Dijeljenje znanja u funkciji unapređenja uspješnosti poslovanja poduzeća

Jakopič Ganić, Marijana

Doctoral thesis / Disertacija

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Economics and Business / Sveučilište u Rijeci, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:192:048846

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Repository / Repozitorij:

Repository of the University of Rijeka, Faculty of Economics and Business - FECRI Repository

UNIRI DIGITALNA KNJIŽNICA

Image not found or type unknown

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET RIJEKA

Marijana Jakopič Ganić

DIJELJENJE ZNANJA U FUNKCIJI UNAPREĐENJA USPJEŠNOSTI POSLOVANJA PODUZEĆA

DOKTORSKI RAD

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET RIJEKA

Marijana Jakopič Ganić

DIJELJENJE ZNANJA U FUNKCIJI UNAPREĐENJA USPJEŠNOSTI POSLOVANJA PODUZEĆA

DOKTORSKI RAD

Mentor: izv. prof. dr. sc. Dunja Škalamera-Alilović
Komentor: prof. dr. sc. Ana Štambuk

Rijeka, 2023. godina

UNIVERSITY OF RIJEKA
FACULTY OF BUSINESS AND ECONOMICS

Marijana Jakopič Ganić

KNOWLEDGE SHARING AND BUSINESS PERFORMANCE IN ENTERPRISES

DOCTORAL THESIS

Rijeka, 2023

Mentor rada: izv. prof. dr. sc. Dunja Škalamera-Alilović

Doktorski rad obranjen je 24. veljače 2023. godine na Ekonomskom fakultetu Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. izv. prof. dr. sc. Zoran Ježić, predsjednik
2. prof. dr. sc. Mira Dimitrić
3. prof. dr. sc. Tjaša Redek

“Everything that can be counted does not necessarily count;
everything that counts cannot necessarily be counted.”
Albert Einstein

Posveta

Mojoj djeci, Lauri i Ivoru

I. PREDGOVOR

Poslijediplomski doktorski studij odlučila sam upisati nedugo nakon svog zaposlenja u sustavu visokog obrazovanja. Moja odluka nije bila uvjetovana formalnim kriterijima prirode radnog mjesta na kojem sam bila angažirana, već mojom osobnom željom da nadogradim postojeće znanje ili, bolje rečeno, sustav vjerovanja, prosuđivanja i zaključivanja. Naime, s obzirom na činjenicu da sam bezbroj puta bila u mogućnosti pripomoći kolegama nastavnicima u prijevodu njihovih znanstvenih i stručnih radova na engleski jezik, zaintrigirao me sadržaj većine radova, jer me potaknuo na daljnje promišljanje. Kod pojedinih me radova oduševila lakoća pisanja i prenošenja znanja o materiji o kojoj su autori istraživali. Tada sam pomislila: „Zašto i sama ne bih probala zaroniti u istraživačke vode?“

Zahvaljujući tadašnjem dekanu, dr. sc. Dušanu Rudiću, to mi je i omogućeno. Na tome ću mu zauvijek biti zahvalna. Put u istraživački rad bio je trnovit, s puno uspona i padova, možda s većim naglaskom na drugo, barem dok me taj isti put nije doveo do mentorice, izv. prof. dr. sc. Dunje Škalamera-Alilović. Njezin entuzijazam, energija i žeđ za znanjem bili su pravo osvježenje. Svojoj ću mentorici zauvijek biti zahvalna na tome – pokazala mi je pozitivnu stranu istraživačkog rada, ohrabrivala kada su se pojavile nedoumice, hvalila kada smo zajedno prešle svaki bitan korak prema uspješnom ostvarenju cilja. Ne samo da me usmjeravala profesionalno, već mi je bila oslonac i osobno, kada je osjetila potrebu da mi treba poticaj da vratim vjeru u sebe i svoja uvjerenja.

Naravno, mnogo dugujem i vlastitoj obitelji – roditeljima, koji su nesebično čuvali dječicu kada je mama bila u fazi „kreativnog izričaja“, i suprugu, koji je isto bio prisiljen svjedočiti „krizama u stvaralaštvu“. Na kraju putovanja mogu samo zaključiti da se isplatilo – uz mnogo truda i odricanja došla sam do cilja, učila o učenju, učila o promišljanju, odslušala mnoga zanimljiva predavanja, dobila uvid u sasvim nov svijet.

Nadam se da ću time uspjeti prenijeti poruku svojoj djeci da se ponekad uistinu dogodi sinkronicitet koji nas pogura u pravom smjeru…

II. SAŽETAK

Poduzeća koja su aktivna u trenutku pisanja ove disertacije djeluju u dinamičnom okruženju koje zahtijeva konstantno prilagođavanje, odnosno unapređivanje organizacijskog znanja. Da bi se znanje učinkovito koristilo, bitno je njime racionalno upravljati, pa upravljanje znanjem od kraja prošloga stoljeća privlači sve veću pozornost istraživača. Riječ je o kompleksnom organizacijskom fenomenu koji nije jednoznačno definiran, no postoji konsenzus glede činjenice da dijeljenje znanja predstavlja njegovu središnju fazu. Dijeljenje znanja dvosmjeran je proces koji se sastoji od davanja i primanja znanja, čije se teorijsko uporište može pronaći u teoriji društvene razmjene. Međutim, troškovi dijeljenja znanja nisu identični s obzirom na vrstu znanja, pa će se u disertaciji razlikovati eksplicitno i implicitno znanje.

Proces dijeljenja znanja podložan je određenim kontekstualnim čimbenicima. U ovom će se radu istražiti sinergijski učinak organizacijske kulture i informacijsko-komunikacijskih tehnologija (IKT-a) kao čimbenika koji pospješuju dijeljenje znanja, a čiji je utjecaj dodatno pojačan podrškom vrhovnog menadžmenta. Kombinacijom triju navedenih čimbenika potencijalno je moguće efikasnije dijeliti znanje, što se može pozitivno odraziti na uspješnost poslovanja, a što će se u ovom radu nastojati dokazati na reprezentativnom uzorku hrvatskih poduzeća.

Istraživanje je provedeno u dvije faze: *online* istraživanje u čiju je svrhu distribuirano 1.500 *online* upitnika, te poštansko istraživanje u čiju je svrhu odaslano 1.500 otisnutih upitnika u frankiranim kovertama s plaćenim odgovorom. Na taj način ujedno se testirala i učinkovitost dviju metoda anketiranja, pri čemu se *online* upitnicima odazvalo 126 ispitanika, dok se tiskanim upitnicima odazvalo 224 ispitanika. Rezultati istraživanja pokazali su da hrvatska poduzeća pristupaju procesu dijeljenja znanja na način da najveću pozornost pridaju davanju eksplicitnog i implicitnog znanja, što je dodatno podržano kvalitetnom implementacijom svih triju kontekstualnih čimbenika dijeljenja znanja. Sukladno rezultatima istraživanja izvedeni su generalizirani zaključci o pripadnosti hrvatskih poduzeća drugoj generaciji upravljanja znanjem kao kvalitativnom kriteriju uspješnosti implementacije procesa dijeljenja znanja, te su navedene smjernice za daljnji razvoj i postupni prijelaz u treću generaciju upravljanja znanjem.

***Ključne riječi**: dijeljenje znanja, eksplicitno znanje, implicitno znanje, organizacijska kultura, informacijsko-komunikacijske tehnologije (IKT), podrška vrhovnog menadžmenta, uspješnost poslovanja, generacije upravljanja znanjem*

III. SUMMARY

Enterprises active in time of writing this thesis, operate in a dynamic environment that urges constant adjustment and improvement of organisational knowledge. For knowledge to be efficiently used it should be rationally managed, so knowledge management attracts increased attention of researchers from the 1990s. It is a complex organisational phenomenon, which cannot be defined unidimensionally, but there is a consensus upon fact that knowledge sharing represents its central main phases. Knowledge sharing is a bidirectional process including knowledge giving and receiving, with its theoretical grounds rooted in social exchange theory. However, costs of knowledge sharing are not identical regarding the type of knowledge shared so this thesis will make a difference between explicit and implicit knowledge.

Knowledge sharing depends upon certain contextual factors. This research will elaborate synergic influence of organisational culture and information and communication technologies (ICT) as knowledge sharing supporting factors, additionally strengthened by a top management support. A combination of these three factors can potentially improve efficiency of knowledge sharing that can positively influence business performance, which will be tested on a representative sample of Croatian enterprises.

Research has been conducted in two phases: online research for which purpose 1.500 questionnaires were distributed and postal research for which purpose additional 1.500 guestionnaires were distributed in envelopes with paid return. This process also enabled a comparison of the efficiency between two types of questionnaires with online version receiving 126 and postal version receiving 224 completed questionnaires in total. Research results imply that Croatian companies implement process of knowledge sharing by giving special attention to giving explicit and implicit knowledge, which is additionaly supported by qualitative implementation of all three contextual factors. According to research results, general conclusions are made suggesting Croatian companies belong to the second generation of knowledge management with further progress being possible if companies implement guidelines for ensuring contextual prerequisites needed for transfer into the third generation of knowledge management.

Key words*: knowledge sharing, explicit knowledge, implicit knowledge, organisational culture, Information-communication technologies (ICT), top management support, business results, knowledge mnanagement generations*

