Attribute Modeling’, *Informatica*, vol. 37, pp. 49–54, 2013.

[109] M. Asif and S. Cory, ‘A composite index for measuring performance in higher education institutions’, *Int. J. Qual. Sci.*, vol. 31, no. 9, pp. 983–1001, 2014.

[110] L. J. Bauman and E. G. Adair, ‘The Use of Ethnographic Interviewing to Inform Questionnaire Construction’, *Heal. Educ. Behav.*, vol. 19, no. 1, pp. 9–23, 1992, doi: 10.1177/109019819201900102.

[111] M. A. Masadeh, ‘Focus Group: Reviews and Practices’, *Int. J. Appl. Sci. Technol.*, vol. 2, no. 10, 2012.

[112] C. Boddy, ‘A rose by any other name may smell as sweet but “group discussion” is not another name for a “focus group” nor should it be’, *Qual. Mark. Res. An Int. J.*, vol. 8,

no. 3, pp. 248–255, Sep. 2005, doi: 10.1108/13522750510603325.

[113] S. Dawson, L. Manderson, and V. L. Tallo, *A manual for the use of focus groups*. Boston, MA, USA: International Nutrition Foundation for Developing Countries, 1993.

[114] R. A. Krueger, *Focus groups: A practical guide for applied research*, Second. Thousand Oaks, CA: Thousand Oaks, CA: Sage, 1994.

[115] D. Morgan, *Focus Groups as Qualitative Research*, Second. Newbury Park, CA: SAGE Publications, Inc., 1997.

[116] M. AGAR and J. MacDONALD, 'Focus Groups and Ethnography', *Human Organization*, vol. 54. Society for Applied Anthropology, pp. 78–86, 1995, doi: 10.2307/44126575.

[117] J. Kitzinger, 'Qualitative Research: Introducing focus groups', *BMJ*, vol. 311, no. 7000, p. 299, Jul. 1995, doi: 10.1136/bmj.311.7000.299.

[118] A. Gibbs, 'Social Research Update 19: Focus Groups', *Social Research Update*, 1997. [Online]. Available: http://sru.soc.surrey.ac.uk/SRU19.html. [Accessed: 01-Feb-2020].

[119] J. A. MacIntosh, 'Focus groups in distance nursing education', *J. Adv. Nurs.*, vol. 18, no. 12, pp. 1981–1985, 1993, doi: 10.1046/j.1365-2648.1993.18121981.x.

[120] J. D. Goss and T. R. Leinbach, 'Focus groups as alternative research practice: Experience with transmigrants in Indonesia', *Area*, vol. 28, no. 2, pp. 115–123, 1996, doi: 10.2307/20003647.

[121] J. Burgess, 'Focusing on fear', *Area*, vol. 28, no. 2, pp. 130–136, 1996.

[122] N. Dalkey and O. Helmer, 'An Experimental Application of the DELPHI Method to the Use of Experts', *Manage. Sci.*, vol. 9, no. 3, pp. 458–467, Apr. 1963, doi: 10.1287/mnsc.9.3.458.

[123] H. A. Linstone and M. Turoff, *Delphi Method: Techniques and Applications*. Addison-Wesley Educational Publishers Inc, 1975.

[124] M. R. Rogers and E. C. Lopez, 'Identifying critical cross-cultural school psychology competencies', *J. Sch. Psychol.*, vol. 40, no. 2, pp. 115–141, 2002.

[125] J. C. Norcross, R. A. Pfund, and J. O. Prochaska, 'Psychotherapy in 2022: A Delphi poll on its future', *Prof. Psychol. Res. Pract.*, vol. 44, no. 5, pp. 363–370, 2013.

[126] R. A. Green, 'The Delphi Technique in Educational Research', *SAGE Open*, vol. 4, no. 2, p. 215824401452977, Jun. 2014, doi: 10.1177/2158244014529773.

[127] A. Ali Mosa Al-araibi, M. N. bin Mahrin, and R. C. M. Yusoff, 'Technological aspect factors of E-learning readiness in higher education institutions: Delphi technique', *Educ. Inf. Technol.*, vol. 24, no. 1, pp. 567–590, 2019.

[128] S. B. Rane, Y. A. M. Narvel, and B. M. Bhandarkar, 'Developing strategies to improve agility in the project procurement management (PPM) process. Perspective of business intelligence (BI)', *Bus. Process Manag. J.*, vol. 26, no. 1, pp. 257–86, 2020.

[129] A. G. Manizade and M. M. Mason, 'Using Delphi methodology to design assessments of teachers' pedagogical content knowledge', *Educ. Stud. Math.*, vol. 76, no. 2, pp. 183–207, 2011, doi: 10.1007/s10649-010-9276-z.

[130] A. R. Scott *et al.*, ‘Constructing post-surgical discharge instructions through a Delphi consensus methodology’, *Patient Educ. Couns.*, vol. 101, no. 5, pp. 917–925, 2018.

[131] C. Hun-Hsing and C. C. Yang, ‘Applications of Web-QFD and E-Delphi method in the higher education system’, *Hum. Syst. Manag.*, vol. 23, no. 4, pp. 245–256, 2004.

[132] M. F. van der Schaaf and K. M. Stokking, ‘Construct validation of content standards for teaching’, *Scand. J. Educ. Res.*, vol. 55, no. 3, pp. 273–289, Jun. 2011, doi: 10.1080/00313831.2011.576878.

[133] F. Vio, G. Fretes, E. Montenegro, C. G. González, and J. Salinas, ‘Prevention of Children Obesity: A Nutrition Education Intervention Model on Dietary Habits in Basic Schools in Chile’, *Food Nutr. Sci.*, vol. 06, no. 13, pp. 1221–1228, 2015, doi: 10.4236/fns.2015.613128.

[134] A. Ciptono, S. Setiyono, F. Nurhidayati, and R. Vikaliana, ‘Fuzzy Delphi method in education: A mapping’, *J. Phys. Conf. Ser.*, vol. 1360, no. 1, p. 012029, Oct. 2019, doi: 10.1088/1742-6596/1360/1/012029.

[135] E. Kaynak and J. A. Macaulay, ‘The Delphi technique in the measurement of tourism market potential. The case of Nova Scotia’, *Tour. Manag.*, vol. 5, no. 2, pp. 87–101, Jun. 1984, doi: 10.1016/0261-5177(84)90056-6.

[136] G. Rowe and G. Wright, ‘The Delphi technique as a forecasting tool: Issues and analysis’, *Int. J. Forecast.*, vol. 15, no. 4, pp. 353–375, Oct. 1999, doi: 10.1016/S0169-2070(99)00018-7.

[137] S. Keeney, F. Hasson, and H. Mckenna, *The Delphi Technique in Nursing and Health Research*. Wiley-Blackwell, 2010.

[138] H. P. McKenna, ‘The Delphi technique: a worthwhile research approach for nursing?’, *J. Adv. Nurs.*, vol. 19, no. 6, pp. 1221–1225, Jun. 1994, doi: 10.1111/j.1365-2648.1994.tb01207.x.

[139] A. Habibi, A. Sarafrazi, and S. Izadyar, ‘Delphi Technique Theoretical Framework in Qualitative Research’, *Int. J. Eng. Sci.*, vol. 3, no. 4, pp. 8–13, 2014.

[140] C. Powell, ‘METHODOLOGICAL ISSUES IN NURSING RESEARCH The Delphi technique: myths and realities’, *J. Adv. Nurs.*, vol. 41, no. 4, pp. 376–382, 2003.

[141] S. J. van Zolingen and C. A. Klaassen, ‘Selection processes in a Delphi study about key qualifications in Senior Secondary Vocational Education’, *Technol. Forecast. Soc. Change*, vol. 70, no. 4, pp. 317–340, 2003, doi: 10.1016/S0040-1625(02)00202-0.

[142] R. Likert, ‘A technique for the measurement of attitudes’, *Arch. Psychol.*, vol. 22, no. 140, p. 55, 1932.

[143] B. McKeown and D. B. Thomas, *Q methodology*. SAGE Publications Inc., 2013.

[144] S. R. Brown, ‘A Primer on Q Methodology’, *Operant Subj.*, vol. 16, no. 3–4, pp. 91–138, 1993.

[145] S. R. Brown, D. W. Durning, and S. C. Selden, ‘Q methodology’, in *Handbook of research methods in public administration*, K. Yang and G. J. Miller, Eds. Taylor&Francis, New York, USA, 2008, pp. 721–763.

[146] W. Stephenson, *The study of behavior; Q-technique and its methodolog*. University of

Chicago Press, 1953.

[147] I. Goldman, ‘Q methodology as process and context in interpretivism, communication and psychoanalytic psychotherapy research.’, *Psychol. Rec.*, vol. 49, pp. 589–604, 1999.

[148] S. Ramlo, ‘Free speech on US university campuses: differentiating perspectives using Q methodology’, *Stud. High. Educ.*, pp. 1–19, 2018.

[149] H. Addams and J. L. R. Proops, *Social discourse and environmental policy : an application of Q methodology*. Edward Elgar Pub, 2001.

[150] T. Webler, S. Danielson, and S. Tuler, ‘Using Q Method to Reveal Social Perspectives in Environmental Research’, Greenfield, MA, USA, 2009.

[151] S. Watts and P. Stenner, *Doing Q Methodological Research: Theory, Method & Interpretation*. SAGE Publications, Inc., 2012.

[152] F. N. Kerlinger, ‘Q-methodology’, in *Foundations of behavioral research*, New York: Holt, Rinehart, and Winston, 1986, p. 1008.

[153] M. Popovich, N. Masse, and B. Pitts, ‘Revisiting Student Writer Apprehension: A New Interpretation of the Riffe and Stacks’s Writing Apprehension Measure’, *Operant Subj.*, vol. 26, no. 3, pp. 88–111, 2003.

[154] P. Stenner and R. Stainton-Rogers, ‘Q methodology and qualiquantology: The example of discriminating between emotions’, in *Mixing methods in psychology*, Psychology Press, 2004, p. 264.

[155] D. Spencer, *Card Sorting: Designing Usable Categories*. Brooklyn, New York: Rosenfeld Media, 2009.

[156] R. F. DeVellis, *Scale Development: Theory and Applications (Applied Social Research Methods)*, Fourth. SAGE Publications, 2016.

[157] R. K. Gable, *Instrument Development in the Affective Domain*. Amsterdam: Kluwer Nijhoff Publishing, 1986.

[158] D. Straub *et al.*, ‘Validation Guidelines for IS Positivist Research’, *Commun. Assoc. Inf. Syst.*, vol. 13, pp. 380–427, 2004, doi: 10.17705/1CAIS.01324.

[159] Y. S. Wang, ‘Assessment of learner satisfaction with asynchronous electronic learning systems’, *Inf. Manag.*, vol. 41, no. 1, pp. 75–86, Oct. 2003, doi: 10.1016/S0378-7206(03)00028-4.

[160] N. Ali, T. Alexei, and D. Whiddett, ‘A content validity study for a Knowledge Management Systems Success Model in Healthcare’, *J. Inf. Technol. Theory Appl.*, vol. 15, no. 2, pp. 21–36, 2014.

[161] S. N. Haynes and D. C. S. Richard, ‘Content Validity in Psychological Assessment: A Functional Approach to Concepts and Methods Introduction to Content Validity’, *Psychol. Assess.*, vol. 7, no. 3, pp. 238–247, 1995.

[162] M. R. Lynn, ‘Determination and quantification of content validity’, *Nurs. Res.*, vol. 35, no. 6, pp. 382–386, 1986, doi: 10.1097/00006199-198611000-00017.

[163] M. Vakil and J. N, ‘Content Validity and Reliability of the Measurement Tools in

Educational, Behavioral, and Health Sciences Research', *Vakili al J. Med. Educ. Dev.*, vol. 10, no. 28, pp. 106–119, 2018.

[164] T. L. Saaty, 'An eigen value allocation model for prioritization and planning', Philadelphia, USA, 1972.

[165] T. L. Saaty, 'A scaling method for priorities in hierarchical structures', *J. Math. Psychol.*, vol. 15, no. 3, pp. 234–281, 1977.

[166] T. L. Saaty, *The Analytic Hierarchy Process: Planning, Priority Setting, Resource Allocation (Decision Making Series)*. New York, USA: McGraw-Hill, New York, 1980.

[167] T. L. Saaty, 'Decision making with the analytic hierarchy process', *Int. J. Serv. Sci.*, vol. 1, no. 1, pp. 83–98, 2008.

[168] P. T. Harker and L. G. Vargas, 'The Theory of Ratio Scale Estimation: Saaty's Analytic Hierarchy Process', *Manage. Sci.*, vol. 33, no. 11, pp. 1383–1403, Nov. 1987, doi: 10.1287/mnsc.33.11.1383.

[169] R. Jurenka, D. Cagáňová, and D. Špirková, 'Application of AHP Method in Decision-Making Process', *EAI/Springer Innov. Commun. Comput.*, pp. 3–15, 2019, doi: 10.1007/978-3-319-76998-1_1.

[170] M. Bertolini, M. Braglia, and G. Carmignanib, 'Application of the AHP methodology in making a proposal for a public work contract', *Int. J. Proj. Manag.*, vol. 24, no. 5, pp. 422–430, 2006.

[171] K. Schmidt, I. Aumann, I. Hollander, K. Damm, and J. M. G. Von Der Schulenburg, 'Applying the Analytic Hierarchy Process in healthcare research: A systematic literature review and evaluation of reporting', *BMC Med. Inform. Decis. Mak.*, vol. 15, no. 1, pp. 1–27, Dec. 2015, doi: 10.1186/S12911-015-0234-7/PEER-REVIEW.

[172] M. C. de C. R. Ribeiroa and A. da S. Alves, 'Application of the Analytic Hierarchy Process (AHP) method with absolute measurement in a qualitative selection problem', *Syst. Manag.*, vol. 11, pp. 270–281, 2006.

[173] A. Anis and R. Islam, 'The application of analytic hierarchy process in higher-learning institutions: a literature review', *J. Int. Bus. Entrep. Dev.*, vol. 8, no. 2, p. 166, 2015, doi: 10.1504/JIBED.2015.070446.

[174] T. Hunjak, 'Višekriterijsko odlučivanje', in *Informacijska tehnologija u poslovanju*, V. Čerić and M. Varga, Eds. 2004, pp. 105–119.

[175] E. Forman and M. A. Selly, *Decision By Objectives (How to convince others that you are right)*. World Scientific, 2001.

[176] T. Hunjak and D. Jakovčević, 'Višekriterijski modeli za rangiranje i uspoređivanje banaka', *Zb. Ekon. Fak. u Zagreb.*, vol. 1, no. 1, pp. 43–60, Dec. 2003.

[177] T. L. Saaty, 'Fundamentals of the Analytic network Process', *Japan, Kobe Int. Symp. Anal. Hierarchy Process*, pp. 12–14, 1999.

[178] N. Kadoić, N. Begičević Ređep, and B. Divjak, 'Decision Making with the Analytic Network Process', in *SOR 17 Proceedings*, 2017, pp. 180–186.

[179] T. L. . Saaty, 'Online Course Materials: Decision Making in Complex Environment',

University of Pittsburgh, 2008.

[180] T. L. Saaty and L. G. Vargas, *Decision Making with the Analytic Network Process: Economic, Political, Social and Technological Applications with Benefits, Opportunities, Costs and Risks*. Springer; Softcover reprint of hardcover 1st ed. 2006 edition (December 28, 2009), 2006.

[181] T. L. Saaty and B. Cillo, *A Dictionary of Complex Decision Using the Analytic Network Process, The Encyclicon, Volume 2*, 2nd ed. Pittsburgh: RWS Publications, 2008.

[182] V. Đurek, N. Kadoić, and N. Begičević Ređep, 'Assessing the Digital Maturity Level of Higher Education Institutions', in *41st International Convention on Information and Communication Technology, Electronics and Microelectronics MIPRO 2018*, 2018, pp. 747–752.

[183] G. H. Tzeng, C. H. Chiang, and C. W. Li, 'Evaluating intertwined effects in e-learning programs: A novel hybrid MCDM model based on factor analysis and DEMATEL', *Expert Syst. Appl.*, vol. 32, no. 4, pp. 1028–1044, May 2007, doi: 10.1016/j.eswa.2006.02.004.

[184] H. Chen-Yi, C. Ke-Ting, and T. Gwo-Hshiung, 'FMCDM with Fuzzy DEMATEL Approach for Customers' Choice Behavior Model', *Int. J. Fuzzy Syst.*, vol. 9, no. 4, pp. 236–246, 2007.

[185] W.-W. Wu, 'Choosing knowledge management strategies by using a combined ANP and DEMATEL approach', *Expert Syst. Appl.*, vol. 35, pp. 828–835, 2008, doi: 10.1016/j.eswa.2007.07.025.

[186] B. Chang, C. W. Chang, and C. H. Wu, 'Fuzzy DEMATEL method for developing supplier selection criteria', *Expert Syst. Appl.*, vol. 38, no. 3, pp. 1850–1858, Mar. 2011, doi: 10.1016/j.eswa.2010.07.114.

[187] J. I. Shieh, H. H. Wu, and K. K. Huang, 'A DEMATEL method in identifying key success factors of hospital service quality', *Knowledge-Based Syst.*, vol. 23, no. 3, pp. 277–282, Apr. 2010, doi: 10.1016/j.knosys.2010.01.013.

[188] R. Linxiu and L. Changkun, 'Questionnaire survey and DEMATEL method approach for analysis the influent factors of chinese scientific Principal Investigators', *Int. J. Clin. Exp. Med.*, vol. 11, no. 2, pp. 848–855, 2018.

[189] J. Shaoa, M. Taischa, M. O. Mierb, and E. D'Avolioc, 'Application of the DEMATEL Method to Identify Relations among Barriers between Green Products and Consumers', in *Conference: 17th European Roundtable on Sustainable Consumption and Production - ERSCP 2014*, 2014, pp. 1029–1040.

[190] B. Divjak, 'Assessment of complex, non-structured mathematical problems', in *IMA International Conference on Barriers and Enablers to Learning Maths: Enhancing Learning and Teaching for All Learners*, 2015, pp. 1–8.

[191] Y. M. Reddy and H. Andrade, 'A review of rubric use in higher education', *Assessment and Evaluation in Higher Education*, vol. 35, no. 4. pp. 435–448, Jul-2010, doi: 10.1080/02602930902862859.

[192] H. Andrade and A. Valtcheva, 'Promoting Learning and Achievement Through Self-Assessment, Theory Into Practice', vol. 48, no. 1, pp. 12–19, 2009, doi:

10.1080/00405840802577544.

[193] J. S. Halonen *et al.*, ‘A Rubric for Learning, Teaching, and Assessing Scientific Inquiry in Psychology’, *Teach. Psychol.*, vol. 30, no. 3, pp. 196–208, Jul. 2003, doi: 10.1207/S15328023TOP3003_01.

[194] A. Jonsson and G. Svingby, ‘The use of scoring rubrics: Reliability, validity and educational consequences’, *Educ. Res. Rev.*, vol. 2, pp. 130–144, 2007, doi: 10.1016/j.edurev.2007.05.002.

[195] L. Bayerlein, ‘Students’ feedback preferences: how do students react to timely and automatically generated assessment feedback?’, *Assess. Eval. High. Educ.*, vol. 39, no. 8, pp. 916–931, Jan. 2014, doi: 10.1080/02602938.2013.870531.

[196] K. E. Czekanski and Z. R. Wolf, ‘Encouraging and Evaluating Class Participation’, 2013.

[197] E. Panadero, J. Alonso-Tapia, and J. A. Huertas, ‘Rubrics vs. self-assessment scripts effects on self-regulation, learning and self-efficacy in secondary education’, *Learn. Individ. Differ.*, vol. 22, no. 6, pp. 806–813, Jan. 2012, doi: 10.1016/j.lindif.2012.04.007.

[198] A. Balan, ‘Assessment for learning: A case study in mathematics education’, Malmö University, 2012.

[199] H. Andrade and Y. Du, ‘Rubric-referenced self-assessment and middle school students’ writing’, *Assess. Educ. Princ. Policy Pract.*, vol. 17, no. 2, pp. 199–214, 2010.

[200] R. Green and M. Bowser, ‘Observations from the Field’, *J. Libr. Adm.*, vol. 45, no. 1–2, pp. 185–202, Nov. 2008, doi: 10.1300/J111V45N01_10.

[201] D. Petkov and O. Petkova, ‘Development of Scoring Rubrics for IS Projects as an Assessment Tool’, *Issues Informing Sci. Inf. Technol.*, vol. 3, pp. 499–510, 2006.

[202] M. J. Mccormick, K. E. Dooley, J. R. Lindner, and R. L. Cummins, ‘Perceived growth versus actual growth in executive leadership competencies: An application of the stair-step behaviorally anchored evaluation approach’, *J. Agric. Educ.*, vol. 23, no. 2, 2007, doi: 10.5032/jae.2007.02023.

