UNIVERZITET U SARAJEVU

EKONOMSKI FAKULTET

ZAVRŠNI RAD

ULOGA EMOCIONALNE I VJEŠTAČKE INTELIGENCIJE U UNAPREĐENJU RADNIH PERFORMANSI

Sarajevo, novembar 2024.

SAMIR DŽAFIĆ

U skladu sa članom 54. Pravila studiranja za I, II ciklus studija, integrisani, stručni i specijalstički studij na Univerzitetu u Sarajevu, daje se

I Z J A V A O A U T E N T I Č N O S T I R A D A

Ja, **Samir Džafić,** student drugog (II) ciklusa studija na Odsjeku **Menadžment**, broj index-a **5459 - 73680** smjer **Menadžment i informacione tehnologije**, izjavljujem da sam završni rad na temu:

ULOGA EMOCIONALNE I VJEŠTAČKE INTELIGENCIJE U UNAPREĐENJU RADNIH PERFORMANSI

pod mentorstvom **prof. dr. Amra Kapo** izradio/izradila samostalno i da se zasniva na rezultatima mog vlastitog istraživanja. Rad ne sadrži prethodno objavljene ili neobjavljene materijale drugih autora, osim onih koji su priznati navođenjem literature i drugih izvora informacija uključujući i alate umjetne inteligencije.

Ovom izjavom potvrđujem da sam za potrebe arhiviranja predao/predala elektronsku verziju rada koja je istovjetna štampanoj verziji završnog rada.

Dozvoljavam objavu ličnih podataka vezanih za završetak studija (ime, prezime, datum i mjesto rođenja, datum odbrane rada, naslov rada) na web stranici i u publikacijama Univerziteta u Sarajevu i Ekonomskog fakulteta.

U skladu sa članom 34. 45. i 46. Zakona o autorskom i srodnim pravima (Službeni glasnik BiH, 63/10) dozvoljavam da gore navedeni završni rad bude trajno pohranjen u Institucionalnom repozitoriju Univerziteta u Sarajevu i Ekonomskog fakulteta i da javno bude dostupan svima.

Sarajevo, 11.11.2024.g. Student

_____

Potpis studenta

SAŽETAK

Ovaj rad istražuje složenu i sve značajniju ulogu emocionalne i vještačke inteligencije u poboljšanju radnih performansi zaposlenika, s posebnim naglaskom na kontekst modernih poslovnih procesa u Bosni i Hercegovini. Razvoj savremenih tehnologija i sve veći izazovi u poslovanju nameću potrebu za istraživanjem kako ovi faktori mogu unaprijediti radnu učinkovitost. U istraživanju je primijenjena kvantitativna metodologija, dok su podaci putem ankete prikupljeni i analizirani koristeći tehniku modeliranja strukturnih jednačina (PLS-SEM) putem SmartPLS softvera.

Uzorak ispitanika obuhvata 210 zaposlenika iz različitih industrija i kompanija, a podaci su prikupljeni putem strukturiranog upitnika. Mjereni su uticaji emocionalne inteligencije, vještačke inteligencije, inovativnosti, tehnološke svijesti i percipiranog rizika na radnu učinkovitost. Rezultatima je utvrđeno da emocionalna inteligencija značajno pozitivno utiče na radnu učinkovitost kroz smanjenje stresa i povećanje zadovoljstva zaposlenika. Zaposlenici sa razvijenim emocionalnim kompetencijama pokazali su bolje performanse, naročito u složenim i stresnim situacijama.

Vještačka inteligencija se pokazala kao ključan faktor u optimizaciji poslovnih procesa, omogućavajući zaposlenicima da se fokusiraju na kreativnije i strateške zadatke. Primjena AI tehnologija u poslovanju dovela je do poboljšanja u donošenju odluka i povećanju efikasnosti timova. Inovativnost, kao jedan od važnih faktora, doprinosi radnoj učinkovitosti kroz poticanje kreativnosti i prilagodljivosti u radu. Zaposlenici koji rade u inovativnim okruženjima pokazali su veći nivo angažovanosti i produktivnosti. Tehnološka svijest zaposlenika, koja se odnosi na sposobnost prilagođavanja i usvajanja novih tehnologija, također ima pozitivan uticaj na radnu učinkovitost. Zaposlenici sa visokom tehnološkom sviješću lakše koriste moderne alate i prilagođavaju se brzim promjenama u poslovanju, što dovodi do poboljšanja ukupnih performansi zaposlenih. S druge strane, percipirani rizik se pokazao kao negativan faktor koji može ograničiti primjenu vještačke inteligencije na radnom mjestu. Visok nivo percipiranog rizika izaziva otpor među zaposlenicima prema novim tehnologijama, što može usporiti njihovu integraciju i smanjiti potencijalne koristi od vještačke inteligencije.

Zaključak rada sugeriše da je integracija emocionalne inteligencije i vještačke inteligencije ključna za unapređenje radne učinkovitosti u savremenim organizacijama. Menadžeri bi trebali posvetiti pažnju razvoju emocionalnih kompetencija zaposlenika, kao i primjenu AI tehnologija koje podržavaju radne procese. Ovo istraživanje je značajno za akademsku zajednicu kao i za stručnjake u oblasti menadžmenta i ljudskih resursa, posebno u kontekstu vještačke i emocionalne inteligencije. Ovaj rad doprinosi razumijevanju kako povezanost između EI i AI može unaprijediti radnu učinkovitost i pruža smjernice za dalje istraživanje i primjenu ovih tehnologija u poslovanju. Predložene strategije uključuju edukaciju zaposlenika, smanjenje percipiranog rizika i poticanje inovativnosti kao ključnih faktora za uspjeh u implementaciji novih tehnologija.

Ključne riječi: Emocionalna inteligencija (EI), vještačka inteligencija (AI), tehnološka svijest, inovativnost, radna učinkovitost, percipirani rizik, PLS-SEM, ljudski resursi, digitalna transformacija.

ABSTRACT

This paper explores the complex and increasingly significant role of emotional and artificial intelligence in improving employee work performance, with a particular focus on the context of modern business processes in Bosnia and Herzegovina. The development of modern technologies and the growing challenges in business highlight the need to investigate how these factors can enhance work efficiency. A quantitative methodology was applied in the research, and the collected data were analyzed using the structural equation modeling (PLS-SEM) technique through the SmartPLS software.

The sample consisted of 210 employees from various industries and companies, with data collected through a structured questionnaire. The study measured the impacts of emotional intelligence, artificial intelligence, innovation, technological awareness, and perceived risk on work performance. The results indicated that emotional intelligence significantly and positively affects work performance by reducing stress and increasing employee satisfaction. Employees with well-developed emotional competencies demonstrated better performance, especially in complex and stressful situations.

Artificial intelligence proved to be a key factor in optimizing business processes, enabling employees to focus on more creative and strategic tasks. The application of AI technologies in business led to improvements in decision-making and increased team efficiency. Innovation, as one of the important factors, contributes to work performance by fostering creativity and adaptability in the workplace. Employees working in innovative environments showed higher levels of engagement and productivity. Technological awareness, which refers to the ability to adapt to and adopt new technologies, also has a positive impact on work performance. Employees with high technological awareness more easily utilize modern tools and adapt to rapid changes in the business environment, leading to overall performance improvements. On the other hand, perceived risk was identified as a negative factor that can limit the application of artificial intelligence in the workplace. A high level of perceived risk creates resistance among employees toward new technologies, potentially slowing their integration and reducing the potential benefits of AI.

The paper concludes that the integration of emotional intelligence and artificial intelligence is crucial for enhancing work performance in modern organizations. Managers should focus on developing employees' emotional competencies and the application of AI technologies that support work processes. This research is significant for the academic community as well as for professionals in management and human resources, particularly in the context of digital transformation and increasingly complex work environments. The paper contributes to understanding how the connection between EI and AI can improve work performance and

provides guidelines for further research and the application of these technologies in business. The proposed strategies include employee education, reducing perceived risk, and promoting innovation as key factors for successful implementation of new technologies.

Key words: Emotional Intelligence (EI), Artificial Intelligence (AI), Technological Awareness, Innovation, Work Performance, Perceived Risk, PLS-SEM, Human Resources, Digital Transformation.

SADRŽAJ

SAŽETAK ..... **I**
ABSTRACT ..... **II**
POPIS ILUSTRACIJA ..... **V**
POPIS TABELA ..... **VI**
POPIS FIGURA ..... **VI**
POPIS SKRAĆENICA ..... **VI**
1. UVOD **1**
1.1. Problem i predmet istraživanja **1**
1.2. Svrha teze **3**
1.3. Ciljevi istraživanja **3**
1.4. Istraživačka pitanja **4**
1.5. Hipoteze istraživanja **4**
1.6. Konceptualni okvir istraživanja **5**
1.7. Metodologija istraživanja **6**
1.8. Struktura rada **7**
2. PREGLED LITERATURE **7**
2.1. Emocionalna inteligencija i radna učinkovitost **7**
2.1.1. Definicije i modeli emocionalne inteligencije 7
2.1.1.1. Model Mayera i Saloveya *9*
2.1.1.2. Bar-Onov model *11*
2.1.1.3. Golemanov model *11*
2.1.2. Radna učinkovitost u poslovanju 13
2.2. Vještačka inteligencija i njena integracija u poslovne procese **16**
2.2.1. Historija vještačke inteligencije 16
2.2.2. Mašinsko učenje 20
2.2.3. Duboko učenje 21
2.2.4. Neuronske mreže 22
2.3. Primjena vještačke inteligencije u poslovanju **23**
2.3.1. Prednosti vještačke inteligencije u poslovanju 27
2.4. Inovativnost i radna učinkovitost **29**
2.4.1. Teorijski okviri i različiti pristupi razumijevanju inovativnosti 29
2.4.2. Faktori koji podstiču inovativnost u organizacijama 31
2.5. Tehnološka svijest i radna učinkovitost **32**
2.5.1. Značaj tehnološke svijesti u savremenom poslovanju 33

2.5.2. Edukacija i razvoj tehnoloških vještina 33
2.5.3. Uticaj tehnološke svijesti na performanse zaposlenih 33
2.6. Percipirani rizik i prihvatanje vještačke inteligencije 34
2.6.1. Razumijevanje percipiranog rizika 34
2.6.2. Strahovi i izazovi percipiranog rizika vezani uz primjenu vještačke inteligencije 35
2.6.3. Strategije za smanjenje percipiranog rizika 36
3. EMPIRIJSKO ISTRAŽIVANJE 37
3.1. Metodologija 37
3.2. Analiza podataka 41
3.2.1. Demografski podaci 41
3.1.1. Analiza upitnika 47
3.1.1.1. Konvergentna validnost 52
3.1.1.2. Diskriminativna validnost 53
3.1.1.3. Analiza hipoteza 55
3.3. Interpretacija rezultata 59
4. ZAKLJUČAK 60
4.1. Ograničenja i preporuke 61
REFERENCE 62
PRILOZI 1

POPIS ILUSTRACIJA

Ilustracija 1 Golemanov model emocionalne inteligencije 12
Ilustracija 2 Koncepualni model 38
Ilustracija 3 Podatak o spolu ispitanika Izvor: Google Forms 41
Ilustracija 4 Starosna struktura ispitanika Izvor: Google Forms 42
Ilustracija 5 Nivo obrazovanja ispitanika Izvor: Google Forms 42
Ilustracija 6 Tip industrije 43
Ilustracija 7 Pozicija zaposlenog u kompaniji ili instituciji Izvor: Google Forms 43
Ilustracija 8 Iskustvo korištenja računara i IT alata Izvor: Google Forms 44
Ilustracija 9 Radno iskustvo zaposlenog Izvor: Google Forms 44
Ilustracija 10 Iskustvo korištenja AI tehnologija Izvor: Google Forms 45
Ilustracija 11 Iskustvo korištenja ChatGPT-a ili drugih AI alata Izvor: Google Forms 45
Ilustracija 12 Stanje emocionalne inteligencije Izvor: Google Forms 46
Ilustracija 13 Radna učinkovitost Izvor: Google Forms 46
Ilustracija 14 Lično zadovoljstvo Izvor: Google Forms 47
Ilustracija 15 Tip inteligencije Izvor: Google Forms 47

POPIS TABELA

Tabela 1 Interna konzistentnost mjernog modela 51
Tabela 2 Opterećenje indikatora (outer loading) 53
Tabela 3 Diskriminativna validnost - HTMT kriterij 54
Tabela 4 Diskriminativna validnost - Fornell i Lacker kriterij 55
Tabela 5 Odnos hipoteza 55
Tabela 6 Testiranje hipoteza 56
Tabela 7 Intervali povjerenja Izvor: SmartPLS 57

POPIS FIGURA

Figure 1 Grafički prikaz odnosa hipoteza Izvor: SmartPLS 56
Figure 2 Utjecaj varijabli Izvor: SmartPLS 57
Figure 3 Prikaz distribucije varijabli 58

POPIS SKRAĆENICA

EI – emocionalna inteligencija

AI – vještačka inteligencija

PLSM – metoda parcijalnih najmanjih kvadrata

ADHD – poremećaj hiperaktivnosti i deficita pažnje

LISP – prvi jezik vještačke inteligencije

GUI – grafički korisnički interfejs

HTMT – Heterotrait-monotrait kriterij

HR – ljudski resursi

1. UVOD

1.1. Problem i predmet istraživanja

U savremenim organizacijama, digitalna transformacija i sve složenija radna okruženja donose brojne izazove koji utiču na radne performanse zaposlenika. Savremeno poslovno okruženje je jasno okarakterizirano rastućim zahtjevima za efikasnošću, zadovoljstvom zaposlenika i produktivnošću. Emocionalna inteligencija (EI) i vještačka inteligencija (engl. Artificial intelligence, AI) se često posmatraju kao ključni faktori koji mogu unaprijediti radnu učinkovitost, ali njihov uticaj još uvijek nije dovoljno istražen i shvaćen. Uloga vještačke inteligencije (AI) i emocionalne inteligencije (EI) predstavlja inovativan pristup u savremenom poslovanju, koji ima za cilj unapređenje performansi zaposlenih kroz sinergiju emocionalnih i kognitivnih sposobnosti. Stoga, ovo područje je vrlo interesantno za istraživanje, te implikacije studija mogu poslužiti i praktičarima i teoretičarima. Empirijske studije pokazuju da primjena EI i AI može dovesti do značajnog unapređenja radnih performansi. Recimo, Kaplan i Haenlein (2019) ističu da AI sistemi sa integrisanom EI mogu poboljšati korisničko iskustvo, smanjiti stres zaposlenih i povećati njihovu angažovanost i zadovoljstvo na radu. Slična istraživanja podržavaju i druge studije koje ukazuju na to da EI može igrati ključnu ulogu u razvoju AI tehnologija koje su više prilagođene ljudskim potrebama i očekivanjima. Postoje različite definicije i konceptualizacije emocionalne inteligencije u literaturi, pri čemu svaka od njih ima malo sličnosti sa drugima. Teorijski okviri i modeli koji podupiru konceptualizacije EI proističu iz jednog od dva pristupa koji su davno utemeljeni; kao oblik čiste inteligencije koji se sastoji isključivo od kognitivnih sposobnosti (Mayer i Salovey, 1997), ili kao mješovite inteligencije, koja se sastoji od kognitivnih sposobnosti i aspekata ličnosti, pri čemu se razlike pripisuju različitim shvatanjima o tome šta čini EI (Bar-On, 1997; Goleman, 1998). Ova dva pristupa, iako različita, više su komplementarna nego kontradiktorna. EI ima potencijal da objasni dio preostale varijanse u predviđanju radnog učinka i uspjeha u karijeri, koji nisu objašnjeni tradicionalnom inteligencijom (Prentice *et al*., 2020). U radnim okruženjima, utvrđeno je da EI utiče na širok spektar stavova i ponašanja na poslu. Za razliku od toga, vještačka inteligencija se odnosi na računske sisteme sposobne za obavljanje zadataka koji obično zahtijevaju ljudsku inteligenciju, kao što su prepoznavanje dokumenata, učenje, donošenje odluka i komunikacija (Russell i Norvig, 2016). Generalno, AI se koristi za automatizaciju dosadnih i repetitivni zadataka. Na osnovu četiri taksonomije analitičke inteligencije (mehanička, analitička, intuitivna i empatična inteligencija) koju su predložili Huang i Rust (2018), Wirtz *et al*. (2018) intuitivno razumijevanje pružanja usluga na osnovu složenosti emocionalnih i kognitivnih zadataka. Vještačka inteligencija se može operacionalizovati kroz različite dimenzije koje ukazuju na kvalitet informacija i sistema (Wixom i Todd, 2005), i to: pouzdanost (stepen do kojeg je rad sistema pouzdan), fleksibilnost (stepen do kojeg se sistemi prilagođavaju promjenjivim zahtjevima korisnika), integritet (stepen do kojeg sistemi integrišu podatke iz različitih izvora), pristupačnost (stepen do kojeg su informacije lako dostupne), pravovremenost (stepen do kojeg sistemi pružaju pravovremene

odgovore na zahtjeve), sveobuhvatnost (stepen do kojeg sistemi pružaju potrebne informacije), tačnost (stepen do kojeg sistemi pružaju tačne informacije), format (stepen do kojeg su informacije dobro predstavljene) i aktuelnost (stepen do kojeg su informacije ažurirane). Dimenzije vještačke inteligencije zajedno odražavaju percepciju zaposlenih o kvalitetu vještačke inteligencije. Prethodna literatura je pokazala da ove dimenzije kvaliteta informacija i sistema mogu rezultirati pozitivnim stavovima pojedinaca prema tehnologiji i olakšati radne rezultate zaposlenih (Wixom i Todd, 2005). Vještačka inteligencija može olakšati i unaprijediti rad zaposlenih interpretacijom pitanja korisnika (npr. prevođenje jezika), pretraživanjem poslovnih sistema znanja i pripremom odgovora prilagođenih ljudima (Kirkpatrick, 2017). Vještačka inteligencija postaje posrednik u poboljšanju radnih performansi zaposlenika. Zaposleni sa višim EI obično postižu bolje rezultate kada je AI slabije ocijenjen. Takođe, rezultati pokazuju da zaposleni koji visoko ocjenjuju AI, a nisko EI, ne postižu bolje rezultate od onih koji visoko ocjenjuju EI, a nisko AI (Prentice *et al.*, 2020).

Usvajanjem i implementacijom AI u poslovnim procesima, najveći izazov s kojim se organizacije suočavaju je njena veza sa emocionalnom inteligencijom (Sharma i Kaur, 2021). Neosporno je da kako se sve više tehnologije uvodi, postaje dvostruki proces. Ljudi se obučavaju da rade sa tehnologijom, a tehnologija se uči kako da se odnosi prema ljudima. Tehnologije zasnovane na AI alatima su vješte u savladavanju ljudskih kognitivnih sposobnosti koje jednostavni softveri mogu razumjeti, ali emocionalna inteligencija je jedno područje gdje je AI još uvijek u početnim fazama, što EI čini najvažnijom vještinom u današnjem poslovnom okruženju. Iako automatizovani sistemi omogućavaju personalizovanija i interaktivnija HR iskustva i za poslodavca i za zaposlenog, u ovoj digitalnoj transformaciji, težak posao je na nama, analognim ljudima. Osnovni problem koji se razmatra u ovom radu odnosi se na istraživanje uloge emocionalne inteligencije i vještačke inteligencije kroz njihov doprinos unapređenju efikasnosti, zadovoljstvu i produktivnosti zaposlenih u organizacijama koje implementiraju napredne informacione tehnologije za njihovu bolju radnu učinkovitost. Postoji potreba za dubljim razumijevanjem kako EI i AI mogu zajedno doprinijeti poboljšanju radnih performansi zaposlenika. Takođe, neophodno je istražiti dodatno i faktore koji utiču na uspješnost primjene ovih tehnologija, kao što su inovativnost, tehnološka svijest i percipirani rizik.

Dosadašnje studije su vrijedna osnova za nastavak istraživanja ove teme, obzirom da pružaju ključne uvide kao smjernice koje su ujedno predmet i problem ovog master rada. Smith *et al.* (2021) istražuju kako integracija emocionalne inteligencije (EI) u sisteme vještačke inteligencije (AI) utiče na poslovne performanse zaposlenih. Anketirajući 500 zaposlenih u tehnološkim kompanijama, autori su otkrili da AI sistemi koji su obogaćeni EI mogu značajno poboljšati efikasnost i zadovoljstvo zaposlenih. Konkretno, sposobnost AI sistema da prepoznaju i odgovore na emocionalne signale zaposlenih smanjuje nivo stresa i povećava angažovanost na poslu. Ovi rezulatati istraživanja naglašavaju važnost obuke AI sistema za upravljanje emocijama, što može unaprijediti radno okruženje i ukupne performanse kompanije. Jones i Brown (2020) istražuju kako AI i EI utiču na zadržavanje zaposlenih i

njihovu produktivnost. Koristeći longitudinalnu studiju u velikim korporacijama, autori su identifikovali da AI sistemi sa integrisanim EI funkcijama smanjuju fluktuaciju zaposlenih i povećavaju produktivnost. Specifično, AI sistemi koji razumiju emocionalne potrebe zaposlenih mogu pružiti pravovremenu podršku i poboljšati radno iskustvo. Ovi rezultati su ključni za HR odjele koji bi trebali implementirati EI u AI sisteme kako bi podržali zaposlenike i ojačali njihovu lojalnost prema kompaniji. Rogers *et al*. (2019) istražuje kako emocionalna inteligencija i vještačka inteligencija utiče na performanse zaposlenih. Kroz eksperimentalnu studiju u različitim industrijama, autori su utvrdili da AI sistemi obogaćeni EI sposobnostima poboljšavaju radne performanse zaposlenih. Zaposlenici koji koriste AI sisteme, a koji razumiju njihova emocionalna stanja pokazuju bolje rezultate u izvršavanju zadataka, donošenju odluka, kreativnosti i inovativnosti.

U konačnici, rad nastoji riješiti niz aktuelnih izazova koje organizacije imaju u kontekstu digitalne transformacije i sve složenijih radnih okruženja. Osim toga, cilj je doprinijeti razumijevanju kako upotreba vještačke inteligencije zajedno sa emocionalnom inteligencijom može biti uspješno primijenjena za unapređenje radnih performansi. Tema je od značaja za menadžere, tehnološke stručnjake i istraživače koji se bave razvojem AI tehnologija i upravljanjem ljudskim resursima. Kroz kombinaciju teorijskih i empirijskih istraživanja, rad će ponuditi dublje uvide u potencijalne koristi, ali i izazove koje donose emocionalna i vještačka inteligencija u poslovnom kontekstu, te preporuke za praksu i dalja istraživanja.

1.2. Svrha teze

Svrha ove teze je istražiti kako emocionalne inteligencije i vještačke inteligencije može unaprijediti poslovni performans zaposlenika tj. radnu učinkovitost. Fokusirajući se na ključne aspekte kao što su emocionalna inteligencija, vještačka inteligencija, inovativnost, tehnološka svijest i percipirani rizik, ovaj rad ima za cilj da pruži sveobuhvatno razumijevanje faktora koji utiču na radnu učinkovitost. Kroz analizu uticaja emocionalne inteligencije i vještačke inteligencije, te istraživanje njihovog međusobnog odnosa, ova teza teži da doprinese teorijskom i praktičnom znanju u oblasti poslovne učinkovitosti i tehnološkog razvoja.

1.3. Ciljevi istraživanja

Osnovni cilj ovog istraživanja je ispitati na koje načine emocionalna inteligencija (EI) i vještačka inteligencija (AI) mogu doprinijeti unapređenju radnih performansi zaposlenika. Također, neki od dodatnih ciljeva obuhvataju:

- Analizirati uticaj emocionalne inteligencije na radnu učinkovitost zaposlenika i istražiti kako različiti aspekti emocionalne inteligencije (samosvijest, samoupravljanje, društvena svijest i upravljanje odnosima) utiču na radnu učinkovitost kao i identifikovati konkretne primjere gdje je emocionalna

inteligencija doprinijela poboljšanju radne učinkovitosti.

- Ispitati doprinos vještače inteligencije (AI) radnoj učinkovitosti zaposlenika i analizirati kako primjena AI tehnologija može povećati efikasnost i produktivnost na radnom mjestu, te istražiti primjere iz prakse gdje je implementacija AI pozitivno uticala na radnu učinkovitost.

- Ispitati uticaj inovativnosti na radnu učinkovitost zaposlenika i identifikovati načine na koje inovativnost u radu doprinosi većoj efikasnosti i efektivnosti zaposlenog.

- Utvrditi značaj tehnološke svijesti za radnu učinkovitost zaposlenika i istražiti koliko je važno da zaposlenici budu tehnološki svjesni i osposobljeni za korištenje modernih tehnologija.

- Ispitati uticaj percipiranog rizika na primjenu vještačke inteligencije na radnom mjestu i istražiti kako percipirani rizik utiče na spremnost zaposlenika da prihvate i koriste AI tehnologije.

1.4. Istraživačka pitanja

Iz predmeta istraživanja proizlaze sljedeća istraživačka pitanja:

- Kako emocionalna inteligencija (EI) utiče na radnu učinkovitost zaposlenika?
- Na koji način vještačka inteligencija (AI) doprinosi radnoj učinkovitosti zaposlenika?
- Kako inovativnost zaposlenika utiče na njihovu radnu učinkovitost?
- U kojoj mjeri tehnološka svijest zaposlenika utiče na njihovu radnu učinkovitost?
- Na koji način percipirani rizik utiče na primjenu vještačke inteligencije na radnom mjestu?

1.5. Hipoteze istraživanja

Hipoteze su pretpostavke koje će biti istražene i analizirane putem prikupljanja i interpretacije relevantnih podataka i literature, s ciljem odgovora na postavljena istraživačka pitanja i ostvarivanja ciljeva rada. U nastavku su navedene hipoteze:

H1: Emocionalna inteligencija pozitivno utiče na radnu učinkovitost.

H2: Vještačka inteligencija pozitivno utiče na radnu učinkovitost.

H3: Inovativnost pozitivno utiče na radnu učinkovitost.

H4: Tehnološka svijest pozitivno utiče na radnu učinkovitost.

H5: Percipirani rizik negativno utiče na vještačku inteligenciju na radnom mjestu.

1.6. Konceptualni okvir istraživanja

U nastavku se navode pojašnjenja hipoteza istraživanja sa ciljem elaboracije i razumijevanja njihovog značaja za sam proces istraživanja:

► H1: Emocionalna inteligencija pozitivno utiče na radnu učinkovitost

Emocionalna inteligencija (EI) se pokazala ključnim faktorom u poboljšanju radne učinkovitosti zaposlenika kroz različite aspekte radnog okruženja. Studija od Goleman *et al.* (2013) pokazala je da visoki nivoi EI kod menadžera značajno poboljšavaju performanse tima kroz bolje rukovođenje konfliktnim situacijama i povećanu emocionalnu stabilnost. Druga istraživanja, poput onog od Wong i Law (2002), ukazuju na to da EI direktno utiče na zadovoljstvo poslom i organizacijsku predanost, što su ključni indikatori radne učinkovitosti. Takođe, Mayer *et al.* (2008) identifikuju pozitivnu korelaciju između EI i efikasnog donošenja odluka, što je ključno za visok nivo radne performanse. Konačno, istraživanje od Boyatzis (2018) sugeriše da EI omogućava zaposlenicima bolju adaptaciju na promjene, čime se dodatno poboljšava njihova radna učinkovitost.

► H2: Vještačka inteligencija (AI) pozitivno utiče na radnu učinkovitost

Korištenje vještačke inteligencije (AI) u poslovnim procesima značajno unapređuje radnu učinkovitost kroz automatizaciju zadataka i poboljšanje analitičkih sposobnosti. Studija od Brynjolfsson i McAfee (2014) pokazala je da AI tehnologije omogućavaju zaposlenicima da se fokusiraju na kreativnije i složenije zadatke, dok automatizacija preuzima rutinske poslove. Istraživanje od Davenport i Ronanki (2018) ukazuje na to da implementacija AI sistema poboljšava donošenje odluka kroz bolje i brže analize velikih podataka. Takođe, Bessen (2019) ističe da AI može značajno poboljšati produktivnost u sektorima kao što su proizvodnja i zdravstvo, što direktno doprinosi ukupnoj radnoj učinkovitosti. Istraživanje od Jarrahi (2018) dodatno naglašava važnost AI u unapređenju kolaborativnog rada i komunikacije među zaposlenicima, što pozitivno utiče na timsku efikasnost.

► H3: Inovativnost pozitivno utiče na radnu učinkovitost

Inovativnost unutar organizacija značajno doprinosi povećanju radne učinkovitosti kroz unapređenje procesa, proizvoda i usluga. Studija od Damanpour (1991) pokazala je da inovativne organizacije imaju tendenciju bržeg rasta i bolje prilagodbe tržišnim promjenama, što direktno povećava njihovu operativnu efikasnost. Istraživanje od Calantone *et al.* (2002) potvrđuje da inovativna kultura unutar kompanije poboljšava kolektivnu kreativnost i motivaciju zaposlenika, što rezultira višim nivoima radne učinkovitosti. Također, Tushman i O'Reilly (2013) ističu da organizacije koje uspješno balansiraju između eksploatacije postojećih resursa i istraživanja novih mogućnosti postižu bolje performanse. Istraživanje od West i Anderson (1996) pokazuje da timovi s visokim nivoom inovativnosti postižu bolje rezultate kroz poboljšanu saradnju i razmjenu znanja.

► H4: Tehnološka svijest pozitivno utiče na radnu učinkovitost

Tehnološka svijest među zaposlenicima značajno doprinosi radnoj učinkovitosti kroz bolje korištenje dostupnih alata i resursa. Studija od Tarafdar *et al*. (2019) pokazala je da tehnološki pismeni zaposlenici imaju veću sposobnost prilagođavanja i usvajanja novih tehnologija, što poboljšava njihovu radnu produktivnost. Istraživanje od Parasuraman (2000) ukazuje na to da visok nivo tehnološke svijesti smanjuje otpor prema promjenama i povećava efikasnost rada kroz bolju integraciju tehnoloških rješenja. Takođe, istraživanje od Venkatesh *et al*. (2003) identifikuje pozitivnu korelaciju između tehnološke svijesti i korisničke efikasnosti, što doprinosi ukupnoj radnoj učinkovitosti. Istraživanje od Devaraj i Kohli (2003) potvrđuje da organizacije koje ulažu u tehnološko obrazovanje zaposlenika postižu bolje operativne rezultate i veću konkurentnost.

► H5: Percipirani rizik negativno utiče na vještačku inteligenciju na radnom mjestu.

Percipirani rizik značajno utiče na stavove i ponašanja zaposlenika prema novim tehnologijama, uključujući vještačku inteligenciju (AI). Prema Charlwood i Guenole (2022), visok nivo percipiranog rizika može smanjiti razumijevanje i prihvatanje AI, dok Shi, Gong i Gursoy (2021) naglašavaju da zaposleni koji osjećaju rizik oklijevaju da prihvate novitete, što može ometati efikasnost obuke i razvoja. Sagheer *et al*. (2022) ističe da percipirani rizik može ograničiti spremnost na korištenje AI tehnologija. Da bi se uspješno integrisale AI tehnologije, ključno je smanjenje percipiranog rizika putem edukacije, transparentnosti i stvaranja kulture povjerenja (Chatterjee *et al*., 2022).

1.7. Metodologija istraživanja

U ovom radu predlaže se kvantitativni istraživački pristup zasnovan na primarnim podacima prikupljenim iz unaprijed definisanog uzorka. Podaci će biti prikupljeni putem upitnika, a dobiveni rezultati će se obraditi primjenom modeliranja strukturnih jednačina, sa ciljem analize odnosa između izmjerenih varijabli i latentnih konstrukata.