SADRŽAJ

1. UVOD ... 1
1.1. PROBLEM I PREDMET ISTRAŽIVANJA ... 2
1.2. HIPOTEZE RADA ... 3
1.3. SVRHA I CILJEVI ISTRAŽIVANJA ... 4
1.4. OCJENA DOSADAŠNJIH ISTRAŽIVANJA ... 5
1.5. ZNANSTVENE METODE ... 8
1.6. STRUKTURA DOKTORSKE DISERTACIJE ... 9
2. DEFINIRANJE ZNANJA I NJEGOVA UTJECAJA NA DRUŠTVENI I EKONOMSKI RAZVOJ ... 12
2.1. RAZVOJ DRUŠTVA I EKONOMIJE ZNANJA ... 12
2.2. HRVATSKA U KONTEKSTU DRUŠTVA ZNANJA ... 14
2.3. TAKSONOMIJA KONCEPTA UPRAVLJANJA ZNANJEM ... 16
2.4. TEORIJSKI PRISTUPI DEFINIRANJU POJMA ZNANJA ... 19
3. ANALITIČKI PRIKAZ DIJELJENJA ZNANJA S ASPEKTA NJEGOVA UČINKA NA USPJEŠNOST POSLOVANJA PODUZEĆA ... 24
3.1. TEORIJSKI PRISTUPI PROCESU DIJELJENJA ZNANJA ... 24
3.2. DIJELJENJE ZNANJA KAO DUALNI PROCES ... 25
3.2.1. Davanje znanja ... 26
3.2.2. Primanje znanja ... 32
3.3. KONTEKSTUALNI ČIMBENICI USPJEŠNOG DIJELJENJA ZNANJA U PODUZEĆU ... 38
3.3.1. Organizacijska kultura ... 40
3.3.1.1. Poslovna misija ... 45
3.3.1.2. Opunomoćivanje zaposlenika ... 48
3.3.1.3. Kontinuirano učenje ... 50
3.3.2. Informacijsko-komunikacijske tehnologije (IKT) ... 55
3.3.2.1. Investicije u informacijsko-komunikacijske tehnologije ... 56
3.3.2.2. Prepoznavanje poslovnih prilika ... 59
3.3.2.3. Poboljšana komunikacija ... 64
3.3.3. Podrška vrhovnog menadžmenta ... 69
3.3.3.1. Otvorenost idejama zaposlenika ... 71
3.3.3.2. Razvijanje međusobnog povjerenja ... 74
3.3.3.3. Mentoriranje zaposlenika ... 76
3.4. UTJECAJ DIJELJENJA ZNANJA NA USPJEŠNOST POSLOVANJA PODUZEĆA 78
4. METODOLOGIJA ISTRAŽIVANJA MEĐUZAVISNOSTI DIJELJENJA ZNANJA I USPJEŠNOSTI POSLOVANJA PODUZEĆA ... 86
4.1. KONCEPTUALNI MODEL ISTRAŽIVANJA UČINKA DIJELJENJA ZNANJA NA USPJEŠNOST POSLOVANJA PODUZEĆA ... 86
4.2. ODREĐIVANJE UZORKA ZA EMPIRIJSKO ISTRAŽIVANJE POVEZANOSTI DIJELJENJA ZNANJA I USPJEŠNOSTI POSLOVANJA PODUZEĆA ... 93
4.3. ISTRAŽIVAČKI INSTRUMENT I PRIKUPLJANJE PODATAKA ZA MJERENJE DOPRINOSA DIJELJENJA ZNANJA OSTVARENOM POSLOVNOM REZULTATU 96
4.4. REZULTATI ISTRAŽIVANJA DOPRINOSA DIJELJENJA ZNANJA USPJEŠNOSTI POSLOVANJA HRVATSKIH PODUZEĆA ... 99
4.4.1. Eksploratorna faktorska analiza korištenih skala u konceptualnom modelu dijeljenja znanja ... 103
4.4.1.1. Eksploratorna faktorska analiza za skalu Organizacijska kultura ... 103
4.4.1.2. Eksploratorna faktorska analiza za skalu IKT ... 104

4.4.1.3. Eksploratorna faktorska analiza za skalu Podrška vrhovnog menadžmenta 105
4.4.1.4. Eksploratorna faktorska analiza za skalu Dijeljenje znanja 107
4.4.1.5. Eksploratorna faktorska analiza za skalu Uspješnost poslovanja poduzeća 108
4.4.2. Prikaz rezultata istraživanja i njihovih implikacija na postavljene hipoteze o međuzavisnosti kontekstualnih čimbenika i dijeljenja znanja te njihovog učinka na uspješnost poslovanja 110
4.4.2.1. Rezultati ispitivanja povezanosti arhivskih i perceptivnih pokazatelja uspješnosti poslovanja poduzeća 110
4.4.2.2. Rezultati predistraživanja temeljem analize online upitnika o učinku dijeljenja znanja na uspješnost poslovanja poduzeća 114
4.4.2.3. Rezultati glavnog istraživanja temeljem analize odaslanih tiskanih upitnika o učinku dijeljenja znanja na uspješnost poslovanja poduzeća 121
4.4.2.4. Rezultati sveukupnog istraživanja temeljem objedinjenih uzoraka o učinku dijeljenja znanja na uspješnost poslovanja poduzeća 125
4.4.3. Analiza učinka prediktorskih varijabli na proces dijeljenja znanja u odnosu na potprocese davanje i primanje znanja i vrste znanja (eksplicitno i implicitno znanje) 134
4.4.4. Klaster analiza poduzeća s aspekta razvoja kontekstualnih čimbenika koji pridonose učinkovitom dijeljenju znanja 143
5. KRITIČKI OSVRT NA EMPIRIJSKO ISTRAŽIVANJE O MEĐUZAVISNOSTI DIJELJENJA ZNANJA, PODRŽAVAJUĆIH KONTEKSTUALNIH ČIMBENIKA I USPJEŠNOSTI POSLOVANJA PODUZEĆA 149
5.1. ZAKLJUČNA RAZMATRANJA O REZULTATIMA ISTRAŽIVANJA GENERIRANIM U OBJEDINJENOM ISTRAŽIVANJU TE NJIHOVE IMPLIKACIJE ZA PROCESE DIJELJENJA ZNANJA U ODNOSU NA OSTVARENJE POSLOVNOG REZULTATA 149
5.2. TEORIJSKI I PRAKTIČNI DOPRINOS ISTRAŽIVANJA KONTEKSTUALNIH ČIMBENIKA KOJI OMOGUĆUJU DIJELJENJE ZNANJA I UNAPREĐENJE POSLOVNE USPJEŠNOSTI 153
5.3. OGRANIČENJA ISTRAŽIVANJA I PRIJEDLOZI DALJNJEG ISTRAŽIVANJA MOGUĆIH UNAPREĐENJA PROCESA DIJELJENJA ZNANJA U HRVATSKIM PODUZEĆIMA 160
6. ZAKLJUČAK 163
LITERATURA 168
POPIS TABLICA 177
POPIS SLIKA 179
POPIS PRILOGA 180

EXTENDED ABSTRACT 207

1. UVOD

Istraživanje znanja i njegova značaja za uspješnost poslovanja poduzeća, pa shodno tome i mikroekonomsku strukturu nacionalne ekonomije, intenzivnije se provodi posljednjih tridesetak godina. S pojavom koncepta intelektualnog kapitala proporcionalno raste i osviještenost menadžera o potrebi usmjeravanja fokusa upravljanja poduzećem na jedini resurs čija se vrijednost daljnjim korištenjem multiplicira, a to je znanje. Krajem devedesetih godina prošlog stoljeća kontinuirano se provode znanstvena istraživanja s ciljem empirijske razrade koncepta upravljanja znanjem i njegove učinkovite implementacije. Takav pristup operacionalizaciji razvoja poduzeća dobiva sve snažniji imperativ u uvjetima ograničenih resursa, ubrzanog tehnološkog razvoja i globalizacije. U trenutku pisanja ovog rada pojavila se još jedna prepreka neometanom poslovanju u vidu pandemije Covid-19 koja je usporila poslovne procese na nacionalnoj, regionalnoj i globalnoj razini i time dala dodatni poticaj poduzećima da racionalnije upravljaju znanjem.

S obzirom na to da je znanje kompleksan proces, uzevši u obzir njegova mnogostruka obilježja, kao i činjenicu da zaposlenici kao temeljni nositelji znanja u poduzeću nemaju iste predispozicije za generiranje, prenošenje i korištenje znanja, bilo je nužno istražiti kontekstualne čimbenike koji mogu utjecati na učinkovitost samog procesa. Organizacijska kultura, koja u najvećoj mjeri odražava upravo karakteristike zaposlenika i okruženja u kojemu djeluju, u velikoj mjeri može utjecati na razvijanje pozitivnih afiniteta zaposlenika prema dijeljenju znanja. Razvijanjem zajedničkih vrijednosti i obrazaca ponašanja zaposlenici se postepeno povezuju u kompaktne cjeline koje djeluju u smjeru održivog razvoja poduzeća. Informacijsko-komunikacijski sustavi pružaju logističku podršku učinkovitom dijeljenju znanja, te u uvjetima ubrzanog tehnološkog razvoja postaju nezaobilazan segment uspješnog poslovanja poduzeća. Usprkos tome, postoje značajne razlike u učinkovitoj implementaciji IKT sustava od poduzeća do poduzeća, ne samo zbog problema vezanih za usklađenost IKT sustava s potrebama poslovnih procesa, već i zbog razine prihvaćanja novih tehnologija od strane zaposlenika. Uloga menadžera u poduzeću, te način interakcije menadžera sa zaposlenicima radikalno se promijenio posljednjih par desetljeća. Menadžeri više nisu samo nadzor, oni su prvenstveno podrška u smislu mentoriranja i usmjeravanja zaposlenika u daljnjem rastu i razvoju. Menadžeri su ključna karika koja povezuje sve ostale segmente poduzeća, u smislu ovoga rada organizacijsku kulturu i IKT sustave, te na taj način omogućuju razvijanje temeljnih preduvjeta za učinkovito dijeljenje znanja.

S obzirom na to da je na nacionalnoj razini ova problematika još uvijek u ranoj fazi razvoja u odnosu na relevantnu literaturu i provedena istraživanja, čini se opravdanim znanstveno utemeljeno istražiti kontekstualne čimbenike uspješnog dijeljenja znanja.

1.1. PROBLEM I PREDMET ISTRAŽIVANJA

Početkom devedesetih godina prošlog stoljeća, **Drucker (1999.)** naglašava važnost spoznaje o tranziciji u društvo znanja u kojemu primat u proizvodnim procesima pripada neopipljivim resursima među kojima poseban značaj pripada ljudskom znanju. Znanje je jedini resurs čija se vrijednost korištenjem ne troši, već proporcionalno raste. Stoga je bitno da menadžment na vrijeme osvijesti raspoloživost organizacijskog znanja, odnosno segment poslovanja u kojima je znanje nužno unaprijediti. S obzirom na kompleksnost znanja, odnosno njegovu eksplicitnu i implicitnu dimenziju, kao i sklonost zaposlenika kao temeljenih nositelja znanja da samovoljno sudjeluju u procesu dijeljenja znanja, znanstveno utemeljeno je istražiti načine na koje poduzeća operacionaliziraju dijeljenje znanja. Posebice je to bitno kada u okvirima nacionalnih znanstvenih i empirijskih radova ima relativno malen, premda rastući broj autora, koji se definiranoj problematici sve više posvećuju (**Vidović, 2008**.; **Milanović, 2010**.). U okviru navedene problematike moguće je definirati i problem istraživanja:

U društvu znanja raste značaj znanja i njegova dijeljenja za uspješnost poslovanja poduzeća, što je dodatno poduprto procesima globalizacije, digitalizacije i hiperkonkurencije. Slijedom rečenog, više nije dovoljno pratiti isključivo financijske pokazatelje uspješnosti poslovanja, već i nefinancijske, posebice jer oni predstavljaju neposredan ishod neopipljivih resursa. S obzirom na kompleksnost procesa dijeljenja znanja, nužno je definirati i istražiti kontekstualne čimbenike čiji razvoj potencijalno može unaprijediti učinkovitost procesa dijeljenja znanja. Konkretnije, potrebno je ispitati u prvom redu utječe li i u kojoj mjeri proces dijeljenja znanja na uspješnost poslovanja poduzeća, odnosno postoji li veza između organizacijske kulture i IKT-a s jedne strane te dijeljenja znanja s druge. Ako postoji, na koji je način potrebno operacionalizirati organizacijsku kulturu i IKT da bismo pojačali učinak dijeljenja znanja na uspješnost poslovanja poduzeća? U kojoj mjeri poticaj vrhovnog menadžmenta mijenja vezu između organizacijske kulture i IKT-a s jedne strane i dijeljenja znanja s druge? Navedene je probleme potrebno konzistentno istražiti, analizirati i na odgovarajući način riješiti jer u suprotnome oni mogu implicirati višestruke štetne posljedice za uspješnost poslovanja poduzeća.