[203] E. Panadero, J. Alonso-Tapia, and E. Reche, ‘Rubrics vs. self-assessment scripts effect on self-regulation, performance and self-efficacy in pre-service teachers’, *Stud. Educ. Eval.*, vol. 39, no. 3, pp. 125–132, Sep. 2013, doi: 10.1016/J.STUEDUC.2013.04.001.

[204] P. Dawson, ‘Assessment rubrics: towards clearer and more replicable design, research and practice’, *Assess. Eval. High. Educ.*, vol. 42, no. 3, pp. 347–360, Apr. 2017, doi: 10.1080/02602938.2015.1111294.

[205] J. Taylor, ‘Improving performance indicators in higher education: The academics’ perspective’, *J. Furth. High. Educ.*, vol. 25, no. 3, pp. 379–393, 2001, doi: 10.1080/03098770120077739.

[206] M. A. Badri and M. H. Abdulla, ‘Awards of excellence in institutions of higher education: an AHP approach’, *Int. J. Educ. Manag.*, vol. 18, no. 4, pp. 224–242, Jun. 2004, doi: 10.1108/09513540410538813.

[207] R. Lukman, D. Krajnc, and P. Glavič, ‘University ranking using research, educational and environmental indicators’, *J. Clean. Prod.*, vol. 18, no. 7, pp. 619–628, May 2010,

doi: 10.1016/j.jclepro.2009.09.015.

[208] M. Asif and A. Raouf, ‘Setting the course for quality assurance in higher education’, *Qual. Quant.*, vol. 47, no. 4, pp. 2009–2024, Nov. 2013, doi: 10.1007/s11135-011-9639-2.

[209] H. Şencan and A. T. Karabulut, ‘Monitoring of educational performance indicators in higher education: A comparison of perceptions’, *Kuram ve Uygulamada Eğitim Bilim. Sci. Theory Pract.*, vol. 15, no. 2, pp. 359–376, 2015.

[210] J. You, ‘Identifying significant indicators using LMS data to predict course achievement in online learning’, *Internet High. Educ.*, pp. 23–30, 2016.

[211] E. Varouchas, M. A. Sicilia, and S. Sánchez-Alonso, ‘Towards an integrated learning analytics framework for quality perceptions in higher education: a 3-tier content, process, engagement model for key performance indicators’, *Behav. Inf. Technol.*, vol. 37, no. 10–11, pp. 1129–1141, Nov. 2018, doi: 10.1080/0144929X.2018.1495765.

[212] M. Mihelčić and M. Bohanec, ‘Approximating incompletely defined utility functions of qualitative multi-criteria modeling method DEX’, *Cent. Eur. J. Oper. Res.*, vol. 25, no. 3, pp. 627–649, Sep. 2017, doi: 10.1007/s10100-016-0451-x.

[213] R. J. A. Little and D. B. Rubin, *Statistical Analysis with Missing Data*, 2nd ed. New York: John Wiley & Sons, 2002.

[214] V. Đurek, N. Begičević Ređep, and N. Kadoić, ‘Methodology for Developing Digital Maturity Model of Higher Education Institutions’, *J. Comput.*, vol. 14, no. 4, pp. 247–256, 2018.

[215] P. Vindis, B. Mursec, and M. Lakota, ‘A multi-criteria evaluation of energy crops with DEX methodology’, in *45. Hrvatski i 5. Međunarodni simpozij agronoma*, 2010, pp. 352–356.

[216] S. Pozderec, M. Bavec, C. Rozman, J. Vinčec, and K. Pažek, ‘Multi-Criteria Assessment of Vegetable Production Business Alternatives’, *Organizacija*, vol. 48, no. 3, pp. 203–213, 2015.

[217] A. Hidayati, F. A. Juyuspan, C. Novianty, and D. S. Muhammad Bima, ‘Implementation of decision expert (DEX) in the “SALADGARDEN” application’, in *International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, 2017, vol. 2017-Decem, pp. 1–5, doi: 10.1109/EECSI.2017.8239156.

[218] M. Bohanec *et al.*, ‘A decision support system for Parkinson disease management: expert models for suggesting medication change’, *J. Decis. Syst.*, vol. 27, no. sup1, pp. 164–172, May 2018, doi: 10.1080/12460125.2018.1469320.

[219] J. Figueira, S. Greco, and M. Ehrgott, ‘Multiple criteria decision analysis : state of the art surveys’, vol. 25, no. 3, pp. 627–649, 2005.

[220] eLEMER, ‘ICT and School Development’, 2010. [Online]. Available: http://ikt.ofi.hu/english/. [Accessed: 14-May-2018].

[221] National Research Council, *Improving Measurement of Productivity in Higher Education*. Washington, DC, USA: The National Academies Press, 2012.

[222] ENQA, *Standards and Guidelines for Quality Assurance in the European Higher*

Education Area (ESG). 2015.

[223] K. Pažur Aničić, B. Divjak, and K. Arbanas, 'Preparing ICT Graduates for Real-World Challenges: Results of a Meta-Analysis', *IEEE Trans. Educ.*, vol. 60, no. 3, pp. 191–197, 2017.

[224] H. Finne, A. Day, A. Piccaluga, A. Spithoven, P. Walter, and D. Wellen, 'Report from the European Commission's Expert Group on Knowledge Transfer Indicators', 2011.

[225] Higher Education Funding Council for England, 'University Knowledge Exchange (KE) Framework: good practice in technology transfer Report to the UK higher education sector and HEFCE', 2016.

[226] T. T. Kidd and I. Chen, *Ubiquitous learning : strategies for pedagogy, course design, and technology*. Charlotte, NC, USA: Information Age Pub, 2011.

[227] B. Divjak and M. Maretić, 'Geometry for Learning Analytics', *KoG*, vol. 19., no. 19., pp. 48–56, 2015.

[228] R. C. de Loe, 'Exploring complex policy questions using the policy Delphi. A multi-round, interactive survey method', *Appl. Geogr.*, vol. 15, no. 1, pp. 53–68, Jan. 1995, doi: 10.1016/0143-6228(95)91062-3.

[229] C. Spearman, 'The Proof and Measurement of Association between Two Things', *Am. J. Psychol.*, vol. 15, no. 1, 1904, doi: 10.2307/1412159.

[230] S. Prion and K. A. Haerling, 'Making Sense of Methods and Measurement: Spearman-Rho Ranked-Order Correlation Coefficient', *Clin. Simul. Nurs.*, vol. 10, no. 10, pp. 535–536, Oct. 2014, doi: 10.1016/J.ECNS.2014.07.005.

[231] G. Milas, *Istraživačke metode u psihologiji i drugim društvenim znanostima*. Jastrebarsko: Nalada Slap, 2005.

[232] T. Stoddart, R. Abrams, E. Gasper, and D. Canaday, 'Education Concept maps as assessment in science inquiry learning-a report of methodology', *Int. J. Sci.* , vol. 22, no. 12, pp. 1221–1246, 2010, doi: 10.1080/095006900750036235.

[233] J. R. Landis and G. G. Koch, 'The Measurement of Observer Agreement for Categorical Data', *Biometrics*, vol. 33, no. 1, p. 159, Mar. 1977, doi: 10.2307/2529310.

Prilozi

Prilog 1. Istraživanje metodom Delphi - upitnik

Okvir za digitalnu zrelost visokih učilišta

Područje	Elementi	U kojoj mjeri se slažete da je element bitan za digitalnu zrelost visokih učilišta? (obavezno odgovoriti - padajući izbornik)	U kojoj mjeri se slažete da je element smješten u ispravno područje (primjerice element *Strateško planiranje integracije IKT-a VU* u područje *Vodstvo, planiranje i upravljanje)*? (obavezno odgovoriti - padajući izbornik)	Komentari (neobavezno)
Vodstvo, planiranje i upravljanje	Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama			
	Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima			
	Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU			
	Planiranje usavršavanja zaposlenika VU u području primjene IKT-a			
	Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima			
	Upravljanje integracijom IKT-a u učenje i poučavanje na VU			
	Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU			

Osiguranje kvalitete	Politika osiguranja kvalitete primjene IKT-a na VU			
	Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a			
	Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU			
	Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU			
	Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a			
	Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a			
Znanstveno-istraživački rad uz podršku IKT-a	Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova			
	Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu			
	Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima			
	Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja			
	Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu			
	Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a			

Transfer tehnologije i služenje društvu uz podršku IKT-a	Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda			
	Suradnja VU s dionicima društva uz potporu IKT-a			
	Umreženost istraživača i korisnika istraživanja uz potporu IKT-a			
Učenje i poučavanje uz podršku IKT-a	Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU			
	Razvoj digitalnih kompetencija studenata			
	Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a			
	Dostupan repozitorij digitalnih obrazovnih sadržaja			
	Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika			
	Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata			
	Upotreba analitika učenja u unapređenju učenja i poučavanja			
	Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju			
IKT kultura	Samopouzdanje i motivacija djelatnika za primjenu IKT-a			
	Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata			
	Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata			

	Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa			
	Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a			
IKT infrastruktura	Planiranje i nabava IKT infrastrukture			
	Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU			
	Raspoloživost IKT resursa za znanstveno-istraživački rad			
	Raspoloživost IKT resursa za potporne službe			
	Pristup IKT resursima za studente u nastavi i van nastave			
	Tehnička potpora i održavanje IKT resursa na VU			
	Sustav informacijske sigurnosti na VU			

Skup pojedinačnih pitanja o ispitaniku		Odgovor (obavezno odgovoriti - padajući izbornik)	Objašnjenje odgovora (neobavezno)
1	Navedite svoj stupanj obrazovanja.		
2	Da li imate iskustva upravljanjem visokim učilištem (na razini uprave, zavoda, katedre, laboratorija i dr.)?		
3	Koja je Vaša trenutna pozicija?		
4	Koje je vaše znanstveno-nastavno, nastavno ili suradničko zvanje?		

Prilog 2. Istraživanje metodom sortiranja karata

Okvir za digitalnu zrelost visokih učilišta

Elementi	Prema Vašoj procjeni, kojem od sedam predloženih područja Okvira za digitalnu zrelost visokih učilišta pripada pojedini element? (obavezno odgovoriti - padajući izbornik)	Komentari (neobavezno)
Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama		
Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima		
Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU		
Planiranje usavršavanja zaposlenika VU u području primjene IKT-a		
Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima		
Upravljanje integracijom IKT-a u učenje i poučavanje na VU		
Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU		
Politika osiguranja kvalitete primjene IKT-a na VU		
Usvojene procedure praćenja napredovanja studenata kroz studij uz podršku IKT-a		
Kontinuirano praćenje rezultata primjene IKT-a u znanstveno-nastavnom radu u svrhu osiguranja kvalitete VU		
Kontinuirano praćenje primjene IKT resursa u svrhu osiguranja kvalitete VU		
Praćenje i periodička revizija kvalitete studijskih programa s aspekta primjene IKT-a		
Vrednovanje kvalitete rada zaposlenika VU s aspekta integracije IKT-a		

Upotreba IKT-a u pripremi i objavi znanstveno-istraživačkih radova		
Sustav potpore istraživačima na početku karijere u primjeni IKT-a u znanstveno-istraživačkom radu		
Podrška IKT-a u upravljanju znanstveno-istraživačkim radom i projektima		
Podrška VU u stvaranju partnerstva za provođenje zajedničkih IKT istraživanja		
Kontinuirano usavršavanje istraživača u primjeni IKT-a u znanstveno-istraživačkom radu		
Umreženost i suradnja istraživača u znanstveno-istraživačkom radu uz podršku IKT-a		
Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda		
Suradnja VU s dionicima društva uz potporu IKT-a		
Umreženost istraživača i korisnika istraživanja uz potporu IKT-a		
Razvoj digitalnih kompetencija i poticanje inovativnih metoda učenja i poučavanja kod nastavnika VU		
Razvoj digitalnih kompetencija studenata		
Sveprisutno učenje i otvoreni kurikulum uz primjenu IKT-a		
Dostupan repozitorij digitalnih obrazovnih sadržaja		
Izrada, pohrana i upotreba digitalnih sadržaja od strane nastavnika		
Izrada, pohrana i upotreba digitalnih sadržaja od strane studenata		
Upotreba analitika učenja u unapređenju učenja i poučavanja		
Personalizacija i potpora podzastupljenim skupinama primjenom IKT-a u učenju i poučavanju		
Samopouzdanje i motivacija djelatnika za primjenu IKT-a		

Mrežna prisutnost VU kao sastavni dio IKT kulture nastavnika i studenata		
Upotreba online sustava komunikacije, informiranja i izvještavanja nastavnika i studenata		
Primjena smjernica i preporuka za regulirani pristup i sigurnu primjenu IKT resursa		
Primjena etičkih standarda, opće uredbe o zaštiti podataka (GDPR), autorskih prava i intelektualnog vlasništva u području IKT-a		
Planiranje i nabava IKT infrastrukture		
Raspoloživa IKT infrastruktura VU omogućava ostvarenje ciljeva VU		
Raspoloživost IKT resursa za znanstveno-istraživački rad		
Raspoloživost IKT resursa za potporne službe		
Pristup IKT resursima za studente u nastavi i van nastave		
Tehnička potpora i održavanje IKT resursa na VU		
Sustav informacijske sigurnosti na VU		

Skup pojedinačnih pitanja: Pomoću sljedećih pitanja, namjera je dobiti više vrijednih informacija koje Vas čine potpuno kompetentnima za donošenje potrebnih procjena/prosudbi vezanih uz predmet istraživanja.	**Odgovor (obavezno odgovoriti - padajući izbornik)**
Navedite svoj stupanj obrazovanja.	
Da li imate iskustva upravljanjem visokim učilištem (na razini uprave, katedre i dr.)?	
Koja je Vaša trenutna pozicija?	
Koje je vaše znanstveno-nastavno, nastavno ili suradničko zvanje?	
Primjenjujete li digitalnu tehnologiju u svom radu?	

Prilog 3. Istraživanje metodom DEMATEL

Područja Okvir za digitalnu zrelost visokih učilišta

U svakom retku tablice na ljestvici 0-4 procijenite utjecaje među područjima u **Okviru za digitalnu zrelost visokih učilišta (ODZVU)**.

0 - NEMA UTJECAJA (NO INFLUENCE) 1 - NISKI UTJECAJ (LOW) 2 - SREDNJI UTJECAJ (MEDIUM) 3 - JAK UTJECAJ (STRONG) 4 - VRLO JAK UTJECAJ (VERY STRONG)	**1 Vodstvo, planiranje i upravljanje**	**2 Osiguranje kvalitete**	**3 Znanstveno - istraživački rad uz podršku IKT-a**	**4 Transfer tehnologije i služenje društvu uz podršku IKT-a**	**5 Učenje i poučavanje uz podršku IKT-a**	**6 IKT kultura**	**7 IKT infrastruktura**
1 Vodstvo, planiranje i upravljanje	0						
2 Osiguranje kvalitete		0					
3 Znanstveno-istraživački rad uz podršku IKT-a			0				
4 Transfer tehnologije i služenje društvu uz podršku IKT-a				0			
5 Učenje i poučavanje uz podršku IKT-a					0		
6 IKT kultura						0	
7 IKT infrastruktura							0

Prilog 4. Istraživanje metodom AHP – primjer za područje *Vodstvo planiranje i upravljanje*

UPUTE
Uspoređivanje u parovima kao metoda koristi Saatyjevu skalu relativne važnosti. Sadrži 9 stupnjeva. Stupnjem na Saatyjevoj skali opisujemo odnos između 2 elementa. Ako su dva elementa jednako važna s obzirom, na Saatyjevoj skali taj odnos opisujemo brojkom 1. Ostale vrijednosti ukazuju na dominaciju jednog elementa nad drugim i ovisno o tome koliko je ta dominacija jaka koristimo brojeve 3- slaba dominacija, 5- jaka dominacija, 7- dokazana dominacija i 9- apsolutna dominacija. Također, mogu se koristiti i međuvrijednosti 2, 4, 6, 8. **U svakom retku usporedbe stavite "x" na odgovarajuće mjesto, sukladno Vašoj procjeni važnosti pojedinog elementa iz para koji se uspoređuje.** **VAŽNO! Ako je element 1 važniji od elementa 2, a element 2 važniji od elementa 3, tada i element 1 mora biti važniji od elementa 3. (Tranzitivnost na Saatyjevoj skali)** Vođenje računa o tranzitivnosti je jako bitno. Ukoliko se tranzitivnost naruši, usporedbe nisu konzistentne i ne smatraju se valjanima. Postoji mjera CR (omjer konzistencije) koji opisuje koliko je narušeno pravilo tranzitivnosti u matrici usporedbe. CR ne smije biti veći od 0.1. U ćeliji CR možemo u realnom vremenu pratiti konzistentnost usporedbi. Nakon što napravite sve usporedbe u parovima, uvjerite se da je CR<0.1. Ukoliko je potrebno, revidirajte svoje usporedbe. Također, u stupcu "Prioriteti" možete pratiti u realnom vremenu konačne prioritete elemenata koje uspoređujete. Na kraju postupka uspoređivanja, potvrdite da su poredak elemenata i prioriteti Vama prihvatljivi.

Elementi područja Vodstvo, planiranje i upravljanje	**Prioriteti**	CR
1. Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	**0,1429**	**-0,7576**
2. Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	**0,1429**	
3. Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	**0,1429**	CR<0.1
4. Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	**0,1429**	
5. Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	**0,1429**	
6. Upravljanje integracijom IKT-a u učenje i poučavanje na VU	**0,1429**	
7. Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU	**0,1429**	

1. Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	2. Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima
1. Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	3. Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU
1. Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	4. Planiranje usavršavanja zaposlenika VU u području primjene IKT-a
1. Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	5. Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima
1. Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	6. Upravljanje integracijom IKT-a u učenje i poučavanje na VU
1. Strateško planiranje integracije IKT-a VU u skladu s nacionalnim smjernicama	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	7. Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU
2. Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	3. Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU
2. Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	4. Planiranje usavršavanja zaposlenika VU u području primjene IKT-a
2. Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	5. Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima
2. Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	6. Upravljanje integracijom IKT-a u učenje i poučavanje na VU
2. Donesena strategija integracije IKT-a VU usklađena s IKT globalnim trendovima	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	7. Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU
3. Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	4. Planiranje usavršavanja zaposlenika VU u području primjene IKT-a
3. Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	5. Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima
3. Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	6. Upravljanje integracijom IKT-a u učenje i poučavanje na VU

3. Planiranje, praćenje i evaluacija financijskog ulaganja u IKT na VU	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	7. Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU
4. Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	5. Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima
4. Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	6. Upravljanje integracijom IKT-a u učenje i poučavanje na VU
4. Planiranje usavršavanja zaposlenika VU u području primjene IKT-a	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	7. Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU
5. Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	6. Upravljanje integracijom IKT-a u učenje i poučavanje na VU
5. Upravljanje poslovanjem VU uz podršku IKT-a i informacijskog sustava za potporu poslovnim procesima	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	7. Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU
6. Upravljanje integracijom IKT-a u učenje i poučavanje na VU	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	7. Upravljanje integracijom IKT-a u znanstveno-istraživački rad na VU

Prilog 5. Istraživanje upotrebom rubrike – primjer za područje *Transfer tehnologije i služenje društvu uz podršku IKT-a*

Ispitanici u istraživanju su na svakom od 7 radnih listova (svako područje na posebnom radnom listu u alatu MS Excel) u stupcu H iz padajućeg izbornika trebali odrediti razinu zrelosti pojedinog elementa na skali od 1-5, (1-Digitalno neosviješteno VU, 2-Digitalno početno VU, 3-Digitalno osnaženo VU, 4-Digitalno sposobno VU i 5-Digitalno zrelo VU) za koju su smatrali da odgovara razini zrelosti na njihovom visokom učilištu.