Uzorak ispitanika obuhvatit će najmanje 200 zaposlenika koji su zaposleni u kompanijama ili institucijama. Za obradu anketa koristit će se ranije navedene statističke metode, dok će za analizu i prikaz prikupljenih podataka biti korišten Excel, u kojem će biti izrađeni grafikoni radi jasnijeg prikaza rezultata. Također će biti primijenjeni drugi alati za prikaz kvantitativnih podataka, uz korištenje statističkog softvera Smart PLS. Tokom istraživanja primjenjivat će se sinergija teorije i prakse, pri čemu će praksa biti utemeljena na naučnim saznanjima, dok će se nauka potvrđivati kroz praktičnu primjenu. U tom procesu, koristi će se relevantna literatura zajedno s empirijskim analizama iz postojećih istraživačkih radova, uz oslanjanje na savremene domaće i strane literature, te uključivanje sekundarnih podataka.

1.8. Struktura rada

Uvodni dio rada će temeljito predstaviti problem i predmet istraživanja, zajedno s glavnim ciljevima, istraživačkim pitanjima i hipotezama zbog kojih će biti doneseni relevantni zaključci, te opisom metodologije istraživanja. Zatim se nastavlja pregled literature, koji će obuhvatiti nekoliko ključnih oblasti, s posebnim naglaskom na integraciju emocionalne inteligencije (EI) i vještačke inteligencije (AI) u kontekstu radnog performansa, kao i na druge faktore koji utiču na radnu učinkovitost.

Uz pregled postojećih saznanja, biti će predstavljena i veza između nezavisnih varijabli (emocionalna inteligencija (EI), vještačka inteligencija (AI), inovativnost, tehnološka svijest i percipirani rizik) sa zavisnim varijablama (radna učinkovitost i vještačka inteligencija AI).

Najprije je prikazan kontekst istraživanja, nakon čega slijede opis korištenog mjernog modela, postupak prikupljanja podataka i predstavljanje dobivenog uzorka. U dijelu posvećenom empirijskoj analizi, kako bi se teorijski dio praktično potvrdio, interpretirat će se problemi i ciljevi istraživanja, hipoteze, podaci i varijable, kao i korišteni model i metodologija istraživanja.

Nakon toga slijedi analiza prikupljenih podataka i razmatranje rezultata. U zaključnom dijelu bit će predstavljeni najvažniji rezultati ovog istraživanja proizašli iz postavljenih hipoteza, uz njihovu diskusiju i analizu. Također, bit će navedena ograničenja kao i ponuđene preporuke za daljnja istraživanja. Diskusija će se fokusirati na značaj dobivenih nalaza za teoriju i praksu, ističući praktične primjere istraživanja. Zaključni dio će sažeti glavne nalaze istraživanja, naglasiti njihov značaj za teoriju i praksu, te predložiti smjernice za buduća istraživanja u oblasti emocionalne i vještačke inteligencije u kontekstu unapređenja radne učinkovitosti zaposlenika.

2. PREGLED LITERATURE

2.1. Emocionalna inteligencija i radna učinkovitost

2.1.1. Definicije i modeli emocionalne inteligencije

Inteligencija je mentalna sposobnost koja uključuje moć rasuđivanja, predviđanja, rješavanja problema, apstraktno mišljenje, shvaćanje složenih ideja, brzo učenje i korištenje iskustava. Inteligencija nije samo povezana s učenjem u školi ili akademskom kontekstu, već je mnogo širi pojam koji obuhvata dublje razumijevanje svijeta oko nas. Zahvaljujući inteligenciji, stvari i situacije dobijaju smisao, što dovodi do praktičnih rješenja. Za inteligenciju može se reći da je to moć snalaženja u novonastalim sitacijama.

Pojam "između ostalog" u definiciji dijeli inteligenciju na racionalnu koja se odnosi na mentalne funkcije i emocionalnu koja djeluje na razini osjećaja. Iako se općenito vjeruje da

ljudi djeluju na temelju razuma, mnoga istraživanja su pokazala da su emocije, odnosno osjećaji, glavni pokretači ljudskih akcija i odluka. Emocije su ključne u privatnom i poslovnom životu. One su složeni subjektivni, biološki, svrhoviti i socijalni fenomen koji utiče na misli, ponašanje i odnose.

Emocionalna inteligencija pruža odgovore na izazove i pomaže u prilagođavanju kompleksnim situacijama. U poslovnom svijetu, prepoznavanje i upravljanje emocijama je neophodno za uspjeh. Lideri koji su svjesni emocija, kako svojih tako i emocija drugih, mogu povećati produktivnost i angažman zaposlenika. Empatičnost, odnosno razumijevanje drugih je ključna za uspješnu saradnju i vođenje. Kognitivna, emocionalna i suosjećajna empatija igraju važnu ulogu u stvaranju bliskih odnosa i postizanju ciljeva unutar organizacije. Empatični lideri su sposobni slušati, razumjeti i podržavati svoje timove, stvarajući pozitivnu radnu atmosferu i postižući uspješne rezultate, što je od ključne važnosti za svako uspješno poslovanje (Šafarić i Vuković, 2024).

Emocionalna inteligencija (EI) odnosi se na sposobnost prepoznavanja, pravilnog izražavanja i procjene emocija, zatim na razumijevanje emocionalnih stanja i znanja, te na regulaciju emocija kako bi se potaknuo emocionalni i intelektualni razvoj (Mayer *et al.*, 2008).

Psiholozi Mayer i Salovey su početkom dvadesetih godina uveli definiciju koncepta tadašnje emocionalne inteligencije. Iako njihova definicija nije odmah bila prihvaćena među ostalim psiholozima, oni su nastavili razvijati svoju definiciju i model emocionalne inteligencije. Njihov značajan doprinos igrao je ključnu ulogu u dubljem razumevanju koncepta emocionalne inteligencije. Razvijajući svoj model, Mayer i Salovey su došli do zaključka da emocionalna inteligencija obuhvata raznovrsne kognitivne funkcije povezane s emocijama, uključujući sposobnost prepoznavanja, interpretacije i regulacije emocionalnih informacija. Ovaj model ističe važnost emocionalnih vještina u svakodnevnom životu, kao i njihovu ulogu u donošenju odluka i međuljudskim interakcijama. Različite mentalne sposobnosti razvijaju se tokom godina kroz sticanje iskustava, a smatra se da nisu povezane s talentom, ličnošću ili karakterom pojedinca. Prema Mayeru i Saloveyu (1990), emocionalna inteligencija obuhvata četiri ključne sposobnosti: emocionalnu percepciju, poboljšano emocionalno zapažanje, razumijevanje emocija i emocionalno upravljanje. Mayer i Salovey su sproveli mnoga istraživanja o emocionalnoj inteligenciji, ali nisu uspjeli u potpunosti objasniti ovaj koncept široj javnosti.

Daniel Goleman je 1995. godine objavio knjigu o emocionalnoj inteligenciji, nakon čega je ovaj pojam postao popularan. Goleman je razvio i prilagodio definiciju te model Mayera i Saloveya, uključivši motivaciju i ustrajnosti kao bitne elemente, čime je omogućio bolje razumijevanje emocionalne inteligencije. Goleman (1995) ističe da se emocionalna inteligencija razvija kroz četiri ključne dimenzije. Dimenzije obuhvataju prepoznavanje i upravljanje vlastitim emocijama, samomotivaciju, empatiju prema drugima i društvene vještine (Ilić, 2008).

Različiti teoretičari su emocionalnu inteligenciju definisali na različite načine, a u tom kontekstu mogu se izdvojiti tri glavna modela: model sposobnosti, mješoviti model i model osobina. Prema teoretičarima poput Bar-Ona i Golemana, emocionalna inteligencija se može smatrati nekognitivnom. U opštem smislu, postojeći modeli emocionalne inteligencije opisuju je kroz prizmu lične inteligencije (koja obuhvata razumijevanje, upravljanje i korištenje vlastitih emocija) i socijalne inteligencije (koja se fokusira na prepoznavanje i upravljanje emocijama drugih) (Hercigonja, 2018).

Različito definisanje emocionalne inteligencije koje su definisali vodeći teoretičari doprinijele su razvojem različitih modela ovog koncepta. Ove različite definicije su omogućile dublje razumijevanje emocionalne inteligencije i njene kompleksnosti, što je rezultiralo različitim pristupima i interpretacijama unutar akademske zajednice. (Mayer *et al*., 2008).

2.1.1.1. Model Mayera i Saloveya

Najistaknutiji model emocionalne inteligencije je onaj koji su razvili Mayer i Salovey, po kojem je i dobio naziv, a često se naziva i modelom sposobnosti. Prva verzija ovog modela iz 1990. godine obuhvatala je tri nivoa sposobnosti, a to su: (Hercigonja, 2018)

- Prepoznavanje i izražavanje emocija vlastitih i tuđih
- Upravljenje emocijama kod sebe i drugih
- Primjena emocija u adaptivne svrhe.

Teorijske osnove Mayer-Saloveyeva modela emocionalne inteligencije nastale su na temelju rezultata istraživanja u oblasti razvojne, socijalne i psihologije ličnosti. Ova istraživanja ukazuju na to da emocije imaju značajan uticaj na različite kognitivne procese, uključujući percepciju, pamćenje i razne strategije u rješavanju problema, čime se potvrđuje složenost interakcije između emocija i kognicije (Hajncl i Vučenović, 2013).

Prema Mayeru i Saloveyu, model koji su predložili često se naziva modelom sposobnosti. Autori su sugerisali formiranje jedinstvenog koncepta zavisnih elemenata kognitivno definisane emocionalne inteligencije.U njihovoj prvobitnoj definiciji, emocionalna inteligencija se opisuje kao sposobnost prepoznavanja vlastitih emocija i emocija drugih, razlikovanja između njih te korištenja tih informacija za vođenje misli i ponašanja (Mayer i Salovey, 1990). U ovoj definiciji fokus je bio samo na percepciji i upravljanju emocijama, dok je aspekt promišljanja o osjećajima zanemaren. Zbog toga su autori prethodne definicije predložili njenu reviziju (Takšić *et al*., 2006).

Emocionalna inteligencija podrazumijeva i vještinu brzog uočavanja, procjene i prikazivanja emocija, sposobnost prepoznavanja i stvaranja osjećanja koji doprinose boljem razmišljanju, razumijevanje i poznavanje emocija, kao i sposobnost njihovog upravljanja u svrhu

poboljšanja emocionalnijeg i boljeg intelektualnog razvoja (Mayer *et al.*, 2008).

Uzimajući u obzir složenost ovih psihičkih procesa, jednostavniji procesi uključuju prepoznavanje i izražavanje emocija, dok se složeniji odnose na svijest o emocijama i njihovu regulaciju (Takšić *et al.*, 2006).

Prema revidiranoj definiciji emocionalne inteligencije Mayera i Saloveya, uveden je dodatni nivo sposobnosti, čime je ukupan broj nivoa povećan sa tri na četiri. Hercigonja (2018) detaljno opisuje i objašnjava sve četiri nivoa u skladu s Mayerovim i Saloveyevim pristupom.

Prvi nivo: "Zapažanje, procjenjivanje i iskazivanje emocija" – ovaj nivo odnosi se na sposobnost prepoznavanja emocija kod drugih ljudi na osnovu njihovog fizičkog stanja, načina izražavanja i ponašanja. Takođe, obuhvata sposobnost iskrenog izražavanja vlastitih emocija te razlikovanja između iskrenih i neiskrenih emocionalnih izraza kod drugih. Osobe koje su razvile ovu vještinu imaju veću sposobnost prepoznavanja da li neko istinski osjeća emocije koje pokazuje ili ih samo simulira. Ključna karakteristika ovog nivoa je da predstavlja najjednostavniju emocionalnu sposobnost, koja pomaže pojedincu u prepoznavanju stvarnih emocija koje se kriju iza nečijeg fizičkog izgleda, načina izražavanja i ponašanja.

Drugi nivo: "Emocionalno poticanje mišljenja" – predstavlja sposobnost da emocije usmjeravaju proces razmišljanja, omogućujući prosuđivanje i memorisanje događaja povezanih s različitim emocijama. Promjene u raspoloženju, koje su prirodni dio ljudskog iskustva, mogu značajno uticati na to kako se određena situacija sagledava, bilo pozitivno ili negativno. Posmatranjem problema iz različitih uglova povećavaju se šanse za njegovo rješavanje, što je omogućeno sposobnošću promjene emocionalnog stanja. Pojedinci s razvijenim ovim vještinama mogu bolje upravljati emocijama kako bi olakšali svakodnevne aktivnosti, a ove vještine pozitivno doprinose i kognitivnom razvoju.

Treći nivo: Shvatanje i proučavanje emocija, primjena emocionalnog znanja ″- ovaj nivo obuhvata sposobnosti prepoznavanja emocija, tumačenja njihovog značenja, kao i razumijevanje kompleksnih osjećaja i promjena u emocionalnim stanjima. Ove vještine su od ključne važnosti za dublje shvatanje emocija i korištenje emocionalnih znanja u različitim situacijama.

Četvrti nivo: "Samoregulacija emocija radi poboljšanja intelektualnog i emocionalnog razvoja" – odnosi se na sposobnost praćenja i upravljanja vlastitim emocijama, kao i emocijama drugih, s ciljem smanjenja neugodnih i povećanja prijatnih emocija. Ovaj nivo predstavlja najvišu razinu emocionalne inteligencije, jer obuhvata jednu od najsloženijih vještina povezanu s emocionalnom inteligencijom – sposobnost upravljanja emocijama, kako vlastitim, tako i tuđim. Ova vještina značajno doprinosi emocionalnom i intelektualnom razvoju (Hercigonja, 2018).

2.1.1.2. Bar-Onov model

Bar-Onov model emocionalno-socijalne inteligencije (ESI) temelji se na savremenim teorijama emocija koje naglašavaju važnost emocija u oblikovanju temperamenta. Osim toga, model se oslanja na rezultate istraživanja iz oblasti psihologije ličnosti, koja pokazuju jasnu povezanost između osobina ličnosti i stabilnih emocionalnih stanja (Hajncl i Vučenović, 2013). Prema Bar-Onu, emocionalna inteligencija se definiše kao skup neintelektualnih sposobnosti, znanja i vještina koje utiču na sposobnost pojedinca da se uspješno nosi sa zahtjevima okoline. Ovaj model obuhvata pet različitih dimenzija (Schulze i Roberts, 2005);

- Interpersonalne vještine – podrazumijevaju sposobnost empatije, prepoznavanje i razumijevanje emocija, prepoznavanje socijalne odgovornosti, kao i izgradnja i održavanje stabilnih ljudskih odnosa.

- Intrapersonalne vještine – obuhvataju svjesnost o vlastitim emocijama, samostalnost, samopoštovanje (samorazumijevanje i prihvatanje sebe) i samoaktualizaciju (ostvarivanje ličnih mogućnosti)

- Prilagodljivost – koja podrazumijeva rješavanje društvenih i ličnih problema, kao i fleksibilnost u prilagođavanju vlastitih osjećanja, misli i ponašanja u okolnostima u kojima se pojedinac nalazi.

- Upravljanje stresom – koja uključuje toleranciju na stres i sposobnost kontrolisanja impulsa.

- Opće raspoloženje – koja podrazumijeva osjećaj ispunjenosti i zadovoljstva životom, zračenje optimizmom te sposobnost održavanja vedrine i pozitivnog pogleda na svijet. Ova vještina omogućava pojedincu da zadrži emocionalnu stabilnost.

Bar-Onov model pruža širi pristup u poređenju s Mayer-Saloveyevim modelom. Konkretno, Bar-On je proširio koncept emocionalne inteligencije uključivanjem ličnih osobina, poput optimizma, te dodao dodatne vještine koje igraju ključnu ulogu u efikasnom suočavanju s problemima i njihovom rješavanju. Ovaj pristup omogućava dublje sagledavanje kako emocije i lične karakteristike zajedno utiču na uspjeh pojedinca u svakodnevnim situacijama. (Hajncl i Vučenović, 2013).

2.1.1.3. Golemanov model

Goleman je prilagodio model sposobnosti koji su razvili Mayer i Salovey, oblikujući ga prema vlastitom pristupu. On je jasnije istakao uticaj emocionalne inteligencije na poslovne performanse, dodajući elemente poput motivacije i optimizma, čime je dodatno naglasio važnost emocija u profesionalnom kontekstu (Ilić, 2008).

Prvi mješoviti model emocionalne inteligencije osmislio je Goleman, nakon čega je termin emocionalna inteligencija zamijenjen pojmom emocionalne kompetencije. Goleman definira emocionalne kompetencije kao vještine koje se mogu usvojiti i razvijati, a koje su neophodne za efikasno funkcionisanje u društvenim interakcijama (Hajncl i Vučenović, 2013).

Golemanov model ima za cilj obuhvatiti sve socijalne i emocionalne vještine povezane s postizanjem uspjeha, pri čemu je te vještine podijelio u dvije kategorije. Prva kategorija obuhvata intrapsihičke vještine, dok druga uključuje interpsihičke vještine. Intrapsihičke vještine podrazumijevaju motivaciju, samoupravljanje i samosvijest dok interpsihičke vještine podrazumijevaju empatiju i socijalne vještine. U svom modelu Goleman ističe samosvijest, samoupravljanje, društvena svijest i upravljanje odnosima. Pojedinci koji posjeduju visoku razinu emocionalne inteligencije imaju značajno veće mogućnosti da ostvare uspjeh, bilo u privatnom životu ili u profesionalnoj karijeri. Ove osobe uspješnije upravljaju svojim emocijama, bolje se prilagođavaju socijalnim situacijama i donose učinkovitije odluke, što ih čini sposobnijim da se nose sa izazovima i izgrade stabilne međuljudske odnose. (Hajncl i Vučenović, 2013).

Ilustracija 1 Golemanov model emocionalne inteligencije

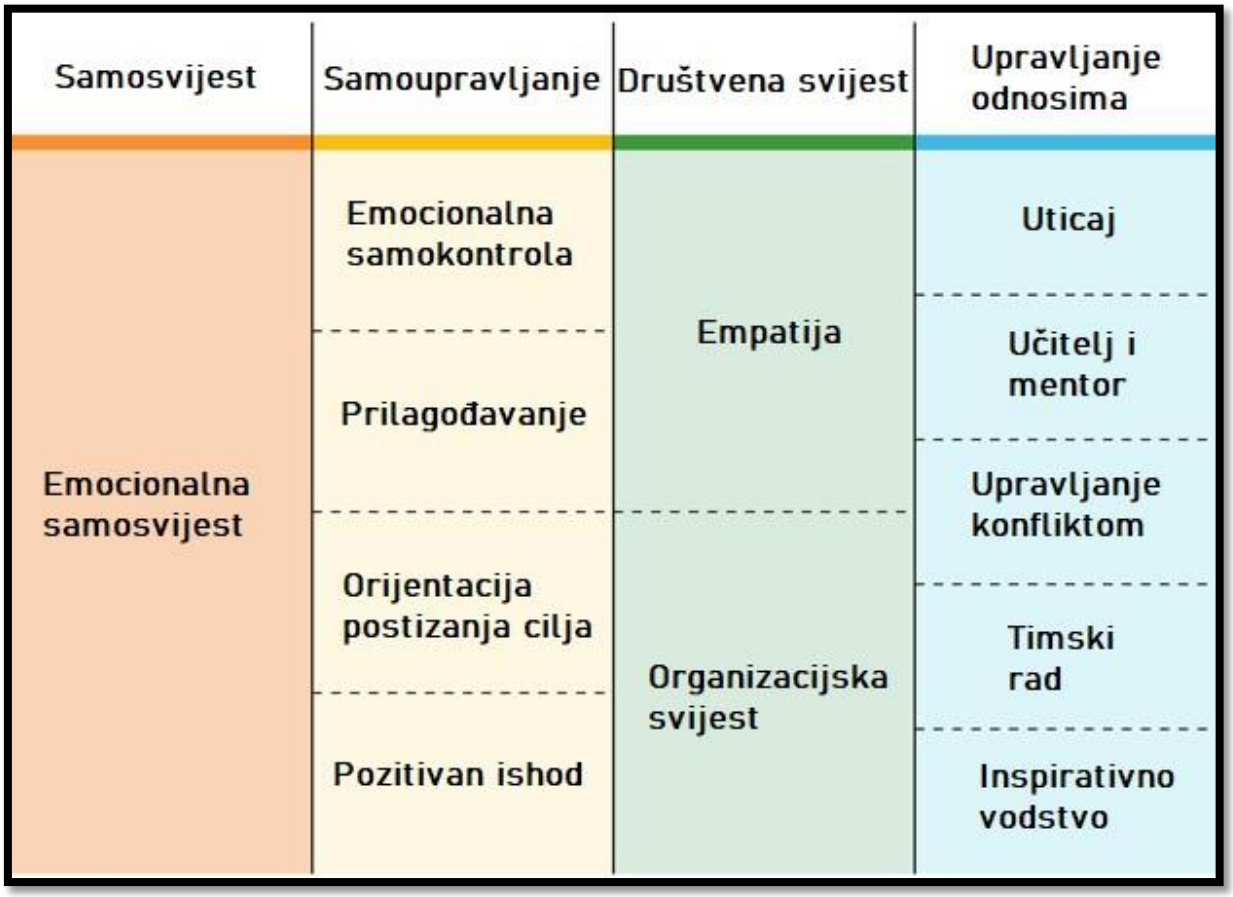

Izvor: Goleman D. i Boyatzis R. E., 2017

2.1.2. Radna učinkovitost u poslovanju

Radna učinkovitost predstavlja jedan od ključnih faktora za napredovanje u karijeri i ostvarivanje poslovnog uspjeha. Kada zaposlenici postižu visoku radnu učinkovitost, otvaraju im se brojne mogućnosti za unapređenje i napredovanje na više pozicije unutar organizacije. Prema Garnidi (2017), radna učinkovitost je rezultat napora, vještina, iskustva i iskrenosti koje pojedinac ulaže u izvršenju povjerenih zadataka koje su u skladu s dodijeljenim odgovornostima.

Radna učinkovitost je direktan rezultat rada koji osoba postiže koristeći svoje sposobnosti, iskustvo i vrijeme. Ovaj koncept naglašava kako pojedinac koristi svoje resurse, uključujući znanje, vještine i dostupno vrijeme, kako bi postigao maksimalan učinak na radnom mjestu. To znači da visoka razina radne učinkovitosti nije samo rezultat tehničkih vještina, već i sposobnosti prilagođavanja, upravljanja vremenom i korištenja stečenog iskustva u svakodnevnim radnim zadacima (Sumenda *et al*., 2018).

Adnyani i Dewi (2019) ističu da radna učinkovitost predstavlja skup vještina koje zaposlenik mora posjedovati kako bi uspješno ispunio različite zahtjeve radnog mjesta.

Radna učinkovitost se često definiše kao ukupna očekivana vrijednost ponašanja koje pojedinac pokazuje za vrijeme standardnog vremenskog razdoblja unutar organizacije. Ova definicija naglašava da varijacije u radnom učinku predstavljaju promjene u očekivanoj organizacijskoj vrijednosti ponašanja zaposlenika. Ključno je razlikovati ponašanja relevantna za organizaciju od samih rezultata koje zaposlenici postižu. Dok se ponašanja odnose na ono što zaposlenici redovno rade, rezultati su stanje koje se mijenja u zavisnosti od toga koliko zaposlenikov rad doprinosi ili ometa efikasnost organizacije (Motowidlo i Kell, 2003). Posebno značajan za razumijevanje radne uspješnosti je Campbellov multifaktorski model koji identificira osam bihevioralnih dimenzija radne uspješnosti:

(a) uspješnost u specifičnim radnim zadacima,

(b) uspješnost u nespecifičnim radnim zadacima,

(c) pisana i usmena komunikacija,

(d) iskazivanje truda,

(e) održavanje osobne discipline,

(f) olakšavanje grupne i partnerske izvedbe,

(g) supervizija,

(h) upravljanje i administracija.

Pojava i značaj ovih faktora varira u zavisnosti od specifičnih karakteristika posla, tri glavne

komponente koje direktno utiču na radnu uspješnost:

(i) deklarativna znanja,

(j) proceduralna znanja i vještine, i

(k) motivacija.

Ovaj koncept pruža temelj za razumijevanje kako se radna uspješnost može unaprijediti kroz razvoj specifičnih znanja, vještina i motivacijskih faktora, što je od ključne važnosti za uspješno poslovanje i upravljanje ljudskim resursima. (Motowidlo i Kell, 2003). Praćenje radne uspješnosti zaposlenika ključni je element uspješnog menadžmenta i efikasnog vođenja organizacije. Uspješni menadžeri kontinuirano i pravedno procjenjuju radni učinak svakog zaposlenika, omogućujući adekvatnu nagradu ili sankciju, ovisno o kvaliteti obavljenih zadataka. Prema Požegi (2012), praćenje radne uspješnosti podrazumijeva postupak praćenja i analiziranja zaposlenika te njihovih radnih učinaka kako bi se stekao što bolji uvid u to kako zaposlenik radi, koliko dobro radi i kako bi se utvrdilo je li moguće i, ako jest, na koji način ili načine raditi brže, bolje, učinkovitije.

Ova definicija naglašava važnost procjene radnog učinka ne samo kao sredstvo za ocjenu trenutne učinkovitosti, već i kao alat za motivaciju i unapređenje budućih performansi zaposlenika. Dessler (2015) dodatno pojašnjava da procjena radne učinkovitosti uključuje određivanje radnih normi, usporedbu stvarne radne učinkovitosti sa postavljenim normama i pružanje povratne informacije zaposlenicima. Povratna informacija je ključna jer omogućava zaposlenicima da uoče svoje nedostatke i unaprijede svoje radne sposobnosti.

Također, ona služi kao motivacijski faktor za one koji pokazuju visoku efikasnost, podstičući ih da zadrže ili čak poboljšaju svoj radni učinak. Bahtijarević-Šiber (1999) ističe da je ocjenjivanje radne uspješnosti ključan faktor uspješnog upravljanja ljudskim resursima. Pravilna procjena radne uspješnosti stvara bolje radno okruženje i doprinosi ukupnoj uspješnosti organizacije. Efikasna evaluacija radne uspješnosti omogućava organizacijama da optimiziraju svoje ljudske resurse i postignu bolje poslovne rezultate.

Milkovich i Newman (2006) objašnjavaju da postoji nekoliko vrsta strategija za određivanje mjera ocjenjivanja radnog učinka i njegovog poboljšanja. Svaka strategija fokusira se na specifične komponente koje su uključene u proces ocjenjivanja radnog učinka i o njima ovisi. Prije svega, važno je obratiti pažnju na osobe koje provode proces ocjenjivanja, jer svaka od njih mora posjedovati odgovarajuća znanja, motivaciju i iskustvo kako bi uspješno obavila ovu vrstu mjerenja. Nadalje, potrebno je prilagoditi definiciju radnog učinka, jer s detaljnijim istraživanjem poslovi postaju dinamičniji, što povećava potrebu za razvojem i prilagođavanjem.

Narušeno mentalno zdravlje zaposlenika može ostaviti određen trag na produktivnost radnika, na ekonomske troškove organizacije i općenito na cijeli kolektiv. U istraživanju Vijeća za mentalno zdravlje Australije (eng. Mental Health Council of Australia) prema

Tapia *et al*. (2013) utvrđeno je da je produktivnost osoba s različitim psihičkim poremećajima iznosila samo 29%. U usporedbi s tim, produktivnost osoba s fizičkom bolešću ili oštećenjem iznosila je 49%. Iz toga je vidljivo da određeni psihički poremećaji mogu dovesti do smanjene produktivnosti, što naknadno može negativno utjecati na organizaciju.

Što se tiče specifičnosti pojedinih psihičkih poremećaja i uspješnosti, pokazalo se da su ADHD i shizofrenija povezane s precjenjivanjem vlastitih (pa tako i radnih) sposobnosti. S druge strane, depresija i anksioznost su povezane s podcjenjivanjem vlastitih sposobnosti (Hennekam *et al*., 2021).

Također, od svih psihičkih poremećaja depresija ima najveći negativni učinak na produktivnost. Najvjerojatniji razlog tomu osjećaj konstantnog umora i bezvoljnosti, koji je jedan od glavnih karakteristika depresivnog poremećaja (Henderson *et al*., 2011).

Stigma također može pogoršati radnu uspješnost, posebice ako osoba samu sebe stigmatizira. Zbog stigme, osobe koje pate od nekog psihičkog poremećaja mogu same sebe smatrati manje učinkovitima i uspješnima u poslu. Drugim riječima, dolazi do samostigme, što u konačnici može negativno utjecati na njihovu radnu uspješnost (Rüsch *et al*., 2005). Raharjo i saradnici (2014) su pokazali da metoda treninga, materijal za trening i instruktori treninga imaju značajan uticaj na radnu učinkovitost zaposlenika, dok motivacija također ima značajan uticaj na performanse zaposlenika. Triasmoko i saradnici (2014) također potvrđuju uticaj treninga na radnu učinkovitost.

Aldi i Susanti (2019) nalaze da motivacija, nadzor i radna disciplina pozitivno utiču na radnu učinkovitost. Prema Priyono i saradnicima (2016), motivacija je proces koji podstiče zaposlenike na rad kako bi se efikasno i efektivno postigli ciljevi. Ključni faktori koji utiču na motivaciju uključuju lične potrebe, ciljeve i percepcije pojedinaca ili grupa, kao i načine na koje se te potrebe, ciljevi i percepcije zadovoljavaju.

Afiyati (2018) definira motivaciju kao pokretačku silu koja potiče zaposlenike da unaprijede svoju radnu učinkovitost i postignu ciljeve kompanije. Harahap i Khair (2019) dodaju da je motivacija snaga, bilo unutrašnja ili vanjska, koja može potaknuti osobu na ostvarenje željenih ciljeva.

Adnyani i Dewi (2019) definišu razvoj karijere kao proces koji povećava vrijednost pojedinca, omogućujući zaposlenicima da steknu radno iskustvo i zadovoljstvo poslom, što potom vodi ka poboljšanju njihovih performansi kao i radne učinkovitosti. Jumawan i Mora (2018) naglašavaju da razvoj karijere omogućava zaposlenicima planiranje buduće karijere unutar kompanije, čime se podstiče optimalan razvoj kompanije i zaposlenika.

2.2. Vještačka inteligencija i njena integracija u poslovne procese

2.2.1. Historija vještačke inteligencije

Pojam vještačke inteligencije (AI) prvi put se spominje na kongresu održanom na Dartmouth Collegeu 1956. godine, John McCarthy će posati prvi naučnik koji je uveo pojam vještačke inteligencije. McCarthy je vještačku inteligenciju definisao kao naučnu oblast usmjerenu na razvoj računarskog sistema čije se aktivnosti mogu interpretirati i posmatrati kao inteligentne. Ovaj koncept predstavlja posebnu naučnu oblast i novo polje istraživanja, koje se fokusira na razvoj sistema sposobnih za inteligentno ponašanje. Tokom dvomjesečne radionice koju su vodili John McCarthy, Marvin Minsky, Nathaniel Rochester i Claude Shannon, pojam "vještačka inteligencija" je službeno uveden 1956. godine. Radionica je obuhvatala teme kao što su teorije automata, neuronske mreže i vještačka inteligencija, što je stvorilo temelje za dalji razvoj i istraživanje ovog područja. (Balaž i Meštrović, 2014).

Međutim, temelji AI postavljeni su mnogo ranije, prije 1956. godine, kada je pojam zvanično uveden.