Iz takve problematike i problema istraživanja determinira se i predmet istraživanja:
Istražiti i utvrditi relevantne kontekstualne čimbenike poslovanja, posebice organizacijsku kulturu, informacijsko-komunikacijske tehnologije i podršku vrhovnog menadžmenta u odnosu na njihov utjecaj na proces dijeljenja znanja neposredno, odnosno posredno i na uspješnost poslovanja poduzeća i to na uzorku hrvatskih velikih, srednjih i malih poduzeća.

1.2. HIPOTEZE RADA

Znanstvena hipoteza definirana je u skladu sa složenošću problema i predmeta znanstvenog istraživanja. Temeljna **znanstvena hipoteza** glasi:

Postoji pozitivna veza između organizacijske kulture i IKT-a s jedne strane te dijeljenja znanja s druge, što se manifestira na uspješnost poslovanja, dok podrška vrhovnog menadžmenta pojačava vezu između organizacijske kulture i IKT-a s jedne strane i procesa dijeljenja znanja s druge.

Tako postavljena hipoteza implicira i tri **pomoćne hipoteze** koje glase:

PH1. Organizacijsku kulturu koja podržava dijeljenje znanja odlikuje: jasna misija, kontinuirano učenje i opunomoćivanje zaposlenika.
PH2. Moguće značajke IKT-a koji podržava dijeljenje znanja jesu: kontinuirane investicije u IKT, prepoznavanje poslovnih prilika i unaprijeđena komunikacija.
PH3. Podršku vrhovnog menadžmenta dijeljenju znanja moguće je identificirati u: otvorenosti idejama podređenih, razvijanju visoke razine povjerenja i redovitom mentoriranju suradnika.

Više je argumenata koji podupiru postavljenu temeljnu hipotezu i njene pomoćne hipoteze, pri čemu se navode samo najvažniji:

- Postepena tranzicija u društvo znanja nameće potrebu usmjeravanja fokusa upravljanja poduzećem na znanje kao temeljni neopipljivi resurs koji pridonosi uspješnijem poslovanju poduzeća.
- Poduzeća moraju sistematično analizirati i strateški pristupiti planiranju operacionalizacije kontekstualnih čimbenika koji potencijalno pridonose uspješnijem poslovanju.

- Organizacijska kultura može pozitivno i negativno utjecati na stav zaposlenika prema dijeljenju znanja. Pomnim planiranjem i komunikacijom poslovne misije, opunomoćivanjem zaposlenika i pružanjem mogućnosti kontinuiranog učenja moguće je pozitivno utjecati na stav zaposlenika prema dijeljenju znanja.
- Uspješna implementacija IKT-a ovisi o usklađenosti tehnologija koje se planiraju operacionalizirati s potrebama i znanjem zaposlenika, pa je nužno da menadžment pomno planira investicije u IKT, posebice s obzirom na njihov potencijal u prepoznavanju poslovnih prilika i unapređenju komunikacije među zaposlenicima.
- Uspješnost poslovanja poduzeća neposredno je povezana s podrškom koju vrhovni menadžment osigurava zaposlenicima u realizaciji njihovih radnih zadataka. S obzirom na to da je zaposlenicima nužno potvrditi njihov značaj za uspješnost poslovanja, potrebno je kod menadžera razviti obrasce ponašanja koji će osigurati otvorenost idejama i prijedlozima zaposlenika, razvijanje međusobnog povjerenja i mentorskog odnosa prema zaposlenicima.

1.3. SVRHA I CILJEVI ISTRAŽIVANJA

U skladu s problemom i predmetom istraživanja te postavljenom znanstvenom hipotezom, determinirana je **svrha istraživanja**:

Temeljem teorijskih spoznaja o konceptima upravljanja znanjem i dijeljenja znanja objedinjenih u okviru ekonomskih znanosti istražiti učinkovitost procesa dijeljenja znanja unutar poduzeća s posebnim naglaskom na kontekstualne čimbenike sa svrhom razvijanja eksplanatornog modela za unapređenje procesa dijeljenja znanja u poduzeću.

Cilj istraživanja *je ispitati učinak dijeljenja znanja na uspješnost poslovanja poduzeća, odnosno ispitati utječu li predloženi kontekstualni čimbenici dijeljenja znanja na pojačavanje učinka dijeljenja znanja na poslovni rezultat*.

Da bi se uspješno ostvario cilj istraživanja i dokazale hipoteze rada, potrebno je pronaći odgovore na sljedeća pitanja:

- S obzirom na sve veću ulogu organizacijskog znanja kao neopipljivog resursa za uspješnost poslovanja poduzeća, koliko je jak utjecaj procesa dijeljenja znanja na poslovni rezultat?

- Na koji način i u kojoj mjeri organizacijska kultura utječe na učinkovito dijeljenje znanja?
- Koje su odrednice organizacijske kulture bitne pri njezinoj implementaciji u odnosu na njihov pozitivan učinak na dijeljenje znanja?
- Na koji način informacijsko-komunikacijske tehnologije podržavaju proces dijeljenja znanja?
- Koje su bitne odrednice IKT-a o kojima se mora voditi računa pri implementaciji novih tehnologija u svrhu učinkovitijeg dijeljenja znanja?
- Na koji način i u kojoj mjeri podrška vrhovnog menadžmenta pridonosi unapređenju učinkovitosti procesa dijeljenja znanja?
- O kojim se odrednicama podrške vrhovnog menadžmenta mora posebno voditi računa kako bi se osiguralo uspješnije dijeljenje znanja?
- Utječe li proces dijeljenja znanja na financijske pokazatelje uspješnosti poslovanja poduzeća?
- Utječe li proces dijeljenja znanja na nefinancijske pokazatelje uspješnosti poslovanja poduzeća?
- Kakve su percepcije menadžera i zaposlenika u hrvatskim velikim, srednjim i malim poduzećima prema procesu dijeljenja znanja?
- Kakve su implikacije rezultata istraživanja na oblikovanje mjera i prijedloga za unapređenje procesa dijeljenja znanja u hrvatskim velikim, srednjim i malim poduzećima?

1.4. OCJENA DOSADAŠNJIH ISTRAŽIVANJA

Suvremena poduzeća djeluju u dinamičnim uvjetima poslovanja, pa je neophodno da raspolažu znanjem koje će omogućiti prilagodbu promjenjivom poslovnom okruženju. Kao znanstvena disciplina, upravljanje znanjem razvija se od kraja 1990-ih godina prošlog stoljeća. Prema **Malhotri** (**1998.**) upravljanje znanjem je okvir djelovanja u kojem se svi poslovni procesi zasnivaju na kreiranju, dijeljenju, obnavljanju i korištenju znanja. Analizu najčešće korištenih cikličkih modela upravljanja znanjem ponudio je **Dalkir (2011.)**, pri čemu je definirao sljedeće aktivnosti procesa upravljanja znanjem: i) prikupljanje i/ili kreiranje znanja; ii) dijeljenje znanja te iii) korištenje znanja. Dijeljenje znanja dvosmjeran je proces koji se sastoji od davanja i prikupljanja znanja. Davanje znanja podrazumijeva dobrovoljno prenošenje znanja i

intelektualnog kapitala drugim zaposlenicima (**Sorakraikitikul, Siengthai, 2014**.). Prikupljanje znanja podrazumijeva dobrovoljno konzultiranje s drugim zaposlenicima, učenje od njih, te njihovo poticanje na dijeljenje znanja i intelektualnog kapitala (**Sorakraikitikul, Siengthai, 2014**.). Teorija društvene razmjene nudi teorijsko uporište izučavanja procesa dijeljenja znanja jer pojašnjava ljudsko ponašanje u društvenim razmjenama (**Chen**, **Hung**, **2010.**). Proces dijeljenja znanja počiva na pretpostavci da će zaposlenici međusobno dijeliti znanje po principu reciprociteta u uvjetima visoke razine povjerenja.

S obzirom na to da se modaliteti dijeljenja znanja razlikuju ovisno o vrsti znanja, tada će se problematika dijeljenja znanja u radu izučavati s aspekta dviju osnovnih vrsta znanja: eksplicitnog i implicitnog. **Polanyi** (**1966.**) prvi ističe razliku između eksplicitnog i implicitnog znanja, dok **Nonaka** i **Takeuchi** (**1995.**) prvi razvijaju model dijeljenja znanja – SECI (socijalizacija, eksternalizacija, kombinacija i internalizacija). Premda je SECI model u istraživačkim radovima prihvaćen kao temelj dijeljenja znanja, novi pristup analizi ovog modela ponudila je **Gatarik** (**2019.**) koja uvodi daljnju klasifikaciju eksplicitnog i implicitnog znanja, pa tako opisuje iskustveno znanje i kompetencije zaposlenika kao potkategorije implicitnog znanja, odnosno društveno znanje i eksplanatorno znanje kao potkategorije eksplicitnog znanja. Klasifikacija znanja koju je uveo **Polanyi** (**1966.**) koristit će se u radu pri operacionalizaciji varijable dijeljenje znanja, uz razmatranje nadogradnje klasičnog modela prema **Gatarik** (**2019.**).

Dijeljenje znanja moguće je operacionalizirati uz određene pretpostavke. Radovi koji su se bavili izučavanjem dijeljenja znanja navode sljedeće preduvjete: percipirana podrška rukovodstva, norme koje podržavaju dijeljenje znanja, kvaliteta međuljudskih odnosa (**Ashford** i **dr.**, **1998.**); dostupnost informacija (**Tan**, **Zhao**, **2003.**); sustav nagrađivanja i korištenje IKT-a (**Lin**, **2007.**); organizacijska klima, povjerenje (**Al-Kurdi**, **El-Haddadeh** i **Eldabi**, **2019.**). U ovoj disertaciji predlaže se uključivanje sljedećih preduvjeta u model učinkovitog dijeljenja znanja: organizacijska kultura, informacijsko-komunikacijska tehnologija (IKT) i podrška vrhovnog menadžmenta.