A	B	C	D	E	F	G	H
Područje	**Elementi**	**Digitalno neosviješteno**	**Digitalno početno**	**Digitalno osnaženo**	**Digitalno sposobno**	**Digitalno zrelo**	**Razina zrelosti VU**
Transfer tehnologije i služenje društvu uz podršku IKT-a	Primijenjena istraživanja uz primjenu IKT-a u svrhu razvoja nove tehnologije ili proizvoda	Visoko učilište (VU) ne potiče i ne usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a.	Visoko učilište (VU) djelomično potiče ali ne usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a.	Visoko učilište (VU) djelomično potiče i usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a.	Visoko učilište (VU) potiče i usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a s ciljem unapređenja razvoja i inovacija.	Visoko učilište (VU) potiče i usmjerava zaposlenike i studente na primijenjena istraživanja i stručne projekte uz podršku IKT-a i/ili u području IKT-a s ciljem unapređenja razvoja i inovacija, suradnje između gospodarstva i znanstveno-istraživačkog sektora te aktivnosti razvoja i transfera tehnologija.	
	Suradnja VU s dionicima društva uz	Visoko učilište (VU) ne zalaže se za suradnju s dionicima društva (poslodavci, lokalna zajednica,	Visoko učilište (VU) ne zalaže se za suradnju s dionicima društva (poslodavci, lokalna zajednica,	Visoko učilište (VU) djelomično se zalaže za suradnju s dionicima (poslodavci,	Visoko učilište (VU) potiče i usmjerava zaposlenike i studente na	Visoko učilište (VU) potiče i usmjerava zaposlenike i studente na	

	potporu IKT-a	pred-tercijarno obrazovanje).	pred-tercijarno obrazovanje) uz potporu IKT-a.	lokalna zajednica, pred-tercijarno obrazovanje) uz potporu IKT-a.	suradnju uz potporu IKT-a s poslodavcima, lokalnom zajednicom i sektorom pred-tercijarnog obrazovanja u svrhu savjetovanja.	suradnju uz potporu IKT-a s poslodavcima, lokalnom zajednicom i sektorom pred-tercijarnog obrazovanja (lice u lice, online ili kombinacija jednog i drugog) u svrhu savjetovanja ili buduće suradnje.	
	Umreženost istraživača i korisnika istraživanja uz potporu IKT-a	Visoko učilište (VU) ne zalaže se za suradnju i razmjenu znanja istraživača i korisnika istraživanja.	Visoko učilište (VU) djelomično se zalaže za suradnju, ali ne i razmjenu znanja istraživača i korisnika istraživanja uz potporu IKT-a.	Visoko učilište (VU) djelomično se zalaže za suradnju i razmjenu znanja istraživača i korisnika istraživanja uz potporu IKT-a.	Visoko učilište (VU) se zalaže za suradnju i razmjenu znanja istraživača putem umreženosti istraživača i korisnika istraživanja (dionika) uz potporu IKT-a putem partnerstva s drugim obrazovnim institucijama.	Visoko učilište (VU) se zalaže za suradnju i razmjenu znanja uz potporu IKT-a putem partnerstva s drugim obrazovnim institucijama, privatnim i javnim sektorom te širom zajednicom kao korisnicima istraživanja.	

Prilog 6. Digitalna zrelost VU

Digitalna zrelost VU_1 prikazana je na *Slici 6.1*. VU_1 je digitalno zrelo u tri područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*, *7_IKT infrastruktura* te *6_IKT kultura*. Područja *2_Osiguranje kvalitete* i *3_Znanstveno-istraživački rad uz podršku IKT-a* područja su kod kojih je potrebno tek malo unaprijediti kako bi bila digitalno zrela. Zanimljivo je da su područja *5_Učenje i poučavanje uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje* najmanje zrela za promatrano VU te je potrebno kroz niz aktivnosti ova dva područja podići na veću razinu zrelosti.

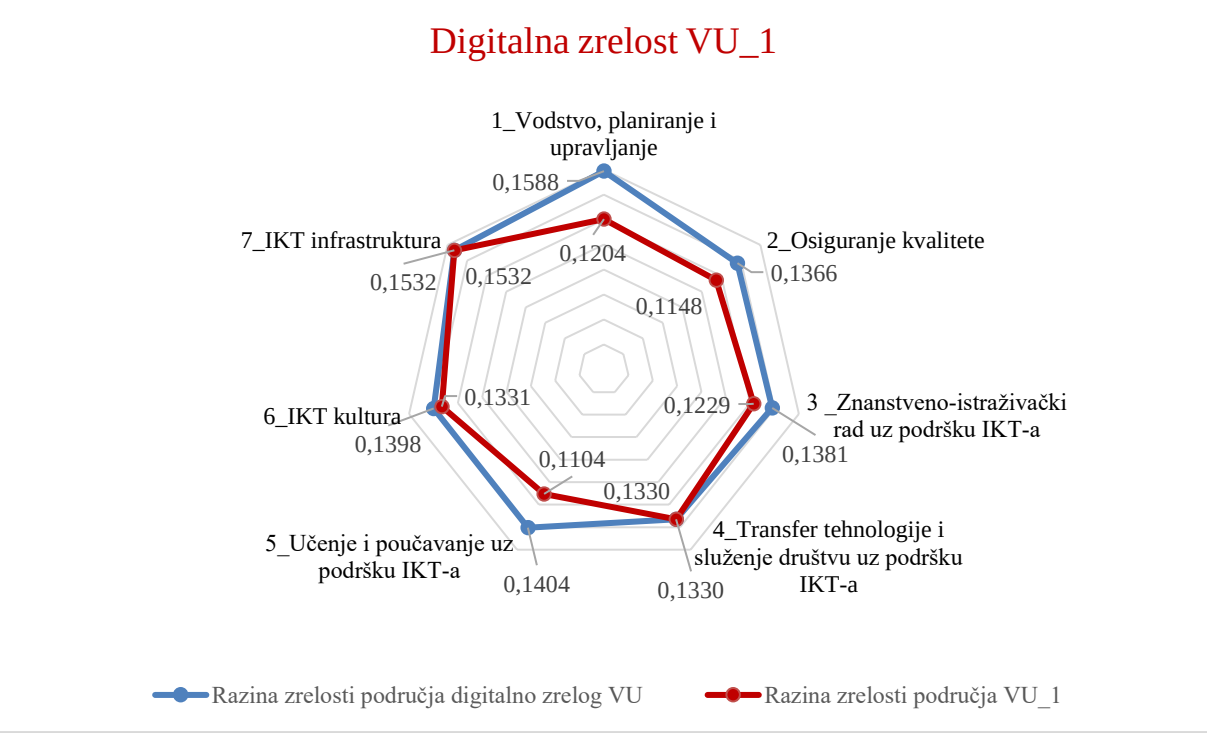

Slika 6.1: Digitalna zrelost VU_1

Digitalna zrelost VU_2 prikazana je na *Slici 6.2*. VU_2 najveću digitalnu zrelost ima u području *7_IKT infrastruktura*, zatim slijede područja *3_Znanstveno-istraživački rad uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje*. Područja *6_IKT kultura*, *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a* područja su koja je potrebno unaprijediti, ali ne odskaču znatno u odnosu na prethodna dva. Područje koje ima najmanju digitalnu zrelost je područje *2_Osiguranje kvalitete* koje potrebno znatno unaprijediti kako bi postiglo veću razinu digitalne zrelosti.

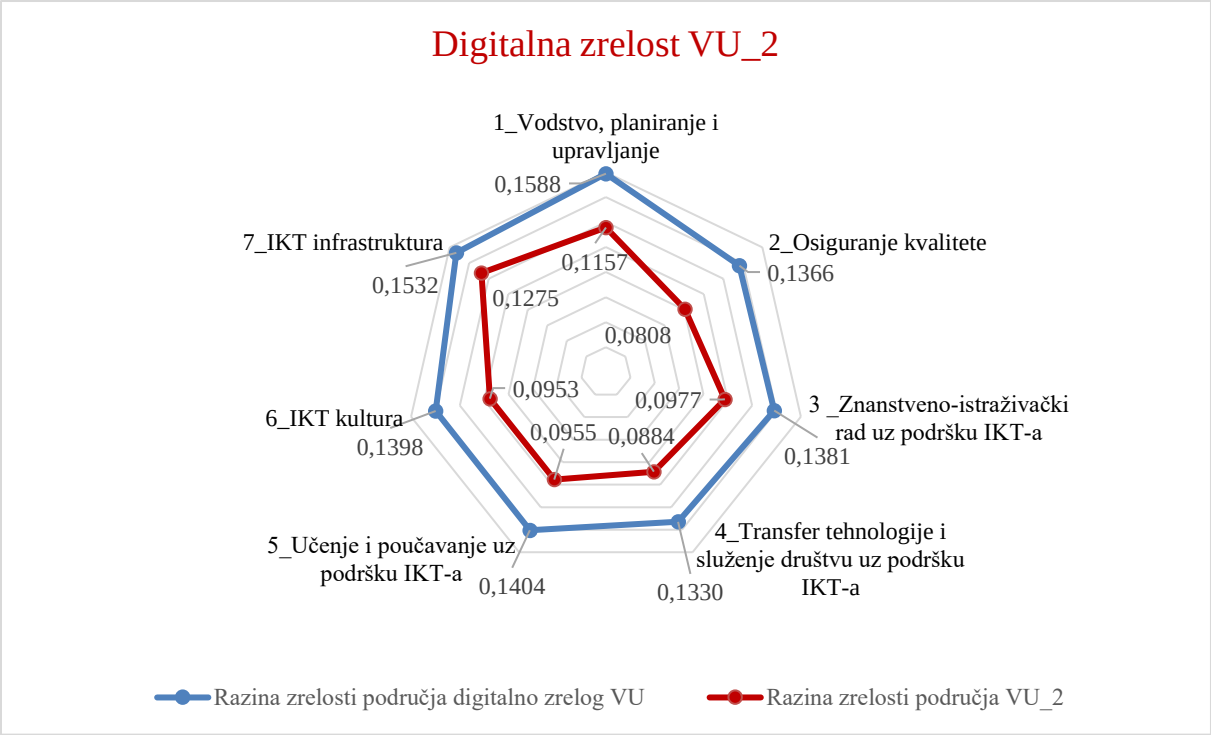

Slika *6.2*: Digitalna zrelost VU_2

Digitalna zrelost VU_3 prikazana je na *Slici 6.3*. VU_3 najveću digitalnu zrelost ima u području *7_IKT infrastruktura*, zatim slijede područja *6_IKT kultura* i *3_Znanstveno-istraživački rad uz podršku IKT-a*. Područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje*. Područje *2_Osiguranje kvalitete* ima drugu najmanju digitalnu zrelost u promatranom VU. Zanimljivo je da područje *5_Učenje i poučavanje uz podršku IKT-a* ima najmanju digitalnu zrelosti. Sva područja je potrebno unaprijediti kako bi se postigla veća razina zrelosti VU s posebnim naglaskom na unapređenju područja koja imaju najmanju digitalnu zrelost.

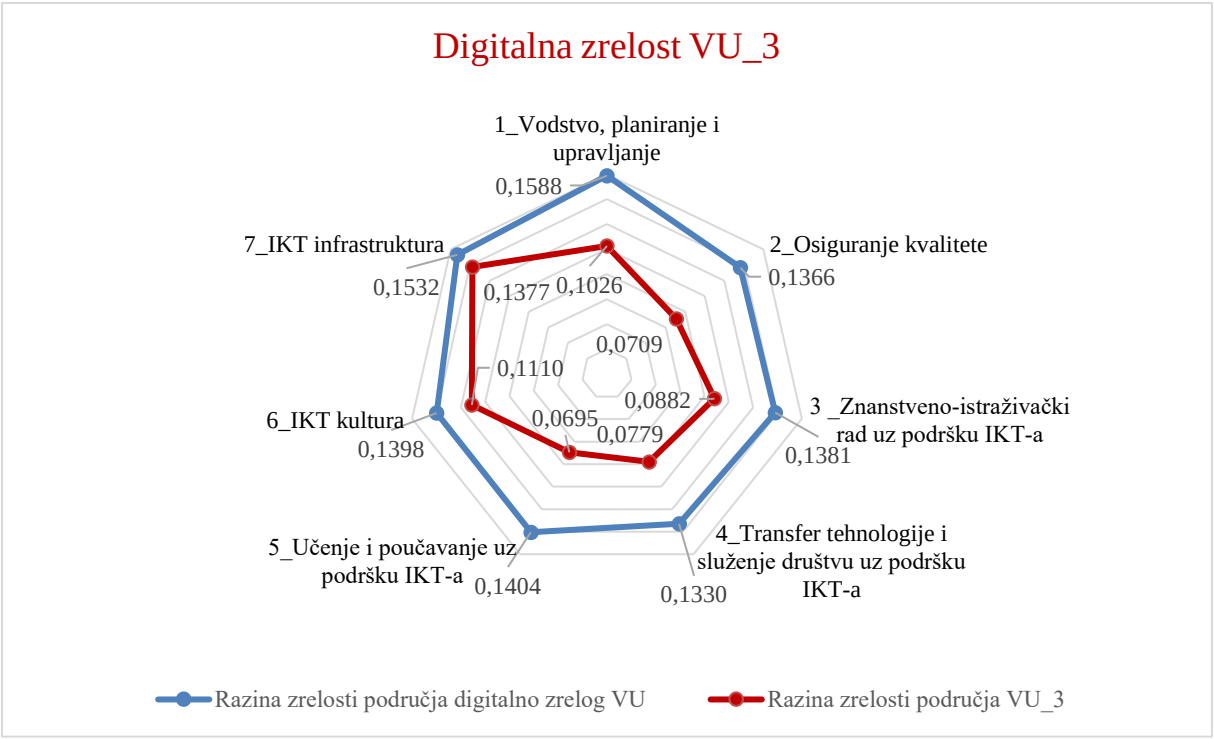

Slika 6.3: Digitalna zrelost VU_3

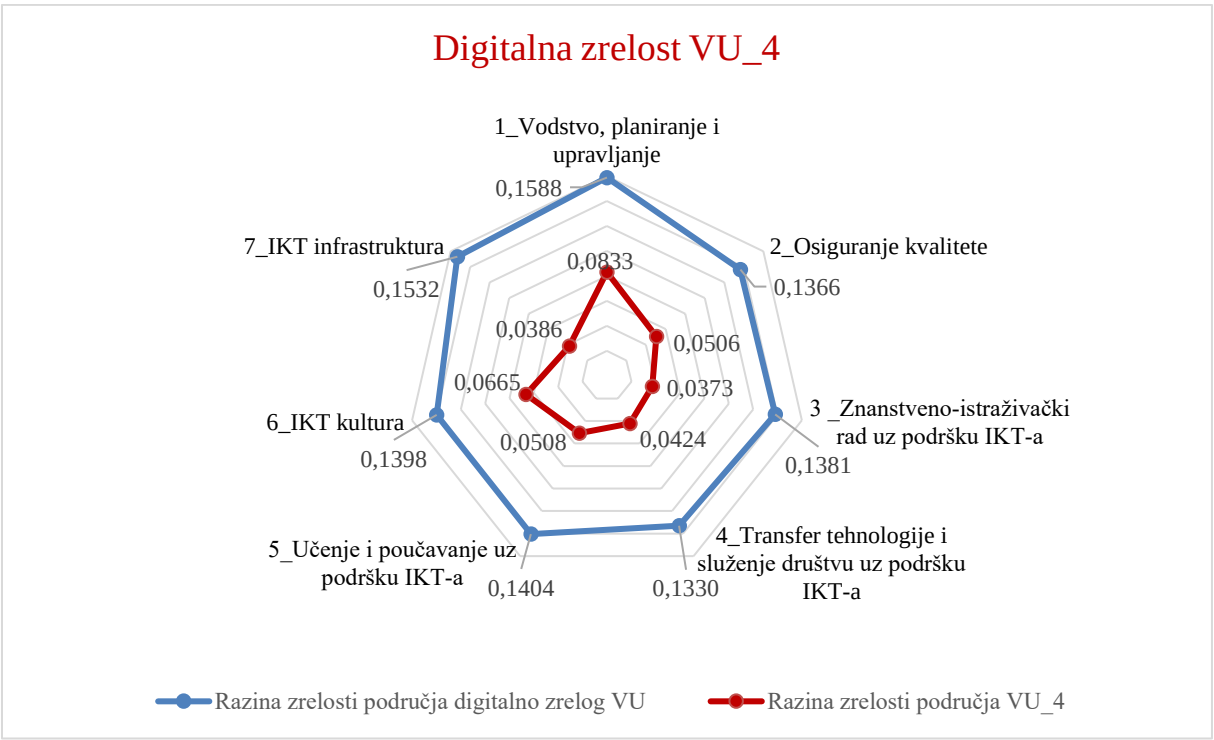

Slika 6.4: Digitalna zrelost VU_4

Digitalna zrelost VU_4 prikazana je na *Slici 6.4*. VU_4 najveću digitalnu zrelost ima u područjima *6_IKT kultura* i *1_Vodstvo, planiranje i upravljanje*. U svim područjima (uključujući i navedena dva koja imaju najveću digitalnu zrelost) potrebno je provesti mnogo aktivnosti kako bi se unaprijedila digitalna zrelost pojedinog područja, a samim time i digitalna zrelost VU.

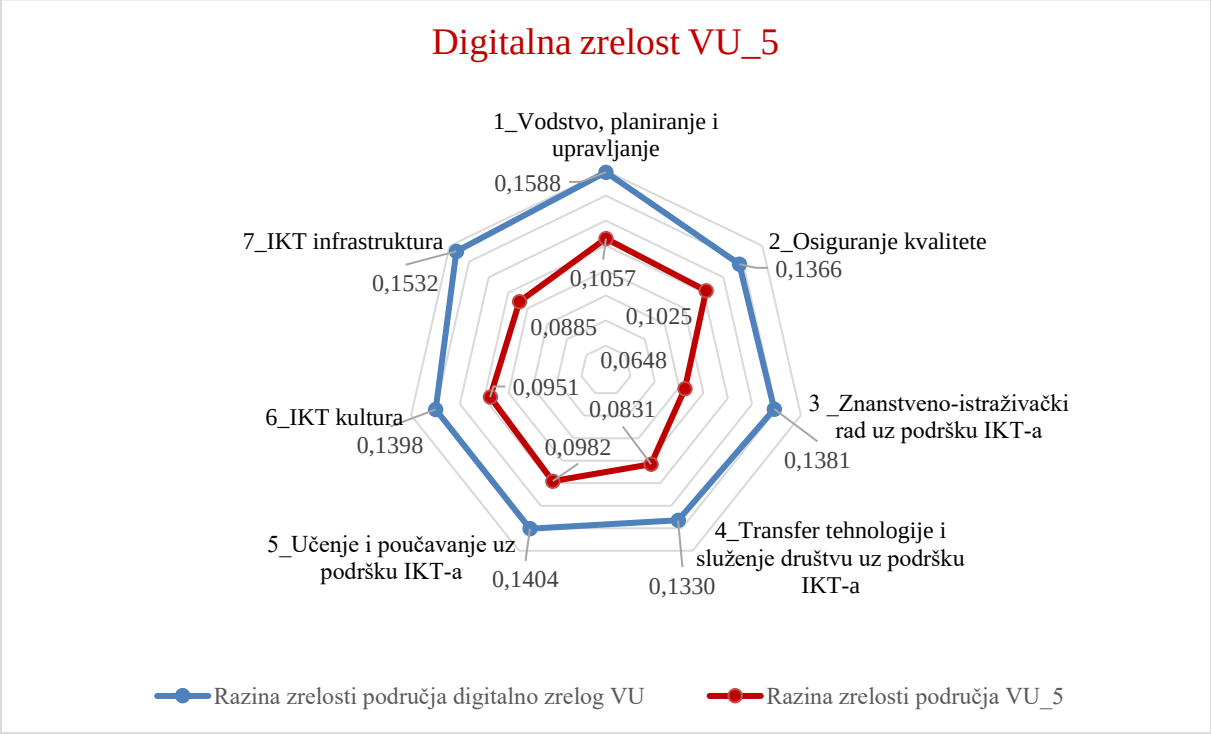

Slika 6.5: Digitalna zrelost VU_5

Digitalna zrelost VU_5 prikazana je na *Slici 6.5*. VU_5 najveću digitalnu zrelost ima u područjima *2_Osiguranje kvalitete* i *5_Učenje i poučavanje uz podršku IKT-a*. Zatim slijede područja *6_IKT kultura*, *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje* s nešto manjom razinom zrelosti. Zanimljivo je da najmanju digitalnu zrelost imaju područja *7_IKT infrastruktura* i *3_Znanstveno-istraživački rad uz podršku IKT-a*. U svim područjima je potrebno provesti niz aktivnosti kako bi se razina digitalne zrelosti VU povećala.

Digitalna zrelost VU_6 prikazana je na *Slici 6.6*. VU_6 najveću digitalnu zrelost ima u područjima *5_Učenje i poučavanje uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje*. Zatim slijede područja *6_IKT kultura*, *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *3_Znanstveno-istraživački rad uz podršku IKT-a* s nešto manjom razinom zrelosti. Zanimljivo je da najmanju digitalnu zrelost imaju područja *7_IKT infrastruktura* i *2_Osiguranje kvalitete*. U svim područjima je potrebno provesti niz aktivnosti kako bi se razina digitalne zrelosti VU povećala.