Ključne temelje za razvoj vještačke inteligencije je postavio još davne 1936. godine Alan Turing. Koncept poznat kao Turingova mašina, koji je omogućio da se mašine mogu ponašati inteligentno, stvarajući osnovu za kasnije teorije i istraživanja u ovoj oblasti. Ovaj mali doprinos otvorio je vrata razmišljanju o tome kako "neživi" sistemi mogu imitirati ljudsku inteligenciju, čime je započelo novo doba istraživanja vještačke inteligencije. Turing je ovim pokazao kako se može napraviti mašina sposobna za obavljanje bilo kojeg računarskog procesa ili rješavanje bilo kojeg algoritma. Posebno značajan je njegov Turingov test, koji procjenjuje da li mašina posjeduje osobine inteligencije. Ovaj test postao je ključni kriterij za ocjenu sposobnosti računara da imitiraju ljudsku inteligenciju, čime je dao veliki doprinos razvoju teorije vještačke inteligencije. Turingov test, osmišljen 1950. godine, zahtijeva tri učesnika: dva čovjeka i jedan računar. Jedan od ljudi preuzima ulogu sudije. Sudija vodi razgovor s drugim učesnikom, koji može biti ili čovjek ili računar, ali nije informisan s kim komunicira. Cilj sudije je da, kroz pisanu komunikaciju, utvrdi da li razgovara s osobom ili sa mašinom. Ako sudija nije u stanju precizno odrediti s kim komunicira, računar se smatra uspješnim u prolasku testa, demonstrirajući sposobnost vještačke inteligencije (Putica, 2018).

Prvim radovima vještačke inteligencije je i rad kojim je Claude Shannon programirao računar za igranje šaha. Njegov rad "Programming a Computer for Playing Chess" iz 1950. godine postavio je osnovne principe za programiranje računara ove igre. Iako se ovaj rad ne smatra direktnim radom na vještačkoj inteligenciji, on je značajan jer je pokazao kako bi računar mogao oponašati aspekte ljudske inteligencije, poput strategije i donošenja odluka.

Prvi program vještačke inteligencije zvao se Logic Theorist – LT razvijen 1955-1956. godine od strane Allena Newella i Herberta A. Simona. Ovaj program je bio osmišljen da dokazuje logičke teoreme i smatra se jednim od prvih primjera automatskog rasuđivanja. Logic

Theorist je posebno značajan jer je mogao samostalno izvoditi logičke zaključke, koristeći se osnovnim principima simboličkog zaključivanja. Program je bio sposoban da dokaže 38 od prvih 52 teorema iz "Principia Mathematica", klasičnog djela iz oblasti logike koje su napisali Alfred North Whitehead i Bertrand Russell.

Dartmouth konferencija se smatra formalnim rođenjem polja vještačke inteligencije. Prije ove konferencije, ideje o vještačkoj inteligenciji su postojale, ali nije postojalo organizirano istraživačko područje koje bi se bavilo ovim pitanjem.

List Processing (LISP) prvi programski jezik iz 1958. Godine bio je dizajniran za potrebe vještačke inteligencije. Ovaj jezik postao je ključni alat u istraživanju i razvoju AI tehnologija, postavljajući temelje za napredne sisteme obrade podataka i računarskog učenja, te se i danas koristi u određenim oblastima. McCarthyjev doprinos kroz LISP bio je od presudne važnosti za dalji napredak u svijetu vještačke inteligencije. Zbog svoje fleksibilnosti i snage u obradi simboličkih podataka, LISP je postao standard za istraživanje u području vještačke inteligencije 1960-ih i 1970-ih godina. Njegova sposobnost da manipulira kodom kao podatkom (homoikoničnost) bila je izuzetno korisna za vještačku inteligenciju daljnje eksperimente i razvoj. Jedna od najvažnijih karakteristika LISP-a je njegova homoikoničnost, što znači da je kod u LISP-u predstavljen na isti način kao i podaci. Ova osobina omogućava programima da tretiraju vlastiti kod kao podatak, što je vrlo korisno za pisanje programa koji mogu modifikovati sami sebe ili kreirati nove programe za vrijeme izvođenja, što je ključna funkcionalnost za mnoge AI aplikacije. Njegova fleksibilnost i sposobnost obrade složenih simboličkih struktura učinile su ga osnovnim alatom za mnoge AI eksperimente i projekte u tom periodu. Iako su se s vremenom pojavili i drugi jezici, LISP je ostao značajan u historiji vještačke inteligencije i nastavlja se koristiti u određenim područjima istraživanja i danas (Putica, 2018).

Između šezdesetih i sedamdesetih godina prošlog stoljeća, počeo je razvoj prvih ekspertnih sistema, koji su bili dizajnirani da rješavaju specifične probleme koristeći znanje iz određene oblasti. Tokom sedamdesetih godina prošlog stoljeća, počinje razvoj prvih programa usmjerenih na razumijevanje prirodnog jezika, što je označilo važan korak naprijed u oblasti vještačke inteligencije. Razvoj ekspertnih sistema, posebno onih namijenjenih specifičnim zadacima, značajno se ubrzava u osamdesetim godinama prošlog stoljeća. Robotika također bilježi napredak, dok vještačke neuronske mreže postaju sve sofisticiranije, postavljajući temelje za modernu vještačku inteligenciju. U osamdesetim godinama postavljeni su ključni temelji vještačke inteligencije, koji i danas imaju značajan utjecaj na savremene AI tehnologije. Ove rane inovacije oblikovale su napredak u vještačkoj inteligenciji, omogućavajući razvoj sofisticiranijih sistema koji se i dalje usavršavaju u današnjim primjenama..

Od devedesetih godina pa do danas već se može govoriti o „modernoj“ vještačkoj inteligenciji, čija se primjena, područje i koncepti proučavaju u nastavku. Sam pojam „Vještačka inteligencija“ se sastoji od dvije riječi: vještačko i inteligencija. Pod vještačkim se misli na nešto što nije stvarno i predstavlja određeni vid simulacije. Inteligencija se

definiše na različite načine kao što su učenje, logika, razumijevanje, kreativnost i rješavanje problema. Zajedno, ove dvije riječi čine karakteristike neživog sistema koji pokazuje inteligenciju. Pod tim sistemom smatra se svaki sistem koji prikuplja i obrađuje informacije, uči na temelju iskustava i komunicira sa čovjekom prirodnim jezikom i govorom. Ako se posmatra vještačka inteligencija sa stanovišta nauke onda je to grana informatike koja se bavi proučavanjem i stvaranjem računarskih sistema koji pokazuju određeni oblik inteligencije. U praksi to su sistemi koji uče nove koncepte i zadatke, sistemi koji mogu rasuđivati i izvlačiti korisne zaključke o svijetu oko nas. Prema toj definiciji, vještačka inteligencija prikazuje teoriju i razvoj računarskih sistema koji mogu normalno obavljati zadatke, zahtijevajući ljudsku inteligenciju, poput vizualne percepcije, prepoznavanja govora, odlučivanja i prevođenja između jezika (Peterson, 1990).

Vještačka inteligencija je dio računarske nauke (informatike) koji se bavi razvojem sposobnosti računara da obavljaju zadatke za koje je potreban neki oblik inteligencije, odnosno da se mogu snalaziti u novim situacijama, učiti nove pojmove, donositi zaključke, razumjeti prirodni jezik, prepoznavati prizore i slično (Prister, 2019). Svako u svakodnevnom obavljanju osnovnih životnih i poslovnih aktivnosti na neki način se oslanja na vještačku inteligenciju, tako da ona postaje neminovno sastavni dio poslovnog okruženja, obrazovanja, domaćinstva, svakodnevnog iskustva i slobodnog vremena. Stoga je sasvim jasno da vještačka inteligencija postaje jedan od glavnih pokretača privrednog rasta. Pored nabrojanih definicija, ipak će se reći da ne postoji općeprihvaćena definicija vještačke inteligencije (Putica, 2018). Vještačka inteligencija, kao veoma mlada nauka, naslijedila je mnoge ideje, pristupe i tehnike iz drugih disciplina, a posebno onih koje se bave istraživanjem načina ljudskog mišljenja: kognitivnih nauka, logike, psihologije, biologije, filozofije, lingvistike, matematike i dr. Ona uključuje sisteme koji imaju posebna obilježja (Putica, 2018):

- Sistemi koji misle kao čovjek,
- Sistemi koji se ponašaju kao čovjek,
- Sistemi koji misle razumski,
- Sistemi koji se ponašaju razumski,
- Sistemi kojim je cilj imati sve izglede inteligencije (razumske ili ljudske),
- Sistemi čije unutarnje funkcionisanje pokušava biti u skladu s ljudskim bićem odnosno razumskim bićem.

Dakle, vještačka inteligencija postaje sveprisutna u privredi, nalazi svoje mjesto u trgovini, medicini, ali isto tako u raznim aplikacijama sa potrošačkog aspekta. Radi se o vrlo prilagodljivoj tehnologiji koja poprima razne oblike te je izložena neprestanom razvoju i napretku, a u njenom definisanju važan je i vremenski faktor (Woodrow, 2018). Područja vještačke inteligencije danas obuhvataju širok spektar i mogu se posmatrati iz različitih

aspekata. Neka od ključnih polja primjene vještačke inteligencije su:

- Računarske igre i simulacije
- Ekspertni sistemi
- Neuronske mreže
- Razumijevanje i obrada prirodnih jezika
- Računarski vid
- Rješavanje problema
- Pretraživanje podataka
- Automatsko programiranje
- Inteligentni agenti i drugi

Vještačka inteligencija se može podijeliti na slabu i jaku, u zavisnosti od stepena inteligencije. Slaba vještačka inteligencija oponaša inteligentno ponašanje, dok jaka vještačka inteligencija podrazumijeva sposobnost razmišljanja na nivou čovjeka. (Valerjev, 2006).

Turing je još davno postavio temelje za razlikovanje ova dva tipa inteligencije, razvijajući test u kojem učesnici pokušavaju prepoznati da li komuniciraju s čovjekom ili sa inteligentnim računarom. Prema ovom testu, računar se smatra inteligentnim ako više od 30% osoba koje s njim komunicira ne može jasno utvrditi da li je u pitanju mašina ili ljudsko biće.

Kod slabe vještačke inteligencije imamo sisteme kojima se mogu dodijeliti samo određene inteligentne osobine, poput raspoznavanja ljutskog glasa. Ovaj oblik vještačke inteligencije izaziva manje kontroverzi u poređenju s jakom vještačkom inteligencijom.

Uključuje programiranje računara ili drugih uređaja na inteligentne načine, s ciljem rješavanja specifičnih problema. Važno je napomenuti da računari slabe inteligencije ne razumiju probleme koje rješavaju, ali ih uspješno rješavaju. Radi se, dakle, o modeliranju inteligentnog ponašanja koje je potom moguće koristiti za rješavanje kompleksnih problema.

Računari ili drugi uređaji mogu inteligentno djelovati kako bi riješili određene probleme. Bitno je naglasiti da računari sa slabom inteligencijom ne shvataju prirodu problema koje rješavaju, ali ih uspješno izvršavaju. Ovdje se zapravo radi o simulaciji inteligentnog ponašanja koje se koristi za rješavanje složenih zadataka.

To je ujedno ograničena vrsta inteligencije, jer mašina ne posjeduje pravu inteligenciju, već

je samo simulira, što dovodi sa određenih ograničenja. Slaba AI se odnosi na imitaciju i oponašanje određenih mentalnih procesa, ali bez stvarnog posjedovanja tih sposobnosti. Na primjer, slaba AI obuhvata sposobnosti poput raspoznavanja govora i rješavanja specifičnih zadataka, ali bez mogućnosti šire primjene znanja ili suočavanja sa zadacima koji nisu unutar njenog tačno definisanog spektra. Sistemi AI razvijeni su s ciljem izvršavanja specifičnih zadataka, zbog čega njihove sposobnosti nisu jednostavno primjenjive na druge sisteme ili različite zadatke. (Prister, 2019).

„Jaka vještačka inteligencija naziva se i svjesnom vještačkom inteligencijom, a podrazumijeva mašinu sposobnu ponašati se inteligentno, osjećati i razumijevati svoje rasuđivanje. Njome je moguće postići repliciranje ljudskih mentalnih osobina kao što su emocije, kreativnost, motivacija i slično“ (Putica, 2018).

Prema principu slabe AI, računar služi kao alat za provjeru, oblikovanje i preciziranje različitih procesa. U slučaju jake AI, računar ne djeluje samo kao pomoćno sredstvo, već preuzima ulogu koja se može uporediti s funkcijom ljudskog uma. Prema ovom konceptu, računar zaista shvata informacije, čime mu se dodjeljuju određena mentalna stanja. Načelo jake AI podrazumijeva da, kada sistem pokazuje inteligentno ponašanje, ono mora biti zasnovano na istim procesima i metodama koje koristi ljudski mozak. Kod slabe AI, uspjeh se procjenjuje isključivo na osnovu performansi i krajnjih rezultata koje sistem postiže u izvršavanju zadataka. S druge strane, kod jake AI, osim same efikasnosti sistema, poseban naglasak se stavlja na unutrašnju strukturu sistema, kao i na način na koji različite komponente tog sistema međusobno djeluju i komuniciraju. Ova dublja analiza strukture i komunikacije unutar sistema je ključna za razumijevanje stvarne inteligencije koju takvi sistemi mogu pokazati. Jaka AI uključuje sposobnost razmišljanja koja su jednaka razmišljanju čovjeka, kao i mogućnost primjene znanja i vještina u raznovrsnim okolnostima. Ona predstavlja napredniji oblik slabe AI. Upravo zbog toga, oba principa AI koriste slične, savremene koncepte u svom djelovanju (Putica, 2018).

Akerkar (2019) ističe da, u općem smislu, kada se raspravlja o vještačkoj inteligenciji, neki od ključnih koncepata njenog funkcionisanja obuhvataju sljedeće:

1. Mašinsko učenje (engl. machine learning)
2. Duboko učenje (engl. Deep learning)
3. Neuronske mreže

2.2.2. Mašinsko učenje

Mašinsko učenje predstavlja jednu od ključnih oblasti vještačke inteligencije. Ovaj proces uključuje kreiranje algoritama koji imaju sposobnost da unaprijede svoju efikasnost na osnovu prikupljenih podataka iz prakse. Potencijali primjene ove tehnologije su izuzetno široki i obuhvataju prepoznavanje šablona, detaljnu analizu podataka, računarski vid,

bioinformatika i razne druge oblasti.

Mašine stiču znanje uglavnom na osnovu prethodnih iskustava. Kako bi se izbjegla stalna prilagodba i nadogradnja softvera od strane programera, kroz proces mašinskog učenja mašina je sposobna da s vremenom sama unapređuje svoje performanse i efikasnost. Iako se to možda na prvi pogled čini apstraktnim i namijenjenim za specifične zadatke, realnost je da se prosječan čovjek svakodnevno dolazi u kontakt s mašinskim učenjem, često nesvjestan toga.

Mašinsko učenje je tehnologija koja je postala uobičajena ne samo u redovnim aktivnostima, već je postala standard i u poslovnom okruženju. Tokom proteklih godina, posebno je došlo do izraženog napretka, kako je mašinsko učenje godinama sve efikasnije i pristupačnije većem broju korisnika. Ono je postalo ključni alat u raznim industrijama, od marketinga i finansija do medicine i proizvodnje.Važno je napomenuti da kod mašinskog učenja računar nije programiran da dostigne unaprijed određeni rezultat, već je sposoban je da uči na osnovu primjera. Na ovaj način, mašina analizira velike količine podataka i na osnovu tih podataka stvara modele koji joj omogućavaju donošenje odluka ili predviđanja. Iako termin "učenje" sugerira neku vrstu razumijevanja, mašinsko učenje trenutno pripada području slabe vještačke inteligencije. Razlog za to je činjenica da stroj zapravo ne razumije sadržaj ili značenje onoga što obrađuje; on samo povezuje simbole i značenja te identifikuje obrasce u podacima Akerkar (2019).

Ovo znači da, iako su rezultati mašinskog učenja često impresivni, oni su još uvijek ograničeni na prepoznavanje obrazaca unutar jasno definisanih okvira. Mašina ne posjeduje svijest ili sposobnost razumijevanja konteksta na način na koji to čini ljudski um, već samo simulira inteligenciju kroz složene algoritme i analizu podataka Akerkar (2019).

2.2.3. Duboko učenje

Duboko učenje je oblik mašinskog učenja koji se, u najjednostavnijem smislu, oslanja na neuronske mreže.

Kroz klasično mašinsko učenje, računar uči uglavnom kroz nadzirano iskustvo. Greške se u takvom načinu rada ispravljaja ručno (Smolčić *et al.*, 2018).

Duboko učenje obuhvata više uzastopnih slojeva koji informacije analiziraju na nelinearan način, raspoređeni u hijerarhijskom poretku, gdje niži nivoi doprinose oblikovanju i definisanju složenijih koncepata na višim nivoima. Ovaj proces omogućava slojevitu analizu podataka, gdje se informacije obrađuju korak po korak, slično načinu na koji ljudi obrađuju informacije. Duboko učenje može se definirati kao tehnika mašinskog učenja koja koristi više slojeva nelinearne obrade informacija za ekstrakciju i transformaciju nadziranih i nenadziranih karakteristika, kao i za analizu uzoraka i klasifikaciju.

Duboko učenje se može opisati kao metoda mašinskog učenja koja ima višeslojne procese

nelinearne analize informacija s ciljem izdvajanja i transformisanja karakteristika, bilo da su nadzirane ili nenadzirane, te za prepoznavanje i kategorizaciju obrazaca. Ova vrsta učenja obrađuje i analizira podatke na način sličan ljudskom mozgu, prolazeći kroz nekoliko uzastopnih faza procesuiranja. Svaki sloj obrade omogućava dodatnu složenost i preciznost u prepoznavanju obrazaca i donošenju zaključaka. Duboko učenje se oslanja na hijerarhijsku obradu podataka i informacija, što omogućava višeslojnu arhitekturu. Ova arhitektura omogućava modelima da prepoznaju i analiziraju kompleksne strukture i odnose unutar podataka. Kao i kod drugih metoda mašinskog učenja, duboko učenje se bavi upravljanjem velikim količinama podataka, ali na znatno složeniji način koji uzima u obzir različite faktore, kao što su različito vrijeme, različiti nivoi obrade i različiti konteksti u kojima se podaci pojavljuju.

Ova slojevita analiza omogućava dublje razumijevanje podataka i omogućava sistemima koji koriste duboko učenje da budu izuzetno precizni u svojim prognozama i klasifikacijama, čak i u složenim i dinamičnim okruženjima Akerkar (2019).

2.2.4. Neuronske mreže

Neuronske mreže, inspirisane biološkim nervnim sistemom, procesuiraju informacije na način koji podsjeća na funkcionisanje ljudskog mozga. Ovaj sistem se sastoji od mnogobrojnih međusobno povezanih jedinica (neurona) koje funkcionišu zajedno kao jedinstvena struktura. Osnovna vrijednost i jačina ovog sistema je njegova sposobnost da uči iz primjera. Neuronska mreža pojedinačno mora biti kreirana za izvršenje specifičnog zadatka, a povezanost između neurona se uvijek prilagođava specifičnom zadatku koji se treba riješiti (Kovačević *et al*., 2019). Koncept vještačkih neuronskih mreža zasnovan je na biološkom modelu ljudskih neuronskih mreža. Proces učenja funkcioniše na sličan način. Vještačka neuronska mreža sastoji se od digitalnih elemenata koji simuliraju funkciju neurona u ljudskom mozgu. Svaki od tih elemenata obrađuje informacije i obavlja određeni zadatak kako bi se postigao konačan rezultat. Dobijeni konačani rezultat može proslijediti drugim elementima za dalju obradu.

Vještačka neuronska mreža koristi se za kreiranje modela aktivnosti s ciljem predviđanja njihovog budućeg ponašanja, kao i za napredno upravljanje procesima. Također se primjenjuju u dijagnostici stanja tokom rada mašina i samih procesa. U okviru mašinskog učenja, neuronske mreže igraju ključnu ulogu u zadacima klasifikacije, poput idetifikacije fotografija, analize govora, prevođenja jezika, analize sadržaja na socialnim mrežama, te optimizacije internetskih pretraga i ciljane promocije. Dalje, implementacija vještačke inteligencije u poslovne sfere ne omogučava samo digitalnu transformaciju već i prilagođavanje principima industrije 4.0. Ove dvije oblasti su usko povezane, a njihov glavni cilj u poslovnom okruženju je unapređenje poslovnih aktivnosti i postizanje boljih rezultata. (Ujević Andrijić, 2019).

2.3. Primjena vještačke inteligencije u poslovanju

Ljudski resursi su već dugo vremena prepoznati kao najvažniji resurs u privredi, ali s razvojem vještačke inteligencije (AI) postavlja se pitanje hoće li zadržati tu vodeću ulogu. Vještačka inteligencija, koja uključuje "nežive" sisteme s određenim oblikom inteligencije, sve više postaje neizostavan dio poslovnog svijeta, donoseći revoluciju u načinu rada i upravljanja preduzećima. Iako je implementacija AI još uvijek u ranoj fazi u mnogim zemljama, njena primjena omogućava brži protok informacija, uštedu vremena te podstiče kreativnost i inovativnost u poslovnim procesima. Vještačka inteligencija posebno utiče na radnu učinkovitost kroz povećanje produktivnosti zaposlenih. Automatizacija poslovnih aktivnosti daje mogućnost zaposlenim da se posvete zahtjevnijim inovativnijim projektima i zadacima, što doprinosi njihovom većem učinku i poboljšava ukupne efikasnosti organizacije. Iako s primjenom AI dolaze izazovi, poput smanjenja potrebe za određenim radnim pozicijama, ona istovremeno omogućava razvoj novih proizvoda i usluga, što dodatno poboljšava radnu učinkovitost. Također, AI motiviše zaposlenike na kontinuiranu edukaciju i usavršavanje, što doprinosi njihovom profesionalnom razvoju i adaptaciji na nove tehnologije. Ključni izazov za današnja preduzeća je pronaći ravnotežu između ulaganja u ljudske resurse i sve većeg oslanjanja na napredne tehnologije poput vještačke inteligencije. Iako upotreba vještačke inteligencije u poslovanju raste, ona još uvijek nije pogodna za sve poslovne operacije. Potreba za vještačkom inteligencijom u poslovnom okruženju sve više povećava, iako njena primjena još uvijek ne odgovara svim poslovnim zadacima. Brojni segmenti poslovanja i aktivnosti mogu se automatizirati, međutim zadaci koji uključuju donošenje odluka, postavljanje prioriteta, te balansiranje različitih interesa i ciljeva, i dalje zahtijevaju ljudsku inteligenciju i emocionalnu procjenu. Očigledno je da bez ljudske inteligencije ne bi bilo moguće uspješno implementirati vještačku inteligenciju u poslovne procese. Ljudski faktor je ključan ne samo za uvođenje ove tehnologije, već i za njeno pravilno prilagođavanje specifičnim potrebama kompanije, kao i za njeno kontinuirano nadgledanje i unapređenje u praksi. Uvođenje vještačke inteligencije u poslovne aktivnosti, gdje može donijeti pozitivne rezultate, predstavlja odličan početni korak. Ovaj proces omogućava preduzećima da postepeno testiraju i iskoriste prednosti AI tehnologije u poboljšanju efikasnosti i inovacija. Kako vrijeme bude odmicalo, postat će standardna praksa za kompanije da vještačku inteligenciju uključe u svaku novu poslovnu inicijativu, čime će se dodatno podići nivo automatizacije i unaprijediti operativni procesi. To će rezultirati sve većim oslanjanjem na AI za optimizaciju poslovanja (Šarić *i* Osmanović, 2023).

Vještačka inteligencija se u poslovnom okruženju koristi na razne načine u raznim oblastima. U poslovnom okruženju primjena AI postaje sve efikasnija zahvaljujući informacijama koje su lako dostupne. Riječ je i o strukturiranim podacima, kao što su podaci prikupljeni različitim senzorima i analitikama, ili o nestrukturiranim podacima koji se dobivaju, na primjer, iz kamera, društvenih medija i mreža, itd. Ove informacije obuhvataju strukturirane podatke, prikupljeni putem raznih senzora i analitičkih alata, ali i nestrukturirane podatke koji dolaze iz izvora poput kamera, socialnih mreža i drugih mrežnih

platformi. Taj povećani broj dostupnih podataka glavni je faktor pojačane upotrebe vještačke inteligencije u poslovanju. Poslovni subjekti koriste vještačku inteligenciju kako bi stvorili korisne informacije i modele predviđanja zasnovane na ponašanju njihovih korisnika. Ono što koriste prilikom generisanja takvih modela su dostupni algoritmi unutar AI sistema Povećana dostupnost ovih podataka ključni je faktor za intenzivniju upotrebu vještačke inteligencije u poslovnom svijetu. Kompanije se oslanjaju na vještačku inteligenciju kako bi kreirale vrijedne informacije i prediktivne modele koji se temelje na potrebama njihovih korisnika. U tom procesu koriste dostupne AI tehnologije za kreiranje takvih modela. (Šestak i Dobrinić, 2019).

Obrada velike baze podataka i dostupnost mnogih informacija omogućava detaljniju analizu od koje dobijamo nove rezultate, a koja nam pomaže u donošenju boljih poslovnih odluka. Mnogi korisnici analize, zahvaljujući AI tehnologiji, imaju bržu i dostupniju analitiku koju mogu koristiti u svojim oblastima unutar kompanije. Prva vrsta je opisna analiza, koja pruža pregled trenutne situacije. Zatim dolazi prediktivna analiza, koja se bavi prognoziranjem budućih događaja na temelju vjerovatnoće. Treća vrsta obuhvata akcije koje se poduzimaju kako bi se postigli optimalni rezultati. Zbog ovih sposobnosti analize, vještačka inteligencija najčešće se primjenjuje u upravljanju odnosima s kupcima, prodaji i marketingu. Međutim, AI također ima široku primjenu u mnogim drugim poslovnim oblastima. Vještačka inteligencija igra ključnu ulogu u unapređenju odnosa s kupcima. Prvi korak u ovom procesu je analiza potrošača. Ova analiza se usmjerava na pet glavnih oblasti koje su od suštinskog značaja za razumijevanje potreba potrošača tj. kupaca:

1. Dostupnost podacima: Ovaj segment je od suštinskog značaja za poslovnu analitiku jer promoviše informisano i zajedničko donošenje odluka unutar organizacije. Važno je da ključni akteri imaju dobro razumijevanje svog poslovnog okruženja kako bi mogli donijeti ispravne odluke.

2. Pregled: Sticanje dubljeg uvida u razloge određenih događaja, kao što su analiza historije transakcija, stavovi i ponašanje kupca samo su neki od uvida koji nam pomažu i doprinose izboru boljih poslovnih odluka i strategija.

3. Prognoziranje: Upotreba prethodnih informacija za prognoziranje potencijalnih budućih rezultata zbog optimizacije aktivnosti u cilju postizanja poslovnih ciljeva i ispunjenja zahtjeva.

4. Agilnost u poslovanju: Podrška donošenja odluka u stvarnom vremenu, kako u procesima usmjerenim na ljude, tako i u automatizovanim sistemima. Ovaj pristup omogućava brže i efikasnije reagovanje na promjene i izazove u poslovanju.

5. Strateška usklađenost: Ima za cilj usklađenje elemenata poslovanja, od strategije do realizacije, te se fokusira na bilježenje preferencija, prioriteta, ciljeva i zahtjeva koji utiču na proces odabira najbolje poslovne odluke.

U nastavku se provodi deskriptivna analiza, zatim se izrađuju prognoze budućih događaja, a

potom se preduzimaju konkretne mjere kako bi se postigli očekivani rezultati(Akerkar, 2019).

Upravljanje odnosima s kupcima putem AI može se jasno ilustrirati primjerom savremenih kontakt centara, koji svakodnevno obavljaju komuniciraju sa nekoliko hiljada različitih korisnika Ovaj pristup se može posmatrati kao automatizacija horizontalno integrisanih poslovnih procesa, koji obuhvataju odjele preduzeća koji direktno komuniciraju sa klijentima, kao što su marketing, prodaja, usluge i korisnička podrška. U ovom procesu koriste se razni međusobno povezani kanali (Akerkar, 2019).

Ova oblast je doživjela značajan napredak uslijed integracije AI tehnologija u poslovanju (Mandić, 2007). Glavni motivi kompanija koje teže uspostavljanju dugoročnih veza sa potrošačima su isključivo ekonomske osonove. Cilj je zadržati postojeće potrošače za koje se procjenjuje da imaju profitni potencijal u budućnosti. Polazi se od jednostavne činjenice da, s povećanjem nivoa zadovoljstva potrošača, dolazi oko 60% svih narudžbi preduzeća. Razlozi zbog kojih potrošači žele ulaziti u ovakve odnose s preduzećima su: prepoznavanje, personalizacija, povećanje samopouzdanja u komunikaciji, smanjenje rizika, dostizanje određenog društvenog statusa i potreba za pripadanjem (Živković, 2011).

Cilj je značajno ubrzati proces odgovaranja na korisničke zahtjeve, s naglaskom na rješavanje što većeg broja zahtjeva već prilikom prvog kontakta. Korisničko zadovoljstvo se smatra ključnom varijablom na kojoj se kontinuirano radi, a interakcija s korisnicima postaje sve individualizovanija. (Cvetković, 2015). U kontakt centrima koriste se i botovi, posebno chatbotovi. Općenito, svi botovi mogu se podijeliti u tri osnovne kategorije:

1. botovi koji traže informacije,
2. botovi koji traže informacije kako bi izvršili specifične zadatke,
3. botovi sa socijalnim sposobnostima i zadacima (Henry *et al.*, 2019).

Vještačka inteligencija u kontakt centrima može smanjiti potrebu za ljudskim kognitivnim sposobnostima tako što brzo i efikasno procesuira i analizira veliku količinu podataka. Korištenjem mašinskog učenja moguće je prepoznati obrasce u ponašanju potrošača te predvidjeti njihovo buduće ponašanje. Naravno, bez obzira na svu vještačku inteligenciju koja se koristi u svrhu poboljšanja odnosa s kupcima, nikako se ne smije zanemariti uloga agenta. Kao što je već bilo rečeno, vještačkom inteligencijom upravljaju ljudi i u velikoj većini slučajeva riječ je o procesima koji moraju biti nadzirani (Akerkar, 2019).

Vještačka inteligencija može biti od velike pomoći pri predviđanju ponašanja potrošača. To je zato što na ponašanje potrošača utiče mnoštvo faktora. Zbog toga je potrebno prikupiti i analizirati velike količine podataka, pripremiti ih i na temelju njih predvidjeti buduće ponašanje, u skladu s kojim se zatim donose marketinške strategije i poslovne odluke. Već duže vrijeme preduzeća primjenjuju tzv. digitalni marketing, koji je zapravo preduvjet za implementaciju vještačke inteligencije u marketing. Koriste se i nazivi kao što su internetski

marketing, online marketing, web marketing i slično. Jednostavno rečeno, riječ je o marketinškim aktivnostima koje se odvijaju putem digitalnih medija. Radi se o procesu koji koristi internet kao komunikacijski kanal i uspostavlja marketinške aktivnosti kroz upotrebu tehnoloških dostignuća u vidu računarske tehnologije i interneta kao marketinškog medija, a kao marketinški koncept treba osigurati razmjenu vrijednosti koja će profitabilno zadovoljiti interese pojedinaca i organizacija (preduzeća). Osnovna odrednica takvog marketinga je komunikacija putem računarske mreže, što podrazumijeva neophodnost posjedovanja znanja i sposobnosti umrežavanja i mrežnog komuniciranja (Knežević, 2010).

Baze podataka i tehnologije za kontakt s potrošačima (Internet, mobilna telefonija i sl.) omogućavaju lakšu identifikaciju pojedinačnih potrošača, preciznu segmentaciju i ciljanje potrošača te prilagodbu svih marketinških aktivnosti (ponude, cijene, kanali prodaje i distribucije, komunikacija) pojedinačnim potrošačima (Škare, 2011).

Prediktivna analitika omogućava trgovcima da izvlače informacije iz podataka i koriste ih za predviđanje trendova kupovine i obrazaca ponašanja korisnika. Ovaj alat analizira veliku količinu podataka i pomaže u otkrivanju najvažnijih uvida. Radi kroz sljedeće korake:

1. Identifikacija ciljeva i analiza prikupljenih podataka kako bi se utvrdili obrasci ili modeli koji odgovaraju potrebama.

2. Kreiranje modela i njihova validacija. U ovom koraku koristi se tzv. rudarenje podataka za pročišćavanje i odabir konačnog modela. Modeli se potvrđuju na temelju postavljenih ciljeva.