S obzirom na to da je organizacijska kultura kompleksan koncept, mnogi ga autori analiziraju s aspekta dviju bitnih značajki: vertikalna dimenzija (fleksibilnost nasuprot kontrole) i horizontalna dimenzija (interni nasuprot eksterni fokus djelovanja). **Oh** i **Han** (**2019.**) u tom smislu razlikuju klansku, adhokratsku, hijerarhijsku i tržišnu kulturu. Analizom značajki

organizacijske kulture koja potiče dijeljenje znanja u ovoj će se disertaciji istražiti pripada li takva kultura jednoj od navedenih četiriju vrsta organizacijske kulture ili je ona određeni hibrid među njima. **Denison** i **Mishra** (**1995.**) izučavali su povezanost organizacijske kulture i učinkovitosti poslovanja, te su naveli angažiranost zaposlenika, konzistentnost, adaptibilnost i misiju kao čimbenike utjecaja. S obzirom na to da i drugi autori, poput **Donate** i **Guadamillas** (**2011**.) naglasak stavljaju na misiju, u disertaciji će se izučavati upravo ona jer poduzeću osigurava smisao postojanja, te potiče stvaranje zajedništva. Premda je zajedništvo među zaposlenicima poželjno, dijeljenje znanja zahtijeva kreativnost i pronicljivost, što je moguće ostvariti suprotstavljanjem različitih prijedloga i ideja. Prema tome, organizacijska kultura koja potiče dijeljenje znanja treba ujedno poticati i produktivne konflikte, te omogućiti zaposlenicima da učenjem iz pogrešaka pronađu adekvatno rješenje (**Steyn**, **Kahn, 2008.**). Nadalje, **Lee** i **Kim** (**2001**.) i **Lin** (**2007.**) ističu da je kreativnost zaposlenika moguće potaknuti opunomoćivanjem. Kontinuirano učenje također je mogući izvor unapređenja kreativnosti zaposlenika, pa je među zaposlenicima nužno razvijati norme ponašanja koje ih potiču da budu otvoreni primanju i interpretiranju signala iz okruženja (**Denison**, **Mishra**, **1995.; Diakoulakis** i **dr., 2004.).** Stoga će se u ovoj disertaciji pretpostaviti da bi organizacijska kultura koja pridonosi uspješnijem dijeljenu znanja mogla imati sljedeće značajke: *jasno definirana misija, opunomoćivanje zaposlenika* te *kontinuirano učenje*.

Osnovna svrha IKT-a jest olakšavanje komunikacije među zaposlenicima. Tehnologija može racionalizirati dijeljenje znanja u smislu bržeg davanja i primanja znanja. Upravo zato nužno je pratiti razvijenost IKT-a u poduzeću, a prema dosadašnjim istraživanjima jedan od osnovnih pokazatelja razvijenosti jest visina investicija u IKT (**McCann**, **Buckner**, **2004.**). Kvalitetno razrađeni IKT sustavi trebali bi olakšati prikupljanje informacija i podataka iz internog i eksternog okruženja, te na taj način omogućiti prepoznavanje novih poslovnih prilika (**Moffet, McAdam** i **Parkinson**, **2002**.). IKT olakšava dijeljenje znanja na način da osigurava nove komunikacijske kanale (**Milanović, 2010.**; **Andreeva**, **Kianto**, **2012.**). **Sundać**, **Škalamera-Alilović** i **Babić** (**2016.**) spominju novu generaciju IKT platformi kao sustave koji okupljaju eksterne i interne, personalne i impersonalne izvore u virtualnom obliku. IKT-i prilagođeni poslovnim sustavima omogućuju bolju iskoristivost znanja kroz njegovo sažimanje, filtriranje i prezentiranje, čime se skraćuje vrijeme odlučivanja (**Steyn, Kahn, 2008.**). Temeljem provedene analize prethodnih istraživanja u ovoj će se disertaciji predložiti izučavanje: *kontinuiranog investiranja u IKT sustave; prepoznavanja poslovnih prilika te unapređivanje*

komunikacije među zaposlenicima kao mogućih značajki IKT-a koje omogućuju učinkovito dijeljenje znanja.

Tan i **Zhao** (**2003.**) definirali su podršku vrhovnog menadžmenta kao intenzitet poticanja zaposlenika na izlaganje ideja i davanja prijedloga. Otvorenost idejama podređenih podrazumijeva da menadžeri imaju odlike transformativnih rukovoditelja (**Carmeli**, **Atwater** i **Levi, 2011.**). Da bi zaposlenici bili skloni dijeljenju znanja, potrebno je da prethodno razviju određenu razinu povjerenja (**Migdadi, 2009**.; **Chen, Hung**, **2010.**). **Tan** i **Zhao** (**2003.**) izučavali su sklonost zaposlenika preuzimanju rizika kao jednu od značajki sklonosti zaposlenika učenju. Premda je preuzimanje rizika od strane zaposlenika pozitivno, u određenim je uvjetima poželjno da menadžeri precizno delegiraju poslove, potičući mentorski odnos (**Singh** i **dr., 2021.**). Slijedom navedenoga, za potrebe ove disertacije podrška vrhovnog menadžmenta razmatrat će se kroz sljedeće značajke: *otvorenost idejama podređenih; razvijanje međusobnog povjerenja i redovito mentoriranje podređenih*.

1.5. ZNANSTVENE METODE

U znanstvenom istraživanju, formuliranju i elaboriranju rezultata istraživanja ove doktorske disertacije koristit će se brojne znanstvene metode. Konceptualni dio istraživanja temelji se na sekundarnim podacima kao sinergiji znanstvenih spoznaja novije literature (pretežno znanstvenih članaka) iz područja upravljanja znanjem i dijeljenja znanja, temeljem čega se razrađuje vlastiti stav podržan brojnim argumentima temeljenim na znanstvenim spoznajama.

U teorijskom dijelu doktorske disertacije korištene su sljedeće znanstvene metode: metode analize i sinteze, metoda klasifikacije i kompilacije te deskriptivna metoda u objedinjavanju literature o procesu dijeljenja znanja i definiranju kontekstualnih čimbenika koji utječu na proces dijeljenja znanja.

Empirijsko istraživanje temelji se na prikupljanju primarnih podataka anketnim upitnikom, pri čemu se u svrhu provedbe istraživanja koristila kombinacija *online* i poštanske ankete radi usporedbe učinkovitosti ovih dviju metoda, no i radi osiguravanja dovoljno reprezentativnog uzorka. Statističke metode koje su se koristile u analizi primarnih podataka su primijenjene metode deskriptivne, bivarijatne i multivarijatne statističke analize. Deskriptivna statistička analiza koristila se za opisivanje uzorka, odnosno sociodemografskih karakteristika ispitanika.

Bivarijatnom statističkom analizom utvrdila se značajnost razlike između aritmetičkih sredina više promatranih grupa (testiranje pomoću t-testa i analize varijance – ANOVA). Multivarijatna statistička analiza provela se pomoću eksploratorne faktorske analize pomoću koje se sažeo velik broj elemenata kontekstualnih čimbenika na manji broj zajedničkih faktora koji pojašnjavaju njihovu međusobnu povezanost. Analizom pouzdanosti ocijenila se pouzdanost i dosljednost procesa dijeljenja znanja, dok se višestrukom regresijom utvrdio stupanj povezanosti kontekstualnih čimbenika i procesa dijeljenja znanja. Strukturalnim modeliranjem ispitala se međusobna povezanost kontekstualnih čimbenika i procesa dijeljenja znanja s jedne strane, odnosno procesa dijeljenja znanja i uspješnosti poslovanja poduzeća s druge. Programski paketi korišteni u svrhu statističke obrade podataka jesu SPSS, R i LISREL.

1.6. STRUKTURA DOKTORSKE DISERTACIJE

Doktorska disertacija podijeljena je u šest međusobno povezanih cjelina. U prvom dijelu, **UVODU**, postavljeni su problem i predmet istraživanja, osnovna znanstvena hipoteza i pomoćne hipoteze, svrha i ciljevi istraživanja, kratka ocjena dosadašnjih istraživanja, objašnjene su korištene znanstvene metode te obrazložena struktura rada.

U drugom dijelu, **DEFINIRANJE ZNANJA I NJEGOVA UTJECAJA NA DRUŠTVENI I EKONOMSKI RAZVOJ** analizirao se razvoj društva i ekonomije znanja s obzirom na njihovu ulogu u promicanju znanja kao temeljnog neopipljivog resursa koji dobiva sve veće značenje za uspješno poslovanje poduzeća. Potom se opisao položaj Hrvatske kao društva znanja, odnosno način na koji se strateški i operativno pristupa operacionalizaciji procesa upravljanja znanja u hrvatskim nacionalnim okvirima. Prikazala se taksonomija koncepta upravljanja znanjem, odnosno obrazložili su se teorijski pristupi razradi koncepta znanja.

Naslov treće, ujedno i središnje cjeline rada je **ANALITIČKI PRIKAZ DIJELJENJA ZNANJA S ASPEKTA NJEGOVA UČINKA NA USPJEŠNOST POSLOVANJA PODUZEĆA**. Uvodni dio ove cjeline analizirat će teorijske pristupe procesu dijeljenja znanja, odnosno pojasniti kompleksnost procesa dijeljenja znanja u odnosu na njegova dva temeljna segmenta: davanje i primanje znanja. Potom slijedi razrada kontekstualnih čimbenika uspješnog dijeljenja znanja. Organizacijska kultura razradit će se temeljem analize osnovnih odrednica kulture koja pospješuje proces dijeljenja znanja: 1) poslova misija; 2) opunomoćivanje zaposlenika i 3) kontinuirano učenje koje se analiziralo na individualnoj, timskoj i grupnoj razini. Temeljne odrednice IKT-a koji pospješuje proces dijeljenja znanja prikazale su se

pomoću sljedećih odrednica: 1) investicije u IKT; 2) prepoznavanje poslovnih prilika i 3) poboljšana komunikacija. Podrška vrhovnog menadžmenta sljedeći je kontekstualni čimbenik koji pridonosi procesu dijeljenja znanja, a čiji se učinak opisao pomoću sljedećih odrednica: 1) otvorenost idejama zaposlenika; 2) razvijanje međusobnog povjerenja te 3) mentoriranje zaposlenika. S obzirom na utjecaj dijeljenja znanja na uspješnost poslovanja poduzeća, analizirao se i mogući doprinos procesa dijeljenja znanja arhivskim i perceptivnim pokazateljima uspješnosti poslovanja.