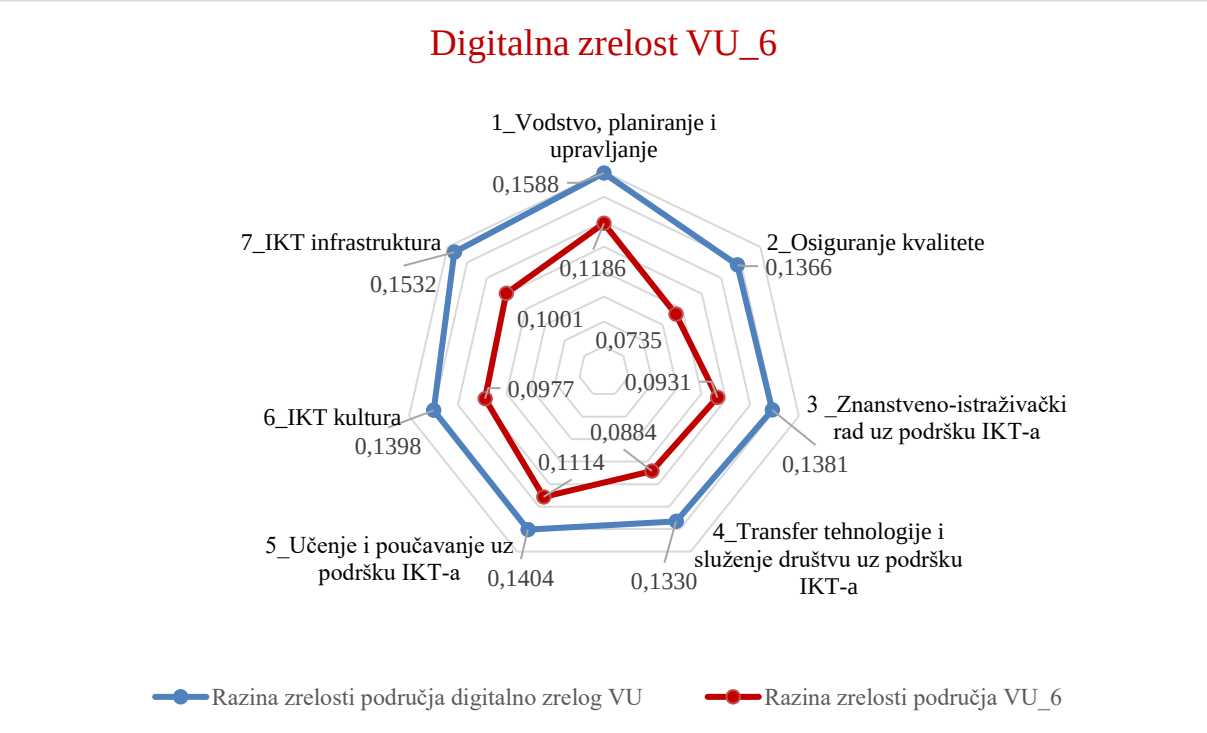

Slika 6.6: Digitalna zrelost VU_6

Digitalna zrelost VU_7 prikazana je na *Slici 6.7*. VU_7 je digitalno zrelo u području *7_IKT infrastruktura*. Drugo najveću razinu digitalne zrelosti ima područje *6_IKT kultura*. Područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *3_Znanstveno-istraživački rad uz podršku IKT-a* imaju treću, odnosno četvrtu razinu digitalne zrelosti u VU_5. Zanimljivo je da drugu najmanju digitalnu zrelost ima područje *1_Vodstvo, planiranje i upravljanje* dok najmanju digitalnu zrelost ima područje *2_Osiguranje kvalitete*. Potrebno je provesti niz aktivnosti unutar svih područja osim područja *7_IKT infrastruktura* kako bi se povećala digitalna zrelost kod preostalih šest područja i samim time povećala razina digitalne zrelosti VU.

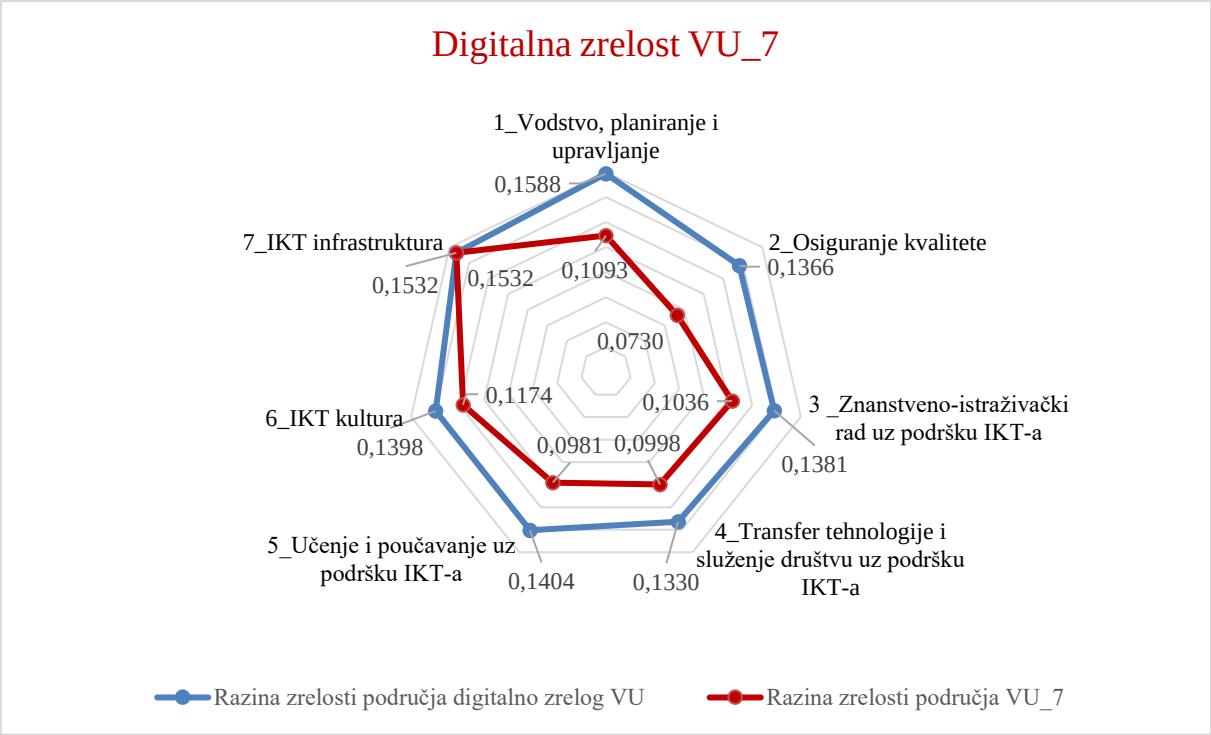

Slika 6.7: Digitalna zrelost VU_7

Digitalna zrelost VU_8 prikazana je na *Slici 6.8.* VU_8 ima najveću digitalnu zrelost u području *1_Vodstvo, planiranje i upravljanje*. Zatim slijede područja s nešto manjom razinom digitalne zrelosti *7_IKT infrastruktura*, *6_IKT kultura*, *3_Znanstveno-istraživački rad uz podršku IKT-a* i *5_Učenje i poučavanje uz podršku IKT-a*. Najmanju digitalnu zrelost imaju područja *2_Osiguranje kvalitete* i *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*. Potrebno je provesti aktivnosti unutar svih područja kako bi se povećala digitalna zrelost unutar područja i samim time povećala razina digitalne zrelosti VU.

Digitalna zrelost VU_9 prikazana je na *Slici 6.9.* VU_9 ima najveću digitalnu zrelost u području *7_IKT infrastruktura*. Zatim slijede područja s nešto manjom razinom digitalne zrelosti *6_IKT kultura*, *1_Vodstvo, planiranje i upravljanje* i *3_Znanstveno-istraživački rad uz podršku IKT-a*. Područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *2_Osiguranje kvalitete* imaju drugu, odnosno treću najmanju digitalnu zrelost unutar promatranog VU. Zanimljivo je da najmanju digitalnu zrelost ima područje *5_Učenje i poučavanje uz podršku IKT-a*. Potrebno je provesti niz aktivnosti unutar svih područja kako bi se povećala digitalna zrelost unutar svih područja i samim time povećala razina digitalne zrelosti VU.

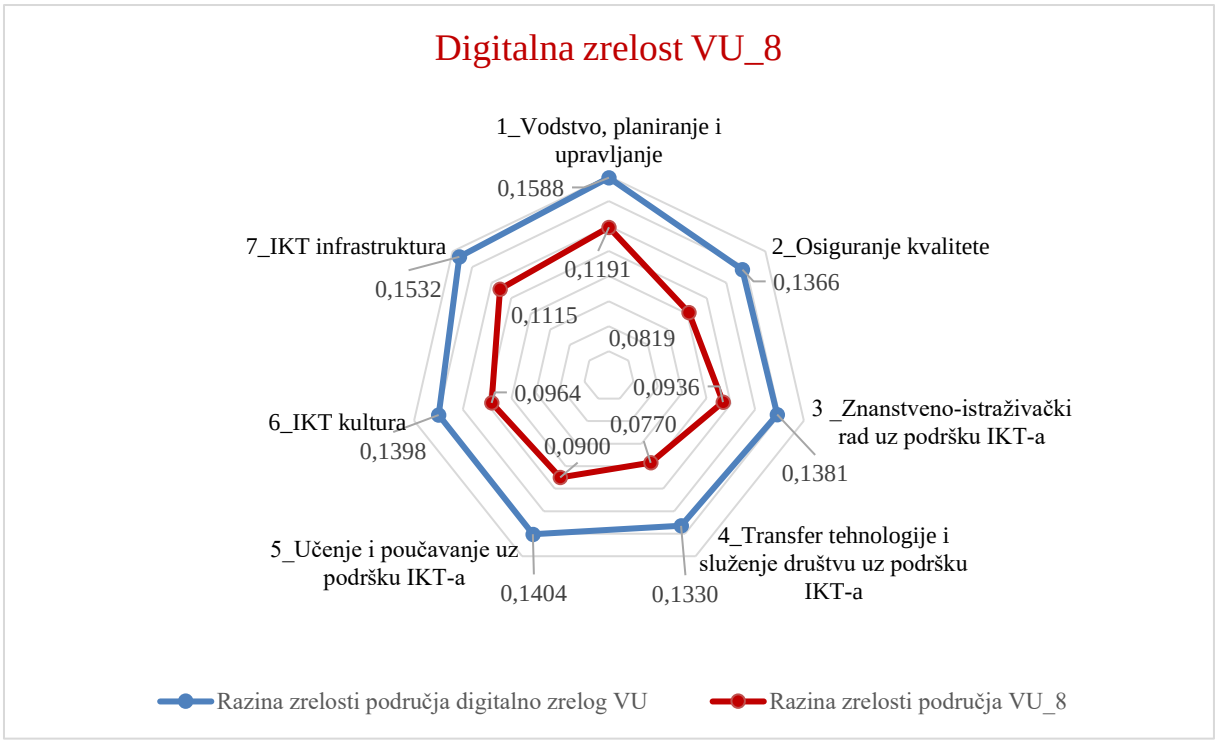

Slika 6.8: Digitalna zrelost VU_8

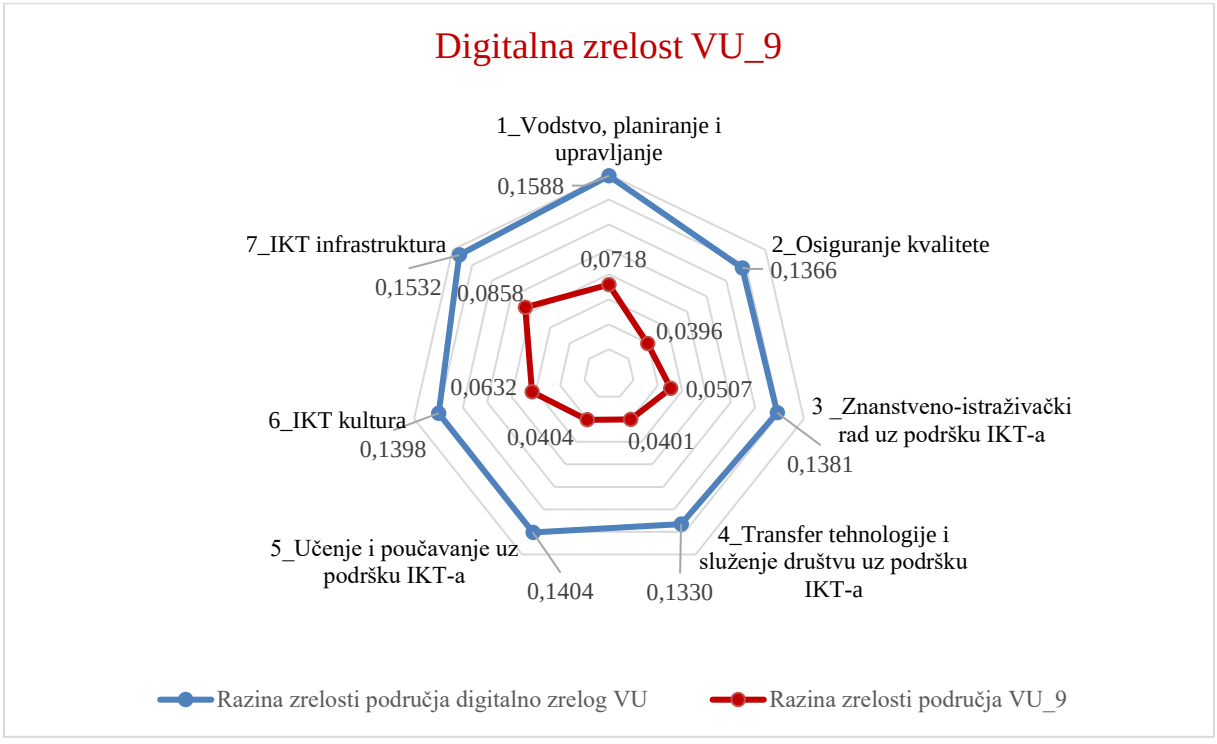

Slika 6.9: Digitalna zrelost VU_9

Digitalna zrelost VU_10 prikazana je na *Slici 6.10*. VU_10 ima najveću digitalnu zrelost u području *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*. Zatim slijede područja s nešto manjom razinom digitalne zrelosti *7_IKT infrastruktura, 5_Učenje i poučavanje uz podršku IKT-a, 6_IKT kultura* i *2_Osiguranje kvalitete*. Područje *3_Znanstveno-istraživački rad uz podršku IKT-a* ima drugu najmanju digitalnu zrelost unutar promatranog VU. Najmanju digitalnu zrelost ima područje *1_Vodstvo, planiranje i upravljanje*. Potrebno je provesti aktivnosti unutar svih područja kako bi se povećala digitalna zrelost unutar svih područja i samim time povećala razina digitalne zrelosti VU.

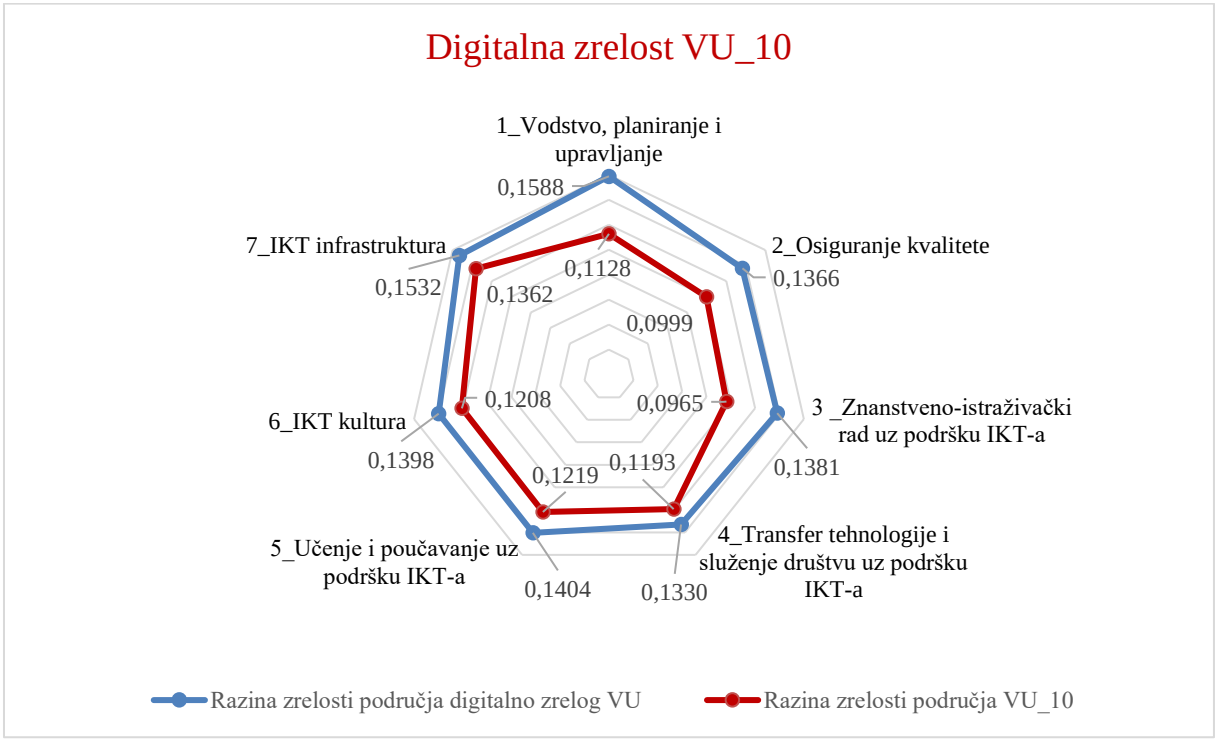

Slika 6.10: Digitalna zrelost VU_10

Digitalna zrelost VU_11 prikazana je na *Slici 6.11*. VU_11 ima najveću digitalnu zrelost u području *6_IKT kultura*. Drugu, odnosno treću najveću digitalnu zrelost imaju područja *7_IKT infrastruktura* i *3_Znanstveno-istraživački rad uz podršku IKT-a*. Zatim slijede područja *2_Osiguranje kvalitete, 5_Učenje i poučavanje uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje*. Najmanju digitalnu zrelost ima područje *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*. Potrebno je provesti aktivnosti unutar svih područja kako bi se povećala digitalna zrelost unutar svih područja i samim time povećala razina digitalne zrelosti VU.