3. Primjena modela rezultira poslovnim odlukama i neprestanim usavršavanjem modela za postizanje boljih rezultata (Thiraviyam, 2018).

Primjena vještačke inteligencije u finansijskom sektoru poznata je i pod nazivom „finansijska vještačka inteligencija“. Neki od primjera kako vještačka inteligencija pomaže finansijskom sektoru uključuju i njen poseban utjecaj u upravljanju rizicima osiguravajućih kuća (Corea, 2019).

ChatGPT predstavlja revolucionarni alat u svijetu, a pogotovo u poslovnom okruženju. Zbog svoje jednostavnosti i lagane implementacije, poslovni subjekti ga koriste svakodnevno. Brynjolfsson i Raymond (2023) su istražili kako vještačka inteligencija, konkretno implementacija ChatGPT-a, može unaprijediti rad u korisničkoj podršci. Preduzeće na kojem je provedeno istraživanje unaprijed je obučilo ChatGPT koristeći snimljene razgovore s korisničkom službom, uključujući i uspješno riješene i neriješene slučajeve. Chatbot su dodatno prilagodili za korisničku podršku tako što daje prioritet odgovorima koji izražavaju empatiju, pružaju odgovarajuću dokumentaciju i ograničavaju upotrebu neprofesionalnog jezika. ChatGPT pomaže promatranom poduzeću na način da agentima nudi prijedloge za odgovore korisnicima ili im nudi poveznicu za interne dokumente koji objašnjavaju rješenja tehničkih poteškoća. U istraživanju su otkrili kako pomoću vještačke inteligencije jedan agent poveća svoju produktivnost za 14% u samo jednom satu (Brynjolfsson i Raymond,

2023). Kako se ChatGPT može primijeniti u finansijskoj industriji objasnili su Ali i Aysan (2023). Fokusirali su se na poređenje ChatGPT-a s postojećim bankarskim i finansijskim chatbotovima. Cilj je bio istražiti šta ChatGPT nudi i kako se razlikuje od postojećih rješenja. ChatGPT pomaže korisnicima tako što im pruža informacije o stanju njihovog računa, obavlja transakcije s odgovarajućim podacima te korisnicima nudi trenutnu podršku bez potrebe za odlaskom u poslovnicu. Pokazalo se da nudi brojne usluge, čime unapređuje i poboljšava efikasnost i korisničko iskustvo (Ali i Aysan, 2023).

Kalla i Smith (2023) su analizirali kako se ChatGPT može koristiti u različitim aspektima poslovanja. U oblasti kibernetičke sigurnosti, naveli su da se ChatGPT može koristiti za otkrivanje i sprječavanje kibernetičkih napada. Chatbot može pomoći u identifikaciji phishing e-mailova analiziranjem jezika i utvrđivanjem da li je e-mail pravi ili lažan. Također, može pomoći u otkrivanju zlonamjernih softvera i može se koristiti kao pomoć u sastavljanju sigurnosnih šifri. Kalla i Smith (2023) objašnjavaju kako je ChatGPT imao veliki utjecaj na razvoj novih softvera jer je omogućio integraciju obrade prirodnog jezika u softverske aplikacije. Pomoću njega, programeri mogu stvoriti naprednije chatbotove koji mogu razumjeti i odgovarati na korisnička pitanja. Također su prikazali kakav utjecaj ChatGPT ima na poslove. ChatGPT je otvorio nove mogućnosti za zapošljavanje, ali je s druge strane utjecao na postojeće poslove. Na primjer, chatbotovi se sve više koriste kao virtualni asistenti za rješavanje korisničkih upita, što smanjuje potrebu za zaposlenicima u korisničkim službama. Iako naglašavaju da će razvoj ChatGPT-a vjerovatno potpuno zamijeniti neka radna mjesta, on će također stvoriti nova radna mjesta, kao što su poslovi vezani za obradu prirodnog jezika i vještačku inteligenciju (Kalla i Smith, 2023). ChatGPT se može koristiti i u softverskom inženjerstvu za razne zadatke, poput generisanja koda i testiranja softvera. Može se koristiti za generisanje dijelova koda putem obrade prirodnog jezika i opisa željene funkcionalnosti, što dovodi do uštede vremena u razvoju programa. U suštini, ChatGPT je inovativna tehnologija koja je revolucionirala načine poslovanja u brojim sektorima različitih industrija, od korisničke službe i marketinga pa sve do razvoja softvera.Njegov potencijal i daljnja evolucija će sa sigurnošću dovesti još bolje rezultate i napretke (Raychev *et al.*, 2014).

2.3.1. Prednosti vještačke inteligencije u poslovanju

Vještačka inteligencija donosi brojne prednosti koje značajno unapređuju poslovne procese i općenito radnu učinkovitost. Njena implementacija omogućava automatizaciju zadataka, smanjenje troškova, te brže i pouzdanije donošenje odluka. Kroz integraciju u različite sektore, vještačka inteligencija omogućava objektivniji i precizniji rad, oslobađajući ljudske resurse za složenije i kreativnije zadatke. Pored toga, ona omogućava stvaranje interaktivnih i inovativnih radnih okruženja, što doprinosi boljim rezultatima i većoj uspješnosti organizacija. Prednosti vještačke inteligencije su sveprisutne i predstavljaju ključni element za unapređenje poslovnog performansa u modernom dobu. Pojednostavljenje poslovnih procesa i preuzimanje radnih zadataka: Automatizacija procesa smanjuje kognitivno opterećenje zaposlenika, omogućavajući im da se fokusiraju na važnije aspekte svog posla.

Brže i pouzdanije donošenje odluka u situacijama s visokim stepenom nesigurnosti, vještačka inteligencija omogućava brže i pouzdanije donošenje odluka (l-Amin *et al.*, 2024).

Primjena vještačke inteligencije u poslovanju progresivno raste. Međutim, još uvijek nije potpuno jasno koji je omjer pozitivnih i negativnih strana. Kao i kod svake tehnologije, i kod vještačke inteligencije postoje određene prednosti i nedostaci. Ipak, čini se da se nedostaci, generalno gledano, smanjuju, dok prednosti postaju sve izraženije. Davenport i Ronanki (2018) ističu da je vještačka inteligencija još uvijek daleko od ljudske inteligencije u pogledu složenosti i općenito, ali je istovremeno izuzetno efikasna u rješavanju specifičnih zadataka, te je njen uticaj na svijet i organizacije nesumnjivo značajan. Kompanije nastoje pronaći načine da optimizuju rad, povećaju prihode i poboljšaju produktivnost. Dizajniraju radne procese koji smanjuju mogućnost grešaka i izbjegavaju preopterećenje zaposlenih, čime se postiže veća efikasnost i razvoj kvalitetnijih radnih procesa (Pillai i Sivathanu, 2020).

Najveća prednost vještačke inteligencije je što značajno smanjuje greške i povećava tačnost i preciznost u izvršavanju zadataka. Ovo je moguće jer se sve odluke donose na osnovu prethodno prikupljenih podataka i koriste se specifični algoritmi koji, ako su pravilno programirani, mogu gotovo u potpunosti eliminisati greške. Vještačka inteligencija pomaže u rješavanju složenih problema koji zahtijevaju kompleksne izračune i moraju se obaviti bez grešaka. Posebno je korisna u obavljanju poslova koji nose određene rizike, omogućavajući njihovo izvođenje bez ugrožavanja ljudi. To uključuje zadatke poput deaktiviranja bombi, istraživanja teško dostupnih mjesta, dubina okeana, vađenja nafte i uglja, kao i reakcije na prirodne i ljudske katastrofe. U ovim situacijama koriste se roboti koji preuzimaju rizik na sebe, pružajući tačan rad i veću odgovornost (Sharma i Kaur, 2021). Ljudi nisu sposobni raditi neprekidno duže vrijeme, a mnoga istraživanja pokazuju da su produktivni samo oko 3 do 4 sata dnevno. U prosjeku, čovjek radi 8 do 9 sati dnevno, uključujući pauze, i potrebno mu je vrijeme za odmor te balans između poslovnog i privatnog života. U takvim situacijama roboti preuzimaju zadatke. Oni mogu raditi bez prekida, razmišljaju brže, imaju sposobnost obavljanja više zadataka istovremeno s većom preciznošću, i mogu preuzeti zamorne poslove (Sharma i Kaur, 2021).

Što se tiče virtualnih asistenata, mnoge ih kompanije koriste za stupanje u kontakt s korisnicima, isporuku traženog sadržaja te za odgovaranje na sve nedoumice i brige koje korisnici imaju u vezi s uslugama ili samom kompanijom (Pillai i Sivathanu, 2020). Ovo predstavlja savršen primjer kompanija koje koriste virtualne asistente za simulaciju gotovo ljudskih razgovora s klijentima. Na taj način oslobađaju značajno vrijeme kako bi se mogli posvetiti važnijim aspektima svog poslovanja. Uz virtualne asistente, vještačka inteligencija predstavlja pokretačku snagu mnogih budućih inovacija koje će na sličan način pomoći ljudima u rješavanju izazovnih problema (Sharma i Kaur, 2021).

Jedna od važnih prednosti vještačke inteligencije je racionalan pristup donošenju odluka. Za razliku od ljudi, koje često pokreću emocije i subjektivni stavovi, što može uticati na donošenje važnih odluka, vještačka inteligencija nema emocije niti stavove, te je vrlo praktična i racionalna u svom pristupu odlučivanju. Pored racionalnog pristupa, vještačka

inteligencija omogućava i brže donošenje odluka. Automatizacijom određenih zadataka i pružanjem uvida u njih, pomaže organizacijama u donošenju odluka, posebno u situacijama gdje greške mogu biti skupe ili gdje odluka može spasiti život. Proces donošenja odluka se kontinuirano poboljšava uzimajući u obzir prethodna iskustva (Pillai i Sivathanu, 2020). Poslovi koji se ponavljaju i koje ljudi smatraju dosadnima, kao što su provjeravanje dokumenata, slanje poruka ili zahvalnica, mogu se automatizovati uz pomoć vještačke inteligencije, što ljudima daje više vremena za kreativnije zadatke. Za manje poslovne zadatke kao što su odgovaranje na e-poštu, fotografisanje, obavljanje poziva, provjera vremena, pronalaženje informacija, navigacija i slično, danas imamo jednostavna rješenja u obliku pametnih telefona s pristupom internetu (Sharma i Kaur, 2021). Aplikacije kao što su Siri (koja funkcioniše kao lični virtualni asistent), karte i GPS (koji nude najkraće rute do odredišta) uveliko su olakšale svakodnevni život. Svi ovi zadaci mogu se obaviti u vrlo kratkom vremenu, dok su ranije zahtijevali mnogo više truda, napora i istraživanja.

Vještačka inteligencija omogućava brzu obradu velike količine podataka. Može analizirati podatke, izdvojiti one koji su relevantni za detaljniju analizu, te im pridružiti smisao i interpretirati ih kako bi ljudi mogli što bolje i efikasnije iskoristiti te informacije. Također, osigurava trajnost podataka, sprječavajući njihov gubitak (Anjila, 2021). Danas je na svim računarima i pametnim telefonima moguće brzo i bez većih poteškoća povratiti izbrisane podatke. Još jedan od važnijih pozitivnih primjera što vještačka inteligencija ima značajnu primjenu u medicini. Uz njenu pomoć, ljekari mogu brzo procijeniti pacijente i njihove zdravstvene rizike. Radi se na treniranju sistema o nuspojavama lijekova, a ljekari imaju mogućnost da uče i napreduju koristeći kirurške simulatore. Također, mašine se koriste za razne operacije koje zahtijevaju visoku preciznost i tačnost (Pillai i Sivathanu, 2020).

Vještačka inteligencija pruža veliki potencijal za poboljšanje ekonomije jedne zemlje. Prilikom određivanja optimalnog pristupa za rukovanje sredstvima, AI sistemi mogu uzeti u obzir veliki broj varijabli, što omogućava brzo donošenje odluka i ostvarivanje visokih prihoda od poslovanja- U tom kontekstu, u budućnosti bi roboti mogli zamijeniti finansijske savjetnike i pomoći ljudima u donošenju što boljih odluka (Sharma i Kaur, 2021).

2.4. Inovativnost i radna učinkovitost

2.4.1. Teorijski okviri i različiti pristupi razumijevanju inovativnosti

Inovacije u poslovanju i šire u ekonomiji imaju ključnu ulogu u podsticanju održivog rasta, otvaranju novih radnih mjesta, te osiguravanju dugoročnog uspjeha kompanija. Inovativnost se može smatrati osnovom za razvoj novih proizvoda, procesa i usluga koji povećavaju produktivnost, unapređuju poslovne performanse i omogućavaju kompanijama da ostvare konkurentsku prednost na tržištu. Stoga je jasno koliko su inovacije važne za uspješno poslovanje. U današnjem vremenu, kada se poslovno okruženje suočava s konstantnim promjenama, neophodno je da kompanije budu inovativne kako bi opstale i napredovale.

Inovativnost postaje ne samo ključna tema, već i imperativ za rast i razvoj kompanija. Ljubanović (2023) tvrdi da je inovativnost prisutna u svim segmentima poslovanja i obuhvata sve dijelove organizacije. Postavlja se ključno pitanje: šta čini jednu kompaniju inovativnom? U većini slučajeva, uspjeh kompanije zavisi od njene sposobnosti da bude kreativna i inovativna, kako na nivou pojedinačnih zaposlenih, tako i na nivou cijele organizacije. Uspjeh se mjeri sposobnošću kompanije da razvije i plasira inovativne proizvode i usluge na tržište, čime se osigurava njen dugoročni opstanak i rast.

U savremenom poslovnom okruženju, oštra konkurencija predstavlja ključnu karakteristiku kompanija, dok promjene koje nastaju usljed globalizacije i razvoja savremenih tehnologija postaju sve intenzivnije i izraženije. Takvi poslovni uslovi prisiljavaju organizacije da razvijaju i primjenjuju raznovrsne pristupe kreativnosti i inovativnosti, s ciljem sticanja i održavanja konkurentske prednosti na globalnom tržištu. U razvijenim zemljama, valorizacija i implementacija kreativnosti i inovativnosti su daleko prisutnije nego u manje razvijenim zemljama ili zemljama u tranziciji, što doprinosi razlikama u stepenu rasta i razvijenosti među njima kao i samom razumijevanju istih. Svaka organizacija, posebno u kontekstu inovativnosti, treba pažljivo uzeti u obzir pojedince, grupe zaposlenih, organizacijski sistem, kao i strateški okvir prilikom odabira intervencija koje povećavaju kreativnost (Gumusluoglu i Ilsev, 2009).

Ako kompanija uspije stvoriti okruženje u kojem se kontinuirano inoviraju proizvodi i usluge, te u kojem se razvija inovativan poslovni sistem, time postavlja temelj za svoj dugoročni uspjeh. Ovakav pristup se često naziva umreženom kreativnošću, što podrazumijeva sposobnost organizacije da kontinuirano jača svoju inovativnost i prilagođava se promjenama kroz inovacije u svojim proizvodima, uslugama i poslovnom modelu, s ciljem osiguranja konkurentske prednosti i opstanka na tržištu (Brennan i Dooley, 2005). Prema Dahlanovom (2010) konceptu evolucijske ekonomije, ekonomija se posmatra kao živi organizam koji se razvija, adaptira, i samoorganizuje u skladu sa promjenama. Inovacija je postala veoma popularan termin, ali se često koristi i bez jasnog razumevanja njenog pravog značenja. Stoga je ključno temeljno razumeti proces i suštinu inovacije i inovativnosti. Često se inovacija i kreativnost koriste kao sinonimi, ali iako su slični, oni nisu isti. Kreativnost u poslovanju je važna jer generiše jedinstvene ideje, ali da bi ideja postala inovativna, mora biti korisna. Kreativne ideje ne dovode uvek do inovacija. U suštini, inovacija predstavlja proizvod, uslugu, poslovni model ili strategiju koja je nova i korisna. Inovacije ne moraju nužno predstavljati velike tehnološke proboje ili nove poslovne modele - one mogu biti jednostavne poput unapređenja korisničkog servisa ili dodavanja novih funkcija postojećem proizvodu (Ljubanović, 2023).

Kada se govori o vrstama inovacija, važno je spomenuti tipologiju iznesenu u Oslo Manual-u (2018), koji predstavlja ključni dokument za definisanje inovacija unutar Evropske unije. U ovom dokumentu se prepoznaju četiri osnovne vrste inovacija u kompanijama: inovacije proizvoda, inovacije procesa, organizacione inovacije i marketinške inovacije. Za razvoj inovacija, neophodno je posjedovati širok spektar znanja iz različitih oblasti, jer se postojeća znanja moraju transformirati u uspješne inovacije, čak i u neizvjesnim poslovnim uslovima.

Kontinuirane inovacije su ključne za održavanje konkurentske prednosti kompanija, a kompanije koje su inovatIvne imaju veći potencijal za brži rast i razvoj (Mumford, 2000).

2.4.2. Faktori koji podstiču inovativnost u organizacijama

Inovativna kultura može se definirati kao „skup zajedničkih vrijednosti, vjerovanja i normi unutar organizacije koje podržavaju i podstiču kreativno razmišljanje, preuzimanje rizika i eksperimentisanje, što sve vodi ka stvaranju novih ideja, proizvoda i usluga“ (Schein, 2010). Ova kultura stvara okruženje u kojem zaposlenici osjećaju slobodu da istražuju nove ideje, preuzimaju rizike i uče iz neuspjeha bez straha od negativnih posljedica. Inovativna kultura nije rezultat slučajnosti, već promišljene strategije koja obuhvata sve aspekte poslovanja od načina vođenja timova, preko organizacijskih struktura, do svakodnevnih operativnih procesa.

Jedan od ključnih faktora razvoja inovativnosti u organizacijama je liderstvo koje podržava i promoviše inovacije. Lideri u organizaciji igraju vitalnu ulogu u stvaranju atmosfere povjerenja i otvorenosti, gdje se svaka ideja vrednuje, a konstruktivne povratne informacije podstiču dalji razvoj. Pored toga, organizacije moraju obezbijediti resurse za kontinuirano učenje i profesionalni razvoj svojih zaposlenika, kako bi im omogućile da prate najnovije trendove i usvajaju nove vještine. Saradnja i timski rad također su suštinski za inovativnu organizaciju. Kroz saradnju i razmjenu ideja, zaposlenici mogu kombinirati različite perspektive i ekspertize, što često vodi do inovativnih rješenja koja pojedinci sami ne bi mogli postići. Transparentnost i otvorena komunikacija na svim nivoima organizacije dodatno podstiču ovu sinergiju, omogućavajući brzo dijeljenje informacija i ideja.

Uvođenje i razvoj inovativne kulture u poslovanju predstavlja dugoročnu investiciju koja može donijeti brojne benefite, uključujući povećanje konkurentnosti, poboljšanje efikasnosti i rast zadovoljstva zaposlenih. Organizacije koje uspješno integrišu inovacije u svoje svakodnevne procese postaju otpornije na tržišne promjene i bolje pripremljene za buduće izazove. Samim tim, razvoj inovativne organizacije nije samo opcija, već imperativ za svaki poslovni sistem koji teži održivom rastu i uspjehu (Gumusluoglu i Ilsev, 2009).

Ključni faktori za posticanje inovativnosti u organizacijama mogu se objasniti na sljedeći način:

Liderstvo: Lideri koji aktivno podržavaju inovacije i kreiraju viziju koja motivira zaposlenike da prepoznaju važnost inovacija za dugoročni uspjeh organizacije. Oni osiguravaju potrebne resurse, grade kulturu povjerenja i sami služe kao uzor svojim ponašanjem (Schein, 2010).

Organizaciona kultura: Kultura koja cijeni kreativnost, otvorenost prema promjenama, timski rad i kontinuirano učenje. Takva kultura omogućava zaposlenicima da se osjećaju podržano u generiranju i implementaciji novih ideja.

Komunikacija: Otvorena i transparentna komunikacija koja omogućava razmjenu ideja i povratnih informacija. Efikasna komunikacija je ključna za suradnju i uspješno novitete unutar organizacije.

Podrška za eksperimentisanje i učenje: Organizacije koje potiču eksperimentisanje i kontinuirano učenje stvaraju okruženje koje omogućava stalni razvoj inovacija. To uključuje toleranciju prema greškama i osiguravanje resursa za eksperimentisanje.

Motivacija i nagrađivanje: Pravilno dizajnirani sistemi motivacije i nagrađivanja potiču zaposlenike na kreativnost i učešće u inovativnim projektima.

Tehnološka podrška: Savremene tehnologije koje omogućavaju efikasniju komunikaciju, saradnju i razvoj kreativnih ideja. Ova podrška uključuje napredne alate, pristup velikim količinama podataka i kontinuiranu obuku zaposlenika.

Kultura povjerenja i suradnje: Okruženje u kojem se zaposlenici osjećaju slobodno dijeliti ideje i preuzimati rizik, gdje je timska saradnja i razmjena znanja ključna za razvoj inovativnih rješenja. Transparentnost i empatija doprinose jačanju ove kulture (Sedighi *et al.*, 2022).

Razvoj inovativne kulture u poslovanju je od suštinskog značaja za dugoročni uspjeh i konkurentnost organizacija u savremenom, dinamičnom poslovnom okruženju. Ovaj proces zahtijeva sveobuhvatan pristup, gdje svaki faktor – od liderstva i organizacione kulture, do komunikacije, podrške za eksperimentisanje i učenje, motivacije, tehnološke podrške, te kulture povjerenja i saradnje imaju ključnu ulogu u stvaranju okruženja koje podstiče inovacije. Lideri koji aktivno podržavaju i promovišu inovacije igraju presudnu ulogu u pokretanju promjena unutar organizacije. Istovremeno, organizaciona kultura koja naglašava otvorenost, spremnost na preuzimanje rizika i promjene, te podstiče saradnju i timski rad, predstavlja temelj za uspješno sprovođenje inovacija. Integracija ovih faktora u poslovnu strategiju ključna je za stvaranje okruženja koje podstiče kreativnost, preuzimanje rizika i saradnju, omogućavajući organizacijama da ostanu konkurentne i ostvaruju dugoročni uspjeh. Samo organizacije koje uspješno razviju inovativnu kulturu mogu očekivati da postanu lideri u svom sektoru i da postignu održivi rast i razvoj (Vuković *et al.*, 2024).

2.5. Tehnološka svijest i radna učinkovitost

U savremenom poslovnom okruženju, tehnološka svijest igra ključnu ulogu u poboljšanju radne učinkovitosti. Razvoj tehnologije i njena sve veća integracija u poslovne procese postavljaju pred zaposlenike potrebu za kontinuiranim usvajanjem novih znanja i vještina. Tehnološka svijest, koja obuhvata razumijevanje, korištenje i adaptaciju novih tehnologija, postaje presudna za poboljšanje performansi zaposlenih i organizacijske efikasnosti.

2.5.1. Značaj tehnološke svijesti u savremenom poslovanju

Tehnološka svijest, koja se odnosi na razumijevanje i poznavanje savremenih tehnologija te njihovu primjenu u svakodnevnim poslovnim aktivnostima, postaje ključna za održavanje konkurentnosti i postizanje organizacionih ciljeva. U dinamičnom poslovnom okruženju, gdje digitalna transformacija predstavlja suštinski dio poslovne strategije, zaposlenici s visokom tehnološkom sviješću imaju mogućnost brze adaptacije na nove tehnologije, što organizacijama omogućava efikasnu implementaciju novih alata i unapređenje poslovnih procesa (Moorthy i Polley, 2010). Zaposlenici s razvijenom tehnološkom sviješću mogu koristiti napredne softverske alate za analizu podataka, što poboljšava donošenje odluka i optimizaciju poslovnih procesa. Ova svijest ne samo da povećava radnu učinkovitost pojedinaca, već doprinosi i sveukupnoj sigurnosti i stabilnosti poslovanja. Primjeri poput zemalja kao što su Kina, Indija, Velika Britanija i SAD pokazuju da su uspješno iskoristile prednosti ekonomije znanja kroz povećanje tehnološke svijesti, što je omogućilo značajne poslovne rezultate i konkurentsku prednost (Bharadwaj, 2000).

2.5.2. Edukacija i razvoj tehnoloških vještina

Edukacija i razvoj tehnoloških vještina predstavljaju osnovu za podizanje tehnološke svijesti u organizacijama. Kao što ističu Moorthy i Polley (2010), ravnoteža između dubine i širine tehnološkog znanja je ključna za omogućavanje zaposlenicima da efikasno rješavaju složene probleme i integrišu znanja iz različitih tehnoloških disciplina. Takva edukacija uključuje formalne obuke, online kurseve, radionice i mentorski rad, usmjerene na sticanje specifičnih vještina potrebnih za rad sa savremenim tehnologijama. Razvoj tehnoloških vještina također zahtijeva stalno praćenje tehnoloških trendova i inovacija. U dinamičnom poslovnom okruženju, gdje se tehnologije brzo mijenjaju, važno je da zaposlenici ostanu informisani o najnovijim dostignućima i mogućnostima koje im stoje na raspolaganju (Wang *et al*., 2020). Organizacije koje prepoznaju važnost kontinuiranog razvoja tehnoloških vještina među svojim zaposlenicima bolje su opremljene za brzu adaptaciju na promjene i mogu efikasnije odgovoriti na zahtjeve tržišta (Ashrafi i Murtaza, 2011).

Pored toga, tehnološka pismenost, koja je od suštinske važnosti za postizanje visokih performansi u digitalnom poslovnom okruženju, poboljšava donošenje odluka unutar organizacija putem efikasnog upravljanja informacijama. Time se omogućava pravovremeno i precizno prikupljanje, tumačenje i dijeljenje relevantnih informacija, što je ključno za organizacijsko planiranje, interakciju i saradnju (Ladokun i Osunwole, 2019). Razvoj tehnološke pismenosti takođe pomaže organizacijama u širenju poslovanja na globalnom nivou, čime se povećava njihova konkurentnost na međunarodnom tržištu (Liang i You, 2019).

2.5.3. Uticaj tehnološke svijesti na performanse zaposlenih

Tehnološka svijest ima direktan uticaj na performanse zaposlenih jer omogućava efikasniju

primjenu tehnologije u svakodnevnim poslovnim aktivnostima. Zaposlenici s visokom tehnološkom sviješću sposobni su brže i preciznije obavljati svoje zadatke, koristeći napredne alate i softvere koji automatizuju rutinske procese, smanjujući tako mogućnost grešaka i povećavajući ukupnu produktivnost. Tehnološka svijest omogućava zaposlenicima da budu proaktivni u rješavanju problema i pronalaženju inovativnih rješenja. Poznavanje analitičkih alata može pomoći zaposlenicima da identifikuju obrasce i trendove u podacima, što vodi do unapređenja poslovnih procesa i donošenja informisanijih odluka. Tako se ne samo poboljšava radna učinkovitost, već se povećava i zadovoljstvo zaposlenika, jer se osjećaju da aktivno doprinose uspjehu organizacije (Ogbeibu *et al.*, 2023).

Visok nivo tehnološke svijesti omogućava organizacijama da bolje iskoriste prednosti digitalne transformacije i postignu konkurentsku prednost na tržištu. Organizacije koje ulažu u razvoj tehnološke svijesti kod svojih zaposlenika mogu očekivati poboljšanje ukupne radne učinkovitosti, inovativnosti i prilagodljivosti na promjene, što je ključno za dugoročni uspjeh u savremenom poslovnom okruženju (Brougham i Haar, 2018).

2.6. Percipirani rizik i prihvatanje vještačke inteligencije

2.6.1. Razumijevanje percipiranog rizika

Percepcija rizika predstavlja ključan faktor u razumijevanju ponašanja pojedinaca i organizacija prilikom suočavanja s neizvjesnostima. Rizik, kako ga doživljavaju ljudi, ne temelji se isključivo na objektivnim činjenicama ili statističkoj vjerovatnoći, već je podložan subjektivnim faktorima, uključujući emocionalne, socijalne i kulturološke aspekte. Ova subjektivnost utiče na način na koji ljudi procjenjuju rizike, te često dovodi do razlika između percepcije laika i stručnjaka. Na primjer, laici su skloniji precjenjivanju rizika koji su dramatični, rijetki ili emocionalno nabijeni, dok stručnjaci teže analizi rizika na osnovu kvantitativnih podataka i vjerovatnoća (Slovic, 2000).

Važno je naglasiti da percepcija rizika ne proizlazi samo iz razumijevanja statističkih pokazatelja, već i iz konteksta u kojem se pojedinac ili grupa nalazi. Društveni i kulturni faktori igraju značajnu ulogu u oblikovanju stavova prema riziku. Na primjer, ljudi ne doživljavaju svijet objektivno, već kroz filter društvenih i kulturnih značenja, što dodatno komplikuje procjenu rizika (Dietz *et al.*, 1993). Pored toga, percepcija rizika može varirati u zavisnosti od vrste rizika s kojim se pojedinci suočavaju. U modernom društvu, rizici koji proizlaze iz tehnologije ili naučnih inovacija često su percipirani kao veći i opasniji zbog svoje nevidljivosti i kompleksnosti, u poređenju sa tradicionalnim rizicima koji su bili fizički opipljivi i lako uočljivi (Beck, 1986/2003).

Ovakav pristup pojašnjava zašto savremeni rizici, poput upotrebe nuklearne energije, izazivaju veći strah u javnosti u poređenju sa rizicima iz svakodnevnih aktivnosti, kao što su pušenje ili vožnja (Renn, 2004). Prema istraživanjima o psihometrijskoj procjeni rizika, percepcija rizika kod laika se najčešće zasniva na dva faktora: strahu i poznatosti rizika.

Rizici koji su nepoznati ili koji izazivaju visok nivo straha obično su precijenjeni u očima javnosti, dok poznati i svakodnevni rizici, iako možda opasniji, bivaju podcijenjeni (Slovic, 2000). Tehnološka svijest odnosi se na znanje, razumijevanje i upoznatost pojedinca s tehnologijom. Slično tome, percipirani rizik opisuje svijest pojedinca o mogućim pozitivnim posljedicama korištenja određene tehnologije (Im *et al.*, 2008).

Zabrinutost za privatnost i sigurnost može dovesti do oklijevanja u korištenju određenih online usluga ili dijeljenju ličnih informacija na internetu, čime se ograničava njihova tehnološka svijest (Vrontis *et al.*, 2022). S druge strane, kada pojedinci percipiraju visoku sposobnost preuzimanja rizika s tehnologijom, veća je vjerovatnoća da će biti uključeni u tehnologiju i razviti veću svijest i upoznatost s njom (Arias-Oliva *et al.*, 2019). Percipirani rizik u vezi s korištenjem pametnih telefona i društvenih mreža doveo je do široke primjene i visokih nivoa tehnološke svijesti u tim oblastima. (Ongena *et al.*, 2020).

Percipirani rizik može biti važan faktor u oblikovanju stavova i ponašanja pojedinaca prema tehnologiji i u utjecaju na nivo njihove tehnološke svijesti. HR funkcije uključuju upravljanje zaposlenicima i njihovim odnosima s organizacijom, poput procesa zapošljavanja, obuke i razvoja, upravljanja učinkom i odnosa sa zaposlenicima (Charlwood i Guenole, 2022). Pojedinci koji imaju visok nivo tehnološke svijesti i percipiraju nizak rizik povezan s korištenjem tehnologije, vjerovatnije će usvojiti i u potpunosti iskoristiti tehnologiju u svojim HR funkcijama (Bhardwaj *et al.*, 2020). Sposobnost pojedinaca da preuzimaju rizike može poboljšati efikasnost i djelotvornost HR praksi, što može dovesti do boljih rezultata u zdravstvenom sektoru. Percipirani rizik može uticati na sposobnost organizacije da privuče vrhunske talente. Potencijalni kandidati preuzimaju rizike korištenjem tehnologije i unapređuju svoju industriju (Im *et al.*, 2008).