U četvrtom dijelu naslova **METODOLOGIJA ISTRAŽIVANJA MEĐUZAVISNOSTI DIJELJENJA ZNANJA I USPJEŠNOSTI POSLOVANJA PODUZEĆA** elaborirali su se rezultati empirijskog istraživanja. Pritom se prikazao metodološki aspekt istraživanja na način da se definirao reprezentativni uzorak iz digitalne baze Hrvatske gospodarske komore (HGK) za područje cijele Hrvatske. Pitanja u upitniku oblikovala su se pomoću ordinalne mjerne ljestvice Likertova tipa s ljestvicom od 1 do 5, pri čemu jedan označava najmanje slaganje, odnosno pet najjače. Pitanja su se oblikovala na način da odražavaju percepcije menadžera i zaposlenika o operacionalizaciji procesa dijeljenja znanja, odnosno stupnju razvijenosti kontekstualnih čimbenika koji potencijalno pridonose uspješnijem dijeljenju znanja. Upitnik se odaslao na adrese 1.500 poduzeća u *online* dijelu istraživanja i 1.500 poduzeća u poštanskom dijelu istraživanja. Nakon prikupljanja odgovora, uslijedila je statistička obrada prikupljenih podataka koji su se kombinirali s arhivskim financijskim pokazateljima uspješnosti poslovanja. Anketnim upitnikom prikupljene su i demografske varijable od kojih se šest odnosilo na ispitanike, a četiri na poduzeća. Kao kontrolne varijable odabrane su veličina poduzeća i djelatnost poslovanja. Povezivanje prikupljenih podataka s arhivskim omogućilo se šifriranjem upitnika uz poštivanje načela tajnosti prikupljenih podataka prilikom njihova prikazivanja. U svrhu dokazivanja temeljne znanstvene hipoteze i pomoćnih hipoteza koristila se statistička metoda modeliranje strukturalnim jednadžbama.

Peti dio naslova **KRITIČKI OSVRT NA EMPIRIJSKO ISTRAŽIVANJE O MEĐUZAVISNOSTI DIJELJENJA ZNANJA, PODRŽAVAJUĆIH KONTEKSTUALNIH ČIMBENIKA I USPJEŠNOSTI POSLOVANJA PODUZEĆA** nudi analizu dobivenih rezultata istraživanja u odnosu na recentna znanstvena istraživanja iz područja upravljanja znanjem, odnosno dijeljenja znanja. Ponudili su se zaključci u odnosu na korelacije opisane u glavnoj i pomoćnim hipotezama, no dodatna analiza provela se i u odnosu

na središnju varijablu Dijeljenje znanja, odnosno njezine sastavnice: eksplicitno i implicitno znanje, te procese njihova dijeljenja koji obuhvaćaju davanje i primanje ovih dviju vrsta znanja.

U petom, završnom dijelu, **ZAKLJUČKU**, sustavno su se i sažeto oblikovale teorijske spoznaje iz konceptualnog dijela rada te su predstavljeni najznačajniji zaključci do kojih se došlo znanstvenim istraživanjem kojim je ujedno dokazana temeljna znanstvena hipoteza. Objasnila se također primjena rezultata istraživanja u teoriji i praksi.

2. DEFINIRANJE ZNANJA I NJEGOVA UTJECAJA NA DRUŠTVENI I EKONOMSKI RAZVOJ

S obzirom na to da je znanje najvrjedniji neopipljivi resurs kojim poduzeće s mikroperspektive, a društvo s makroperspektive raspolaže, tada se smatra učinkovitim započeti rad upravo elaboriranjem procesa kroz koje je prepoznata vrijednost znanja. U tom smislu u ovoj se cjelini pojašnjava razvoj društva i ekonomije znanja, opisuje se položaj Hrvatske s aspekta društva znanja te nudi uvid u temeljne teorijske odrednice upravljanja znanjem odnosno dijeljenja znanja.

2.1. RAZVOJ DRUŠTVA I EKONOMIJE ZNANJA

Znanje kao pojam, individualan, kolektivan i društveni fenomen sve više dobiva na značaju krajem 1990-ih godina prošlog stoljeća uslijed rasta ekonomskog jaza između Europe i njenih glavnih konkurenata, SAD-a i Japana s jedne strane, odnosno Europe i rastućih ekonomija Južne Koreje i Kine s druge strane. Iz navedenog razloga Europska komisija osmislila je u ožujku 2000. godine Lisabonsku strategiju koja je imala za cilj transformirati Europsku uniju u ekonomiju baziranu na znanju do 2010. godine (**Švarc**, **Dabić**, **2017.**). Pritom se konkurentnost EU-a trebala ostvariti kroz realizaciju sljedećih osam ciljeva (**Kesner-Škreb**, **2007**.):

1) širenje i učinkovitije korištenje informacijskih tehnologija;
2) kreiranje europskog prostora za istraživanje i inovacije;
3) dovršetak izgradnje jedinstvenog unutarnjeg tržišta EU-a;
4) stvaranje učinkovitih i integriranih financijskih tržišta;
5) jačanje poduzetništva unapređenjem regulatornog okruženja poduzeća;
6) jačanje socijalne kohezije utemeljene na promicanju zapošljavanja;
7) unapređenje vještina i modernizacija sustava socijalne zaštite te
8) održivi razvoj koji bi osigurao dugoročnu kvalitetu života.

U suštini navedenih ciljeva moguće je uočiti pomak od klasičnog industrijskog društva u kojemu je naglasak bio na trošenje sirovina, proizvodnju i trgovinu industrijskim proizvodima, na društvo u kojemu se naglasak stavlja na znanje, odnosno njegovu reprodukciju kao sržnu konkurentnu prednost koja može osigurati dugoročnu održivost i razvitak (**Liessmann**, **2008.**). Uvriježeno je mišljenje kako je znanje jedina roba čija se vrijednost trošenjem ne smanjuje, već upravo suprotno – povećava. Stoga je temeljno pitanje svih onih društava i ekonomija koje žele krenuti putem dugoročne održivosti i razvoja - na koji način ostvariti temeljne preduvjete da se

znanje prepozna, podijeli, reproducira i implementira u onim područjima djelatnosti koja mogu jamčiti razvoj. **Liessmann** (**2008.**) smatra kako će se napredne ekonomije isključivo zasnivati na onim istraživački intenzivnim tehnologijama koje predstavljaju glavni pokretač proizvodnje znanja: informacijske, genske, biotehnologije i nanotehnologije. Ne čudi stoga činjenica da sve veći broj ekonomija poduzima neophodne korake kako bi razvile političko, socijalno i društveno okruženje u kojemu će se postaviti temelji društvu znanja.

Jedna od mnogobrojnih definicija društva znanja jest da je to društveni i gospodarski poredak u visoko razvijenim zemljama (**Frank, Meyer, 2007**.). Sam koncept nije novina, pa se tako iz istog izvora može iščitati kako je koncept društva znanja koristio još 1966. godine američki sociolog Robert E. Lane, dok ga je popularizirao drugi američki sociolog – Daniel Bell 1973. godine u svojoj studiji „The Coming of Post-Industrial Society". Četiri su temeljne karakteristike društva znanja (Ibid.): 1) znanje je strateški resurs u proizvodima i uslugama; 2) znanje u budućnosti je umreženo, decentralizirano i interdisciplinarno; 3) učinkovito korištenje znanja je ključni čimbenik konkurentnosti te 4) znanje postaje tržišno dobro.

Za razliku od većine sirovina koje ulaze u proizvodni proces, znanje je dobro kojemu je vrlo teško objektivno odrediti vrijednost. Postoje određeni pokušaji da se to učini, pa će se tako, primjerice, pojedine države uspoređivati po udjelu visokoobrazovanog stanovništva u ukupnom broju stanovnika ili po visini investicija usmjerenih na istraživanje i razvoj. Pritom se nameće zaključak da su države koje ostvaruju prosječan ili ispodprosječan GDP u začetku osuđene na sporiji razvoj u odnosu na one koje po istom pokazatelju prednjače u borbi za ekonomsku nadmoć. Iako je ova premisa donekle prihvatljiva, ipak treba skrenuti pozornost da je velika uloga svake pojedine države i društva da razvije okruženje koje će biti poticajno za kreiranje i dijeljenje znanja; gdje će birokratska struktura raditi u korist, a ne protiv ekspanzije znanja; gdje će socijalna inkluzija omogućiti svim stanovnicima jednake predispozicije za obrazovanje; gdje će se poticati mladi talentirani kadrovi da ulažu svoje znanje unutar, a ne izvan nacionalnih granica te gdje će svaki pojedinac razviti misao da svojim znanjem unapređuje ne samo vlastitu dobrobit, već i dobrobit društva kao takvoga. U ovom će se radu znanje analizirati i s aspekta pojedinca i s aspekta poduzeća. Nastojat će se pritom derivirati opći zaključci i smjernice koje mogu pripomoći kvalitetnijoj i, u krajnjoj mjeri, učinkovitijoj reprodukciji i implementaciji znanja. U tom smislu potrebno je s aspekta znanja i njegove racionalne uporabe osvrnuti se i na trenutačnu situaciju u Republici Hrvatskoj.

2.2. HRVATSKA U KONTEKSTU DRUŠTVA ZNANJA

U trenutku nastajanja ovog rada, konkretnije krajem 2019. i početkom 2020. godine, globalno je okruženje doživjelo značajan udarac u smislu usporavanja općeg razvoja – pojavila se pandemija Covid-19, tek jedna u nizu „viših sila“ koja će se itekako odraziti na svjetsku ekonomiju. Ne radi se ovdje samo o zdravstvenom udarcu svjetskoj populaciji u vidu velikog broja preminulih stanovnika država diljem svijeta, već i o općem društvenom, ekonomskom i gospodarskom nazadovanju čije će se posljedice osjećati još desetljećima. I dok se među svekolikim pučanstvom i dalje vode žustre rasprave o valjanosti cjepiva kojima je javnost izložena početkom 2021. godine, nanovo se postavlja pitanje o tome do kuda seže ljudsko znanje ako se uslijed napretka farmaceutske industrije i tehnologije omogućio razvoj cjepiva u svega godinu dana, dok unazad samo pola stoljeća tako nešto nije bilo ni zamislivo? Je li razvoj društva znanja doživio takvu uzlaznu putanju da se ovakva i slična otkrića mogu sve više očekivati i u budućnosti sa sve kraćim razmacima? Možda bi neka studija u budućnosti mogla ponuditi donekle točan odgovor na ovo pitanje, no valja se osvrnuti i na konkretne čimbenike kojima pojedina ekonomija raspolaže.