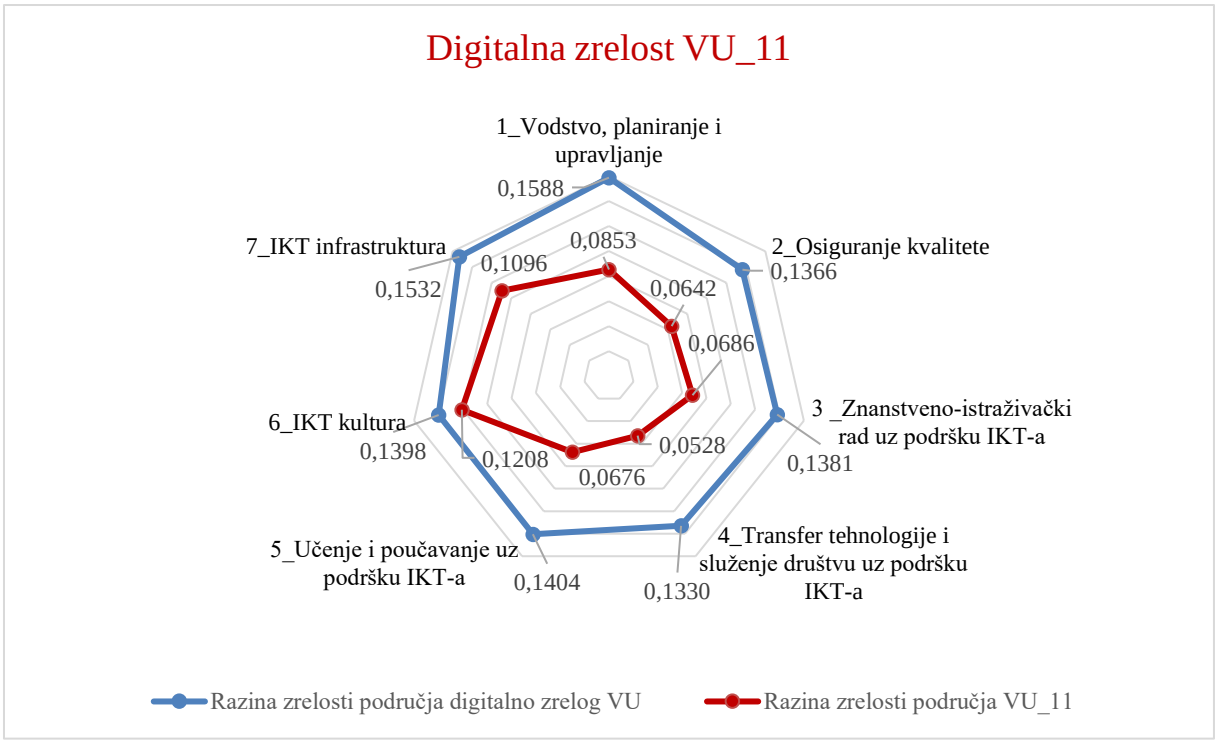

Slika 6.11: Digitalna zrelost VU_11

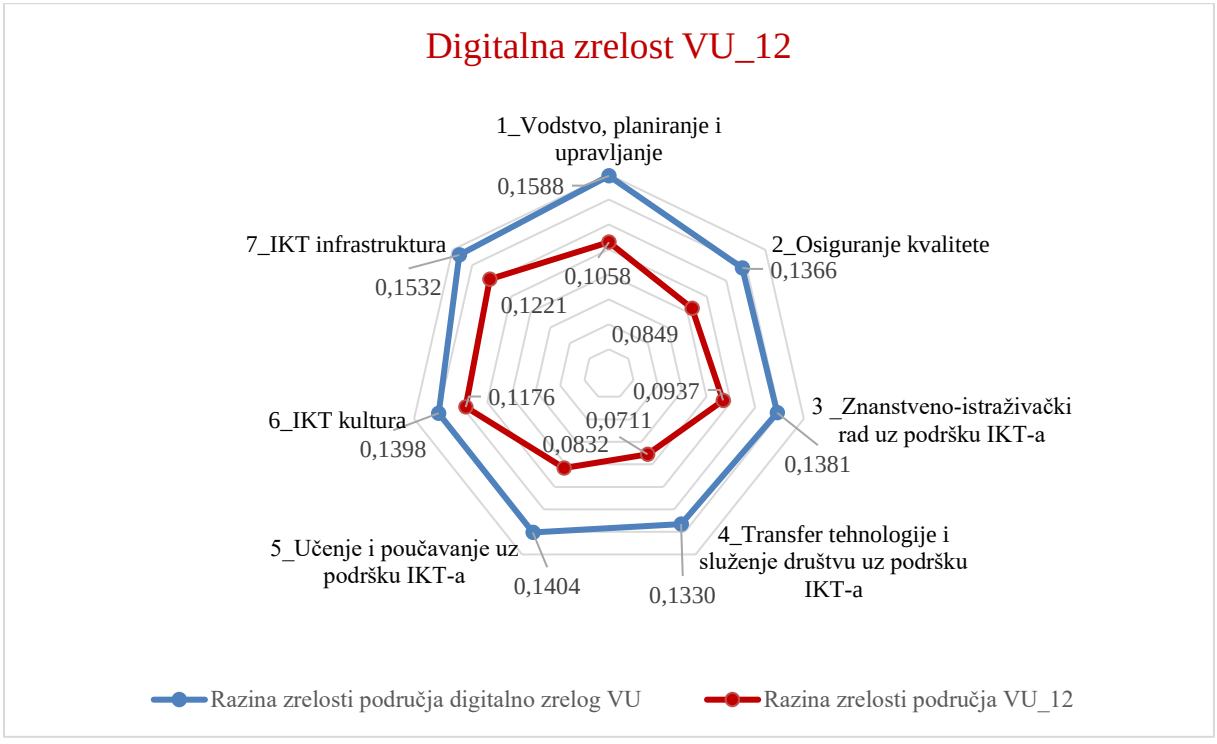

Slika 6.12: Digitalna zrelost VU_12

Digitalna zrelost VU_12 prikazana je na *Slici 6.12.* VU_12 ima najveću digitalnu zrelost u području *6_IKT kultura*. Drugu, odnosno treću najveću digitalnu zrelost imaju područja *7_IKT infrastruktura* i *3_Znanstveno-istraživački rad uz podršku IKT-a*. Zatim slijede područja *2_Osiguranje kvalitete* i *1_Vodstvo, planiranje i upravljanje*. Najmanju digitalnu zrelost imaju područja *5_Učenje i poučavanje uz podršku IKT-a* i *4_Transfer tehnologije i služenje društvu uz podršku IKT-a.* Potrebno je provesti aktivnosti unutar svih područja kako bi se povećala digitalna zrelost unutar svih područja i samim time povećala razina digitalne zrelosti VU.

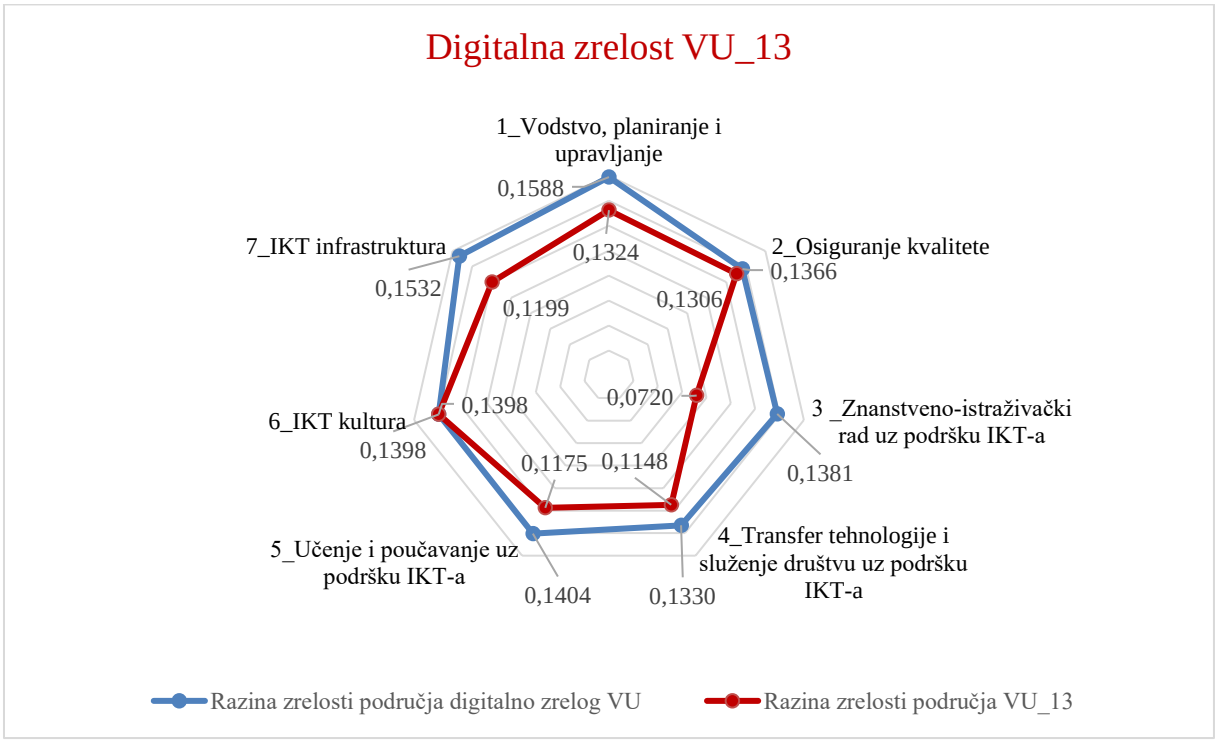

Slika 6.13: Digitalna zrelost VU_13

Digitalna zrelost VU_13 prikazana je na *Slici 6.13.* VU_13 je digitalno zrelo u područjima *6_IKT kultura* i *2_Osiguranje kvalitete*. Zatim slijede područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a, 5_Učenje i poučavanje uz podršku IKT-a* i *3_Znanstveno-istraživački rad uz podršku IKT-a*. Područja koja imaju najmanju razinu digitalne zrelosti su *7_IKT infrastruktura* i *1_Vodstvo, planiranje i upravljanje*. VU trebaju provesti niz aktivnosti u područjima koja imaju najmanju razinu digitalne zrelosti kako bi povećali ukupnu razinu digitalne zrelosti VU.

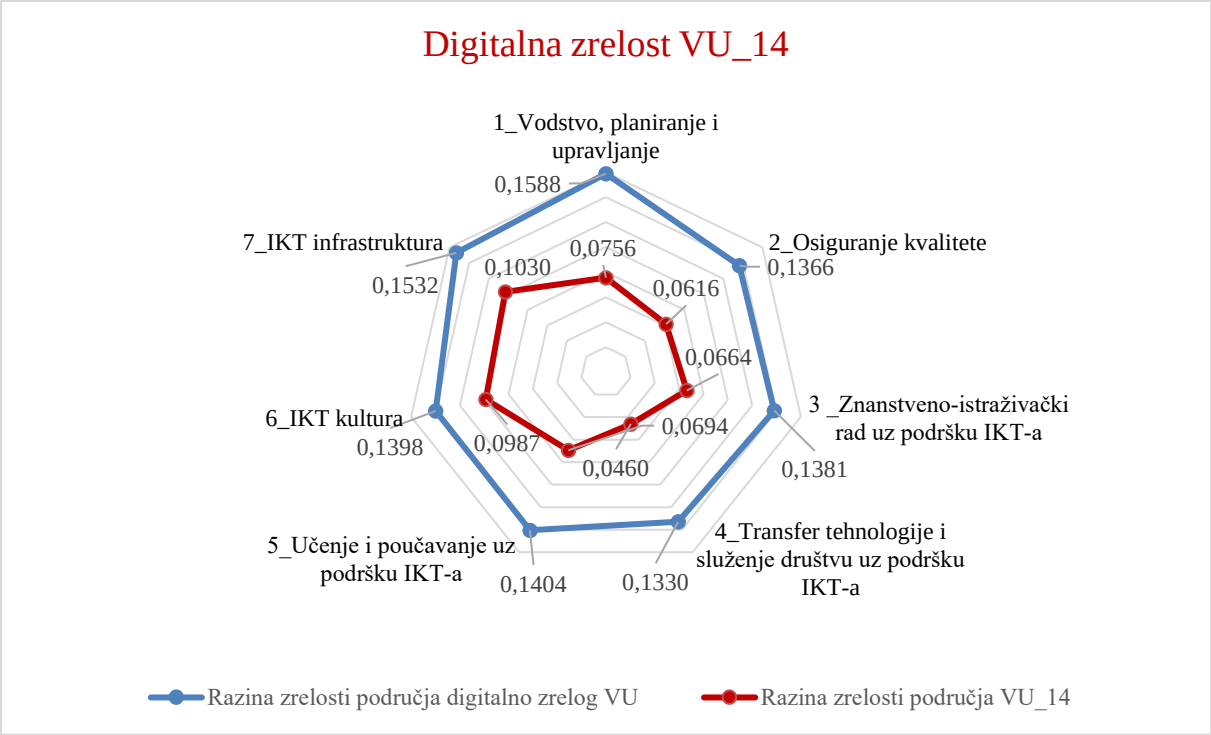

Slika 6.14: Digitalna zrelost VU_14

Digitalna zrelost VU_14 prikazana je na *Slici 6.14.* VU_14 ima najveću digitalnu zrelost u području *6_IKT kultura* i *7_IKT infrastruktura*. Područja *5_Učenje i poučavanje uz podršku IKT-a* i *3_Znanstveno-istraživački rad uz podršku IKT-a* imaju nešto manju digitalnu zrelost. Zatim slijede područja *2_Osiguranje kvalitete* i *1_Vodstvo, planiranje i upravljanje*. Najmanju digitalnu zrelost ima područje *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*. Potrebno je provesti niz aktivnosti unutar svih područja kako bi se povećala digitalna zrelost unutar svih područja i samim time povećala razina digitalne zrelosti VU.

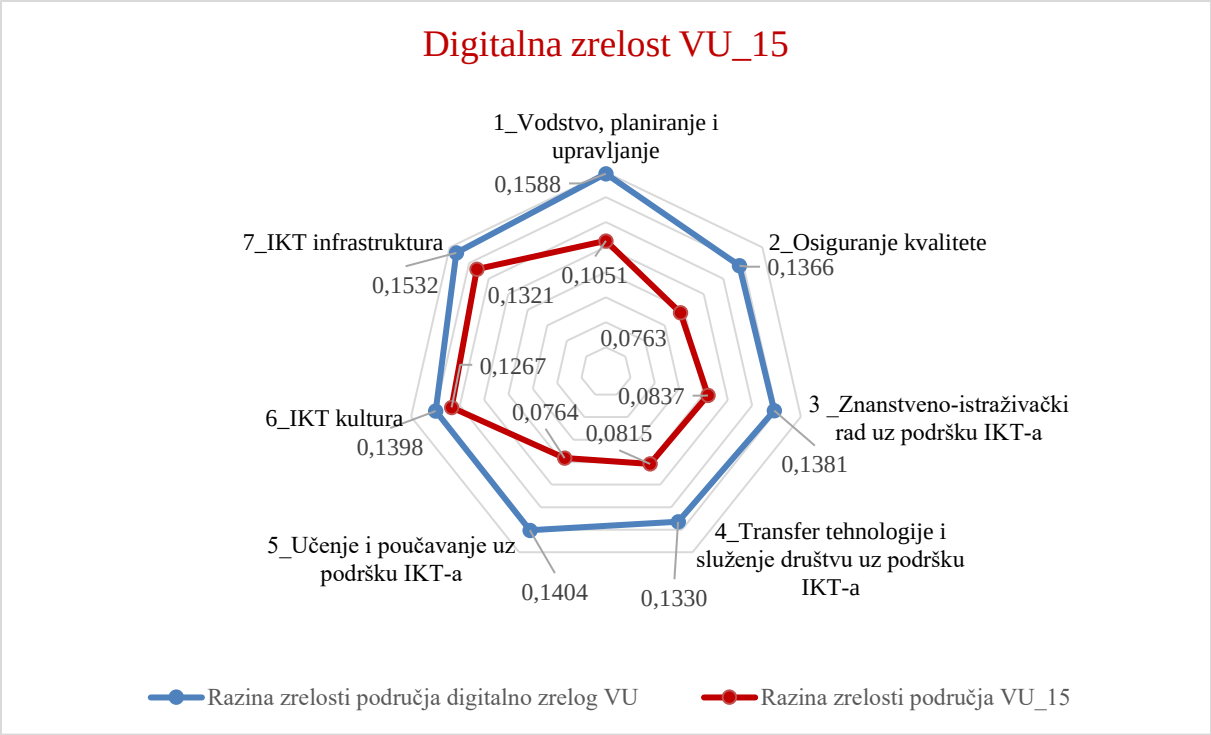

Slika 6.15: Digitalna zrelost VU_15

Digitalna zrelost VU_15 prikazana je na *Slici 6.15.* VU_15 ima najveću digitalnu zrelost u područjima *6_IKT kultura* i *7_IKT infrastruktura*. Područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje* imaju nešto manju digitalnu zrelost. Zatim slijede područja *3_Znanstveno-istraživački rad uz podršku IKT-a* i *2_Osiguranje kvalitete*. Zanimljivo je da najmanju razinu digitalne zrelosti ima područje *5_Učenje i poučavanje uz podršku IKT-a*. Potrebno je provesti niz aktivnosti prvenstveno unutar svih područja, osim područja 6_IKT kultura i 7_IKT infrastruktura, kako bi se povećala digitalna zrelost VU.

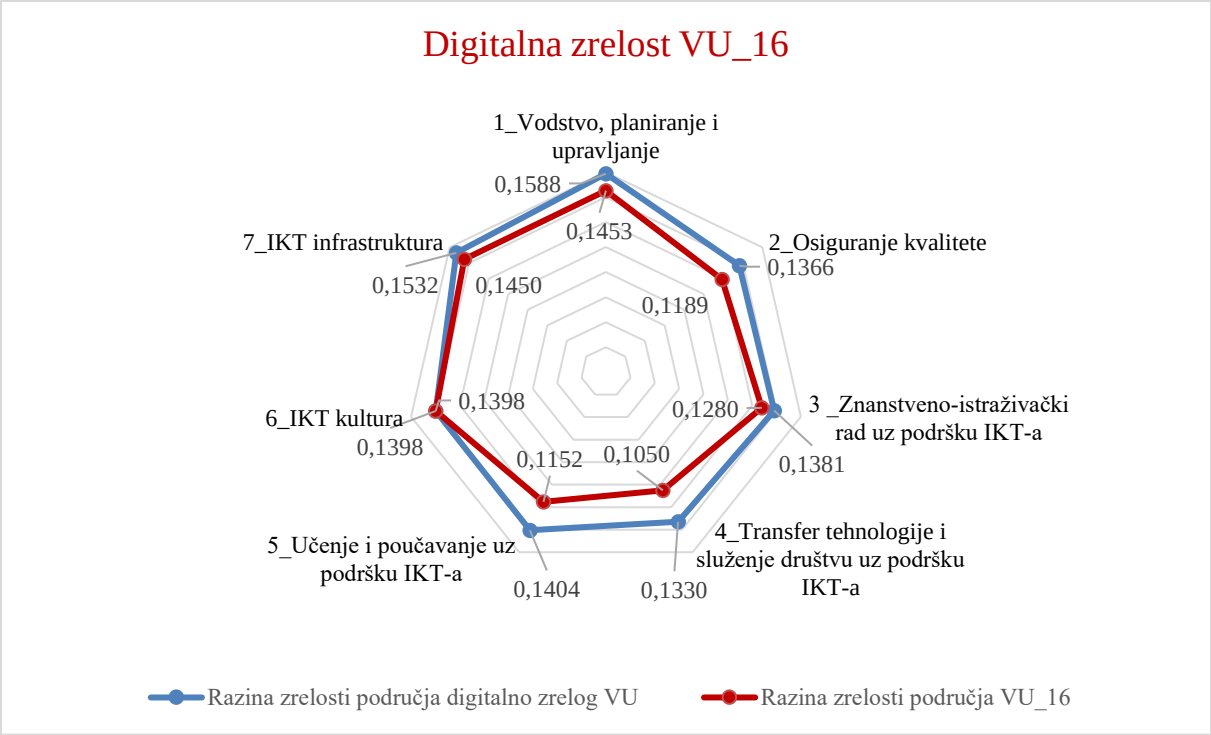

Slika 6.16: Digitalna zrelost VU_16

Digitalna zrelost VU_16 prikazana je na *Slici 6.16.* VU_16 je digitalno zrelo u području *6_IKT kultura*. Područja *7_IKT infrastruktura*, *3_Znanstveno-istraživački rad uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje* imaju nešto manju razinu digitalne zrelosti. Zatim slijede područja *2_Osiguranje kvalitete* i *5_Učenje i poučavanje uz podršku IKT-a*. Najmanju digitalnu zrelost ima područje *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*. Potrebno je provesti aktivnosti unutar posljednja tri područja kako bi VU bilo u potpunosti digitalno zrelo.

Digitalna zrelost VU_17 prikazana je na *Slici 6.17.* VU_17 ima najveću digitalnu zrelost u području *6_IKT kultura* i *7_IKT infrastruktura*. Područja *5_Učenje i poučavanje uz podršku IKT-a* i *3_Znanstveno-istraživački rad uz podršku IKT-a* imaju nešto manju digitalnu zrelost. Zatim slijede područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje*. Najmanju digitalnu zrelost ima područje *2_Osiguranje kvalitete*. Potrebno je provesti niz aktivnosti unutar svih područja kako bi se povećala digitalna zrelost unutar svih područja i samim time povećala razina digitalne zrelosti VU.