Percipirani rizik također može uticati na učinkovitost programa obuke i razvoja (Shi *et al.*, 2021). Zaposlenici koji imaju visoku razinu percipiranog rizika u vezi s iznošenjem zabrinutosti ili davanjem povratnih informacija mogu biti manje skloni to činiti. Percipirani rizik je također lični element koji može povećati transparentnost i adresirati probleme vezane za radni učinak (Chai *et al.*, 2023). Percipirani rizik utiče na organizacije, stoga one moraju prioritizirati kreiranje kulture povjerenja, transparentnosti i jasne komunikacije sa zaposlenicima (Chatterjee *et al.*, 2022). Pojam tehnološkog rizika povezan je sa tehničkim neuspjesima koji negativno utiču na rast poslovanja firme." (Khaksar *et al.*, 2019). Prirodno je da se tehnologija sa vještačkom inteligencijom mora primijeniti na odgovarajući način u firmi kako bi se firma suočila s minimalnim rizikom" (Masakowski, 2020). Neadekvatan razvoj AI rješenja integrisanog s poslovnom analitikom dovest će do povećanja ukupnog rizika za firmu" (Yeoh, 2019).

2.6.2. Strahovi i izazovi percipiranog rizika vezani uz primjenu vještačke inteligencije

Primjena vještačke inteligencije (AI) u različitim sektorima donosi značajne tehnološke napretke, ali i izazove koji su povezani s percepcijom rizika. Strahovi vezani za AI često

proizlaze iz nepoznavanja tehnologije, kao i iz neizvjesnosti o mogućim posljedicama njene primjene. Ovi strahovi uključuju zabrinutost zbog gubitka radnih mjesta, smanjenje privatnosti, kao i potencijalnu zloupotrebu tehnologije u svrhe koje nisu u skladu s javnim interesom (Slovic, 2000).

Percepcija rizika u vezi s vještačkom inteligencijom također se temelji na osjećaju gubitka kontrole. Kako tehnologija postaje sve autonomnija, strahovi da će AI donijeti odluke bez ljudske intervencije dodatno podstiču negativne stavove. Ovo se naročito odnosi na strah od "nepredviđenih posljedica" korištenja AI tehnologija, koje mogu imati dalekosežne uticaje na društvo i ekonomiju (Renn, 2004).

Izazovi povezani s percipiranim rizikom vještačke inteligencije uključuju i etičke dileme, poput pitanja kako osigurati odgovornost za greške koje AI sistemi naprave. Ovi rizici, iako često malo vjerovatni, mogu izazvati disproporcionalne strahove kod javnosti. Ljudi su skloniji precjenjivanju rizika koji su složeni i teže razumljivi, što dovodi do prekomjernog naglašavanja potencijalnih opasnosti AI tehnologija. Dodatno, jedan od ključnih izazova je kako na pravi način komunicirati koristi i rizike AI tehnologija.

Ukoliko javnost nije dovoljno informisana ili ne razumije tehnološke aspekte AI, percipirani rizik može značajno premašiti stvarni rizik, što može usporiti prihvatanje i implementaciju tehnologije. U tom kontekstu, transparentnost i otvorena komunikacija su ključni kako bi se umanjili strahovi i omogućilo bolje razumijevanje vještačke inteligencije (Slovic, 2000).

2.6.3. Strategije za smanjenje percipiranog rizika

Kako bi se uspješno smanjio percipirani rizik povezan s primjenom novih tehnologija, uključujući vještačku inteligenciju, potrebno je primijeniti specifične strategije. Jedna od osnovnih strategija je poboljšanje transparentnosti i komunikacije. Istraživanja pokazuju da jasna i otvorena komunikacija može značajno smanjiti strahove i nesigurnosti koje javnost ili korisnici mogu osjećati u vezi s novim tehnologijama. Transparentnost u pogledu načina funkcionisanja vještačke inteligencije, njenih mogućih rizika i koristi, kao i etičkih standarda, može pomoći u izgradnji povjerenja (Renn, 2004).

Pored komunikacije, ključna strategija za smanjenje percipiranog rizika je edukacija. Kako je Slovic (2000) naglasio, ljudi su skloni precijeniti rizike koje ne razumiju u potpunosti. Zbog toga je obrazovanje javnosti i korisnika o tehnologijama, njihovim funkcionalnostima i ograničenjima neophodno kako bi se smanjila pogrešna percepcija rizika. Informisanje i obrazovanje mogu pomoći u smanjenju strahova koji proizlaze iz nepoznavanja tehnologije i njenog uticaja. Još jedna važna strategija uključuje implementaciju sigurnosnih mehanizama i regulatornih okvira koji osiguravaju zaštitu korisnika. Razvijanje standarda za odgovorno korištenje vještačke inteligencije, kao i uvođenje kontrola koje garantuju privatnost i sigurnost podataka, može pomoći u smanjenju percipiranog rizika. Osiguranje povjerenja korisnika u tehnologiju ključno je za njeno prihvatanje.

Konačno, važno je da organizacije i kreatori procedura unutar organizacije aktivno uključe korisnike i sudionike u proces donošenja odluka o razvoju i implementaciji vještačke inteligencije. Ovakav participativni pristup može smanjiti osjećaj nesigurnosti i straha, jer korisnici imaju osjećaj kontrole i doprinosa procesu donošenja odluka.

3. EMPIRIJSKO ISTRAŽIVANJE

3.1. Metodologija

Namjena ovog poglavlja je da prikaže metodološki pristup koji je primijenjen u izradi ovog rada, a koji se u ovom istraživanju oslanja na korištenje kvantitativne metodologije. U skladu s tim, primijenjeni su upitnici koji će biti detaljno objašnjeni u narednim dijelovima, a koji obuhvataju strategiju korištenja, njihov dizajn, kao i proces prikupljanja podataka, čime se osigurava sveobuhvatan uvid u metodološki pristup istraživanju.

Odabir odgovarajuće metodologije predstavlja osnovni cilj istraživačke strategije, koja će omogućiti pravovremeno postizanje značajnih rezultata i istovremeno doprinijeti unapređenju kvaliteta istraživanja.

Primjenom kvantitativnog istraživanja, ovaj rad pokazuje temeljito empirijsko istraživanje vidljivih fenomena, koje se fokusira na analizu različitih aspekata društvenih pojava, pomoću matematičkih modela, teorija i/ili hipoteza a koje su povezane sa društvenim pojavama i koji se mogu kvantitaivno mjetit. (Vukosav i Zarevski, 2011). Rezultati nam pružaju jasne odgovore, pomoću formiranja generalizovanih zaključaka o uzročnosti za kompletnu populaciju na osnovu uzorka. Stoga, kvantitativni pristup omogućava nam analizu procjene uticaja emocionalne i vještačke inteligencije na radnu efikasnost zaposlenika.

U tom smislu, metoda istraživanja koja se koristi za prikupljanje podataka je upitnik sa postavljenim pitanjima koja zahtijevaju ocjenjivanje. Ispitanici trebaju da ocjenama izraze svoje stavove ili odgovore, čime se omogućava prikupljanje kvantitativnih podataka, a koji olakšavaju analizu njihovih percepcija i mišljenja.

Ispitanicima je ponuđena Likertova skala u odgovorima upitnika, pomoću koje ocjenjuju svoj stepen slaganja ili neslaganja sa tvrdnjama, pri čemu se odgovori kreću od jedan do pet. Zato što je korišten kvalitativi pristupa istraživanju. (Somun-Kapetanović, 2012).

Ilustracija 2 Koncepualni model

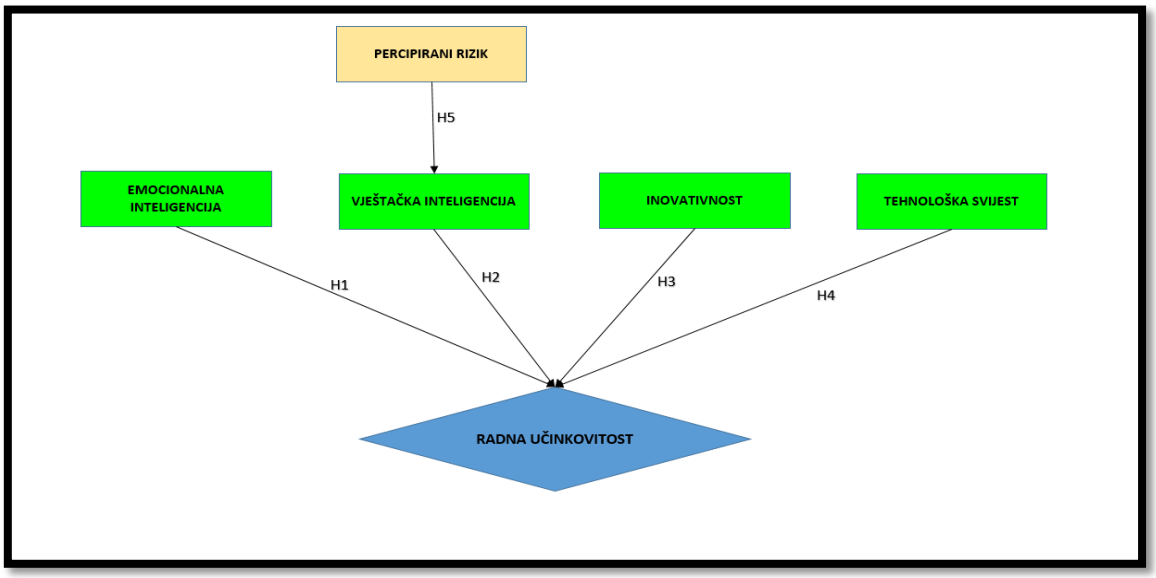

Izvor: Autor završnog rada

Cilj ovog istraživanja, korištenjem navedenog modela, je temeljito istražiti i proučiti uticaj emocionalne inteligencije, vještačke inteligencije, tehnološke svijesti, inovativnosti na radnu učinkovitost, kao i odnos percipiranog rizika na vještačku inteligenciju.

► H1: Emocionalna inteligencija pozitivno utiče na radnu učinkovitost

Hipoteza koja se bavi uticajem emocionalne inteligencije na radnu učinkovitost može se dodatno pojasniti i potkrijepiti relevantnim istraživanjima i teorijama. Emocionalna inteligencija, prema definiciji Mayera i Saloveya (1990), predstavlja skup sposobnosti koje uključuju prepoznavanje, razumijevanje i regulaciju emocija. Ove sposobnosti igraju ključnu ulogu u poslovnom okruženju, gdje lideri sa razvijenom emocionalnom inteligencijom mogu značajno uticati na radnu učinkovitost svojih timova (Goleman, 1995). Emocionalna inteligencija (EI) igra ključnu ulogu u povećanju radne učinkovitosti zaposlenika u različitim segmentima radnog okruženja. Prema Golemanu i saradnicima (2013), menadžeri s visokim nivoom EI mogu znatno poboljšati performanse svojih timova kroz efikasno upravljanje konfliktima i održavanje emocionalne stabilnosti. Wong i Law (2002) naglašavaju da EI direktno doprinosi većem zadovoljstvu poslom i jačoj predanosti organizaciji, što pozitivno utiče na radnu učinkovitost. Mayer i saradnici (2008) otkrivaju da postoji pozitivna veza između EI i sposobnosti donošenja efikasnih odluka, što je ključno za postizanje visokih radnih rezultata. Konačno, prema istraživanju Boyatzisa (2018), EI omogućava zaposlenicima lakšu prilagodbu na promjene, čime se dodatno poboljšava njihova ukupna radna učinkovitost. Dakle, zaključak da emocionalna inteligencija pozitivno utiče na radnu učinkovitost može se potkrijepiti empirijskim dokazima i teorijskim modelima koji ukazuju na snažnu povezanost između emocionalnih kompetencija i performansi na radnom mjestu. Lideri i organizacije koje podstiču razvoj emocionalne inteligencije kod svojih zaposlenika mogu očekivati poboljšanje radne učinkovitosti, što je ključno za postizanje organizacionih ciljeva (Hercigonja, 2018).

► H2: Vještačka inteligencija (AI) pozitivno utiče na radnu učinkovitost

Primjena vještačke inteligencije (AI) u poslovnim procesima donosi značajna poboljšanja u radnoj učinkovitosti kroz automatizaciju zadataka i unapređenje analitičkih mogućnosti. Dalje, vještačka inteligencija pomaže u donošenju bržih i preciznijih odluka, što je ključno u situacijama visokog stepena nesigurnosti. Zahvaljujući analizi velikih količina podataka, AI sistemi mogu identificirati obrasce i predviđati buduće ishode, čime se smanjuje mogućnost ljudske greške i povećava ukupna efikasnost poslovnih procesa (Akerkar, 2019). Brynjolfsson i McAfee (2014) ističu da AI tehnologije omogućavaju zaposlenicima da se usmjere na kreativnije i složenije zadatke, dok se rutinski poslovi prepuštaju automatizaciji. Prema istraživanju Davenporta i Ronankija (2018), implementacija AI sistema poboljšava donošenje odluka zahvaljujući bržim i preciznijim analizama velikih količina podataka. Bessen (2019) također naglašava da AI može značajno povećati produktivnost u sektorima poput proizvodnje i zdravstva, što direktno doprinosi ukupnoj radnoj učinkovitosti. Vještačka inteligencija, kroz tehnologije poput mašinskog učenja, dubokog učenja, i neuronskih mreža, omogućava automatizaciju složenih zadataka, što značajno povećava produktivnost i učinkovitost zaposlenika. Na primjer, prema istraživanju Brynjolfsson i Raymonda (2023), implementacija ChatGPT-a u korisničku podršku dovela je do povećanja produktivnosti agenata za 14% u samo jednom satu rada. Ovaj podatak jasno ukazuje na to da AI tehnologije mogu efikasno smanjiti vrijeme potrebno za obavljanje zadataka, omogućavajući zaposlenicima da se fokusiraju na kreativnije i složenije aktivnosti koje dodaju veću vrijednost organizaciji. Pored toga, Jarrahi (2018) naglašava da AI unapređuje kolaborativni rad i komunikaciju među zaposlenicima, čime se poboljšava timska efikasnost.

► H3: Inovativnost pozitivno utiče na radnu učinkovitost

Unapređenje procesa, proizvoda i usluga kroz inovativnost unutar organizacija značajno doprinosi povećanju radne učinkovitosti. Prema studiji Damanpoura (1991), organizacije koje su inovativne imaju tendenciju bržeg rasta i bolje prilagodbe tržišnim promjenama, što direktno povećava njihovu operativnu efikasnost. Calantone *et al*. (2002) također potvrđuju da inovativna kultura unutar kompanije poboljšava kreativnost i motivaciju zaposlenika, što rezultira višim nivoima radne učinkovitosti. Tushman i O'Reilly (2013) ističu da organizacije koje uspješno balansiraju između iskorištavanja postojećih resursa i istraživanja mogućnosti ostvaruju bolje performanse. West i Anderson (1996) zaključuju da timovi s visokim nivoom inovativnosti ostvaruju bolje rezultate zahvaljujući poboljšanoj saradnji i razmjeni znanja. Inovativnost se može smatrati osnovom za razvoj novih proizvoda, procesa i usluga koji povećavaju produktivnost i unapređuju poslovne performanse, omogućavajući kompanijama da ostvare konkurentsku prednost. U današnjem dinamičnom poslovnom okruženju, kompanije koje se ne prilagođavaju i ne inoviraju rizikuju gubitak konkurentnosti i tržišnog udjela (Ljubanović, 2023). Organizacije koje uspješno integrišu inovacije u svoje poslovne procese postaju otpornije na tržišne promjene i bolje pripremljene za buduće izazove, čime osiguravaju dugoročni rast i uspjeh. Samo kompanije koje razviju inovativnu kulturu mogu očekivati da postanu lideri u svom sektoru i postignu održivi razvoj (Vuković *et al*., 2024).

► H4: Tehnološka svijest pozitivno utiče na radnu učinkovitost

Zaposlenici koji posjeduju visoku tehnološku svijest mogu koristiti napredne softverske alate za analizu podataka, što im omogućava donošenje boljih odluka i optimizacije poslovnih procesa (Moorthy i Polley, 2010). Ovakav pristup ne samo da povećava radnu učinkovitost pojedinaca, već doprinosi i ukupnoj stabilnosti i sigurnosti poslovanja. Razvijena tehnološka svijest među zaposlenicima značajno utiče na povećanje radne učinkovitosti, omogućavajući bolje korištenje dostupnih alata i resursa. Prema istraživanju Tarafdara i saradnika (2019), tehnološki pismeni zaposlenici pokazuju veću sposobnost prilagođavanja i usvajanja novih tehnologija, što rezultira povećanjem njihove produktivnosti. S druge strane, Parasuraman (2000) naglašava da visok nivo tehnološke svijesti smanjuje otpor prema promjenama, što dovodi do efikasnijeg rada zahvaljujući boljoj integraciji tehnoloških rješenja. Venkatesh *et al*. (2003) su pronašli da postoji pozitivna korelacija između tehnološke svijesti i efikasnosti korisnika, što doprinosi ukupnoj radnoj učinkovitosti. Također, tehnološka svijest omogućava zaposlenicima da budu proaktivni u rješavanju problema i pronalaženju inovativnih rješenja, što vodi ka unapređenju poslovnih procesa i donošenju informisanijih odluka (Ogbeibu *et al*., 2023). Devaraj i Kohli (2003) dodaju da organizacije koje ulažu u tehnološko obrazovanje svojih zaposlenika ostvaruju bolje operativne rezultate i postaju konkurentnije na tržištu.

► H5: Percipirani rizik negativno utiče na vještačku inteligenciju na radnom mjestu.

Percipirani rizik ima značajan uticaj na način na koji zaposlenici doživljavaju i prihvataju nove tehnologije, uključujući vještačku inteligenciju (AI). Charlwood i Guenole (2022) ukazuju na to da visok nivo percipiranog rizika može otežati zaposlenicima razumijevanje i usvajanje AI, dok Shi *et al*. (2021) naglašavaju da strah od rizika često dovodi do oklijevanja u prihvatanju novih tehnologija, što može negativno uticati na procese obuke i razvoja. Kako Slovic (2000) navodi, percepcija rizika nije isključivo zasnovana na objektivnim činjenicama ili statističkim pokazateljima, već je podložna subjektivnim faktorima, kao što su emocionalni i socijalni aspekti. Sagheer *et al*. (2022) dodaju da percipirani rizik može smanjiti spremnost zaposlenika na korištenje AI tehnologija. Da bi se osigurala uspješna integracija AI, potrebno je smanjiti percipirani rizik kroz edukaciju, transparentnu komunikaciju i izgradnju povjerenja unutar organizacije (Chatterjee *et al*. (2022). Kako navode Khaksar *et al*. (2019), neadekvatan razvoj AI rješenja može povećati ukupan rizik za firmu, što dodatno doprinosi negativnoj percepciji među zaposlenicima. S obzirom na to da tehnologija poput AI zahtijeva visok nivo povjerenja i razumijevanja od strane korisnika, percipirani rizik može postati prepreka za njenu punu integraciju u poslovne procese. Kako bi se smanjio percipirani rizik, organizacije trebaju primijeniti strategije poput poboljšanja transparentnosti i komunikacije, kao i edukacije korisnika o tehnologiji i njenim mogućnostima. Transparentnost u pogledu načina rada AI i njenih mogućih rizika može pomoći u izgradnji povjerenja, kao ključ za uspješnu integraciju tehnologije (Renn, 2004).

Pilot studija za ispitivanje ispravnosti upitnika predstavlja ključni korak u procesu prikupljanja mogućih i značajnih odgovora, što će omogućiti značajno unapređenje kvaliteta

istraživanja i identifikaciju mogućih problema u dizajnu upitnika. Ovaj postupak je sastavni dio svakog kvantitativnog istraživanja. Dvadeset ispitanika odabrano je za predtestiranje, a oni predstavljaju reprezentativni uzorak koji odražava karakteristike ciljane grupe ispitanika u glavnom istraživanju. Ova selekcija omogućava efikasno testiranje upitnika i prikupljanje dragocenih povratnih informacija koje će značajno doprinijeti daljem razvoju istraživačkog procesa. (Recker, 2021). Većina povratnih informacija u vezi sa ispavnosti upitnikom bila je pozitivna, s izostankom bilo kakvih prigovora na specifične dijelove upitnika, što je omogućilo njegovo korištenje i u glavnom istraživanju.

Anketa je distribuirana online putem *Google Forms*, statističkog alata koji omogućava lako kreiranje i dijeljenje ankete. Ovaj alat takođe omogućava prikupljanje rezultata i provođenje statističkih analiza, što je značajno s obzirom na karakter istraživačke studije.

Online anketa automatski pamti svaki odgovor i omogućava ekstrakciju rezultata aktivne ankete u svakom trenutku. Ovaj način prikupljanja podataka pomoću *Google Forms* omogućava brzo i ekonomično sprovođenje anketa, uz olakšan pristup ispitanicima. Odgovori su pratili putem *Google Forms*-a sve do trenutka kada je prikupljeno 210 odgovora ispitanika, čime smo osigurali reprezentativan uzorak za istraživanje, nakon čega je anketa zaključena (Majstorić, 2023).

3.2. Analiza podataka

3.2.1. Demografski podaci

Ukupan broj ispitanika u sprovedenom istraživanju iznosi 210, s potpunim popunjenim odgovorima, što čini adekvatan uzorak. Istraživački upitnik je bio usmjeren na zaposlene. Prvi dio upitnika posvećen je demografskim podacima ispitanika a rezultati su pokazali da 129 ispitanika čine žene, što predstavlja 61,4% od ukupnog broja, dok 81 ispitanik čine muškarci, što čini 38,6% uzorka.

Ilustracija 3 Podatak o spolu ispitanika

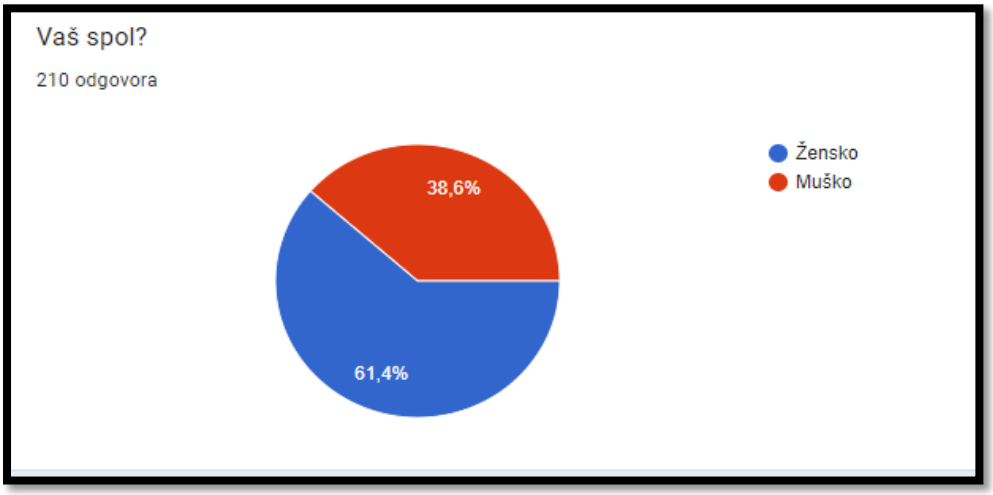

Izvor: Autor završnog rada

Također, godine života su ključni demografski podatak. Najveći broj ispitanika (134) pripada dobnoj skupini od od 26 do 35 godina. U grupi od 18 do 25 godina zabilježeno je (45) ispitanika, dok (17) njih spada u dobnu kategoriju od 36 do 45 godina, u dobnom razdoblju od 47 do 55 imamo (8) ispitanika i najmanje ispitanika (6) je odgovorilo da su njihove godine u razdoblju od 56 do 65 godina. Dakle, može se zaključiti da u ovom uzorku ispitanika je najviše zastupljena mlada skupima zaposlenih.

Ilustracija 4 Starosna struktura ispitanika

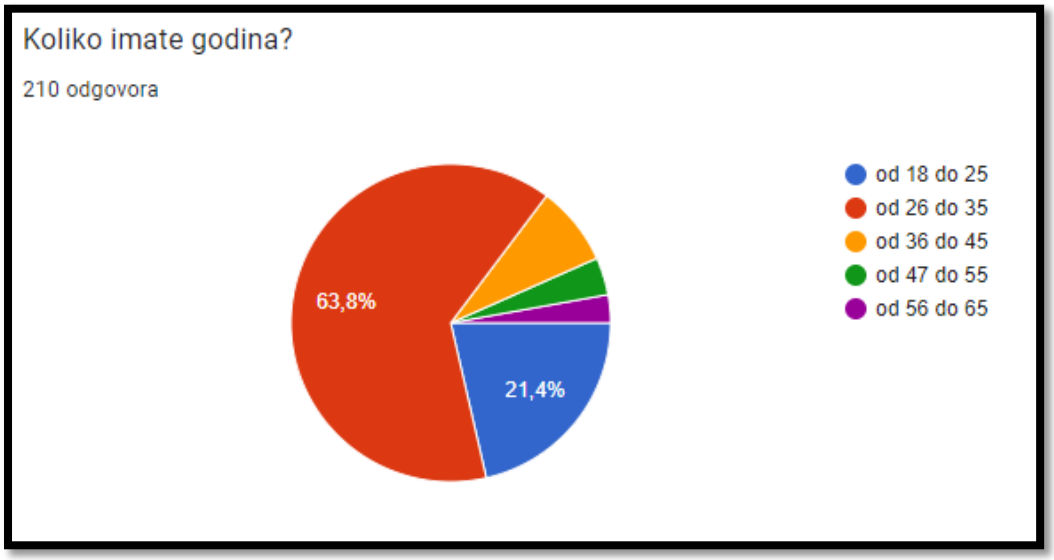

Izvor: Autor završnog rada

U segmentu posvećenom *nivu obrazovanja* ispitanika. Najveći broj ispitanika je VSS 49,5% zatim MA ili MR 22%, SSS 30,5%, VŠS 3,8 % i najmanji broj ispitanika ima DR 2,4% stečeni nivo obrazovanja.

Ilustracija 5 Nivo obrazovanja ispitanika

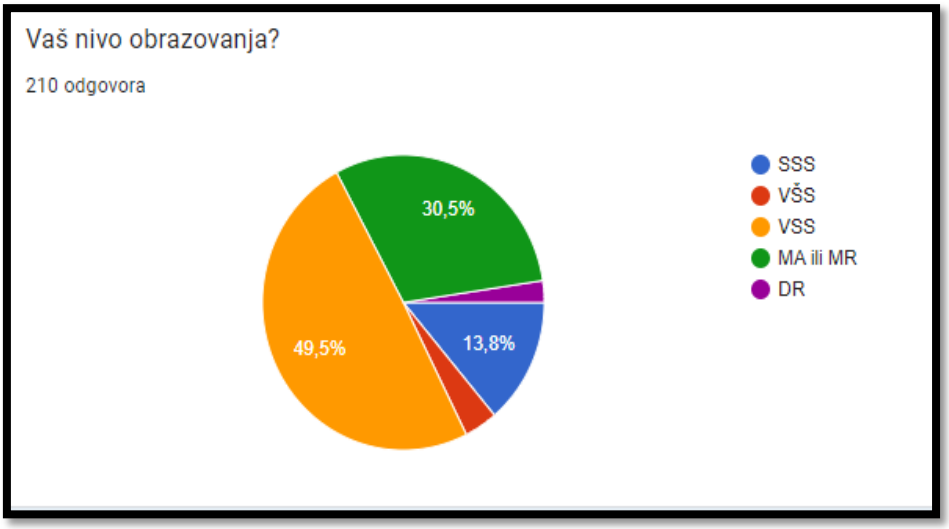

Izvor: Autor završnog rada

Najveći broj ispitanika prema tipu industrije je zaposlen u kategoriji „Ostalo“ 46,7% zatim „Finansije i/ili računovodstvo“ 18,1% ispitanika, „IT“ 11% ispitanika, „Marketing i usluge“ 8,6% ispitanika, „Proizvodnja“ 8,1%, dok je najmanje broj ispitanika zaposlen u „Obrazovanju“ 7,6% ispitanika.

Ilustracija 6 Tip industrije

Izvor: Autor završnog rada

Ispitanici su odgovarali na kojoj poziciji su zaposleni u kompaniji ili instituciji. Najveći broj ispitanika je zaposleno na poziciji Operativni nivo nivo - Entry-Level (EL) 39% zatim Ostalo 32,4% ispitanika, Srednji menadžment - Middle Management (MM) 16,2% ispitanika, Šef odjela - Department Head (DH) 8,1% ispitanika i najmanji broj je zaposleno na poziciji Top menadžment - Top Management (TM) 4,3% ispitanika.

Ilustracija 7 Pozicija zaposlenog u kompaniji ili instituciji

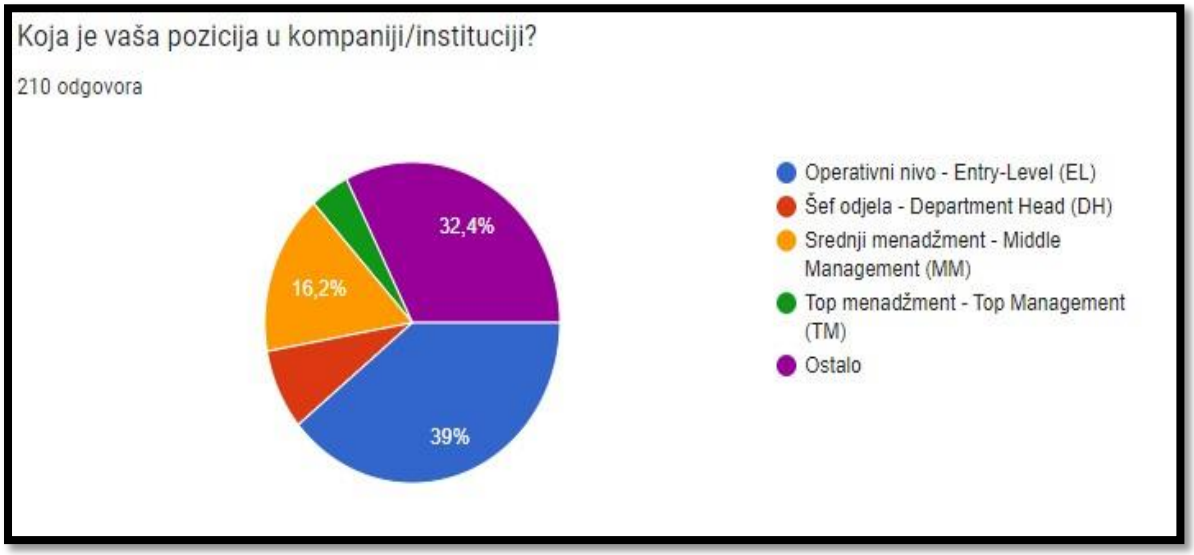

Izvor: Autor završnog rada

Najveći broj ispitanika je korisnik računara i IT alata više od 9 godina 51% zatim između 3

i 6 godine 15,7% ispitanika, između 1 i 3 godine 11,9% ispitanika, između 6 i 9 godina 11,9% ispitanika i najmanji broj ispitanika koristi računar i IT alate manje od 1 godine što čini 9,5% ispitanika.