Švarc (**2009.**) tvrdi kako je u hrvatskoj industriji izostala planirana revitalizacija industrijskog sektora istraživanja ukazujući pritom kako nema novih istraživačkih instituta, jedinica i središta kojima bi se obnovila devastirana industrijska istraživanja u doba tranzicije. Osim toga, dominiraju industrije niske tehnološke razine (tekstil, drvo, brodogradnja), intenzivne radom i s malom dodanom vrijednošću. Međunarodna konkurencija poduzeća (izvozna moć) jest slaba, a broj inovativnih poduzeća nezadovoljavajući u odnosu na europske zemlje. Prema statističkim pokazateljima za 2019. godinu broj ukupno zaposlenih stanovnika u Republici Hrvatskoj iznosio je 1.555.068, što čini ni 40 % ukupnog stanovništva Republike Hrvatske (**HZS**, **2020.**). Izvrši li se daljnja analiza zaposlenog stanovništva prema HZS-u za 2019. godinu, i to prema granama djelatnosti, može se zaključiti kako je najveći dio radno sposobnog stanovništva zaposlen u prerađivačkoj industriji (259.320), građevinarstvu (114.996), trgovini na veliko i malo (229.845), djelatnosti pružanja smještaja te pripreme i posluživanja hrane (115.018), dok je u znanjem intenzivnim djelatnostima, poput informacija i komunikacija, zaposleno razmjerno manje radno sposobnog stanovništva (46.159), stručnim, znanstvenim i tehničkim djelatnostima (80.149) ili pak u obrazovanju njih 116.076. Još jedan pokazatelj koji se redovito analizira pri ispitivanju potencijala eksploatacije znanja u pojedinoj zemlji jest broj visokoobrazovanih stanovnika, pa je tako prema statističkim pokazateljima broj magistara

znanosti i sveučilišnih specijalista u 2019. godini iznosio 498, dok je broj doktora znanosti iznosio 680. Potrebno se ovdje osvrnuti na činjenicu kako su dvije komponente – intelektualni kapital i kanali apsorpcije znanja i inovacija u gospodarstvu – identificirani kao kritične točke koje koče razvoj sustava kao cjeline, pa time i razvoj znanosti (**Švarc**, **2009.**). Prema **Lučinu** (**2007.**) Hrvatska bi, da bi dosegnula razinu obrazovanja potrebnu za prelazak u gospodarstvo znanja, trebala do 2025. godine povećati udio radno aktivnog stanovništva s visokom stručnom spremom na 40 %, a broj doktora znanosti na 2 %. Ako se, u tom smislu, usporedi broj doktora znanosti u 2019. godini s ukupnim brojem radno aktivnog stanovništva, da se zaključiti da se taj cilj nikako neće ostvariti do 2025. godine. Uska suradnja znanstvenog i industrijskog sektora, odnosno kapitalizacija znanja počiva na cjelovitom sustavu: pravnom, financijskom, kulturnom i institucijskom, te je u tom smislu potrebno poduzeti integrirane mjere koje će obilježiti napredak svekolikog sustava na nacionalnoj razini.

Barić i **Jeleč Raguž** (**2010.**) analizirale su potrebne pomake koje Republika Hrvatska mora poduzeti u četiri temeljna stupa društva znanja: obrazovanje, inovacijski sustav, IKT sektor i pravni i ekonomski okvir kako bi načinila prekretnicu k društvu znanja. Autorice pritom predlažu: a) povećanje ukupnih (javnih i privatnih) izdvajanja za obrazovanje kako bi se povećala prosječna obrazovanost stanovništva; b) jačanje suradnje između obrazovnih institucija, znanosti, vlade i gospodarstva kako bi se povećao transfer znanja i tehnologije; c) pojačana ulaganja u IKT sektor koji značajno zaostaje u odnosu na europski prosjek, te d) uklanjanje administrativnih barijera, posebice na mikrorazini, radi jačanja poslovnih aktivnosti i poduzetničke klime. **Švarc** (**2009.**) se nadovezuje, pa smatra da je potrebno učiniti pomake od tehnološkog i ekonomskog determinizma k poimanju tehnološkog razvoja kao primarno društvenog procesa; od standardne znanstvene politike i linearnog modela inovacija prema inovacijskoj politici i nacionalnom inovacijskom sustavu; od tradicionalnog egzogenog modela rasta prema endogenom modelu te pomak prema novoj industrijskoj politici s naglaskom na nove generičke tehnologije i prema mikroekonomskim mjerama jačanja tehnološke i inovativne sposobnosti radi povećanja nacionalnog inovacijskog kapaciteta. S obzirom na to da je riječ o uistinu inkrementalnim promjenama koje moraju uslijediti u hrvatskoj ekonomiji, nadrealno je očekivati da će se značajni pomaci učiniti u sljedećih desetak godina. No sustavnim planiranjem i razradom strateških dokumenata i smjernica mogući su postupni pomaci naprijed koji će i hrvatsku ekonomiju s vremenom učiniti ekonomijom temeljenom na znanju.

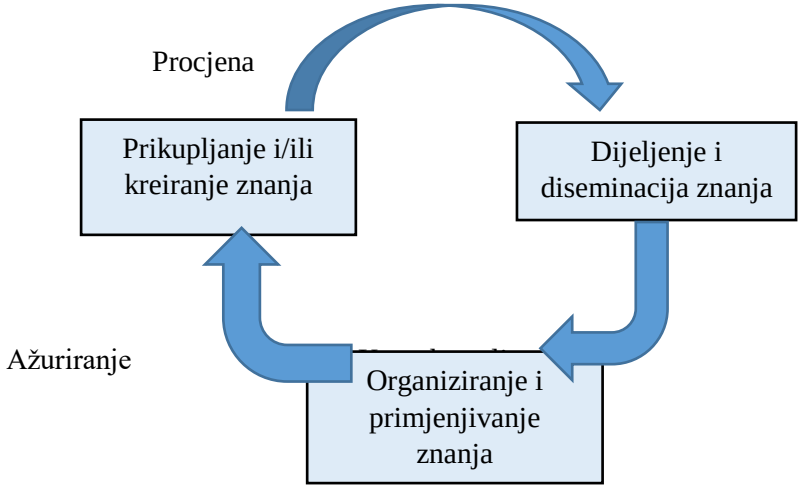
2.3. TAKSONOMIJA KONCEPTA UPRAVLJANJA ZNANJEM

S obzirom na to da se krajem 1990-ih godina prošlog stoljeća intenzivirao interes EU za kvalitetniju eksploataciju znanja uzrokovan sve većim ekonomskim jazom između EU s jedne strane, odnosno SAD-a, Japana, Južne Koreje i Kine s druge, bilo je za očekivati da će se posljedično tome pojačati i interes za upravljanje znanjem (engl. *Knowledge Management*). Premda ne postoji konsenzus oko jednoznačne definicije koncepta upravljanja znanjem, istraživači su ipak suglasni oko činjenice da je upravljanje znanjem skup praksi kojima se pomoću znanja nastoji kreirati i dodati vrijednost poslovanju (**Akbari**, **Ghaffari**, **2017.**).

U tom smislu, upravljanje znanjem može se opisati kao proces prikupljanja i organiziranja bitnih informacija kojim se potiču zaposlenici da prepoznaju relevantno znanje u poduzeću koje će se potom dijeliti s drugim zaposlenicima, implementirati te pohraniti za daljnju uporabu. Slično uporište koriste i **Sundać**, **Škalamera-Alilović** i **Babić** (**2016:139**) koji definiraju upravljanje znanjem kao: „sistematski proces traženja, selektiranja, organiziranja, sažimanja i prezentiranja informacija na način da ih zaposlenici bolje razumiju. Specifične aktivnosti u okviru upravljanja znanjem pomažu kompaniji da se usredotoči na stjecanje, čuvanje i iskorištavanje znanja za rješavanje problema, dinamičko učenje, strateško planiranje i donošenje odluka.“ Prema tome, i u ovoj je definiciji vidljivo kako je krajnji cilj upravljanja znanjem stvaranje dodane vrijednosti.

Može se stoga definiciji upravljanja znanjem pristupiti i iz perspektive strateškog menadžmenta, što su učinili **Diakoulakis** i **dr.** (**2004.**) za koje je upravljanje znanjem proces koji koristi inpute iz eksternog i internog poslovnog okruženja kako bi kreirao znanje koje će omogućiti ostvarivanje željenog poslovnog rezultata. S obzirom na to da je u većini slučajeva znanje kojim poduzeće raspolaže nestrukturirano, nužno je sustavno planirati temeljne aktivnosti koje će omogućiti njegovo racionalno upravljanje, pa je tako za **Malhotru** (**1998.**) upravljanje znanjem okvir djelovanja u kojem se svi poslovni procesi zasnivaju na kreiranju, dijeljenju, obnavljanju i korištenju znanja. Analizu najčešće korištenih cikličkih procesa upravljanja znanjem ponudio je **Dalkir** (**2011.**), pri čemu je definirao sljedeće aktivnosti: i) prikupljanje i/ili kreiranje znanja; ii) dijeljenje znanja te iii) korištenje znanja.

Slika 1. Integrirani ciklus upravljanja znanjem



Izvor: Dalkir (2011.)

Dalkir (**2011.**) je u svojem integriranom modelu upravljanja znanjem objedinio faze procesa koje su drugi autori definirali ponešto drugačije, no u suštini isto kao i ovaj autor. U nastavku se navode faze procesa upravljanja znanjem prema autorima čije je modele **Dalkir** (**2011**.) objedinio u generativni ciklički model upravljanja znanjem, kojemu je nadodao fazu ažuriranja znanja.

Tablica 1. Faze procesa upravljanja znanjem

Faze procesa upravljanja znanjem prema Dalkiru (2011.)	**Aktivnosti procesa upravljanja znanjem i izvori njihova generiranja**
Prikupljanje i/ili kreiranje znanja	Stjecanje, Obnavljanje, Pohranjivanje/Povlačenje, Distribuiranje (Meyer i Zack, 1996.); Prikupljanje, Korištenje, Učenje, Pridonošenje (Bukowitz i Williams, 2003.); Individualno i grupno učenje, Validiranje znanja, Stjecanje informacija, Provjera znanja (McElroy, 1999.); Kreiranje, Pribavljanje, Kompiliranje, Transformacija (Wiig, 1993.)
Dijeljenje i diseminacija znanja	Predstavljanje (Meyer i Zack, 1996.); Procjenjivanje (Bukowitz i Williams, 2003.); Integriranje znanja (McElroy, 1999.); Diseminiranje (Wiig, 1993.)
Organiziranje i primjenjivanje znanja	Organiziranje i održavanje znanja (Bukowitz i Williams, 2003.); Primjenjivanje znanja (Wiig, 1993.)
Ažuriranje znanja	Povlačenje znanja (Bukowitz i Williams, 2003.); Ocjenjivanje vrijednosti znanja (Wiig, 1993.)