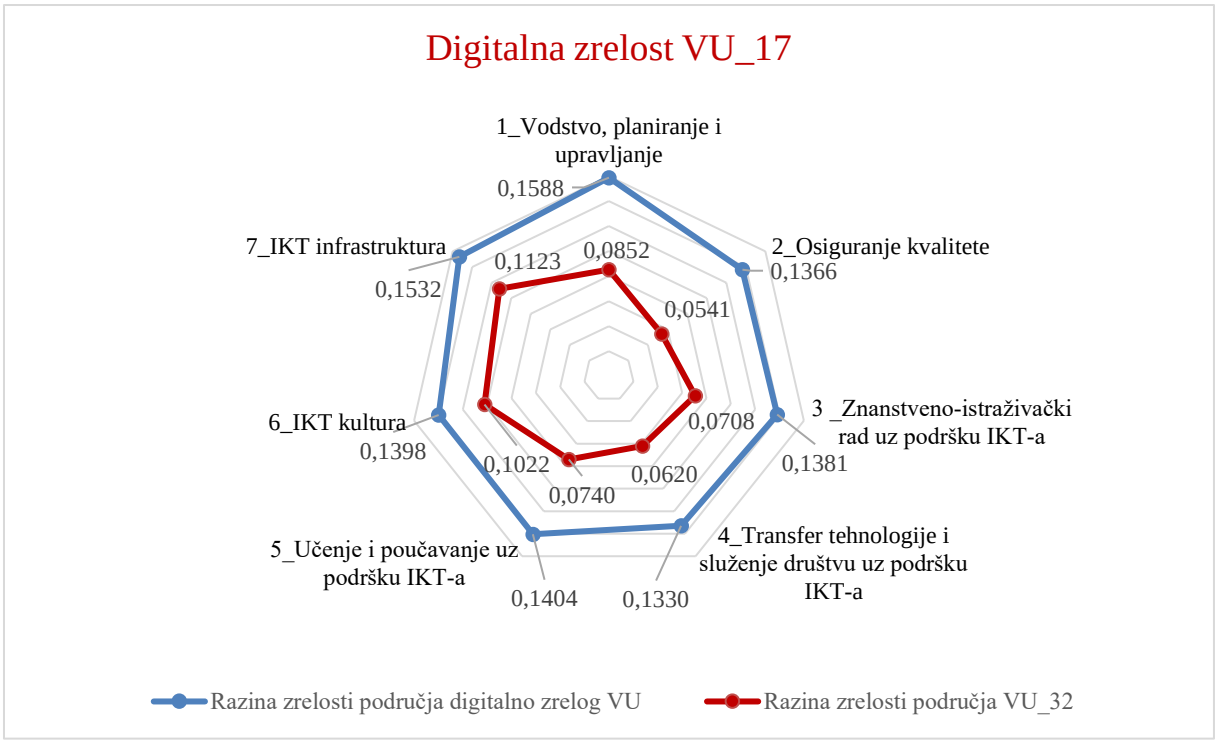

Slika 6.17: Digitalna zrelost VU_17

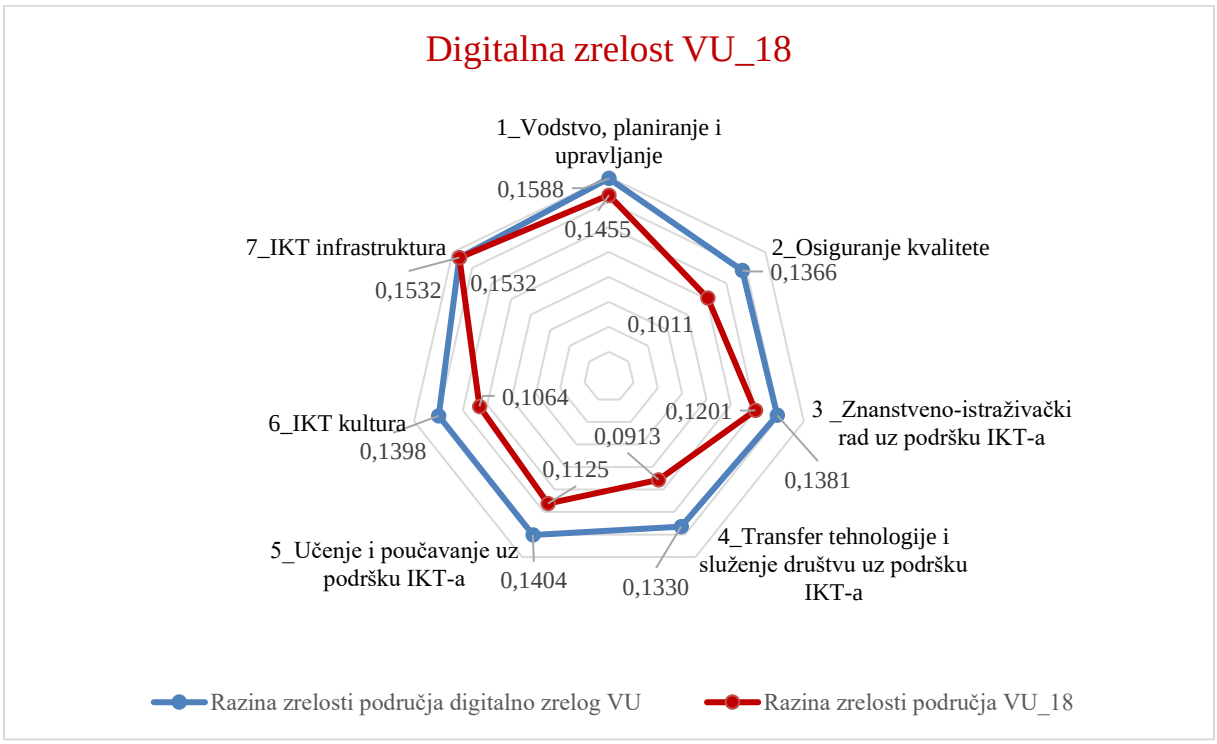

Slika 6.18: Digitalna zrelost VU_18

Digitalna zrelost VU_18 prikazana je na *Slici 6.18.* VU_18 je digitalno zrelo u području *7_IKT infrastruktura*. Drugu najveću digitalnu zrelost ima područje *1_Vodstvo, planiranje i upravljanje*. Zatim slijede područja s nešto manjom razinom digitalne zrelosti *3_Znanstveno-istraživački rad uz podršku IKT-a*, *5_Učenje i poučavanje uz podršku IKT-a* i *6_IKT kultura*. Područja s najmanjom razinom digitalne zrelosti su *2_Osiguranje kvalitete* i *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*. Potrebno je provoditi aktivnosti unutar područja koja imaju manju razinu digitalnu zrelosti kako bi se povećala digitalna zrelost VU.

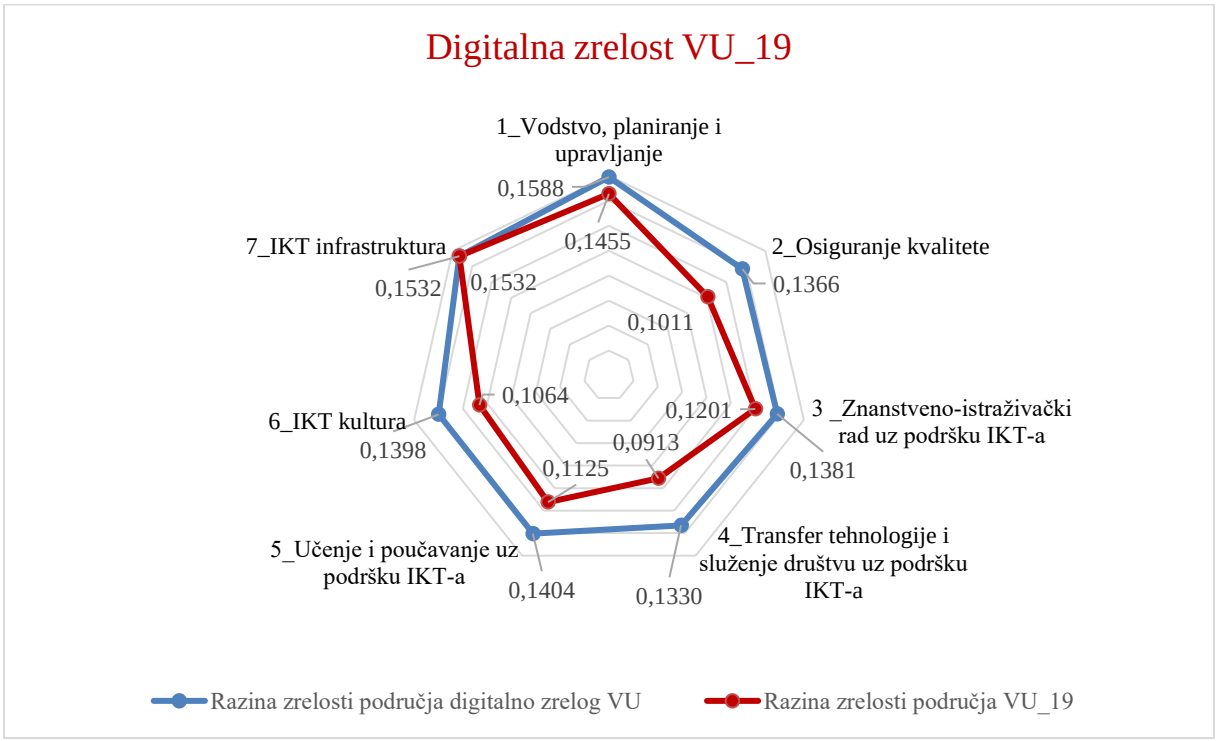

Slika 6.19: Digitalna zrelost VU_19

Digitalna zrelost VU_19 prikazana je na *Slici 6.19.* VU_19 je digitalno zrelo u području *7_IKT infrastruktura*. Drugu najveću digitalnu zrelost ima područje *1_Vodstvo, planiranje i upravljanje*. Zatim slijede područja s nešto manjom razinom digitalne zrelosti *3_Znanstveno-istraživački rad uz podršku IKT-a*, *5_Učenje i poučavanje uz podršku IKT-a* i *6_IKT kultura*. Područja s najmanjom razinom digitalne zrelosti su *2_Osiguranje kvalitete* i *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*. Potrebno je provoditi aktivnosti unutar područja koja imaju manju razinu digitalnu zrelosti kako bi se povećala digitalna zrelost VU.

Digitalna zrelost VU_20 prikazana je na *Slici 6.20.* VU_20 najveću digitalnu zrelost ima u područjima *3_Znanstveno-istraživački rad uz podršku IKT-a* i *7_IKT infrastruktura*, zatim slijede područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje*. Područja *6_IKT kultura* i *2_Osiguranje kvalitete* imaju petu i šestu razinu zrelosti. Zanimljivo je da područje *5_Učenje i poučavanje uz podršku IKT-a* ima najmanju razinu zrelosti. Potrebno je provesti niz aktivnosti unutar svih područja kako bi se povećala digitalna zrelost unutar svih područja i samim time povećala razina digitalne zrelosti VU.

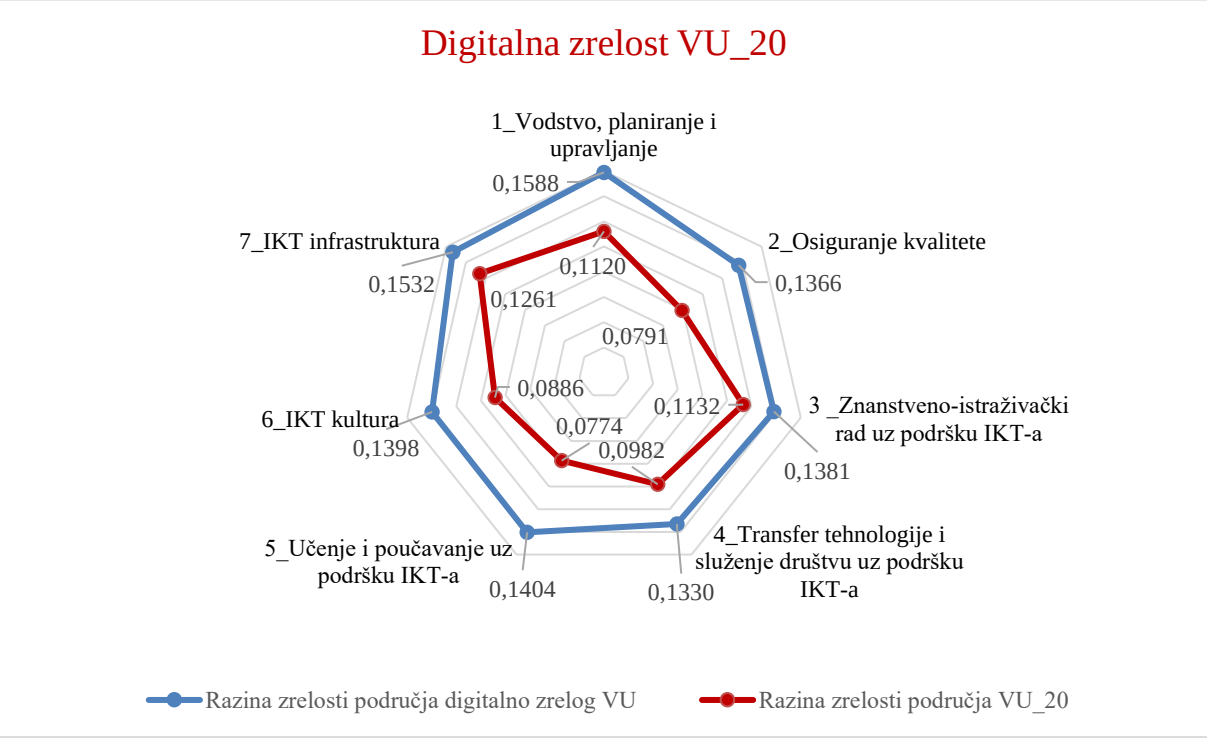

Slika 6.20: Digitalna zrelost VU_20

Digitalna zrelost VU_21 prikazana je na *Slici 6.21.* VU_21 najveću digitalnu zrelost ima u području *7_IKT infrastruktura*, zatim slijede područja *6_IKT kultura, 5_Učenje i poučavanje uz podršku IKT-a i 2_Osiguranje kvalitete.* Područja *1_Vodstvo, planiranje i upravljanje i 3_Znanstveno-istraživački rad uz podršku IKT-a* područja su koja je potrebno unaprijediti, ali ne odskaču znatno u odnosu na prethodna dva. Područje koje ima najmanju digitalnu zrelost je područje *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* koje je potrebno znatno unaprijediti kako bi postiglo veću razinu digitalne zrelosti.

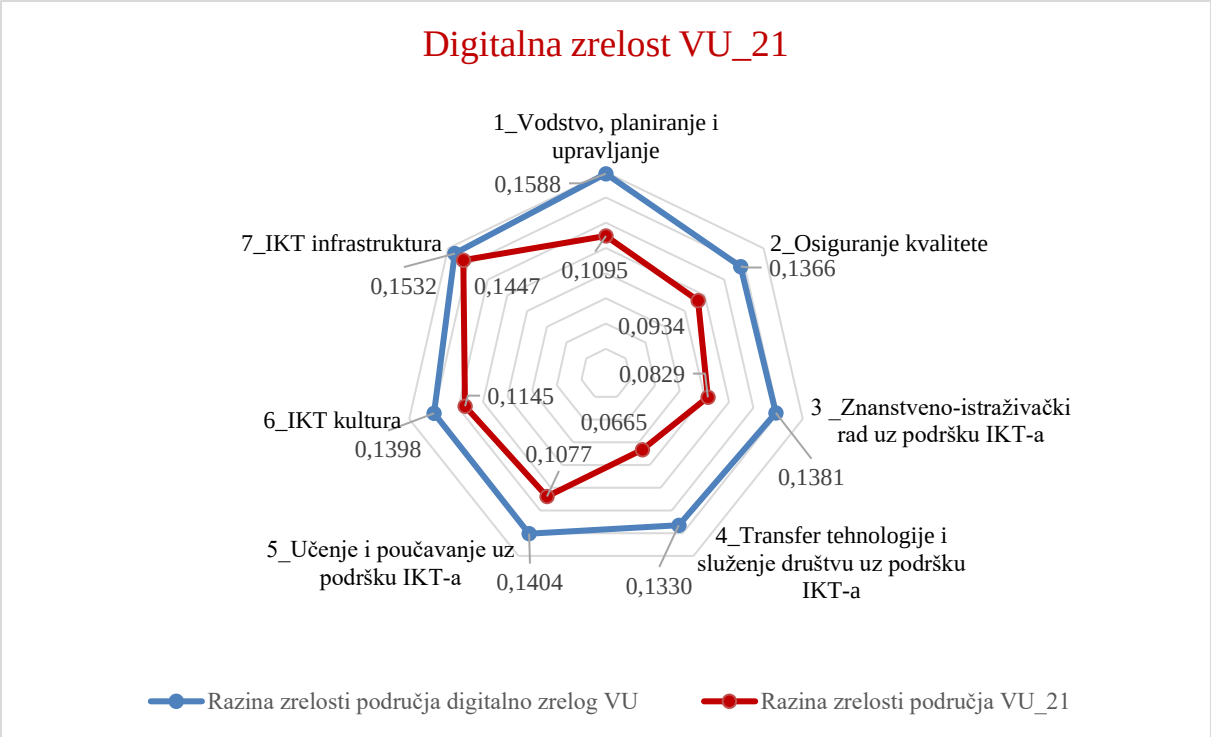

Slika 6.21: Digitalna zrelost VU_21

Digitalna zrelost VU_22 prikazana je na *Slici 6.22.* VU_22 najveću digitalnu zrelost ima u područjima *7_IKT infrastruktura* i *2_Osiguranje kvalitete*. Slijede ih područja *6_IKT kultura, 5_Učenje i poučavanje uz podršku IKT-a, 1_Vodstvo, planiranje i upravljanje* i *3_Znanstveno-istraživački rad uz podršku IKT-a*. Područje *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* ima najmanju digitalnu zrelost. Sva područja potrebno je unaprijediti kako bi se povećala ukupna razina digitalne zrelosti VU.

Digitalna zrelost VU_23 prikazana je na *Slici 6.23.* VU_23 najveću digitalnu zrelost pokazuje u područjima *7_IKT infrastruktura* i *6_IKT kultura*, zatim slijede područja *1_Vodstvo, planiranje i upravljanje* i *5_Učenje i poučavanje uz podršku IKT-a*. Područja koja pokazuju najmanju digitalnu zrelost su područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a, 3_Znanstveno-istraživački rad uz podršku IKT-a* i *2_Osiguranje kvalitete*. Potrebno je provesti niz aktivnosti unutar svih područja kako bi se povećala digitalna zrelost unutar svih područja i samim time povećala razina digitalne zrelosti VU.

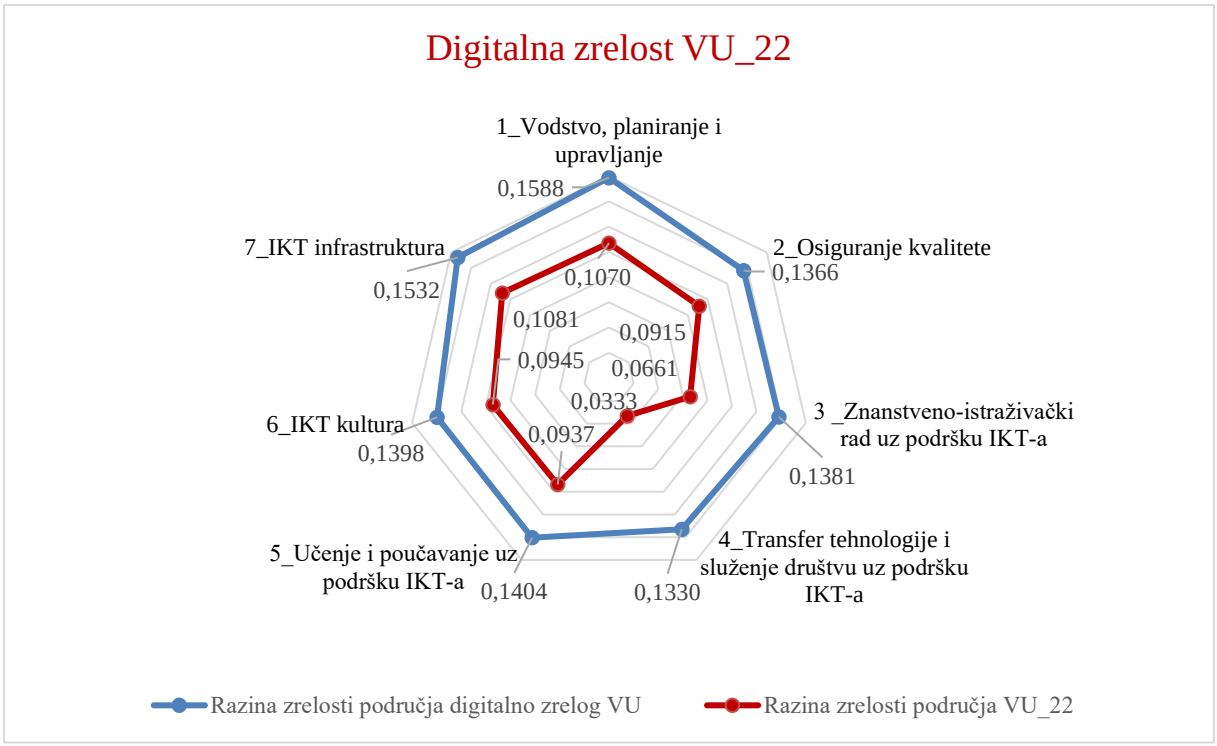

Slika 6.22: Digitalna zrelost VU_22

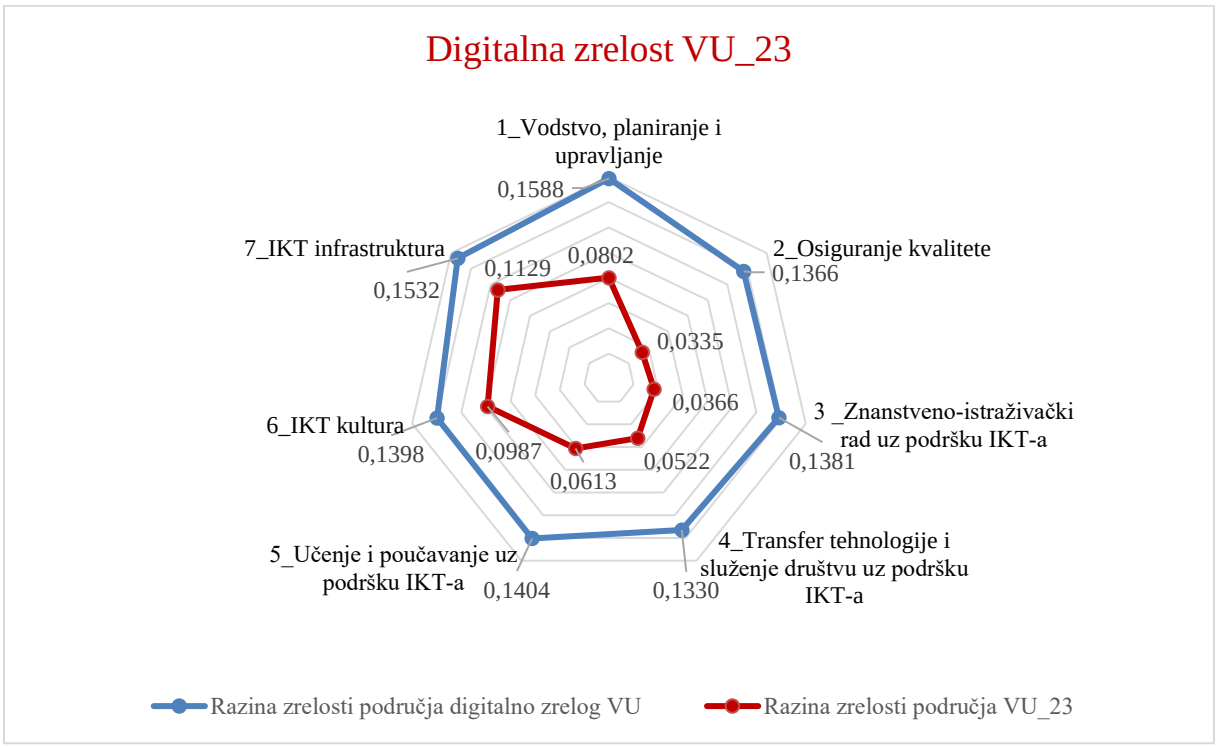

Slika 6.23: Digitalna zrelost VU_23

Digitalna zrelost VU_24 prikazana je na *Slici 6.24.* VU_24 najveću digitalnu zrelost ima u područjima *7_IKT infrastruktura* i *6_IKT kultura*, zatim slijede područja *3_Znanstveno-istraživački rad uz podršku IKT-a*, *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *1_Vodstvo, planiranje i upravljanje* koja je potrebno unaprijediti, ali ne odskaču znatno u odnosu na prethodna dva. Područja koja imaju najmanju digitalnu zrelost su područja *5_Učenje i poučavanje uz podršku IKT-a i 2_Osiguranje kvalitete* i potrebno ih je unaprijediti kako bi postigli veću razinu digitalne zrelosti.