Ilustracija 8 Iskustvo korištenja računara i IT alata

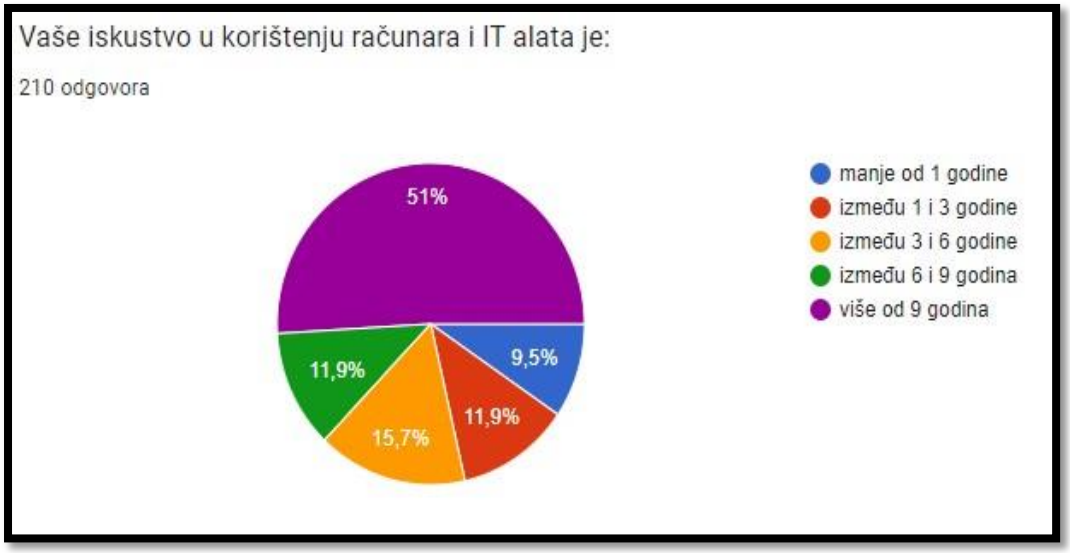

Izvor: Autor završnog rada

Najveći broj ispitanika 35,7% ima između 3 i 6 godina radnog iskustva zatim između 1 i 3 godine 19% ispitanika, više od 9 godina 19% ispitanika, između 6 i 9 godina 15,7% ispitanika i najmanji broj ispitanika 10,5% ima radno iskustvo manje od 1 godine.

Ilustracija 9 Radno iskustvo zaposlenog

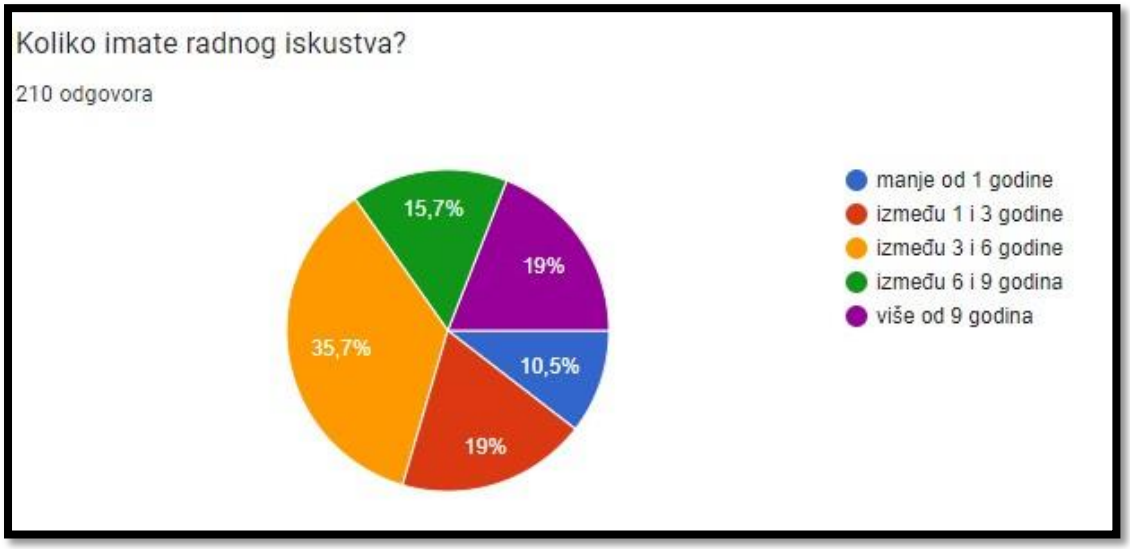

Izvor: Autor završnog rada

Najveći broj ispitanika 51,9% ima manje od 1 godine iskustva u korištenju AI tehnologija, zatim između 1 i 2 godine 28,1% ispitanika, između 2 i 3 godine 11% ispitanika, između 4 i više godina 5,2% ispitanika i najmanji broj ispitanika 3,8% ima iskustvo između 3 i 4 godine u korištenju AI tahnologija.

Ilustracija 10 Iskustvo korištenja AI tehnologija

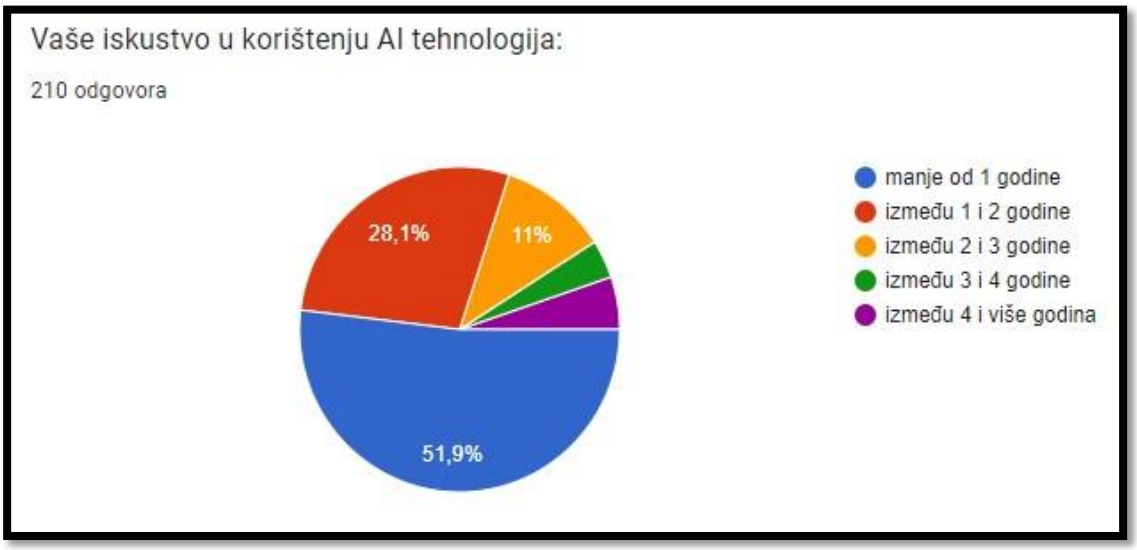

Izvor: Autor završnog rada

Najveći broj ispitanika 24,3% koristi 1 godišnje ChatGPT ili neke druge AI alate zatim više puta mjesečno 19% ispitanika, 1 mjesečno 17,6% ispitanika, dnevna upotreba 11% ispitanika, sedmično 10,5% ispitanika, više puta sedmično 9,5% ispitanika i najmanji broj ispitanika 8,1% ima aktivnu upotrebu više puta dnevno.

Ilustracija 11 Iskustvo korištenja ChatGPT-a ili drugih AI alata

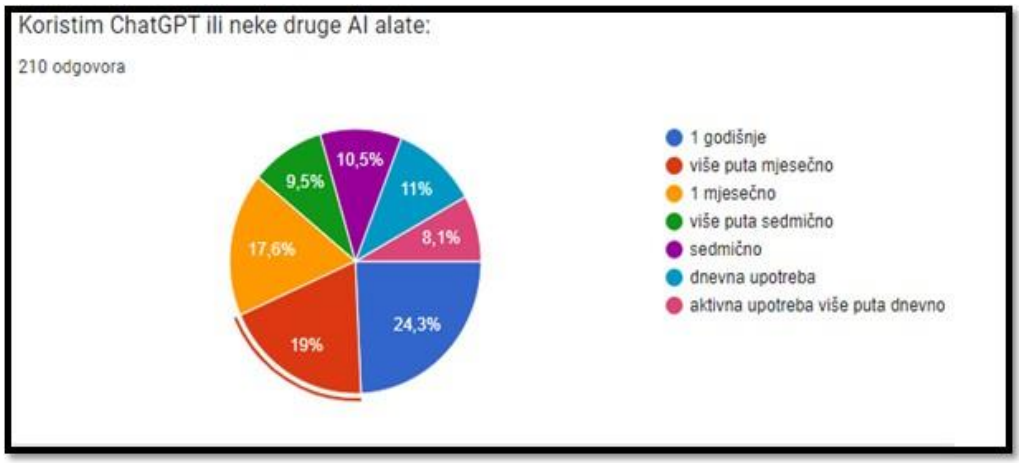

Izvor: Autor završnog rada

Ispitanici su u demografskom dijelu upitnika odgovarali prema ličnoj procjeni u kojem se stanju emocionalne inteligencije nalaze. Najveći broj ispitanika 60,5% je dalo odgovor da je emocionalno inteligentan/na zatim srednje emocionalno inteligentan/na 24,8% ispitanika, natprosječno emocionalno inteligentan/na 11,9% i najmanji broj ispitanika 2,9% tvrdi da je njihovo stanje emocionalne inteligencije status emocionalno neinteligentan/na.

Ilustracija 12 Stanje emocionalne inteligencije

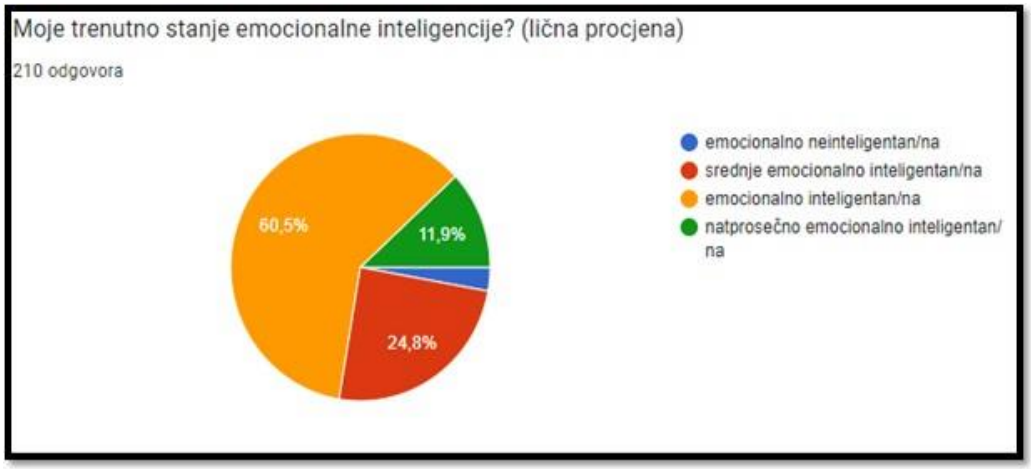

Izvor: Autor završnog rada

Najveći broj ispitanika 70,5% je dalo odgovor da je radno efikasan/na zatim natprosečna radna-efikasnost 18,1% ispitanika, prosječno radno-efikasan/na 11% i najmanji broj ispitanika 0,5% tvrdi da je radno neefikasan/na.

Ilustracija 13 Radna učinkovitost

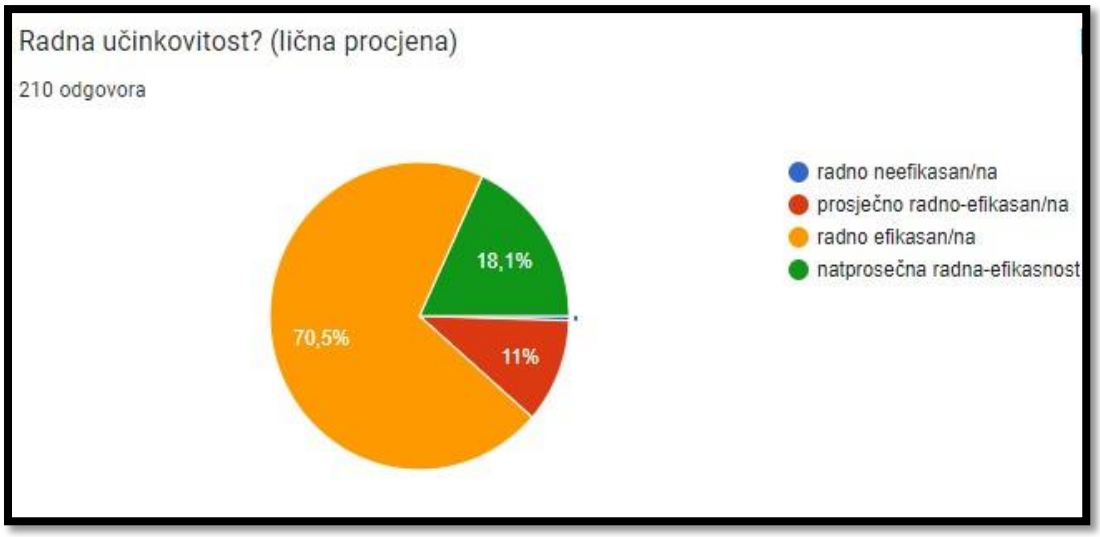

Izvor: Autor završnog rada

Najveći broj ispitanika 70,% je dalo odgovor da je zadovoljan/na sobom zatim prosječno zadovoljan/na sobom 21,4% ispitanika, natprosečno zadovoljan/na sobom 7,6% ispitanika i najmanji broj ispitanika 1% tvrdi da je nezadovoljan/na sobom.

Ilustracija 14 Lično zadovoljstvo

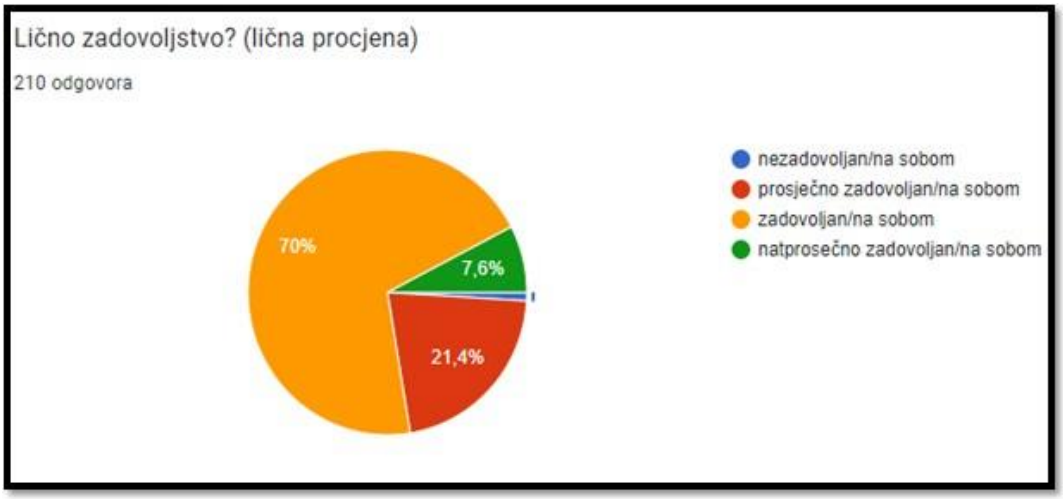

Izvor: Autor završnog rada

Rezultati su pokazali da je 177 ispitanika dalo prednost Emocionalnoj inteligenciji (EI) u poslovanju što predstavlja 84,3% ukupnog broja ispitanika, dok je ostatak 33 ispitanika dalo prednost Vještačkoj inteligenciji (AI) u poslovanju , što predstavlja 15,7% ukupnog broja ispitanika.

Ilustracija 15 Tip inteligencije

Izvor: Autor završnog rada

3.1.1. Analiza upitnika

Za potrebe sprovođenja kvantitativnog istraživanja, prethodno opisani upitnik je distribuiran među ispitanicima. Po završetku prikupljanja podataka, uslijedila je njihova detaljna analiza kako bi se dobili relevantni uvidi i odgovori na postavljena istraživačka pitanja.

Analiza prikupljenih podataka kreće putem upitnika tj. procesom izdvajanja relevantnih informacija. S obzirom na to da je platforma Google Forms automatski pohranjuje sve

odgovore, omogućava korisnicima grafički pregled odgovora kao i vršenje osnovne analize podataka. Dodatno, platforma nudi mogućnost eksportovanja prikupljenih podataka u Excel format, što omogućava detaljniju obradu i prezentaciju rezultata, kao i korištenje naprednih statističkih alata za dublju analizu podataka prikupljenih kroz upitnik.

Ukupan broj ispitanika koji su dali potpune odgovore na anketu iznosi 210 ispitanika. Kako je time dostignut ciljani broj odgovora, upitnik je zaključen.

Da bi se podaci na odgovarajući način analizirali i omogućila izrada modela strukturalnih jednačina putem grafičkog korisničkog interfejsa (GUI), upotrijebljen je napredni statistički softver Smart PLS 4. Ovaj alat je posebno prilagođen za obradu složenih statističkih analiza i pruža korisnicima intuitivno okruženje za kreiranje i testiranje različitih modela, čime se olakšava interpretacija rezultata i donošenje zaključaka na temelju prikupljenih podataka. Za korištenje takvog softvera, neophodno je izvršiti kodiranje rezultata upitnika kako bi podaci bili odgovarajuće formatirani i čitljivi za daljnju analizu u softveru. Shodno tome, podaci su prošli kroz proces kodiranja, unosa i transformacije. Sve prikupljene informacije su tretirane kao ordinalne varijable, osim demografskih podataka, gdje je spol kodiran kao binarna varijabla. Demografski podaci su obrađeni deskriptivnom analizom, koja je primijenjena s ciljem prikazivanja: spol, godine, nivo obrazovanja, industrija u kojoj ispitanik radi, pozicija ispitanika u kompaniji, iskustvo u korištenju IT alata, broj godina radnog iskustva ispitanika, iskustvo u korištenju AI tehnologija ispitanika, korištenje ChatGPT-a ili drugih AI alata, lična procjena trenutnog stanja emocionalne inteligencije ispitanika, lična procjena radne učinkovitosti, lično zadovoljstvo, tip inteligencije kojoj ispitanik daje prednost. Shodno tome, moguće je dobiti jasniji uvid u profil ispitanika i potencijalne veze s njihovim odgovorima. Preostali dio upitnika analiziran je primjenom multivarijantne analize podataka, koja ispituje značaj linearnih odnosa između zavisnih varijabli i prediktora, uzimajući u obzir međusobne korelacije (Lužar-Stiffer V, 2010).

Primijenjena je i inferencijalna statistika kroz strukturalno modeliranje jednačina putem PLS-SEM (eng. *Partial least squares structural equation modeling)*, koja kombinuje faktorijalnu i regresijsku analizu, te se koristi u svrhu testiranja postavljenih hipoteza (Creswell, 2015). PLS-SEM metodologija koristi se za ispitivanje odnosa između latentnih i posmatranih varijabli, pri čemu se procjenjuje kako i u kojoj mjeri ti odnosi objašnjavaju složene modele. Ova metodologija uključuje dva osnovna segmenta: strukturalni ili unutrašnji model, koji uspostavlja povezanost između varijabli, i mjerljivi ili vanjski model, koji istražuje odnose između latentnih varijabli i njihovih posmatranih indikatora. Ova podjela omogućava precizniju analizu i razumijevanje međusobnih odnosa unutar modela, čime se doprinosi boljem tumačenju složenih statističkih rezultata (Hair *et al*., 2021).

Latentne varijable odnose se na one skrivene varijable koje ne mogu biti direktno mjerene, a u okviru istraživanja najčešće se tiču percepcija, stavova ili drugih apstraktnih pojmova. S druge strane, promatrane varijable su rezultat istraživačkog procesa i predstavljaju kvantifikaciju latentnih varijabli u okviru statističkog modela, omogućavajući njihovu analizu i interpretaciju kroz konkretne mjerne pokazatelje.

PLS-SEM metodologije podrazumijeva da je prvo potrebno definisati strukturalni model, odnosno dijagram koji vizualno prikazuje odnose između postavljenih hipoteza i istraživanih varijabli. Ovaj dijagram služi kao osnovna mapa za razumijevanje veza između latentnih i promatranih varijabli, te omogućava jasnije praćenje i interpretaciju rezultata analize.

Nakon toga slijedi određivanje mjernih modela, koji definiraju odnose između latentnih varijabli i njihovih pripadajućih indikatorskih varijabli. Ovi modeli omogućavaju preciznije razumijevanje načina na koji latentne varijable utiču na posmatrane pokazatelje. Ključni korak u ovom procesu je prikupljanje podataka i provjera njihove validnosti, što predstavlja suštinski element analize. Iako su podaci prikupljeni, mogu se pojaviti problemi poput nekonzistentnosti ili odstupanja zbog različitih faktora, što može utjecati na tačnost i pouzdanost rezultata. Stoga je neophodno temeljito ispitati kvalitet podataka prije nastavka s daljnjom obradom.

PLS-SEM koristi se za procjenu nepoznatih parametara unutar modela, pri čemu izračunava vrijednosti konstrukata na temelju dostupnih podataka. Ovi rezultati obuhvataju procjenu odnosa između mjernih modela, koji povezuju latentne varijable s odgovarajućim indikatorima, te strukturalnih modela, koji definišu međusobne veze između latentnih varijabli. Nakon toga slijedi procjena dobivenih rezultata kroz analizu prediktivnih sposobnosti modela, čime se utvrđuje koliko dobro model predviđa zadane ishode. Jedna od glavnih prednosti ove metodologije leži u njenoj sposobnosti da efikasno upravlja i formativnim i reflektivnim mjernim modelima, omogućavajući fleksibilnost i preciznost u analizi složenih odnosa među varijablama.

Budući da se proces evaluacije odvija na više nivoa, jasno razdvaja mjerenje od procjene strukturalnog modela, pri čemu obuhvata i formativno mjerenje endogenih konstrukata. Pored toga, PLS-SEM metodologija olakšava definisanje interakcijskih varijabli, što doprinosi preciznijem mapiranju efekata moderacije unutar modela. Ova metoda omogućava detaljnu analizu uticaja različitih faktora, pružajući dublji uvid u to kako moderirajuće varijable mijenjaju odnose između ključnih konstrukata u modelu.

Kako bi se rezultati PLS-SEM modela pravilno analizirali, potrebno je procijeniti nekoliko ključnih parametara

1. Konvergentne validnosti
2. Indikatora kolinearnosti
3. Statističku signifikantnost

Konvergentna validnost označava stepen u kojem dvije različite mjere istog koncepta pokazuju visok nivo korelacije, odnosno dijele veliku količinu zajedničke varijanse. Da bi se utvrdila validnost mjernog modela, procjenjuje se konvergentna validnost putem nekoliko metoda. Jedan od načina je ispitivanje faktorskih opterećenja manifestnih varijabli na odgovarajući konstrukt, pri čemu je važno da standardizirane vrijednosti faktorskih

opterećenja budu iznad 0,50. Također, validnost se može potvrditi i izračunavanjem prosječne izdvojene varijanse (average variance extracted, AVE), koja predstavlja prosječnu varijansu faktorskih opterećenja varijabli na dati konstrukt. Ako vrijednost AVE premaši 0,50, to ukazuje na adekvatnu konvergenciju. (Bajgorić *et al*., 2019).

Indikator kolinearnosti pokazuje stepen međusobne zavisnosti dva ili više indikatora unutar mjernog modela. Kada je kolinearnost visoka, standardna greška procjena postaje veća, što može uticati na tačnost rezultata. Kolinearnost se mjeri faktorom inflacije varijanse (VIF), koji služi kao pokazatelj nivoa kolinearnosti između indikatora.

Ako vrijednost VIF prelazi 5, to upućuje na značajan problem kolinearnosti. U slučaju da se kreće između 3 i 5, kolinearnost obično nije kritična, dok vrijednosti ispod 3 ukazuju na to da nema ozbiljnijih problema s kolinearnosti (Hair *et al*., 2021).

Statistička signifikantnost koristi se za procjenu pouzdanosti rezultata, a procjenjuje se putem bootstrapping procedure, koja omogućava izračun standardne greške iz prikupljenih podataka (Hair *et al*., 2019a). Što je manji nivo rizika, rezultati su statistički značajniji. Na osnovu p-vrijednosti, uz primjenu Kolmogorov-Smirnov testa, ako je p-vrijednost manja od 0,05, rezultat je statistički značajan. U tom slučaju, hipoteza se prihvata, implicirajući da distribucija analiziranog fenomena ne slijedi pretpostavljenu teorijsku distribuciju. (Somun-Kapetanović, 2012).

Osim navedenih procjena, potrebno je izračunati i dodatne koeficijente, poput koeficijenta puta u konstrukcijskom modelu, Ove vrijednosti se kreću između -1 i 1, te određuju jačinu i smjer odnosa između varijabli. Uz to, koeficijent determinacije (R^2) služi kao mjera za ocjenu kvaliteta modela, te pokazuje prediktivnu sposobnost modela. Vrijednosti R^2 se kreću između 0 i 1, pri čemu više vrijednosti ukazuju na veću prediktivnu snagu. Procjena vrijednosti R^2 također omogućava identifikaciju izostavljenih konstrukata, te procjenu njihovog uticaja na endogene konstrukte, što se ogleda kroz efekt veličine f^2. Vrijednosti od 0,02, 0,15 i 0,35 ukazuju na mali, srednji i veliki efekt, redom.

Prediktivna relevantnost Q^2 pokazuje sposobnost modela da predvidi rezultate izvan uzorka, odnosno njegovu prediktivnu relevantnost. Ako je vrijednost Q^2 iznad nule, to znači da model ima odgovarajuću prediktivnu snagu za određeni endogeni konstrukt. Također, potrebno je izračunati veličinu efekta q^2, koja ukazuje na to koliki doprinos egzogeni konstrukt daje vrijednosti Q^2 endogene latentne varijable. Interpretacija dobijenih vrijednosti q^2 slična je tumačenju efekta f^2, gdje se procjenjuje jačina uticaja egzogenih varijabli na prediktivnu relevantnost modela.

Interna konzistentnost

Interna konzistentnost predstavlja pristup ocjenjivanju pouzdanosti modela, a podrazumijeva nivo dosljednosti između različitih varijabli koje mjere isti latentni konstrukt (Bajgorić et al., 2019). Ako model pokazuje visoku pouzdanost, to znači da manifestne varijable zaista mjere predviđenu dimenziju. Interna konzistentnost se smatra najčešće

korištenim konceptom u procjeni pouzdanosti mjernih instrumenata, jer omogućava provjeru koliko su varijable unutar konstrukta međusobno usklađene(Hair *et al*., 2019a).

Za procjenu interne konzistentnosti primijenjen je Cronbachov alpha koeficijent. Ovaj pokazatelj teoretski može imati vrijednosti u rasponu od 0 do 1, pri čemu se za pouzdan model smatra da alpha prelazi vrijednost od 0,70, dok u istraživanjima koja su eksplorativnog karaktera može biti prihvatljiva vrijednost iznad 0,60. Rezultat ovog koeficijenta ukazuje na to da li različite varijable unutar skupa pružaju konzistentne i pouzdane rezultate, te u kojoj mjeri zajedno mjere isti latentni konstrukt.

Prema Klineu (2011), vrijednosti Cronbachove alfe se tumače na sljedeći način:

- izvrsne mjerne skale: vrijednosti blizu 0,9
- veoma dobre mjerne skale: vrijednosti blizu 0,8
- adekvatne mjerne skale: vrijednosti blizu 0,7

Kompozitna pouzdanost (eng. composite reliability) predstavlja još jednu metodu za procjenu pouzdanosti mjernih instrumenata, a njene se vrijednosti tumače na sličan način kao i Cronbachova alpha. U Smart PLS4 softveru postoje dvije kompozitne mjere pouzdanosti, i to rho_a i rho_c. Kada se svi elementi mjernog instrumenta posmatraju kao jedna cjelina, pod pretpostavkom da svi predmeti mjere isti aspekt konstrukta, rho_a se koristi kao pokazatelj pouzdanosti kompozitne skale. S druge strane, ako se elementi posmatraju kao odvojene skale, gdje svaki mjerni element obuhvata različite dijelove osnovne konstrukcije ili su međusobno slabo povezani, rho_c se koristi kao mjera pouzdanosti. Prema Hair *et al*. (2019), često je preporučljivo analizirati obje ove mjere kako bi se dobila jasnija slika o pouzdanosti modela, s obzirom na to da se stvarna vrijednost pouzdanosti obično nalazi između Cronbachove alfe (koja daje nižu vrijednost) i CR vrijednosti (koja daje višu vrijednost). Prema Hair *et al*. (2017), kombinovanjem ovih pokazatelja omogućava se preciznija procjena stvarne pouzdanosti modela.

Tabela 1 Interna konzistentnost mjernog modela

	Cronbach's alpha	Composite reliability (rho_a)	Composite reliability (rho_c)	Average variance extracted (AVE)
Emocionalna Inteligencija	0,955	0,958	0,959	0,581
Inovativnost	0,889	0,910	0,917	0,691
Percepcioni rizik	0,809	0,834	0,864	0,561
Radna učinkovitost	0,930	0,931	0,947	0,782
Tehnološka svijest	0,942	0,999	0,954	0,807
Vještačka inteligencija	0,882	0,889	0,914	0,681

Izvor: SmartPLS

Rezultati procjene interne konzistentnosti nalaze se u tabeli iznad. Prema prikazanim podacima, sve varijable imaju vrijednosti Cronbachove alfe iznad 0,8, što upućuje na visok nivo dosljednosti i pouzdanosti između mjernih stavki. Ove vrijednosti pokazuju da su

istraživačke varijable ostvarile vrlo dobru, a u nekim slučajevima i izvrsnu internu konzistentnost. Osim toga, kompozitna pouzdanost je također na izuzetno visokom nivou, gdje su rho_a vrijednosti iznad 0,8, a rho_c premašuju 0,9. Ovi pokazatelji potvrđuju da su sve varijable postigle zadovoljavajući nivo interne konzistentnosti, što dodatno osigurava vjerodostojnost rezultata i stabilnost korištenih mjernih instrumenata.