Izvor: Prilagođeno prema Dalkir (2011.)

Autori koji su izučavali doprinos koncepta upravljanja znanjem uspješnosti poslovanja poduzeća pretežno su svoja istraživanja usmjerili na dva područja: utjecaj samog koncepta na uspješnost poslovanja i postojanje određenih kontekstualnih čimbenika koji mogu olakšati ili otežati uspješnu implementaciju samog procesa. Pri analizi utjecaja upravljanja znanja na poslovni rezultat poduzeća, **Chen** i **Mohamed** (**2008.**) su zaključili da je za unapređenje

poslovnog rezultata potrebno uložiti dodatne napore u dijeljenje i korištenje tacitnog, odnosno implicitnog znanja. Ovaj će se rad nadovezati na istraživanje **Chena** i **Mohameda** (**2008.**) u smislu stavljanja jačeg fokusa na fazu dijeljenja znanja, s razlikom da će se osim tacitnog također izučavati i eksplicitno znanje. Naime, s obzirom na to da je riječ o dvije različite vrste znanja koje se koriste u različitim okolnostima (eksplicitno znanje pretežno se koristi za rješavanje rutinskih zadataka, dok se tacitno znanje koristi kod nerutinskih zadataka), tada je poželjno zasebno izučavati aktivnosti dijeljenja eksplicitnog, odnosno implicitnog znanja što će se u koncepcijskom modelu i učiniti.

Kontekstualne čimbenike koji mogu pridonijeti odnosno ograničavati učinkovito upravljanje znanjem izučavali su **Gold, Malhotra** i **Segars** (**2001.**), te **McCann** i **Buckner** (**2004.**). **Gold Malhotra** i **Segars** (**2001.**) analizirali su proces upravljanja znanjem iz perspektive organizacijskih sposobnosti, prema kojoj svako poduzeće raspolaže stanovitom infrastrukturom znanja (tehnologija, te organizacijska struktura i kultura), te procesima upravljanja znanjem koji obuhvaćaju: i) prikupljanje, ii) organiziranje, iii) korištenje i iv) zaštitu znanja. Autori nisu eksplicitno definirali proces dijeljenja znanja, premda ga opisuju u fazi organiziranja znanja gdje navode konverziju tacitnog znanja u eksplicitno znanje. Doprinos ovog istraživanja vidljiv je u činjenici da su autori prepoznali određene infrastrukturalne čimbenike koji utječu na proces upravljanja znanjem, no ograničenje istraživanja prisutno je u činjenici da se pridaje aditivna vrijednost infrastrukturi i arhitekturi znanja, polazeći od pretpostavke da su ta dva sustava međusobno povezana. Može se pretpostaviti da je tehnologija prisutna u svakoj fazi procesa upravljanja znanjem, no može li se isto tvrditi i za organizacijsku strukturu i kulturu? U tom smislu, ovaj će rad učiniti korak dalje pa će izučavati zaseban učinak kontekstualnih čimbenika na dijeljenje znanja, te posljedično na uspješnost poslovanja poduzeća.

Osim internih kontekstualnih čimbenika čiji razvoj direktno ili indirektno utječe na uspješnost procesa upravljanja znanjem, **McCann** i **Buckner** (**2004.**) izučavali su i eksterne prepreke procesa, pa su tako definirali: i) industrijsku politiku; ii) potpuno upravljanje kvalitetom; iii) organizacijsko učenje te iv) informacijske sustave kao bitne preduvjete učinkovite implementacije procesa upravljanja znanjem. Industrijska politika može postati preprekom ako zagovara primjerice jaču zaštitu patenata u određenom tehnološkom sektoru, čime potiče poduzeća na intenzivnije korištenje znanja, pri čemu ne definira interne procese upravljanja znanjem. Potpuno upravljanje kvalitetom (engl. *Total Quality Management*) može postati preprekom u trenutku kada se prakse potpunog upravljanja kvalitetom isključivo oslanjaju na

tehnologiju pretpostavljajući time da će novi tehnološki sustavi *a priori* značiti i bolju kvaliteti sveukupnog poslovanja. Koncept potpunog upravljanja kvalitetom zahtijeva mnogo više od tehnoloških unapređenja, te se temelji na sustavnim naporima svih zaposlenika da smisleno i planski unapređuju kvalitetu svekolikog poslovanja. Stoga se ovaj koncept izravno nadovezuje i na organizacijsko učenje. Međutim, kod organizacijskog učenja pretjerano oslanjanje na meke kategorije, poput organizacijske kulture, vrijednosti i normi može otežati upravljanje znanjem kada se primjerice inzistira na prenošenju znanja osobnim kontaktom, što može predstavljati problem kada pojedinci napuste poduzeće, bilo vlastitom voljom ili voljom rukovoditelja. Informacijski sustavi postaju prepreka uspješnom upravljanju znanjem kada se informacija poistovjećuje sa znanjem. U mnoštvu informacija kojima poduzeća raspolažu, nužno je prepoznati one koje mogu pridonijeti stvaranju dodane vrijednosti za poslovanje poduzeća. U tom smislu, nije dovoljno samo sustavno organiziranje informacija, odnosno mogućnost njihovog filtriranja i prezentiranja. Ključan moment u obradi informacija je upravo njihova refleksija i kritička analiza na način da se iz njih izvuče maksimum dobiti u danom trenutku i danim okolnostima poslovanja. Kako bi poduzeće bilo u mogućnosti ukloniti navedene prepreke, bitno je da sustav upravljanja znanjem implementira kroz sljedeće korake: i) definiranje potrebnog znanja; ii) definiranje ciljeva i strategija učenja; iii) prikupljanje i kreiranje znanja: iv) dijeljenje i zadržavanje znanja, te v) korištenje znanja. Premda su autori (Gold, Malhotra i Segars, 2001.; McCann, Buckner, 2004.) definirali određene eksterne i interne prepreke učinkovitom dijeljenju znanja, oni nisu mjerili učinak svake pojedinačne prepreke na optimalno odvijanje poslovnih aktivnosti. U tom smislu, doprinos ovog rada ogleda se u činjenici da će se koncepcijskim modelom definirati ne samo čimbenici koji mogu ograničiti ili pospješiti dijeljenje znanja, već će se mjeriti i pojedinačni učinak svakog čimbenika na dijeljenje znanja izravnim, odnosno uspješnost poslovanja neizravnim putem.

2.4. TEORIJSKI PRISTUPI DEFINIRANJU POJMA ZNANJA

Znanje je kompleksan koncept, pa i njegova definicija mora biti dovoljno sveobuhvatna da pokrije sva područja individualnog i kolektivnog djelovanja koja su u izravnoj sprezi sa stjecanjem, dijeljenjem i korištenjem znanja. **Sundać** i **dr.** (**2016.**) navode da znanje obuhvaća: činjenice, informacije i vještine koje je osoba stekla iskustvom ili obrazovanjem; teorijsko ili praktično razumijevanje nekog predmeta, odnosno ukupnost svega poznatoga u nekom području; svjesnost ili poznatost stečena iskustvom te pouzdano razumijevanje nekog predmeta. **Diakoulakis** i **dr.** (**2004.**) smatraju da se znanje sastoji od istina i uvjerenja, perspektiva i

koncepata, procjena i očekivanja, te metodologija i ekspertiza. Jedna od češćih zabluda u definiranju znanja jest zanemarivanje razlika između znanja, podataka i informacija. Podatak se može opisati kao skup činjenica, mjerenja i statističkih pokazatelja; informacija je organizirani ili procesuirani podatak u realnom vremenu; znanje je informacija koja je stavljena u određeni kontekst, pa je postala relevantna i upotrebljiva (**Caldeira, 2007**.).

Jedna od najčešćih kategorizacija znanja jest ona koju je razvio **Polanyi** (**1966.**) a prema kojoj se znanje dijeli na eksplicitno i implicitno ili tacitno. S obzirom na to da se eksplicitno znanje može jednostavno prikupiti, dokumentirati, pohraniti i koristiti, za pretpostaviti je da će troškovi dijeljenja ovog znanja biti niži (**Oztekin** i **dr**., **2015**.). Suprotno tome, značajan dio organizacijskog znanja pohranjen je u umovima zaposlenika, pa je njegovo dijeljenje prvenstveno uvjetovano osobnim kontaktom. Međutim, nisu svi zaposlenici podjednako sposobni artikulirati tacitno znanje. Primjerice, **Haldin-Herrgard** (**2000.**), navodi kako zaposlenici koji posjeduju veći opseg iskustva i znanja razvijaju višu razinu implicitnosti znanja, što im dodatno otežava jednostavnu artikulaciju znanja. Prilikom dijeljenja tacitnog znanja moguće je koristiti različite metode, od konvencionalnih poput naukovanja, mentorstva, akcijskog učenja ili korištenja mapa znanja[1] do nešto naprednijih poput umrežavanja i video konferencija (**Davenport, Prusak**, **1998.**). **Nonaka** i **Takeuchi** (**1995.**) definirali su dvije dimenzije tacitnog znanja: kognitivnu i tehničku. Kognitivna obuhvaća vjerovanja, ideje, paradigme, vrijednosti, intuiciju i mentalne modele, dok tehnička dimenzija obuhvaća specifične, neformalne vještine koje se u većini slučajeva poistovjećuju s tacitnim znanjem. Indirektno povezani s ovim vrstama znanja jesu i koncepti eksploatacije i pretraživanja znanja koje je detaljnije opisao **March** (**1991.**). Prema ovom autoru, eksploatacija se odnosi na korištenje znanja generiranog iz prošlih iskustava, pa ona u sebi sadrži nisku razinu noviteta, dok pretraživanje znanja podrazumijeva učenje temeljem novih iskustava. Ove dvije vrste otkrivanja znanja nisu međusobno isključive, već se u većini slučajeva kombiniraju. Pretraživanje znanja dovodi se još i u vezu sa znanjem u nastajanju (engl. *emergent knowledge*), a koje se pak odnosi na znanje kojim nijedan zaposlenik prethodno nije raspolagao, a koje je potaknuto međusobnim raspravama među zaposlenicima. Ovo je znanje, prema **Argote** (**2013.**) posebno korisno u situacijama koje zahtijevaju od zaposlenika visoku razinu kreativnosti i inovativnosti. Oluja mozgova (engl. *brainstorming*) uobičajena je tehnika koja se koristi kod generiranja izranjajućeg znanja, a koja se temelji na nekoliko pretpostavki: poticanje članova

[1] Sveobuhvatan prikaz vrsta znanja i ekspertiza koje postoje u poduzeću, kao i mjesta na kojima su pohranjene.

grupe da iznesu čim veći broj prijedloga; zabrana kritiziranja tuđih ideja te poticanje zaposlenika da nadograđuju postojeće ideje kako bi se osmislile nove.