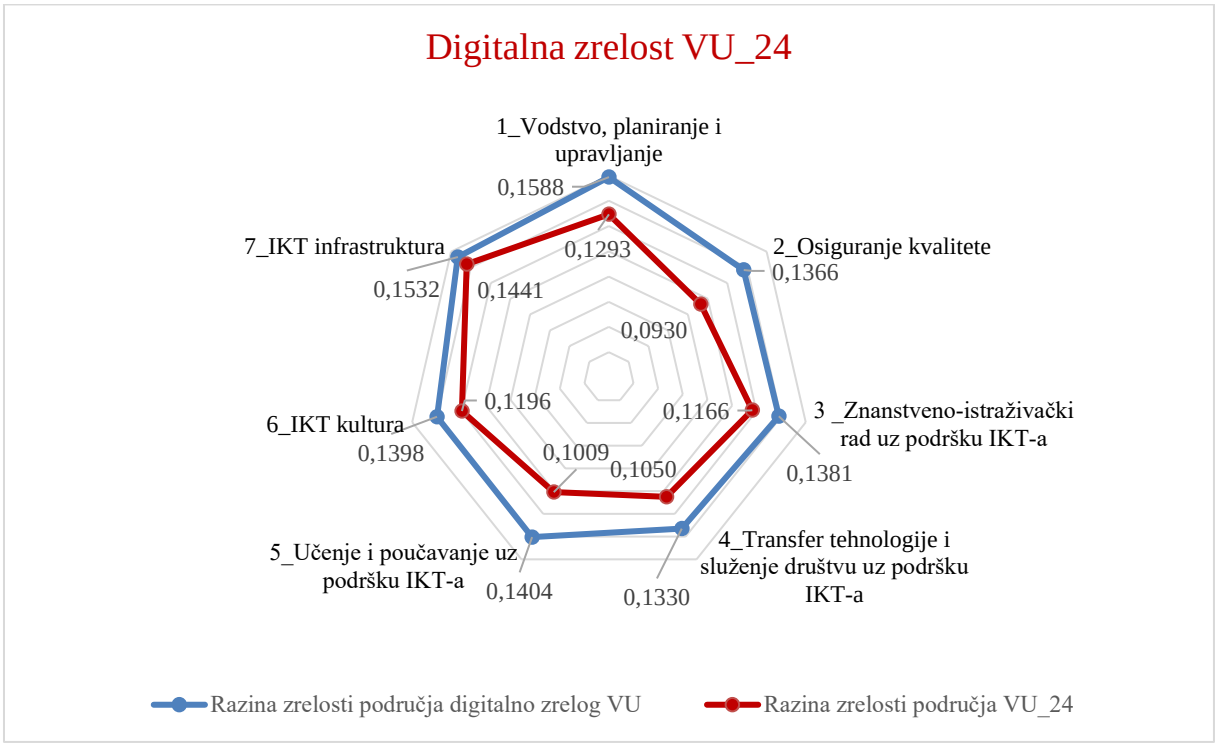

Slika 6.24: Digitalna zrelost VU_24

Digitalna zrelost VU_25 prikazana je na *Slici 6.25.* VU_25 najveću digitalnu zrelost ima u područjima *7_IKT infrastruktura* i *6_IKT kultura*, zatim slijede područja *3_Znanstveno-istraživački rad uz podršku IKT-a*, *1_Vodstvo, planiranje i upravljanje* i *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* koja je potrebno unaprijediti, ali ne odskaču znatno u odnosu na prethodna dva. Područja koja imaju najmanju digitalnu zrelost su područja *5_Učenje i poučavanje uz podršku IKT-a i 2_Osiguranje kvalitete* i potrebno ih je unaprijediti kako bi postigli veću razinu digitalne zrelosti.

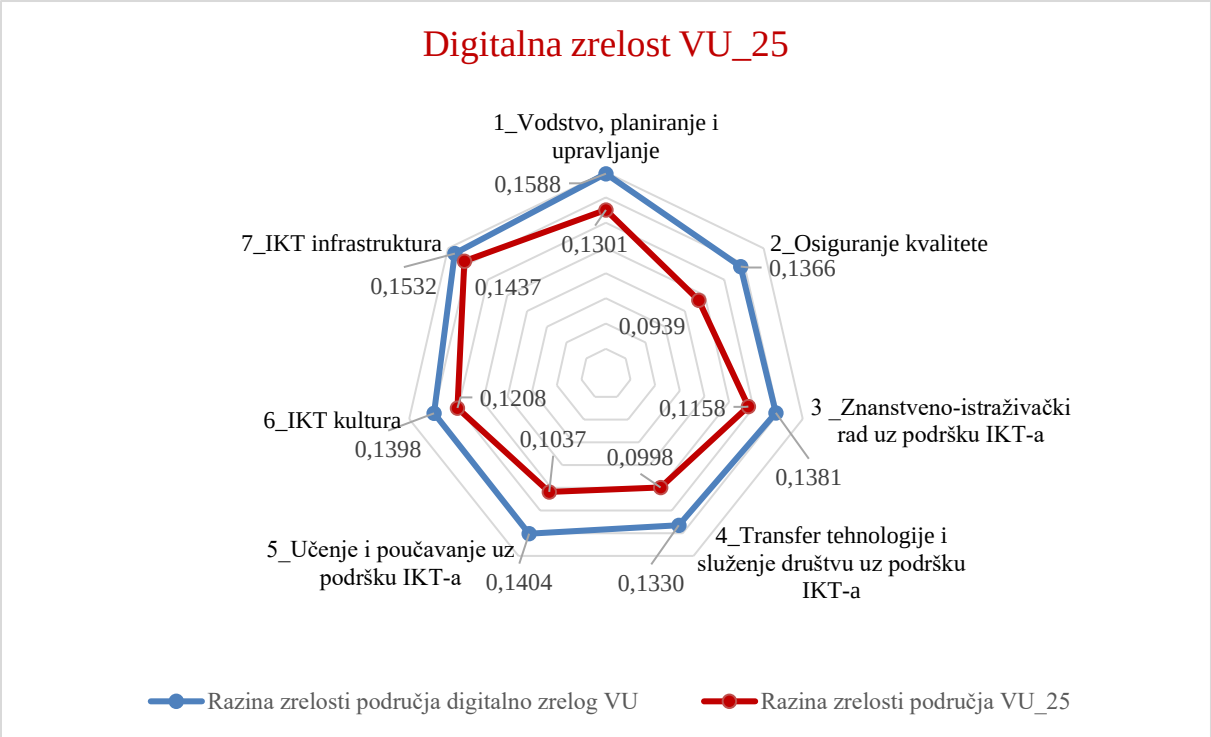

Slika 6.25: Digitalna zrelost VU_25

Digitalna zrelost VU_26 prikazana je na *Slici 6.26.* VU_26 ima najveću digitalnu zrelost u području *7_IKT infrastruktura*, zatim slijede područja *6_IKT kultura* i *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*. Područja *5_Učenje i poučavanje uz podršku IKT-a, 2_Osiguranje kvalitete* i *1_Vodstvo, planiranje i upravljanje* su područja koja je potrebno unaprijediti. Područje koje ima najmanju digitalnu zrelost je područje *3_Znanstveno-istraživački rad uz podršku IKT-a*. Sva područja je potrebno unaprijediti kako bi se povećala razina digitalne zrelosti VU.

Digitalna zrelost VU_27 prikazana je na *Slici 6.27.* VU_27 ima najveću digitalnu zrelost u područjima *7_IKT infrastruktura* i *3_Znanstveno-istraživački rad uz podršku IKT-a,* zatim slijede područja *1_Vodstvo, planiranje i upravljanje*, *2_Osiguranje kvalitete*, *6_IKT kultura* i *5_Učenje i poučavanje uz podršku IKT-a*. Područje koje ima najmanju digitalnu zrelost je područje *4_Transfer tehnologije i služenje društvu uz podršku IKT-a.* Potrebno je provesti niz aktivnosti unutar svih područja kako bi se povećala digitalna zrelost i samim time povećala razina digitalne zrelosti VU.

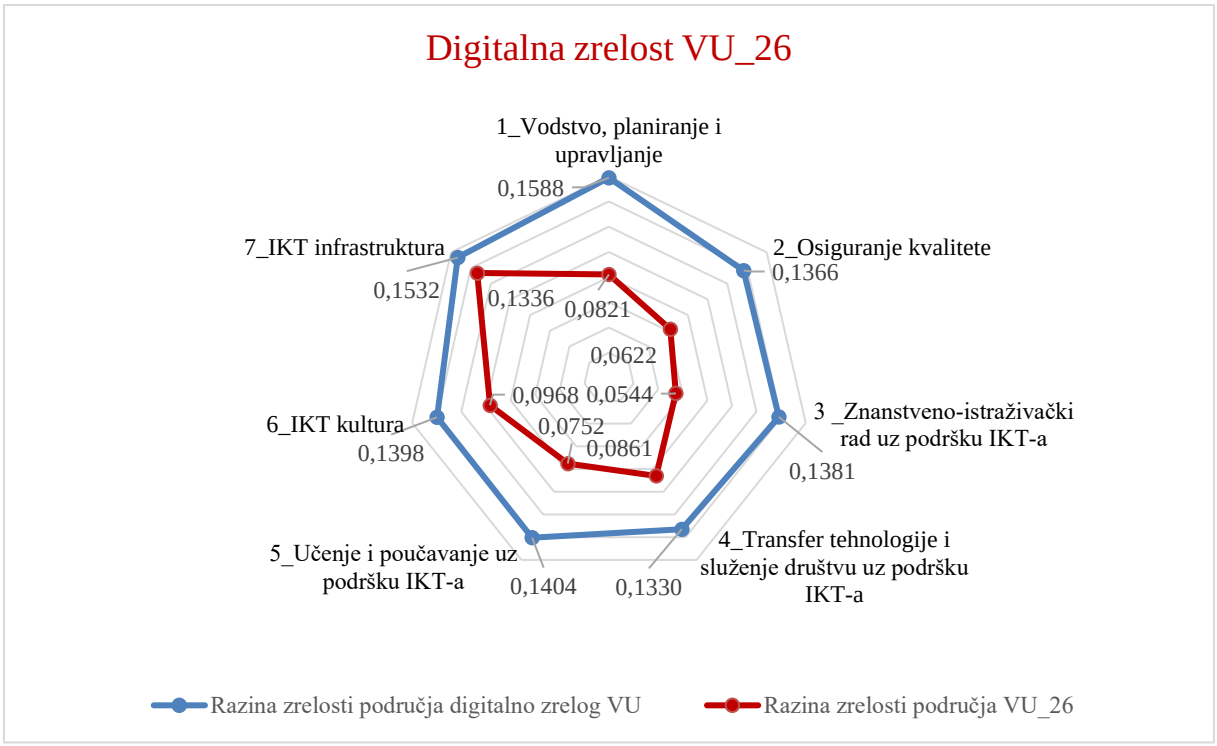

Slika 6.26: Digitalna zrelost VU_26

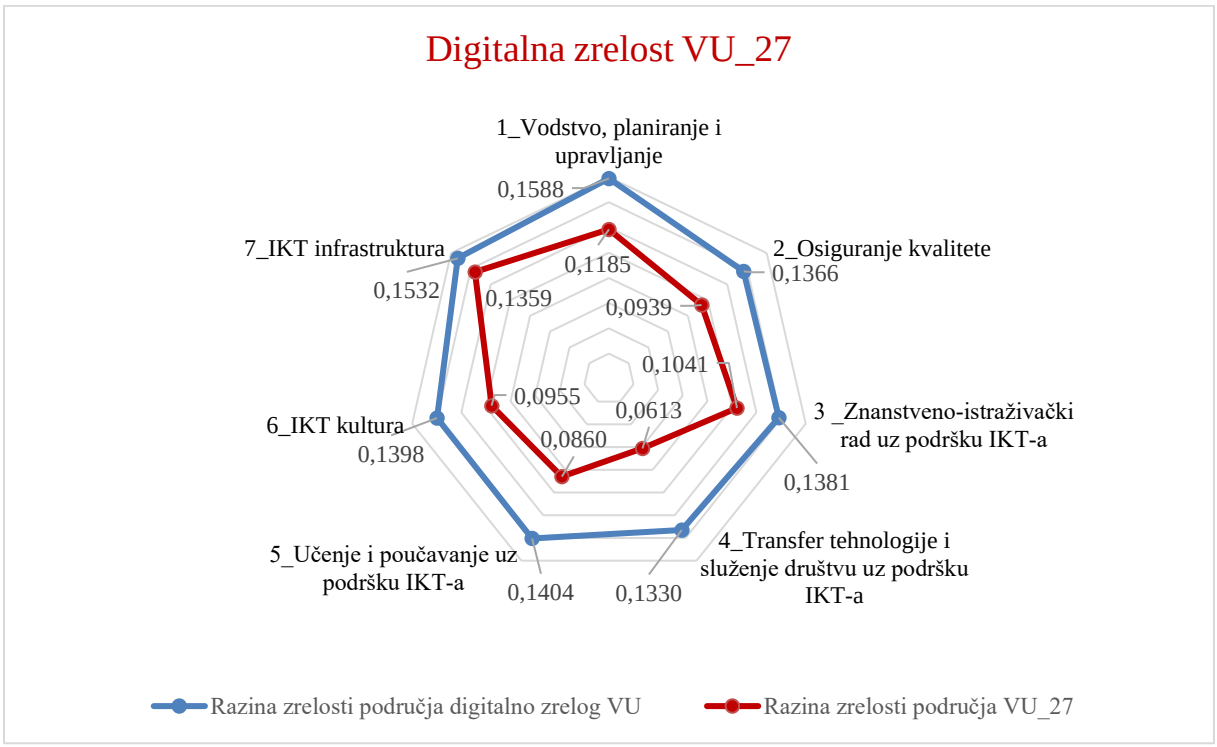

Slika 6.27: Digitalna zrelost VU_27

Digitalna zrelost VU_28 prikazana je na *Slici 6.28.* VU_28 najveću digitalnu zrelost ima u području *7_IKT infrastruktura,* zatim slijede područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a, 6_IKT kultura* i *1_Vodstvo, planiranje i upravljanje* koja je potrebno unaprijediti, ali ne odskaču znatno u odnosu na prethodnom područje. Područja koja imaju najmanju digitalnu zrelost su područja *5_Učenje i poučavanje uz podršku IKT-a, 3_Znanstveno-istraživački rad uz podršku IKT-a* i *2_Osiguranje kvalitete*. Sva područja, osim područja *7_IKT infrastruktura*, potrebno je znatno unaprijediti kako bi postiglo veću razinu digitalne zrelosti.

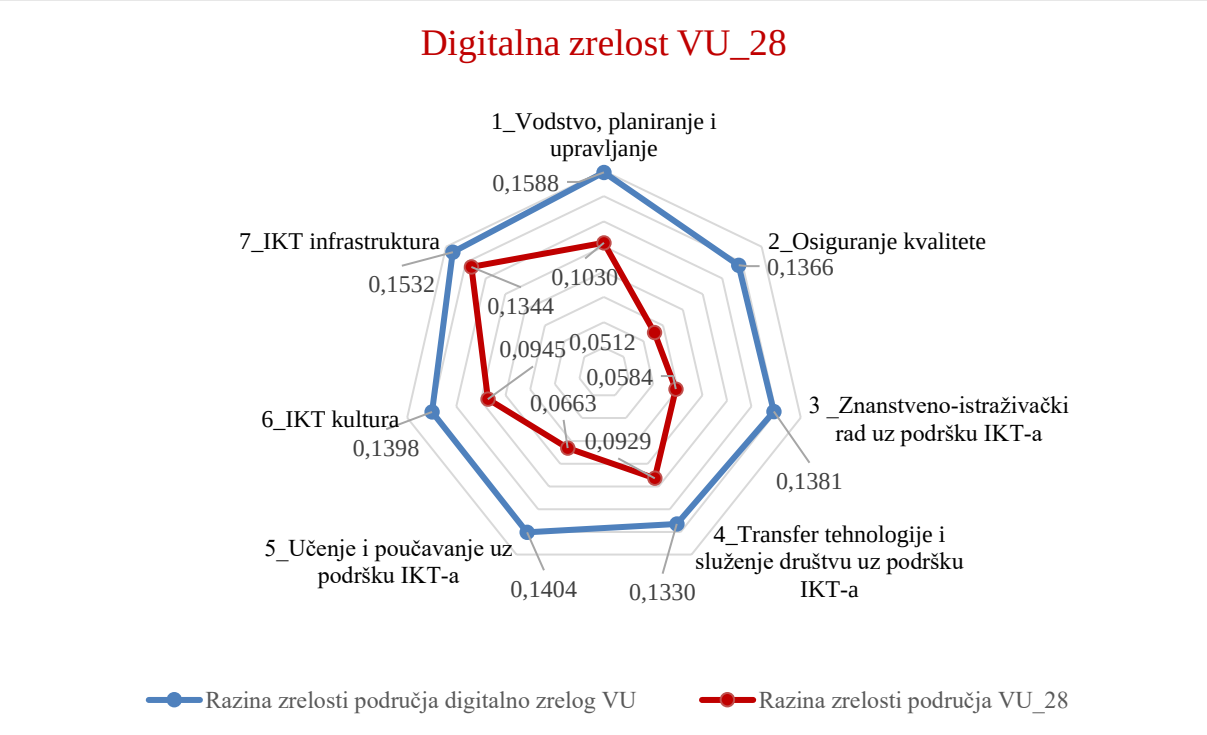

Slika 6.28: Digitalna zrelost VU_28

Digitalna zrelost VU_29 prikazana je na *Slici 6.29.* VU_29 najveću digitalnu zrelost ima u području *1_Vodstvo, planiranje i upravljanje*. Područja koja je potrebno unaprijediti su područja *4_Transfer tehnologije i služenje društvu uz podršku IKT-a, 6_IKT kultura, 7_IKT infrastruktura* i *3_Znanstveno-istraživački rad uz podršku IKT-a*; dok je područja *2_Osiguranje kvalitete* i *5_Učenje i poučavanje uz podršku IKT-a* potrebno znatno unaprijediti kako bi se povećala digitalna zrelost VU.