3.1.1.1. Konvergentna validnost

Konvergentna validnost odnosi se na nivo do kojeg su dvije različite mjere istog koncepta međusobno kolinearne, odnosno koliko dijele zajedničku varijansu, što je i teoretski očekivano. Ova validnost predstavlja metodu za procjenu pouzdanosti modela, a procjenjuje se putem AVE pokazatelja (eng. average variance extracted). Kada je vrijednost AVE veća od 0,5, smatra se da postoji zadovoljavajuća konvergencija, jer manifestne varijable objašnjavaju više od 50% varijanse konstrukta (Bajgorić *et al.*, 2019). Osim procjena interne konzistentnosti, prikazane su i vrijednosti AVE indikatora. Sve varijable imaju vrijednosti iznad 0,7, što u velikoj mjeri ispunjava kriterije za konvergentnu validnost. Ovi podaci pokazuju da je više od 70% varijanse konstrukata objašnjeno kroz odgovarajuće manifestne varijable, čime se potvrđuje da postoji zadovoljavajući nivo konvergencije. Pouzdanost modela može se dodatno analizirati kroz tabelu vanjskih opterećenja (outer loading), koja prikazuje procijenjene veze u reflektivnim mjernim modelima i omogućava procjenu doprinosa svake mjere unutar (Hair *et al.*, 2021). Za prihvatljive se smatraju vrijednosti opterećenja indikatora koje prelaze 0,5, jer to pokazuje da konstrukt objašnjava više od polovine varijanse indikatora. Ipak, preporučuje se da te vrijednosti budu iznad 0,7 kako bi se osigurala veća pouzdanost indikatora. Sve vrijednosti prikazane u tabeli ispod značajno prelaze 0,5, što potvrđuje zadovoljavajući nivo pouzdanosti indikatora. Indikatori koji nisu ispunili ovaj kriterij su:

- *AI4 : U bliskoj budućnosti, AI bi mogla preuzeti moj posao.*
- *EI1: Svjestan sam svog raspoloženja na poslu*
- *EI17: Osetljiv sam na osećanja i emocije drugih.*
- *EI2: Pozitivno reagiram na događaje koji me frustriraju*
- *EI23: Pomažem drugima u rješavanju sukoba na radnom mjestu.*
- *EI3: Kritiku kolega doživljavam osobno*
- *EI4: Svjestan sam kako moji osjećaji utječu na odluke koje donosim na poslu.*
- *EI5: Teško mi je prepoznati svoje osjećaje o problemima na poslu.*
- *EI8: Na odgovarajući način reagiram na kolege koji me frustriraju na poslu.*
- *EI9: Uspijevam se učinkovito nositi sa stresnim situacijama na poslu*
- *JP5: Obaviti svoj posao bolje od mnogih drugih kolega/ica koji obavljaju isti posao.*

Tabela 2 Opterećenje indikatora (outer loading)

	Outer loadings
AI1 <- Vještačka inteligencija	0,839
AI2 <- Vještačka inteligencija	0,869
AI3 <- Vještačka inteligencija	0,851
AI5 <- Vještačka inteligencija	0,715
AI6 <- Vještačka inteligencija	0,843
EI10 <- Emocionalna Inteligencija	0,723
EI11 <- Emocionalna Inteligencija	0,715
EI12 <- Emocionalna Inteligencija	0,809
EI13 <- Emocionalna Inteligencija	0,757
EI14 <- Emocionalna Inteligencija	0,762
EI15 <- Emocionalna Inteligencija	0,814
EI16 <- Emocionalna Inteligencija	0,722
EI18 <- Emocionalna Inteligencija	0,726
EI19 <- Emocionalna Inteligencija	0,723
EI20 <- Emocionalna Inteligencija	0,730
EI21 <- Emocionalna Inteligencija	0,754
EI22 <- Emocionalna Inteligencija	0,835
EI24 <- Emocionalna Inteligencija	0,838
EI25 <- Emocionalna Inteligencija	0,765
EI26 <- Emocionalna Inteligencija	0,821
EI6 <- Emocionalna Inteligencija	0,748
JP1 <- Radna učinkovitost	0,880
JP2 <- Radna učinkovitost	0,899
JP3 <- Radna učinkovitost	0,900
JP4 <- Radna učinkovitost	0,891
JP6 <- Radna učinkovitost	0,850
PINN1 <- Inovativnost	0,838
PINN2 <- Inovativnost	0,871
PINN3 <- Inovativnost	0,823
PINN4 <- Inovativnost	0,874
PINN5 <- Inovativnost	0,741
PR1 <- Percepcioni rizik	0,787
PR3 <- Percepcioni rizik	0,703
PR4 <- Percepcioni rizik	0,766
PR5 <- Percepcioni rizik	0,785
TA1 <- Tehnološka svijest	0,847
TA2 <- Tehnološka svijest	0,942
TA3 <- Tehnološka svijest	0,897
TA4 <- Tehnološka svijest	0,916
TA5 <- Tehnološka svijest	0,887

Izvor: SmartPLS

3.1.1.2. Diskriminativna validnost

Diskriminativna validnost odnosi se na stepen u kojem su različiti konstrukti zaista međusobno različiti, odnosno u kojoj mjeri pojedinačna varijabla odgovara isključivo jednom latentnom konstruktu (Hair *et al.*, 2021). Ovo znači da teorijski različiti konstrukti ne bi smjeli pokazivati visoku korelaciju, jer bi to ugrozilo njihovu jedinstvenost i

pouzdanost. Za procjenu diskriminativne validnosti najčešće se koristi HTMT (eng. Heterotrait-Monotrait Ratio) kriterij, koji omogućava preciznu provjeru da li su različiti konstrukti dovoljno odvojeni jedan od drugog u smislu mjerenja. Ova metoda je ključna za osiguranje da se latentni konstrukti ne preklapaju, čime se povećava vjerodostojnost mjernog modela.

Heterotrait-monotrait (HTMT) kriterij pokazuje omjer između korelacija indikatora koji mjere različite osobine i korelacija indikatora koji mjere iste osobine unutar konstrukta. Drugim riječima, HTMT procjenjuje prosječnu vrijednost korelacija između indikatora različitih konstrukata i upoređuje je sa geometrijskom sredinom prosječnih korelacija indikatora koji mjere isti konstrukt (Hair *et al*., 2021). Ovaj kriterij je ključan za procjenu diskriminativne validnosti, pri čemu se očekuje da vrijednosti HTMT ne prelaze 0,9 kada se ispituju konceptualno slični konstrukti. Ukoliko vrijednosti prelaze taj prag, to bi značilo da konstrukti nisu dovoljno različiti, što ugrožava diskriminativnu validnost i sugerira preklapanje konstrukata.

Tabela 3 Diskriminativna validnost - HTMT kriterij

Heterotrait-monotrait ratio (HTMT) - List	
	Heterotrait-monotrait ratio (HTMT)
Inovativnost <-> Emocionalna Inteligencija	0,438
Percepcioni rizik <-> Emocionalna Inteligencija	0,406
Percepcioni rizik <-> Inovativnost	0,620
Radna učinkovitost <-> Emocionalna Inteligencija	0,579
Radna učinkovitost <-> Inovativnost	0,427
Radna učinkovitost <-> Percepcioni rizik	0,325
Tehnološka svijest <-> Emocionalna Inteligencija	0,151
Tehnološka svijest <-> Inovativnost	0,751
Tehnološka svijest <-> Percepcioni rizik	0,476
Tehnološka svijest <-> Radna učinkovitost	0,104
Vještačka inteligencija <-> Emocionalna Inteligencija	0,416
Vještačka inteligencija <-> Inovativnost	0,778
Vještačka inteligencija <-> Percepcioni rizik	0,537
Vještačka inteligencija <-> Radna učinkovitost	0,443
Vještačka inteligencija <-> Tehnološka svijest	0,557

Izvor: SmartPLS

U tabeli *HTMT kriterija* može se primijetiti da su vrijednosti varijabli niže od 0,9, što implicira da je postignuta zadovoljavajuća diskriminativna validnost.

Diskriminativna validnost se može provjeriti primjenom Fornell-Lacker kriterija, koji upoređuje kvadratni korijen AVE vrijednosti (na dijagonali) s korelacijama latentnih varijabli (ispod dijagonale). Da bi diskriminativna validnost bila zadovoljena, kvadratni korijen AVE vrijednosti, prikazan na dijagonalama, mora biti veći od bilo koje druge vrijednosti u istoj vrsti ili koloni. Ovo znači da latentna varijabla bolje objašnjava svoje indikatore nego što je povezana s drugim varijablama, što potvrđuje da su konstrukti međusobno različiti.

Tabela 4 Diskriminativna validnost - Fornell i Lacker kriterij

	Emocionalna Inteligencija	Inovativnost	Percepcioni rizik	Radna učinkovitost	Tehnološka svijest	Vještačka inteligencija
Emocionalna Inteligencija	0,763					
Inovativnost	0,419	0,831				
Percepcioni rizik	0,362	0,547	0,749			
Radna učinkovitost	0,552	0,403	0,305	0,884		
Tehnološka svijest	0,132	0,672	0,423	0,096	0,899	
Vještačka inteligencija	0,383	0,700	0,482	0,405	0,514	0,825

Izvor: SmartPLS

Vrijednosti Fornell i Lacker kriterija, prikazane u tabeli, ukazuju na to da je diskriminativna validnost zadovoljavajuća, jer su dijagonalne vrijednosti veće od onih koje se nalaze ispod dijagonale.

Analizom je potvrđen adekvatan nivo pouzdanosti i validnosti prema različitim kriterijima, što omogućava daljnje testiranje hipoteza.

3.1.1.3. Analiza hipoteza

Na prvom mjestu, u PLS-SEM modelu, ključno je razumjeti da se hipoteze testiraju pomoću Path koeficijenata, koji predstavljaju ključne vrijednosti za procjenu međusobnih odnosa između varijabli. Ovi koeficijenti pružaju detaljne informacije o smjeru i intenzitetu uticaja jedne varijable na drugu, što je od velikog značaja za potvrdu ili odbacivanje postavljenih hipoteza u istraživanju. Pored toga, njihova statistička značajnost određuje se intervalom pouzdanosti, pri čemu je posebno važno da nula ne bude uključena u 95% interval, čime se potvrđuje postojanje značajne veze. Path koeficijenti moraju se nalaziti u rasponu od -1 do +1 kako bi se smatrali prihvatljivim, dok vrijednosti izvan tog raspona sugeriraju na slabost ili nevalidnost veze između analiziranih varijabli.

Tabela koja slijedi ukazuje da sve istaknute hipoteze podvrgnute testiranju i da pokazuju pozitivan odnos, osim *Tehnološka svijest* → *Radna učinkovitost* koje imaju negativan odnos.

Tabela 5 Odnos hipoteza

	Path coefficients
Emocionalna Inteligencija -> Radna učinkovitost	0,403
Inovativnost -> Radna učinkovitost	0,253
Percepcioni rizik -> Vještačka inteligencija	0,482
Tehnološka svijest -> Radna učinkovitost	-0,225
Vještačka inteligencija -> Radna učinkovitost	0,190

Izvor: SmartPLS

Figure 1 Grafički prikaz odnosa hipoteza

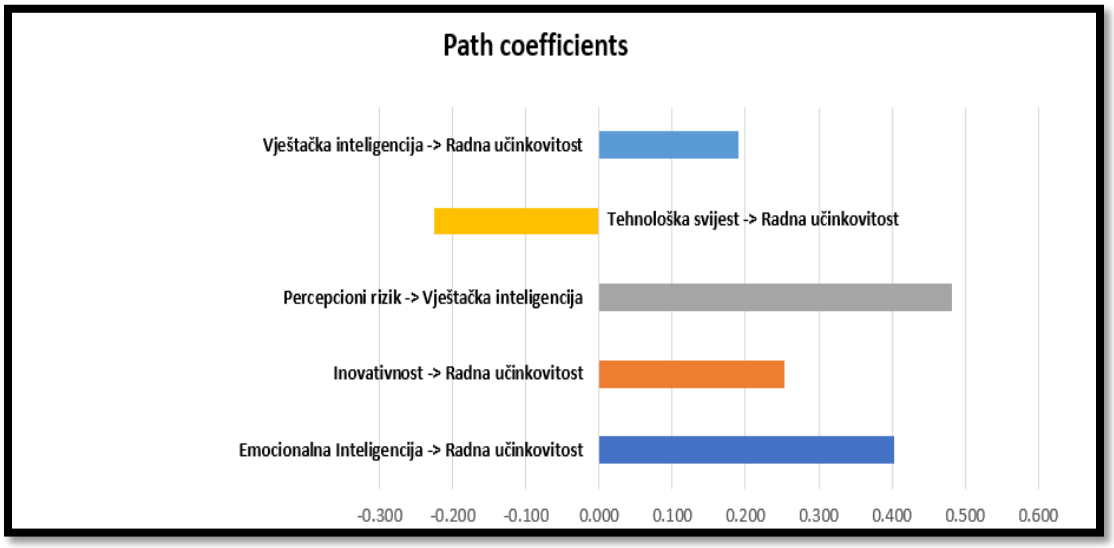

Izvor: SmartPLS

Bootstrapping je statistička tehnika za procjene standardnih grešaka i intervala povjerenja, dakle za testiranje odnosa između varijabli. Ova metoda se temelji na procesu ponovnog uzorkovanja, gdje se nasumično izvlače uzorci iz originalnog skupa podataka. Na taj način stvaraju se novi uzorci koji služe za procjenu modela putanje, pri čemu se svaki put mijenjaju raspodjele podataka. Ovim postupkom moguće je procijeniti distribuciju koeficijenata, što omogućava izračun standardne greške, odnosno standardne devijacije procijenjenih koeficijenata kroz više uzoraka. Bootstrapping tehnika omogućava procjenu statističke značajnosti parametara bez oslanjanja na klasične pretpostavke o distribuciji podataka, čineći ovu metodu fleksibilnom i pouzdanom u različitim situacijama. (Hair *et al.*, 2021).

Tabela 6 Testiranje hipoteza

	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (|O/STDEV|)	P values
Emocionalna inteligencija -> Radna učinkovitost	0,403	0,415	0,071	5,673	0,000
Inovativnost -> Radna učinkovitost	0,253	0,230	0,116	2,179	0,029
Percipirani rizik -> Vještačka inteligencija	0,482	0,491	0,054	8,864	0,000
Tehnološka svijest -> Radna učinkovitost	-0,225	-0,196	0,081	2,767	0,006
Vještačka inteligencija -> Radna učinkovitost	0,190	0,188	0,086	2,195	0,028

Izvor: SmartPLS

Tabela 6 pokazuje da su hipoteze istraživanja potvrđene, budući da su sve p vrijednosti iznad 0,05.

- H1: Emocionalna inteligencija pozitivno utiče na radnu učinkovitost. - POTVRĐENA
- H2: Vještačka inteligencija (AI) pozitivno utiče na radnu učinkovitost. - POTVRĐENA
- H3: Inovativnost pozitivno utiče na radnu učinkovitost. - POTVRĐENA
- H4: Tehnološka svijest pozitivno utiče na radnu učinkovitost. - POTVRĐENA
- H5: Percipirani rizik negativno utiče na vještačku inteligenciju na radnom mjestu. – POTVRĐENA

Figure 2 Utjecaj varijabli

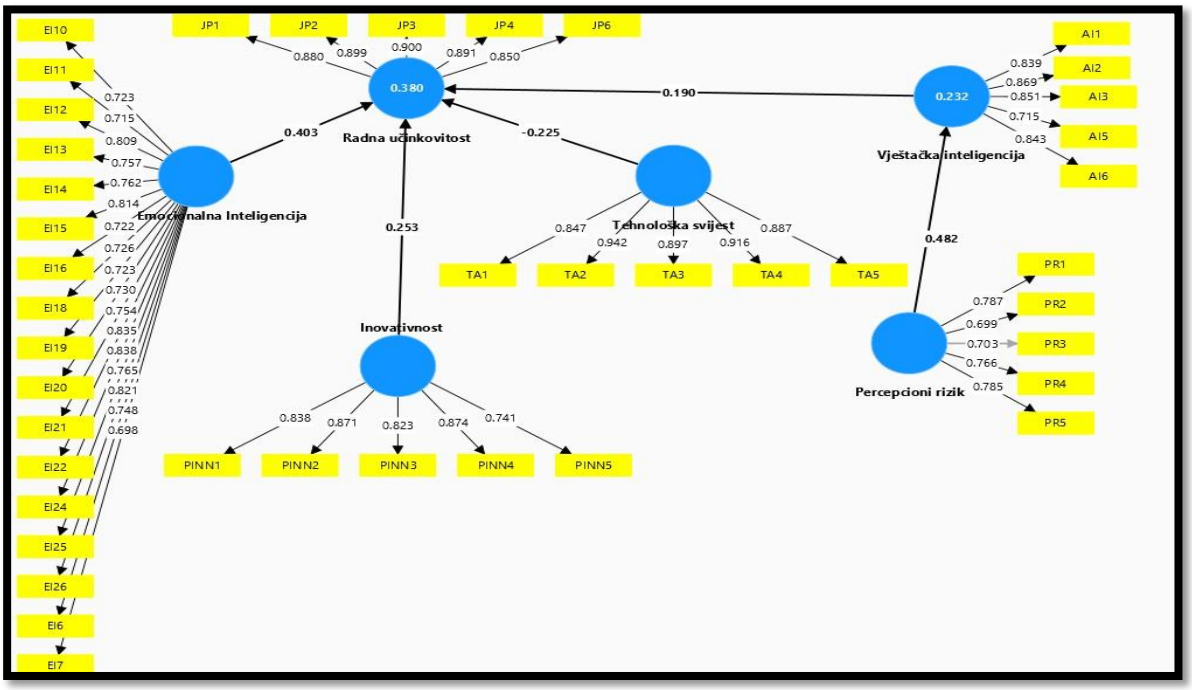

Izvor: SmartPLS

Nakon izračunavanja intervala povjerenja, iz tabele 7 se može uočiti da prosjek uzorka pripada središtu intervala, što ukazuje na normalnu distribuciju svih veza.

Tabela 7 Intervali povjerenja

	Original sample (O)	Sample mean (M)	2.5%	97.5%
Emocionalna inteligencija -> Radna učinkovitost	0,403	0,415	0,271	0,551
Inovativnost -> Radna učinkovitost	0,253	0,230	-0,004	0,458
Percipirani rizik -> Vještačka inteligencija	0,482	0,491	0,380	0,595
Tehnološka svijest -> Radna učinkovitost	-0,225	-0,196	-0,352	-0,021
Vještačka inteligencija -> Radna učinkovitost	0,190	0,188	0,020	0,361

Izvor: SmartPLS

U nastavku se nalazi grafički prikaz distribucija hipoteza:

Figure 3 Prikaz distribucije varijabli

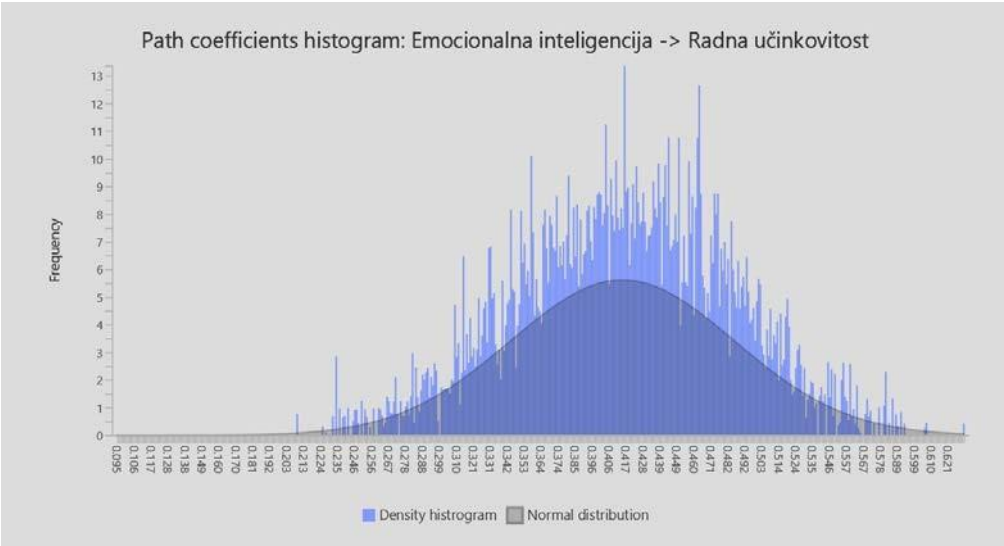

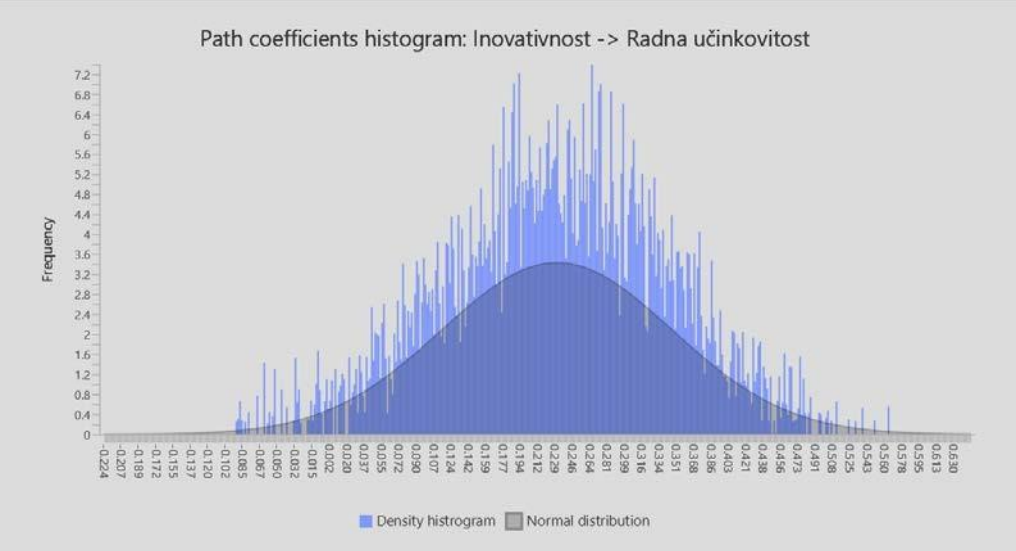

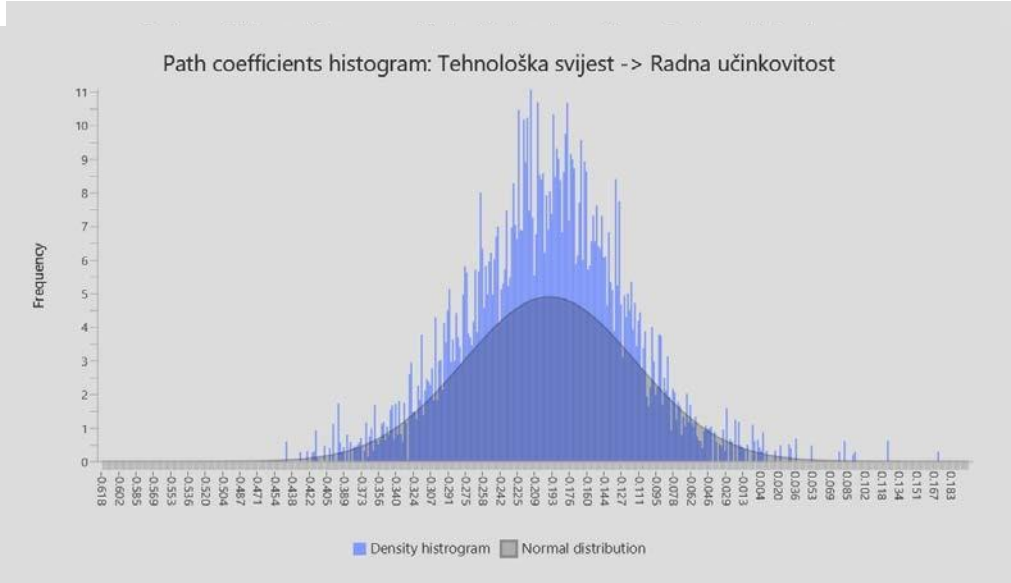

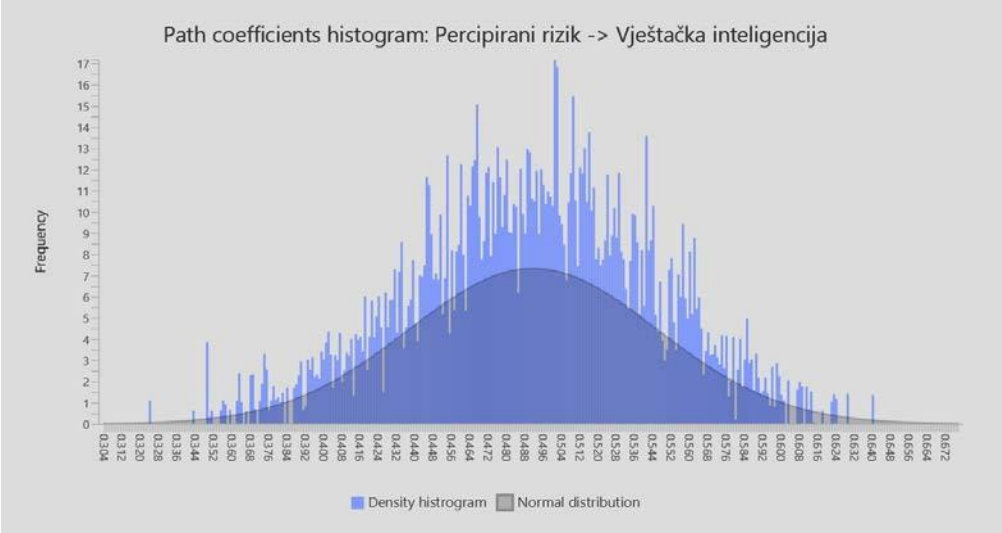

Izvor: SmartPLS

3.3. Interpretacija rezultata

U daljnjem dijelu rada biće sažeti glavni rezultati sprovedenog istraživanja zasnovani na kvantitativnom pristupu i kvantitativoj metodologiji, s ciljem da se donesu odgovarajući zaključci o uticaju emocionalne i vještačke inteligencije na poboljšanje radnih performansi. Rezultati će biti pažljivo analizirani i objedinjeni kako bi se omogućilo donošenje ispravnih zaključaka iz sprovedenog istraživanja. Ova analiza rezultaza će također poslužiti kao osnov za pružanje jasnih i konkretnih odgovora na postavljena istraživačka pitanja.

Većina prikupljenih odgovora ispitanika bila je slična, izražavajući pozitivne stavove prema vještačkoj i emocionalnoj inteligenciji, pri čemu ispitanici pretežno prednost daju emocionalnoj inteligenciji. Budući da ispitanici dolaze iz različitih sektora, a ponajviše iz IT sektora, bez obzira na razvoj tehnologija, može se zaključiti da ipak vještačka inteligencija nije na nivou emocionalne inteligencije. Uzimajući u obzir cijelu populaciju uzorka, gdje je više od 80% ispitanika dalo prednost emocionalnoj inteligenciji, time se može potvrditi da vlada emocionalna inteligencija u tehnološkom dobu današnjice.

Kvantitativna analiza sprovedenog istraživanja pokazala je da su sve hipoteze koje su bile formirane ujedno i potvrđene, te da navedeni parametri imaju povoljan uticaj. Kroz analizu dobivenih rezultata, zaključeno je da interna konzistentnost istraživanja jeste vrlo dobra ili izvrsna, kao i kompozitna pouzdanost varijabli, pri čemu je zasigurno interna konzistentnost svih varijabli zadovoljena. Posmatrajući kroz prizmu konvergentne validnosti, većina pokazatelja ispunila je potrebne kriterije, što sugerira nivo kolinearnosti između dvije mjere, koje bi teoretski trebale ispunjavati uslov visokog dijeljenja varijanse. Kroz opterećenje indikatora moguće je primjetiti da osigurana pouzdanost istih, iako su postojali indikatori kroz određene varijable koje nisu zadovoljile ovaj kriterij. Iste su izbačene iz daljneg razmatranja i analize. Također, diskriminativna validnost je također potvrđena, ona naglašava u kojoj mjeri se različiti konstrukti zaista razlikuju, a rezultat je potvrđen kroz HTMT kriterij i Fornel Lacker kriterij.

Utvrđeno je da varijable emocionalna inteligencija, inovativnost, vještačka inteligencija imaju signifikantan utjecaj na radnu učinkovitost, dok percepcioni rizik ima signifikantan utjecaj na vještačku inteligenciju. Također, tehnološka svijest ima negativan signifikantan utjecaj na radnu učinkovitost.

Ovi nalazi su značajni kako za akademsku zajednicu, tako i za praktičare u oblasti menadžmenta i ljudskih resursa, jer ukazuju na konkretne strategije za unapređenje radne učinkovitosti kroz adekvatno upravljanje ovim varijablama.

4. ZAKLJUČAK

Tehnološka usavršavanja i digitalizacija u današnjici postaje složenija u radnim okruženjima, što kompanijama donosi brojne izazove koji utiču na radne performanse zaposlenika. Savremeno poslovno okruženje je jasno okarakterizirano rastućim zahtjevima za efikasnošću, zadovoljstvom zaposlenika i produktivnošću. U ovom radu analizirana je uloga emocionalne inteligencije, vještačke inteligencije, inovativnosti, tehnološke svijesti i percipiranog rizika u unaprijeđenju radne učinkovitosti zaposlenika. Istraživanje je provedeno s ciljem da se odgovori na postavljena istraživačka pitanja, a rezultati su potvrdili postavljene hipoteze.

Prvo istraživačko pitanje odnosilo se na uticaj emocionalne inteligencije na radnu učinkovitost zaposlenika. Rezultati pokazuju da emocionalna inteligencija značajno doprinosi poboljšanju radne učinkovitosti, posebno kroz smanjenje stresa i povećanje zadovoljstva zaposlenika (Goleman, 2013). Ovo potvrđuje da su zaposlenici sa višim nivoom emocionalne inteligencije bolje prilagođeni promjenama i efektivniji u međuljudskim odnosima, što direktno utiče na njihove radne performanse (Mayer *et al.*, 2008).

Drugo istraživačko pitanje istraživalo je doprinos vještačke inteligencije radnoj učinkovitosti zaposlenika. Uočeno je da vještačka inteligencija omogućava optimizaciju radnih procesa, poboljšanje donošenja odluka i fokusiranje zaposlenika na kreativnije zadatke (Brynjolfsson i McAfee, 2014). Time se potvrđuje da integracija vještačke inteligencije u poslovne procese može značajno unaprijediti efikasnost i produktivnost zaposlenika (Bessen, 2019).

Treće istraživačko pitanje odnosilo se na uticaj inovativnosti na radnu učinkovitost. Istraživanje je pokazalo da inovativnost značajno doprinosi povećanju radne učinkovitosti, jer podstiče kreativnost i omogućava bržu prilagodbu promjenama na tržištu (Damanpour, 1991). Organizacije koje promovišu inovativnost među zaposlenicima ostvaruju bolje performanse i postižu veći uspjeh u dinamičnim poslovnim okruženjima (Tushman i O'Reilly, 2013).

Četvrto istraživačko pitanje analiziralo je značaj tehnološke svijesti za radnu učinkovitost zaposlenika. Rezultati sugeriraju da je visoka tehnološka svijest ključna za efikasno

korištenje modernih alata i tehnologija, što direktno utiče na radnu produktivnost (Tarafdar *et al.*, 2019). Zaposlenici sa razvijenom tehnološkom sviješću lakše prihvataju i usvajaju nove tehnologije, čime doprinose ukupnoj učinkovitosti organizacije (Venkatesh *et al.*, 2003).

Peto istraživačko pitanje ispitivalo je uticaj percipiranog rizika na primjenu vještačke inteligencije na radnom mjestu. Istraživanje je pokazalo da visok nivo percipiranog rizika može ograničiti primjenu vještačke inteligencije, jer izaziva otpor i nevoljnost među zaposlenicima da prihvate nove tehnologije (Charlwood i Guenole, 2022). Ovi rezultati naglašavaju važnost edukacije i transparentne komunikacije kako bi se smanjio percipirani rizik i olakšala integracija vještačke inteligencije (Chatterjee *et al.*, 2022).

Zaključno, rezultati ovog istraživanja pružaju dragocjene uvide u načine na koje emocionalna i vještačka inteligencija, inovativnost, tehnološka svijest i percipirani rizik utiču na radnu učinkovitost.

Sve u svemu, ovo istraživanje doprinosi boljem razumijevanju međusobnog odnosa između emocionalne i vještačke inteligencije i njihove uloge u poboljšanju radne učinkovitosti. Rezultati pružaju teoretsku osnovu za dalja istraživanja i praktične preporuke za menadžere koji žele unaprijediti radnu učinkovitost kroz integraciju ovih koncepata u poslovne procese. Dakle, integracija EI i AI u poslovne procese može signifikantno doprinijeti poboljšanju radnih performansi, a u budućim istraživanjima bi trebalo dodatno se fokusirati na testiranje međusobnih odnosa ovih koncepata, kao i definisanje strategija za smanjenje percepcionog rizika pri implementaciji AI tehnologija.

4.1. Ograničenja i preporuke

Zasigurno se može tvrditi da osnovno ograničenje istraživačkog rada jeste proces prikupljanja podataka, a posebno veličina uzorka, budući da nije moguće sakupiti dovoljno velik uzorak za sve industrije ispitanika. Stoga, istraživanje bi trebalo obuhvatiti širi spektar, uključujući detaljnije analize sektora i podsektora industrije, s ciljem da se istraže i prikažu različiti stavovi, kao i sama primjena i upotreba različitih tipova inteligencije unutar različitih organizacija. Istraživanje vještačke i emocionalne inteligencije, bez sumnje, zahtijeva temeljitiju analizu, zbog čega bi buduća istraživanja trebala biti sprovedena s većom pažnjom, dužim vremenskim periodom analize i sa više detalja. Također, jedno od općih ograničenja u proučavanju tehnologija proističe iz subjektivnog optimizma, ljudi često vjeruju da su sve tehnološke implementacije isključivo korisne. Ovaj stav dovodi do situacije u kojoj se pretežno bilježe samo pozitivni rezultati, a pritom se zanemaruju mogući negativni efekti. To je posebno važno u kontekstu varijable percipiranog rizika, koja može značajno utjecati na cjelokupnu percepciju i uspješnost primjene tehnologija. Kako bi se dobila objektivnija slika, neophodno je uključiti analizu i negativnih aspekata, kako bi se bolje razumjele sve dimenzije utjecaja tehnologije na organizacije i društvo u cjelini.