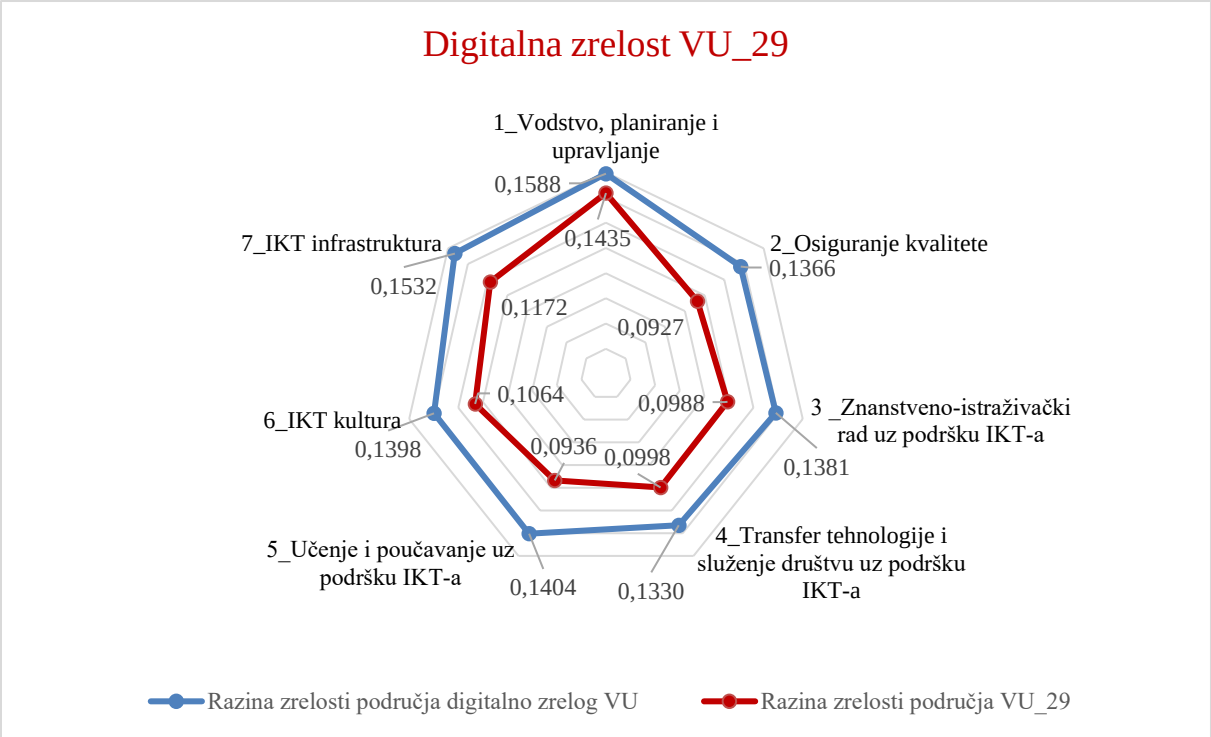

Slika 6.29: Digitalna zrelost VU_29

Digitalna zrelost VU_30 prikazana je na *Slici 6.30.* VU_30 najveću digitalnu zrelost ima u područjima *6_IKT kultura* i *7_IKT infrastruktura*. Područja koja je potrebno unaprijediti su područja *3_Znanstveno-istraživački rad uz podršku IKT-a*, *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*, *2_Osiguranje kvalitete* i *5_Učenje i poučavanje uz podršku IKT-a*. Područje koje ima najmanju digitalnu zrelost je područje *1_Vodstvo, planiranje i upravljanje* koje je potrebno znatno unaprijediti kako bi postigla veća razina digitalne zrelosti VU.

Digitalna zrelost VU_31 prikazana je na *Slici 6.31.* VU_31 najveću digitalnu zrelost ima u području *7_IKT infrastruktura*. Područja *6_IKT kultura*, *5_Učenje i poučavanje uz podršku IKT-a*, *4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *3_Znanstveno-istraživački rad uz podršku IKT-a* i 2_Osiguranje kvalitete. Područje *1_Vodstvo, planiranje i upravljanje* imaju najmanju digitalnu zrelost. Sva područja potrebno je znatno unaprijediti kako bi se podigla razina zrelosti VU.

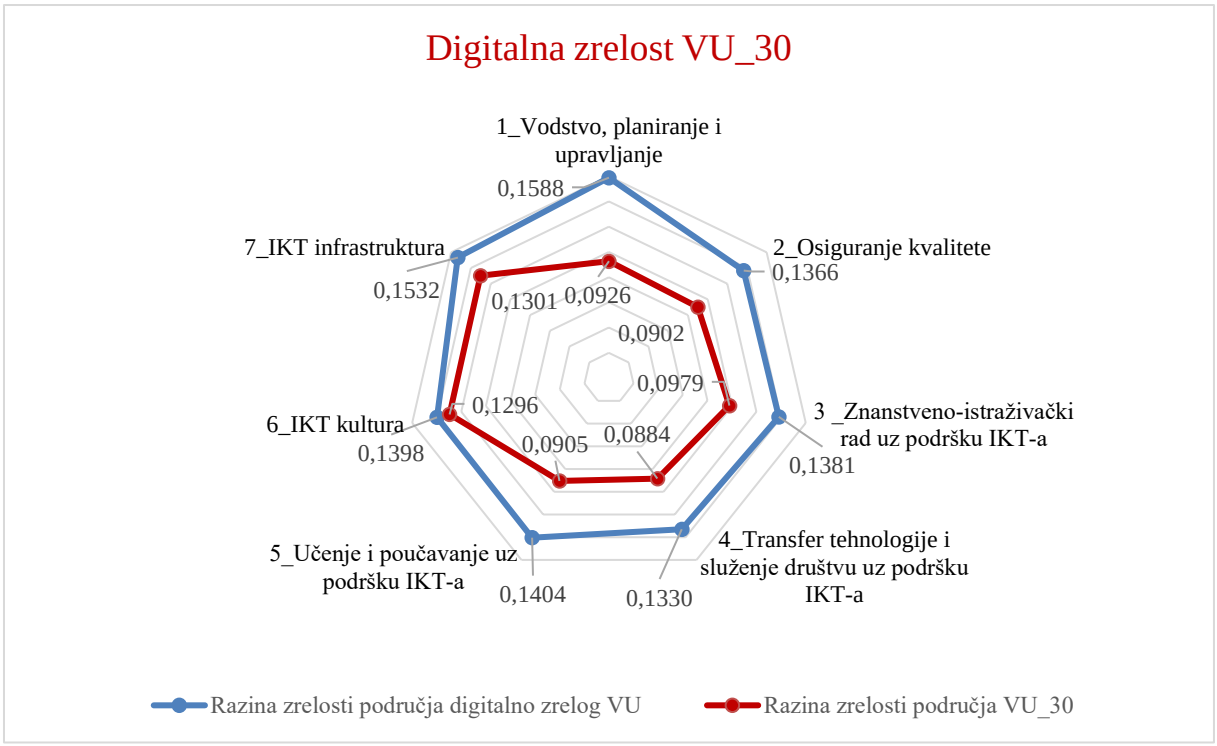

Slika 6.30: Digitalna zrelost VU_30

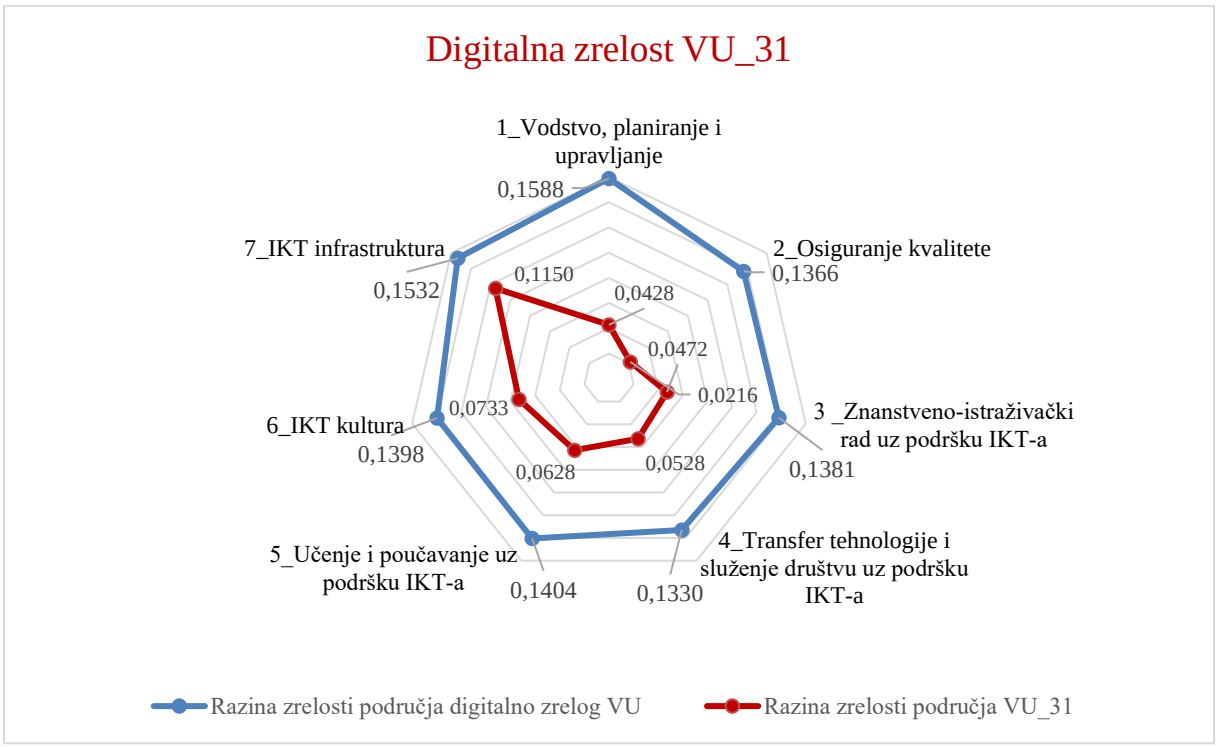

Slika 6.31: Digitalna zrelost VU_31

Digitalna zrelost VU_32 prikazana je na *Slici 6.32.* VU_32 najveću digitalnu zrelost ima u područjima *7_IKT infrastruktura i 5_Učenje i poučavanje uz podršku IKT-a*. Zatim slijede područja *6_IKT kultura, 4_Transfer tehnologije i služenje društvu uz podršku IKT-a* i *3_Znanstveno-istraživački rad uz podršku IKT-a*, dok područja *1_Vodstvo, planiranje i upravljanje* i *2_Osiguranje kvalitete* pokazuju najmanju razinu digitalne zrelosti i potrebu za unapređenjem kako bi se povećala razina zrelosti VU.

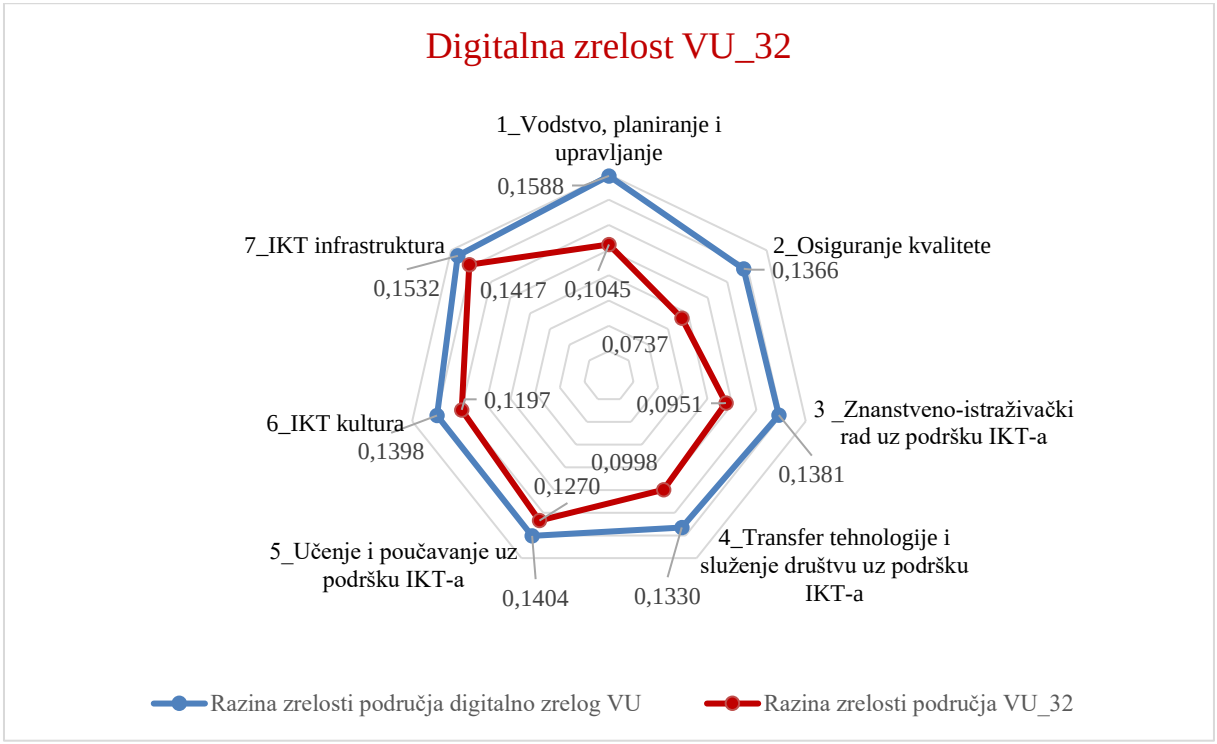

Slika 6.32: Digitalna zrelost VU_32

Digitalna zrelost VU_33 prikazana je na *Slici 6.33.* VU_33 najveću digitalnu zrelost ima u području *4_Transfer tehnologije i služenje društvu uz podršku IKT-a*, zatim slijede područja *5_Učenje i poučavanje uz podršku IKT-a, 1_Vodstvo, planiranje i upravljanje, 3_Znanstveno-istraživački rad uz podršku IKT-a* i *7_IKT infrastruktura i 6_IKT kultura.* Područje *2_Osiguranje kvalitete* je jedino područje koje nije digitalno zrelo te ga je potrebno unaprijediti kako bi postigli veću razinu digitalne zrelosti.

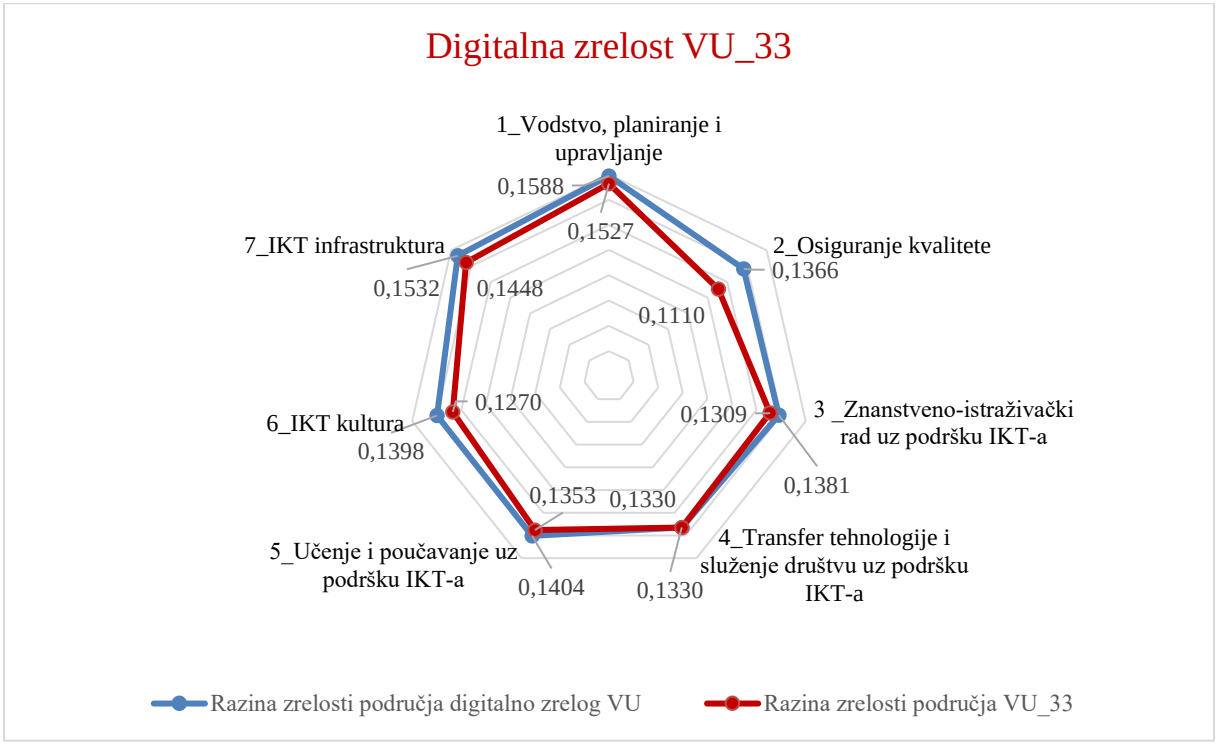

Slika 6.33: Digitalna zrelost VU_33

Životopis autorice

Valentina Đurek rođena je 11. ožujka 1974. u Zaboku gdje je završila Osnovnu školu K.Š. Gjalskog.

2003. diplomirala je na Fakultetu organizacije i informatike Sveučilišta u Zagrebu (FOI). U razdoblju od 2003. do 2011. radila je u Osnovnoj školi Matije Gupca u Gornjoj Stubici kao učiteljica informatike. 2011. završava poslijediplomski sveučilišni studij menadžmenta poslovnih sustava na FOI-u. Na istom fakultetu upisala je poslijediplomski doktorski studij. Od 2011. do 2017. radila je u Školi za umjetnost, dizajn, grafiku i odjeću u Zaboku kao profesorica stručnih informatičkih predmeta. Od 2017. do 2021. godine obnašala je dužnost zamjenice gradonačelnika Grada Zaboka. Od 2021. godine pročelnica je Upravnog odjela za EU fondove i strateške projekte Grada Zaboka.

Voditeljica je dva projekta kojima je nositelj Grad Zabok financiranih iz Europskog socijalnog fonda (MIPOS i MIPOS II), strateškog projekta Grada Zaboka – projekta re-GENERATOR financiranog iz Europskih strukturnih i investicijskih fondova. U razdoblju od 2019. do 2021. bila je predsjednica Lokalne akcijske grupe Zagorje-Sutla. Također, bila je članica raznih povjerenstava i radnih skupina, poput izrade Strategije razvoja Urbane aglomeracije Zagreb, Master plana gospodarskog razvoja Krapinsko-zagorske županije za razdoblje do 2027., Prometne studije Grada Zaboka, Plana razvoja Grada Zaboka 2021. – 2027. Bila je predsjednica Odbora za ekologije Grada Zaboka. Trenutno je predsjednica Odbora za kulturu Grada Zaboka i predsjednica Povjerenstva za ravnopravnost spolova Grada Zaboka. Članica je Upravnog vijeća Zagorske razvojne agencije i potpredsjednica Školskog odbora Srednje škole Zabok.

Autorica je i suautorica desetak znanstvenih i stručnih radova, od kojih je većina bila prezentirana na konferencijama (znanstvenim i stručnim).

Popis izdvojenih znanstvenih i stručnih radova:

[1] V. Đurek and C. Sedda, 'Primjena metoda odlučivanja u lokalnoj samoupravi', *Zb. Veleučilišta u Rijeci*, vol. 8, no. 1, pp. 203–226, Jun. 2020, doi: 10.31784/ZVR.8.1.20.

[2] V. Đurek, D. Oreški, and N. Kadoić, 'Hybrid approach based on multi-criteria decision making and machine learning in the public sector', B. Abstr. *17th International conference on operational research KOI 2020*, p. 38, 2020.

[3] V. Đurek, N. Begičević Ređep, and N. Kadoić, ‘Methodology for Developing Digital Maturity Model of Higher Education Institutions’, *J. Comput.*, vol. 14, no. 4, pp. 247–256, 2018.
[4] V. Đurek, N. Kadoić, and Ž. Dobrović, ‘Digital Maturity of Higher Education Institution: A meta model of the Analytical Network Process (ANP) and Decision EXpert (DEX)’, *Proceedings of Central European Conference on Information and Intelligent Systems 2018*, pp. 223–230, 2018.
[5] V. Đurek, N. Kadoić, and N. Begičević Ređep, ‘Assessing the Digital Maturity Level of Higher Education Institutions’, in *41st International Convention on Information and Communication Technology, Electronics and Microelectronics MIPRO 2018*, pp. 747–752, 2018.
[6] V. Đurek, N. Begičević Ređep, and B. Divjak, ‘Digital Maturity Framework for Higher Education Institutions’, *Proceedings of Central European Conference on Information and Intelligent Systems 2017*, pp. 99–106, 2017.
[7] V. Đurek and N. Begičević Ređep, ‘Review on e-readiness assessment tools’ *Proceedings of Central European Conference on Information and Intelligent Systems 2016*, pp. 161–169, 2016.
[8] V. Đurek, N. Begičević Ređep, and B. Divjak, Preconditions for the implementation of e-learning in primary school in the Republic of Croatia - Pupil's perspective, *Proceedings of the International Conference on Information Technology Interfaces, ITI*, University Computing Centre SRCE, University of Zagreb, 2012., pp. 183-188.

Znanstveni projekti

1. „HELA - Podizanje zrelosti visokih učilišta za implementaciju analitika učenja” Financira Hrvatska zaklada za znanost. Voditeljica projekta: prof. dr. sc. Nina Begičević Ređep. Trajanje projekta: ožujak 2021. – veljača 2025.

2. „Razvoj metodološkog okvira za strateško odlučivanje u visokom obrazovanju - primjer implementacije otvorenog učenja i učenja na daljinu – HigherDecision“. Financirano od strane Hrvatske zaklade za znanost. Voditeljica projekta: prof.dr.sc. Blaženka Divjak. Trajanje projekta: lipanj 2015. - svibanj 2019.