REFERENCE

1. Adnyani, N. L. P. R., i Dewi, A. A. S. K. (2019). Pengaruh pengalaman rada, prestasi rada i obuka na razvoj karijere zaposlenika. *E-Jurnal Manajemen Universitas Udayana*, 8(7), 4073. Dostupno na: https://doi.org/10.24843/ejmunud.2019.v08.i07.p03 (pristupljeno 25.9.2024)
2. Afiyati, E. M. (2018). Pengaruh pengembangan karir, motivasi kerja, i disiplin kerja terhadap kinerja karyawan Bank Syariah Mandiri Cabang Surakarta. *Journal of Materials Processing Technology*, 1(1), 1–142
3. Akerkar, R. (2019). *Artificial intelligence for business*. Sogndal: Springer
4. Aldi, Y., i Susanti, F. (2019). *Pengaruh stres kerja i motivacija rada na radnu učinkovitost zaposlenika u PT*. Frisian Flag Indonesia, Padang. 1–11. Dostupno na: https://doi.org/10.31227/osf.io/et4rn (pristupljeno 25.9.2024)
5. Ali, H., i Aysan, A. F. (2023). What will ChatGPT revolutionize in the financial industry? *Abstract*, Hamad Bin Khalifa University, Qatar Foundation. Dostupno na: https://doi:10.1016/j.stemcr.2022.12.009 (pristupljeno 25.9.2024)
6. Anjila, F. (2021). Artificial intelligence. U J. Karthikeyan, T. Su Hie, i N. Y. Jin (ur.), *Learning outcomes of classroom research* (str. 65–73). New Delhi, India: L Ordine Nuovo Publication
7. Arias-Oliva, M., Pelegrín-Borondo, J., i Matías-Clavero, G. (2019). Variables influencing cryptocurrency use: A technology acceptance model in Spain. *Frontiers in Psychology*, 10, Article 475. Dostupno na: https://doi.org/10.3389/fpsyg.2019.00475 (pristupljeno 25.9.2024)
8. Ashrafi, R., i Murtaza, M. (2011). Use and impact of ICT on SMEs in Oman. *The Electronic Journal Information Systems Evaluation*, 14(2), 167-180
9. Bajgorić, N., Somun-Kapetanović, R., Resić, E., i Turulja, L. (2019). *Uvod u metodologiju NIRa* (2nd ed.). Ekonomski fakultet u Sarajevu
10. Bahtijarević-Šiber, F. (1999). *Menagement ljudskih potencijala*. Golden marketing
11. Bar-On, R. (1997). The Emotional Intelligence Inventory *(EQI): Technical manual*. Toronto, Canada: Multi-Health System
12. Beck, U. (1986/2003). A kockázat-társadalom – *Út egy másik modernitásba. Századvég Kiadó*
13. Bessen, J. E. (2019). *AI and Jobs: The role of demand*. National Bureau of Economic Research
14. Bhardwaj, G., Singh, S. V., i Kumar, V. (2020). An empirical study of artificial intelligence and its impact on human resource functions. *U Proceedings of the International Conference on Computer Automation and Knowledge Management* (ICCAKM). Dostupno na: https://doi.org/10.1109/ICCAKM46823.2020.9051544 (pristupljeno 25.9.2024)
15. Boyatzis, R. E. (2018). The behavioral level of emotional intelligence and its impact on leadership and performance. *Journal of Management Development*, 37(4), 14-29
16. Brennan, A., i Dooley, L. (2005). Networked creativity: a structured management framework for stimulating innovation. *Technovation*, 25(12), 1388-1399
17. Brougham, D., i Haar, J. (2018). Smart technology, artificial intelligence, robotics, and algorithms (STARA): Employees' perceptions of our future workplace. *Journal of Management i Organization*, 24(2), 239-257. Dostupno na: https://doi.org/10.1017/jmo.2016.55 (pristupljeno 25.9.2024)
18. Brynjolfsson, E., Li, D., i Raymond, L. R. (2023). Generative AI at work. *National Bureau of Economic Research*. Dostupno na: https://www.nber.org/system/files/working_papers/w31202/w31202.pdf (pristupljeno 25.9.2024)

19. Brynjolfsson, E., i McAfee, A. (2014). The Second Machine Age: *Work, Progress, and Prosperity in a Time of Brilliant Technologies*. W. W. Norton i Company
20. Calantone, R. J., Cavusgil, S. T., i Zhao, Y. (2002). Learning orientation, firm innovation capability, and firm performance. *Industrial Marketing Management*, 31(6), 515-524
21. Charlwood, A., i Guenole, N. (2022). Can HR adapt to the paradoxes of artificial intelligence? *Human Resource Management Journal*, 32(4), 729-742. Dostupno na: https://doi.org/10.1111/1748-8583.12433 (pristupljeno 25.9.2024)
22. Chai, C. S., Chiu, T. K. F., Wang, X., Jiang, F., i Lin, X. F. (2023). Modeling Chinese secondary school students' behavioral intentions to learn artificial intelligence with the theory of planned behavior and self-determination theory. *Sustainability*, 15(1), Article 605. Dostupno na: https://doi.org/10.3390/su15010605 (pristupljeno 25.9.2024)
23. Chatterjee, S., Chaudhuri, R., i Vrontis, D. (2022). Examining the impact of adoption of emerging technology and supply chain resilience on firm performance: Moderating role of absorptive capacity and leadership support. *IEEE Transactions on Engineering Management*. Dostupno na: https://doi.org/10.1109/TEM.2021.3134188 (pristupljeno 25.9.2024)
24. Corea, F. (2019). *Applied Artificial Intelligence: Where AI Can Be Used in Business.* Rome: Springer
25. Creswell, J. W. (2015). A concise introduction to mixed methods research. *SAGE Publications*
26. Cvetković, S. (2015). Razvoj kontaktnog centra kao preduvjet porasta zadovoljstva korisnika. *Željeznice* 21, 14(2)
27. Dahlan, A., Nicol, M., i Maciver, D. (2010). Elements of life satisfaction amongst elderly people living in institutions in Malaysia: A mixed methodology approach. *Hong Kong Journal of Occupational Therapy*, 20(2), 71-79
28. Damanpour, F. (1991). Organizational innovation: A meta-analysis of effects of determinants and moderators. *Academy of Management Journal*, 34(3), 555-590
29. Davenport, T. H., i Ronanki, R. (2018). Artificial Intelligence for the Real World. *Harvard Business Review*, 96(1), 108-116
30. Devaraj, S., i Kohli, R. (2003). Performance impacts of information technology: Is actual usage the missing link? *Management Science*, 49(3), 273-289
31. Dietz, T., Frey, R. S., i Rosa, E. (1993). Risk, technology, and society. U R. E. Dunlap i W. Michelson (ur.), *Handbook of environmental sociology* (str. 177-187). Greenwood Press
32. Garnida, D. (2017). Pengaruh pendidikan, pengalaman rada i radna učinkovitost na razvoj karijere zaposlenika u Uredu za javne radove Kutai Timur. *EJournal Pemerintahan Integratif*, 5(4), 626–635
33. Goleman, D. (1995). *Emotional Intelligence: Why It Can Matter More Than IQ*. Bantam Books
34. Goleman, D. (1998). *Working with emotional intelligence.* New York, USA: Bantam Books
35. Goleman, D., Boyatzis, R. E., i McKee, A. (2013). Primal Leadership: Learning to Lead with Emotional Intelligence. *Harvard Business Review Press*
36. Gumusluoglu, L., i Ilsev, A. (2009). Transformational leadership, creativity, and organizational innovation. *Journal of Business Research*, 62(4), 461-473
37. Hair, J. F., Hult, G. T. M., Ringle, C. M., i Sarstedt, M. (2021). Partial Least Squares Structural Equation Modeling (PLS-SEM) *Using R*. Springer. Dostupno na: https://doi.org/10.1007/978-3-030-80519-7 (pristupljeno 25.9.2024)
38. Hamid, H., i Zeki, A. M. (2014). Users' awareness of and perception on information security issues: A case study of Kulliyyah of ICT postgraduate students. U *Proceedings*

of the 3rd International Conference on Advanced Computer Science Applications and Technologies (ACSAT), 139-144. Dostupno na:https://doi.org/10.1109/ACSAT.2014.31 (pristupljeno 25.9.2024)

39. Harahap, D. S., i Khair, H. (2019). Pengaruh kepemimpinan i kompenzacija na zadovoljstvo rada kroz motivaciju rada. *Maneggio: Jurnal Ilmiah Magister Manajemen*, 2(1), 69–88. Dostupno na: https://doi.org/10.30596/maneggio.v2i1.3404 (pristupljeno 25.9.2024)
40. Hajncl, L. J., i Vučenović, D. (2013). Emocionalna inteligencija: Modeli i mjerenje 20 godina poslije. *Suvremena psihologija*, 16(1), 97
41. Henderson, M., Harvey, S. B., Øverland, S., Mykletun, A., i Hotopf, M. (2011). Work and common psychiatric disorders. *Journal of the Royal Society of Medicine*, 104(5), 198-207
42. Hercigonja, Z. (2018). Važnost stvaranja discipline i unutarnje kontrole u procesu razvoja čovjeka. *Acta Iadertina*, 15(1), 59-78
43. Hennekam, S., Follmer, K., i Beatty, J. E. (2021). The paradox of mental illness and employment: A person-job fit lens. *The International Journal of Human Resource Management*, 32(15), 3244-3271
44. Huang, M.-H., i Rust, R. T. (2018). Artificial intelligence in service. *Journal of Service Research*, 21(2), 155–172. https://doi.org/10.1177/1094670517752459
45. Ilić, E. (2008). Emocionalna inteligencija i uspješno vođenje. *Ekonomski pregled*, 59(9-10), 576-592
46. Im, Y., Kim, H. J., i Han, H. J. (2008). The effects of perceived risk and technology type on users' acceptance of technologies. *Information i Management*, 45(1), 1-9. Dostupno na: https://doi.org/10.1016/j.im.2007.03.005 (pristupljeno 25.9.2024)
47. Jarrahi, M. H. (2018). Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. *Business Horizons*, 61(4), 577-586
48. Jones, D., i Brown, K. (2020). AI and EI: Enhancing Employee Retention and Productivity. *Journal of Management Studies*, 68(3), 412-428. Dostupno na: https://doi.org/10.1111/joms.12456 (pristupljeno 25.9.2024)
49. Jumawan, i Mora, M. T. (2018). Pengaruh pelatihan i razvoj karijere na radnu učinkovitost u korporativnim preduzećima. *Jurnal Riset Manajemen Dan Bisnis* (JRMB) Fakultas Ekonomi UNIAT, 3(3), 343–352. Dostupno na:https://doi.org/10.36226/jrmb.v3i3.153 (pristupljeno 25.9.2024)
50. Kaplan, A., i Haenlein, M. (2019). Siri, Siri, in my Hand: Who's the Fairest in the Land? On the Interpretations, Illustrations, and Implications of Artificial Intelligence. *Business Horizons*, 62(1), 15-25. Dostupno na: https://doi.org/10.1016/j.bushor (pristupljeno 25.9.2024)
51. Khaksar, S. M. S., Behzadian, A., Golpayegani, S. A., i Shafie-Khah, M. (2019). A comprehensive review on renewable energy integration for combined heat and power generation. *Energy*, 189, 116138. Dostupno na:https://doi.org/10.1016/j.energy.2019.116138 (pristupljeno 25.9.2024)
52. Kirkpatrick, G. (2017). Critical technology: A social theory of personal computing (1st ed.). *Routledge*. Dostupno na: https://doi.org/10.4324/9781351160643 (pristupljeno 25.9.2024)
53. Knežević, M. (2010). *Internet marketing u službi komercijalizacije uspjeha* - specijalistički rad. Banja Luka: Fakultet poslovne ekonomije
54. Kovačević, R., Cesar, I., i Cafuta, D. (2019). Artificial intelligence in computer games. *Polytechnic and Design*, 7(2), 117-124
55. Ladokun, I. O., i Osunwole, O. O. (2019). Influence of technological literacy on organizational performance. *International Journal of Business and Management*, 14(2), 25-34

56. Liang, H., i You, J. (2019). Impact of technological literacy on business performance. *Journal of Business Research*, 103, 14-25
57. Ljubanović, A. (2023). *Uloga inovativnosti u razvoju brzorastućih preduzeća (Gazela) iz oblasti računarskog programiranja* (Završni rad). Univerzitet u Sarajevu, Ekonomski fakultet
58. Majstorić, L. (2023.) *Vizualizacija podataka: BI alati kao osnova za efikasno izvještavanje i podrška menadžmentu* (Završni rad). Univerzitet u Sarajevu, Ekonomski fakultet
59. Mandić, M. (2007). Povezanost upravljanja odnosima s klijentima i tržišne marke. *Tržište*, 19(1), 89
60. Manual, O. (2018). Guidelines for collecting, reporting and using data on innovation. *The measurement of Scientific, Technological and Innovation Activities*
61. Masakowski, Y. (2020). The rise of artificial intelligence: Its impact on decision-making and technology risk. *Technology Review Journal*, 15(4), 102-120
62. Mayer, J. D., i Salovey, P. (1997). What is emotional intelligence. *Emotional Development and Emotional Intelligence: Educational Implications*, 3, 31
63. Mayer, J. D., Roberts, R. D., i Barsade, S. G. (2008). Human abilities: Emotional intelligence. *Annual Review of Psychology*, 59(1), 507-536
64. Mayer, J. D., Salovey, P., i Caruso, D. R. (2004). Emotional Intelligence: Theory, Findings, and Implications. *Psychological Inquiry*, 15(3), 197-215. Dostupno na: https://doi.org/10.1207/s15327965pli1503_02 (pristupljeno 25.9.2024)
65. Mayer, J. D., Salovey, P., i Caruso, D. R. (2008). Emotional intelligence: New ability or eclectic traits? *American Psychologist*, 63(6), 503-517
66. Milkovich, G. T., i Newman, J. M. (2006). *Plaće i modeli nagrađivanja*. MASMEDIA
67. Moorthy, S., i Polley, D. E. (2010). Technological knowledge breadth and depth: Performance impacts. *Journal of Knowledge Management*, 14(3), 359-377. Dostupno na: https://doi.org/10.1108/13673271011050102 (pristupljeno 25.9.2024)
68. Motowidlo, S. J., i Kell, H. J. (2003). Job performance. U W. C. Borman, D. R. Ilgen, i R. J. Klimoski (ur.), *Handbook of psychology: Industrial and organizational psychology* (Vol. 12, str. 91-130). John Wiley i Sons
69. Mumford, M. D. (2000). Managing creative people: Strategies and tactics for innovation. *Human Resource Management Review*, 10(3), 313-351
70. Ogbeibu, S., et al. (2023). Demystifying the roles of organisational smart technology, artificial intelligence, robotics and algorithms capability: A strategy for green human resource management and environmental sustainability. *Business Strategy and the Environment*. Dostupno na:https://doi.org/10.1002/bse.3495 (pristupljeno 25.9.2024)
71. Ongena, Y. P., Haan, M., Yakar, D., i Kwee, T. C. (2020). Patients' views on the implementation of artificial intelligence in radiology: Development and validation of a standardized questionnaire. *European Radiology*, 30(2), 1033-1040. Dostupno na: https://doi.org/10.1007/s00330-019-06486-0 (pristupljeno 25.9.2024)
72. Parasuraman, A. (2000). Technology Readiness Index (TRI): A multiple-item scale to measure readiness to embrace new technologies. *Journal of Service Research*, 2(4), 307-320
73. Peterson, W. D. (1990). *Introduction to artificial intelligence and expert systems*. New Jersey: Prentice Hall
74. Pillai, R., i Sivathanu, B. (2020). Adoption of artificial intelligence (AI) for talent acquisition in IT/ITeS organizations. *Benchmarking*, 27(9), 2599-2629. Dostupno na: https://doi.org/10.1108/BIJ-04-2020-0186 (pristupljeno 25.9.2024)
75. Požega, Ž. (2012). *Menadžment ljudskih resursa: Upravljanje ljudima i znanjem u poduzeću.* Osijek: Ekonomski fakultet, Grafika

76. Priyono, Chandra, T., i Ariana, S. (2016). Influence of work environment, motivation and career development on the work achievement on a timeless gift PT. Aligned Sidoarjo. *International Journal of Applied Business and Economic Research*, 14(3), 2113–2131
77. Prister, V. (2019). Umjetna inteligencija. *Media, Culture and Public Relations*, 10(1), 69
78. Putica, M. (2018). *Umjetna inteligencija: Dvojbe suvremenog razvoja*. Hrčak, 13(20), 198-209. Dostupno na: https://hrcak.srce.hr/file/320733 (pristupljeno 25.9.2024)
79. Raharjo, R. P., Hamid, D., i Prasetya, A. (2014). Pengaruh pelatihan terhadap motivasi rada i radnu učinkovitost zaposlenika (Studi na zaposlenicima Balai Besar Pelatihan Pertanian (BBPP) Ketindan-Lawang). *Jurnal Administrasi Bisnis S1 Universitas Brawijaya*, 15(2), 84788.403
80. Raychev, V., Vechev, M., i Yahav, E. (2014, June). Code completion with statistical language models. U *Proceedings of the 35th ACM SIGPLAN Conference on Programming Language Design and Implementation* (str. 419-428)
81. Renn, O. (2004). Perception of risks. *The Geneva Papers on Risk and Insurance*, 29(1), 102-114
82. Rogers, E., White, S., i Garcia, M. (2019). Integrating EI in AI Systems: Benefits for Employee Performance. *Organizational Behavior and Human Decision Processes*, 54(1), 89-105. Dostupno na:https://doi.org/10.1016/j.obhdp.2018.12.002 (pristupljeno 25.9.2024)
83. Russell, S. J., i Norvig, P. (2016). *Artificial Intelligence: A Modern Approach*. Pearson
84. Sagheer, N., Khan, K. I., Fahd, S., Mahmood, S., Rashid, T., i Jamil, H. (2022). *Factors affecting adaptability of cryptocurrency: An application of technology acceptance model*
85. Salovey, P., i Mayer, J. D. (1990). *Emotional intelligence*. Imagination, Cognition and Personality, 9(3), Dostupno na: https://scholar.google.com/scholar?hl=hrias_sdt=0%2C5iq=saloveya%2C+mayera%2C+1990ibtnG= (pristupljeno 25.9.2024)
86. Schulze, R., i Roberts, R. D. (2005). *Emotional intelligence: An international handbook.* Cambridge, MA: Hogrefe i Huber Publishers
87. Schein, E. H. (2010). *Organizational culture and leadership* (4th ed.). Jossey-Bass
88. Sedighi, M., Sarcheshmeh, B., i Bagheri, R. (2022). Employee commitment to innovation performance: Investigating the role of knowledge acquisition and knowledge sharing. *International Journal of Systematic Innovation*, 7, 1–11
89. Sharma, R., i Kaur, S. (2021). Emotion AI: integrating emotional intelligence with artificial intelligence in the digital workplace. U Innovations in Information and Communication Technologies (IICT-2020) *Proceedings of International Conference on ICRIHE-2020*, Delhi, India: IICT-2020 (str. 337-343). Springer International Publishing
90. Shi, S., Gong, Y., i Gursoy, D. (2021). Antecedents of trust and adoption intention toward artificially intelligent recommendation systems in travel planning: A heuristic–systematic model. *Journal of Travel Research*, 60(8), 1714-1734. Dostupno na: https://doi.org/10.1177/0047287520966395 (pristupljeno 25.9.2024)
91. Slovic, P. (2000). *The perception of risk*. Earthscan
92. Šafarić, P., i Vuković, D. (2024). Emocionalna inteligencija. U A. Hunjet (ur.), Knjižica sažetaka Festival znanosti 2024. godine: *INTELIGENCIJA* (str. 95). Koprivnica, Varaždin: Sveučilište Sjever
93. Šarić, D., i Osmanović, A. (2023). Uticaj umjetne inteligencije na ljudske resurse u poslovanju. *Zbornik radova*
94. Šestak, P., i Dobrinić, D. (2019). Primjena novih tehnologija u marketingu s osvrtom na marketing stvari. CroDiM: *International Journal of Marketing Science*, 2(1), 244

95. Škare, V. (2011). *Internetski marketing*. Zagreb: Adverta
96. Smolčić, T., i dr. (2018). *Primjena strojnog učenja u naprednom računarstvu*. Dostupno na: https://hrcak.srce.hr/file/361974 (pristupljeno 25.9.2024)
97. Smith, A., Johnson, B., i Lee, C. (2021). Emotional Intelligence and Artificial Intelligence: Synergy in Business Performance. *Journal of Applied Psychology*, 73(2), 245-261. Dostupno na: https://doi.org/10.1037/apl0000123 (pristupljeno 25.9.2024)
98. Somun-Kapetanović, R. (2012). Metodologija istraživanja. Univerzitet u Sarajevu
99. Streukens, S., i Leroi-Werelds, S. (2016). Bootstrapping and PLS-SEM: A step-by-step guide to get more out of your bootstrap results. *European Management Journal*, 34(6), 618–632. Dostupno na:https://doi.org/10.1016/j.emj.2016.06.003 (pristupljeno 25.9.2024)
100. Sumenda, V., Kaunang, M., i Kumayas, N. (2018). Prestasi rada državnih službenika u podršci promociji položaja u Kabupaten Kepulauan Talaud. *Jurnal Jurusan Ilmu Pemerintahan*, 1(1)
101. Takšić, V., Mohorović, T., i Munjas, R. (2006). Emocionalna inteligencija: Teorija, operacionalizacija, primjena i povezanost s pozitivnom psihologijom. *Društvena istraživanja*, 15(4-5), 84-85
102. Tapia, D. M., Castro, W. L., i Aguilera, J. M. (2013). Employability strategies in population with mental disabilities: A review. *Salud Ment*, 36, 143-148
103. Tarafdar, M., Beath, C. M., i Ross, J. W. (2019). Using AI to enhance business operations. *MIT Sloan Management Review*, 60(4), 37-44
104. Thiraviyam, T. (2018). Artificial intelligence Marketing. *International Journal of Recent Research Aspects*, 450
105. Tushman, M. L., i O'Reilly, C. A. (2013). Organizational ambidexterity: Past, present, and future. *Academy of Management Perspectives*, 27(4), 324-338
106. Valerjev, P. (2006). Uloga umjetne inteligencije u istraživanju uma: Povijest i perspektiva. U M. Kotrla Topić (ur.), *Mozak i um* (str. 119). Zagreb: Institut društvenih znanosti Ivo Pilar
107. Venkatesh, V., Morris, M. G., Davis, G. B., i Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 27(3), 425-478
108. Vrontis, D., Christofi, M., Pereira, V., Tarba, S., Makrides, A., i Trichina, E. (2022). Artificial intelligence, robotics, advanced technologies and human resource management: A systematic review. *The International Journal of Human Resource Management*, 33(6), 1237-1266. Dostupno na:https://doi.org/10.1080/09585192.2020.1871398 (pristupljeno 25.9.2024)
109. Vukosav, S., i Zarevski, P. (2011). *Osnove sociologije*. Školska knjiga
110. Vuković, D., Dukić, A., Mihailović, Đ., i Urošević, A. (2024). Faktori razvoja inovativne kulture u poslovanju. U *Konferencija sa međunarodnim učešćem: Napredne tehnologije u obrazovanju i privredi*, Vrnjačka Banja, 28-30. maj 2024. (str. 449)
111. Wang, B., Liu, Y., i Parker, S. (2020). How does the use of information communication technology affect individuals? A work design perspective. *Academy of Management Annals*, 14, 695-725. Dostupno na https://doi.org/10.5465/annals.2018.0127 (pristupljeno 25.9.2024)
112. West, M. A., i Anderson, N. R. (1996). Innovation in top management teams. *Journal of Applied Psychology*, 81(6), 680–693. Dostupno na:https://doi.org/10.1037/0021-9010.81.6.680 (pristupljeno 25.9.2024)
113. Wirtz, J. (2018). Design complaint handling and service recovery strategies (Vol. 11, Winning in Service Markets Series). *Mobile book*. ISBN 9781944659417
114. Šafarić, P., i Vuković, D. (2024). Emocionalna inteligencija. U A. Hunjet (ur.), Knjižica sažetaka Festival znanosti 2024. godine: *INTELIGENCIJA* (str. 95). Koprivnica, Varaždin: Sveučilište Sjever

PRILOZI

Prilog 1

Istraživački upitnik

Sve su promjene spremljene na Disk

Pitanja Odgovori 210 Postavke

Odjeljak 1 od 5

ISTRAŽIVAČKA PITANJA

Poštovani/a

Molim Vas da odgovorite na postavljena istraživačka pitanja koja će se koristiti u izradi analize master teze na temu **"Uloga emocionalne i vještačke inteligencije u unapređenju radnih performansi"** smjer Menadžment informacionih tehnologija na Ekonomskom fakultetu Univerziteta u Sarajevu - student Samir Džafić

Odgovori su anonimni i koristiti će se isključivo u analizi master rada za navedenu temu.

Potrebno vrijeme za odgovoriti na postavljena pitanja Cca 5 min.

Hvala Vam velika.

Vaš spol? *

1. Žensko
2. Muško

Koliko imate godina? *

1. od 18 do 25
2. od 26 do 35
3. od 36 do 45
4. od 47 do 55
5. od 56 do 65

Vaš nivo obrazovanja? *

1. SSS
2. VŠS
3. VSS
4. MA ili MR
5. DR

Kojoj industriji pripada kompanija/institucija u kojoj ste zaposleni? *

1. IT
2. Marketing i usluge
3. Finansije i/ili računovodstvo
4. Proizvodnja
5. Obrazovanje
6. Ostalo

Koja je vaša pozicija u kompaniji/instituciji? *

1. Operativni nivo - Entry-Level (EL)
2. Šef odjela - Department Head (DH)
3. Srednji menadžment - Middle Management (MM)
4. Top menadžment - Top Management (TM)
5. Ostalo

Vaše iskustvo u korištenju računara i IT alata je: *

1. manje od 1 godine
2. između 1 i 3 godine
3. između 3 i 6 godine
4. između 6 i 9 godina
5. više od 9 godina

Koliko imate radnog iskustva? *

1. manje od 1 godine
2. između 1 i 3 godine
3. između 3 i 6 godine
4. između 6 i 9 godina
5. više od 9 godina

Vaše iskustvo u korištenju AI tehnologija: *

1. manje od 1 godine
2. između 1 i 2 godine
3. između 2 i 3 godine
4. između 3 i 4 godine
5. između 4 i više godina

Koristim ChatGPT ili neke druge AI alate: *

1. 1 godišnje
2. više puta mjesečno
3. 1 mjesečno
4. više puta sedmično
5. sedmično
6. dnevna upotreba
7. aktivna upotreba više puta dnevno

Moje trenutno stanje emocionalne inteligencije? (lična procjena) *

1. emocionalno neinteligentan/na
2. srednje emocionalno inteligentan/na
3. emocionalno inteligentan/na
4. natprosečno emocionalno inteligentan/na

Radna učinkovitost? (lična procjena) *

1. radno neefikasan/na
2. prosječno radno-efikasan/na
3. radno efikasan/na
4. natprosečna radna-efikasnost

Lično zadovoljstvo? (lična procjena) *

1. nezadovoljan/na sobom
2. prosječno zadovoljan/na sobom
3. zadovoljan/na sobom
4. natprosečno zadovoljan/na sobom

Kojem tipu inteligencije u poslovanju dajete prednost? *

1. Vještačka inteligencija (AI)
2. Emocionalna inteligencija (EI)

Odjeljak 2 od 5

U nastavku na naredna pitanja odgovorite tako da izrazite svoj nivo slaganja sa navedenim tvrdnjama odabirom brojeva na skali od 1 - 5 (1 - Ne slažem se, 2 - Djelomično se ne slažem, 3 - Niti se slažem niti se ne slažem / Neutralan/a sam, 4 - Djelomično se slažem, 5 - Slažem se)

Opis (po izboru)

Pitanje *

	1	2	3	4	5
Svjesna/tan sa...	○	○	○	○	○
Pozitivno reagi...	○	○	○	○	○
Kritiku kolega/i...	○	○	○	○	○
Svjesna/tan sa...	○	○	○	○	○
Teško mi je pre...	○	○	○	○	○
Svjesna/tan sa...	○	○	○	○	○
Učinkovito rješ...	○	○	○	○	○
Na odgovaraju...	○	○	○	○	○
Uspijevam se u...	○	○	○	○	○
Pokrećem akcij...	○	○	○	○	○

Nastojim unapr...	○	○	○	○	○
Težim poboljša...	○	○	○	○	○
Smatram da je ...	○	○	○	○	○
Zadovoljna/an ...	○	○	○	○	○
Nastojim da ra...	○	○	○	○	○
Pokazujem dru...	○	○	○	○	○
Osjetljiv/a sam...	○	○	○	○	○
Dobro razumije...	○	○	○	○	○
Ja dobro vidim...	○	○	○	○	○
Efikasno reaguj...	○	○	○	○	○
Precizno sagle...	○	○	○	○	○
Pomažem stva...	○	○	○	○	○
Pomažem drug...	○	○	○	○	○
Pružam korisn...	○	○	○	○	○
Pomažem drug...	○	○	○	○	○
Pozitivno utiče...	○	○	○	○	○

Odjeljak 3 od 5

U nastavku na naredna pitanja odgovorite tako da izrazite svoj nivo slaganja sa navedenim tvrdnjama odabirom brojeva na skali od 1 - 5 (1 - Ne slažem se, 2 - Djelomično se ne slažem, 3 - Niti se slažem niti se ne slažem / Neutralan/a sam, 4 - Djelomično se slažem, 5 - Slažem se)

Opis (po izboru)

Uspjevam *

	1	2	3	4	5
Ispuniti specifi...	○	○	○	○	○
Dosegnuti stan...	○	○	○	○	○
Zadovoljiti nivo...	○	○	○	○	○
Efikasno obavit...	○	○	○	○	○
Obaviti svoj po...	○	○	○	○	○
Raditi visoko-k...	○	○	○	○	○

Nakon odjeljka 3 Nastavi na sljedeći odjeljak

Odjeljak 4 od 5

U nastavku na naredna pitanja odgovorite tako da izrazite svoj nivo slaganja sa navedenim tvrdnjama odabirom brojeva na skali od 1 - 5 (1 - Ne slažem se, 2 - Djelomično se ne slažem, 3 - Niti se slažem niti se ne slažem / Neutralan/a sam, 4 - Djelomično se slažem, 5 - Slažem se)

Opis (po izboru)

Pitanje *

	1	2	3	4	5
Ja dobro znam...	○	○	○	○	○
Implementacij...	○	○	○	○	○
Primjena AI u p...	○	○	○	○	○
U bliskoj buduć...	○	○	○	○	○
Za primjenu AI ...	○	○	○	○	○
AI će ubrzati o...	○	○	○	○	○
Pridajem veliku...	○	○	○	○	○
Uživam u kupo...	○	○	○	○	○
Čini me poseb...	○	○	○	○	○
Želim da posje...	○	○	○	○	○

Često kupujem...	○	○	○	○	○
Zadovoljna/an ...	○	○	○	○	○
Volio/ljela bih ...	○	○	○	○	○
Novi proizvodi ...	○	○	○	○	○
Kad bih saznao...	○	○	○	○	○
Često sam prvi...	○	○	○	○	○
Kada se koristi ...	○	○	○	○	○
Osjećam se ne...	○	○	○	○	○
AI čini uposleni...	○	○	○	○	○
Mislim da će z...	○	○	○	○	○
AI se može kori...	○	○	○	○	○

Nakon odjeljka 4 Nastavi na sljedeći odjeljak

Odjeljak 5 od 5

HVALA VAM !

Opis (po izboru)