Vrlo često spominje se i podjela znanja na deklarativno i proceduralno. Deklarativno znanje ili „znati što“ odnosi se na činjenične informacije, dok proceduralno znanje ili „znati kako“ obuhvaća procese koji podupiru deklarativno znanje (**Leach** i **dr**., **2003.**). **Zack** (**1999.**) nadalje navodi kauzalno znanje ili „znati zašto“ (znanje o načelima i zakonitostima po kojima djeluju priroda, društvo i ljudski um); kondicionalno ili „znati kada“, te relacijsko ili „znati tko/što s kim/čim“. **Khamseh** i **Jolly** (**2008.**) još razlikuju sržno i periferno znanje u odnosu na njihov doprinos učinkovitosti izvršavanja radnih zadataka. Tako će, primjerice, korištenje prednosti koje nude tehnologije e-učenja u visokoškolskom obrazovanju omogućiti stjecanje konkurentskih prednosti u odnosu na institucije koje ne nude tu uslugu.

Tablica 2. Kategorizacija znanja u odnosu na izvore generiranja

Izvor	**Vrste znanja i njihov opis**
Polanyi (1966.)	Eksplicitno (kodificirano) znanje: dokumentirano znanje koje se lako prenosi; Implicitno (tacitno) znanje: znanje svojstveno pojedincima, prenosi se osobnim kontaktom
Zack (1999.)	Kauzalno znanje (znati zašto); Kondicionalno znanje (znati kada); Relacijsko znanje (znati tko/što s kim/čim)
Leach i dr. (2003.)	Deklarativno znanje (znati što); Proceduralno znanje (znati kako)
Khamseh i Jolly (2008.)	Sržno znanje – znanje imanentno pojedincu/organizaciji; Periferno znanje – znanje koje se koristi u svakodnevnom poslovanju
Argote (2013.)	Izranjajuće (engl. *emergent*) znanje – znanje koje se razvija interakcijom zaposlenika, te je novo zaposlenicima

Izvor: pripremila doktorandica.

Dok je **Polanyi** (**1966.**) definirao dvije najčešće primjenjivane kategorije znanja prihvaćene među ostalim istraživačima, **Nonaka** i **Takeuchi** (**1995.**) su razvili jedan od najčešće korištenih modela dijeljenja znanja – SECI model (socijalizacija – eksternalizacija – kombinacija – internalizacija). Socijalizacija ili transformacija tacitnog znanja u tacitno obuhvaća dijeljenje iskustava u obliku mentalnih modela i tehničkih vještina. Jedan od najčešće korištenih mehanizama socijalizacije jesu društvene mreže koje se učestalo koriste kod poduzeća koja dijele praktična iskustva i znanja sa svojim partnerima (**Bolisani**, **Scarso**, **1999.**). Eksternalizacija, odnosno transformacija tacitnog znanja u eksplicitno obično se provodi kada je nužno pojednostaviti pohranjivanje i povlačenje znanja. Pritom se eksternalizira izvoran sadržaj jer se tacitno znanje ne može kodificirati izravno. Kombinacija se odnosi na pretvaranje

eksplicitnog znanja u tacitno. Kao primjer može se navesti korištenje određene tehnološke opreme u nove svrhe. Pretvaranje eksplicitnog znanja u novo eksplicitno znanje poznato je još kao internalizacija, te se može manifestirati kao definiranje nove formule, procedure ili softvera iz postojećeg programa. Tržišni i institucijski pritisci, poput potrebe certificiranja sustava kvalitete, uobičajeni su razlozi za primjenu ove vrste transformacije znanja.

Premda je SECI model jedan od najčešće primjenjivanih modela dijeljenja znanja, radom će se skrenuti pozornost i na novi pristup analizi SECI modela kojeg je ponudila autorica **Gatarik (2019**.), a koja je svoj model opisala kao proces „jezik-informacija-realnost" (engl. *Language – Information – Reality*). Ovaj se model epistemiološki nadovezuje na istraživanja koja se bave racionalizacijom procesa odlučivanja. Model se temelji na ideji da zaposlenici i menadžeri pri odlučivanju raspolažu određenim kvantumom znanja koje se može kategorizirati na iskustveno i kulturološko znanje odnosno predznanje koji zajedno čine temeljno ili engl. *common sense* znanje, dok pravila i vještine s jedne strane, odnosno eksplanatorno ili meta-znanje s druge strane, čine apstraktno znanje. Kombinacijom navedenih četiriju vrsta znanja omogućeno je odlučivanje, pri čemu neće svaka kombinacija znanja osigurati jednako kvalitetnu odluku. Tako će se primjerice kombiniranjem slabog kulturološkog predznanja s pravilima razviti rješenja koja su prihvatljiva u realizaciji svakodnevnih zadataka, međutim koja nisu optimalna u odnosu na iskustveno znanje rukovodećih kadrova. Da bi se osigurala optimizacija odlučivanja nužno je potaknuti intenzivnije dijeljenje znanja od iskustvenog znanja rukovoditelja prema kulturološkom predznanju zaposlenika jer se jedino na taj način može ostvariti pozitivan ishod dijeljenja znanja. Premda će se u koncepcijskom modelu koristiti SECI model dijeljenja znanja **Nonake** i **Takeuchia** (**1995.**), razmotrit će se i noviji pristup sveopće prihvaćenom modelu od strane autorice **Gatarik** (**2019.**), a radi moguće usporedbe pristupa.

U prethodnim su cjelinama opisane različite vrste znanja, kao i različiti modeli upravljanja znanjem. Zajedničko svim navedenim modelima jest faza dijeljenja znanja za koju se pretpostavlja da, ako se učinkovito implementira, može imati dugoročno pozitivne ishode na uspješnost poslovanja. Značaj dijeljenja znanja, među ostalima, ističu i **Al-Kurdi** i **dr.** (**2019.**) koji tvrde kako mnoga istraživanja u komercijalnom i javnom sektoru opisuju dijeljenje znanja kao ključan čimbenik procesa i strategija upravljanja znanjem. Kontinuirano učenje i dijeljenje znanja unutar i između poduzeća postaju ključan strateški preduvjet razvoja i održive konkurentnosti prema **Oztekin** i **dr.** (**2015.**). Imajući u vidu ove argumente, dijeljenju znanja

pridalo se središnje mjesto u koncepcijskom modelu dijeljenja znanja, a sam se proces detaljnije opisuje u nastavku rada.

3. ANALITIČKI PRIKAZ DIJELJENJA ZNANJA S ASPEKTA NJEGOVA UČINKA NA USPJEŠNOST POSLOVANJA PODUZEĆA

Temeljna premisa ovoga rada jest da je znanje jedinstveni, neopipljivi resurs čija se vrijednost trošenjem povećava. Da bi se shvatila poanta navedene premise, nužno je doprijeti do same srži koncepta, što se u ovome dijelu i čini. Pritom se nude pojašnjenja teorijskih pristupa procesu dijeljenja znanja, pojašnjava se dualnost procesa dijeljenja znanja, opisuju modaliteti davanja i primanja znanja, te se posebna pažnja posvećuje razradi kontekstualnih čimbenika neophodnih za uspješno dijeljenje znanja: organizacijska kultura, IKT sustavi i podrška vrhovnog menadžmenta. Na kraju cjeline dodatno se pojašnjavaju načini mjerenja uspješnosti poslovanja poduzeća.

3.1. TEORIJSKI PRISTUPI PROCESU DIJELJENJA ZNANJA

Dijeljenje znanja dualan je proces koji se sastoji od dvije temeljne aktivnosti: davanja znanja i primanja znanja. S tog aspekta potrebno ga je izučavati sa stajališta osobe koja ustupa svoje znanje (davanje), odnosno s aspekta osobe ili osoba koje primaju znanje, te ga koriste unutar specifičnog konteksta (primanje). Ovakav opis koncepta daje naslutiti da je riječ o društvenom fenomenu koji uvelike ovisi i o psihičkim osobinama sudionika procesa. Teorija društvene razmjene (engl. *Social Exchange Theory*) nudi stoga teorijsko uporište izučavanja samog procesa, jer pojašnjava ljudsko ponašanje u društvenim razmjenama koje se razlikuju od ekonomskih po tome što obveze sudionika nisu jasno definirane (**Chen**, **Hung**, **2010.**).

Sudionici društvenih razmjena čine si međusobne usluge poštujući pritom principe reciprociteta i međusobnog povjerenja. Premda je kod određenog broja pojedinaca uvijek prisutno odvagivanje vlastite koristi prilikom donošenja odluke o tome hoće li određeno znanje ustupiti drugima ili ga zadržati za sebe povećavajući time provizorno vlastitu moć, pretpostavka je ove teorije da će većina zaposlenika ipak svojevoljno sudjelovati u razmjeni znanja. Logično je za očekivati da će svi zaposlenici protekom vremena doći u situaciju da od osobe kojoj su ustupili svoje znanje u budućnosti očekuju da će to znanje i uzvratiti. Time se poštuje načelo reciprociteta, a ono je indirektno povezano i s postojanjem visoke razine povjerenja, za koju se pretpostavlja da je i sastavni dio konceptualnog modela dijeljenja znanja.

Istražujući čimbenike koji utječu na dijeljenje znanja, **Liang** i **dr.** (**2008**.) definirali su skupinu individualnih čimbenika (odanost organizaciji, očekivana korist od radnog mjesta), čimbenike interakcije (društvene interakcije i međusobno povjerenje), te organizacijske čimbenike

(organizacijska podrška, odnosno podrška nadređenih i sustav nagrađivanja) kao čimbenike od utjecaja na učinkovitost dijeljenja znanja. Među navedenim su čimbenicima posebno slabo istraženi odanost zaposlenika i organizacijska podrška. **Cropanzano** i **Mitchell** (**2005.**) pridružili su ovim čimbenicima još i razvijanje međusobne podrške između zaposlenika, razvijanje podrške od strane nadređenih i međusobno povjerenje kao posebno značajne za učinkovito dijeljenje znanja.

Osim teorije društvene razmjene, analizi koncepata upravljanje znanjem i dijeljenje znanja često se pristupa i s aspekta teorije razložne akcije (engl. *Theory of reasoned action*). Prema ovoj teoriji, koju su 1975. godine razvili **Fishbein** i **Ajzen** (**1977.**), ponašanje pojedinaca predodređeno je sa dva bitna čimbenika: namjerom da se ostvare određene radnje i subjektivnim normama naspram određenog ponašanja. Namjera pojedinca da se ponaša na određeni način ovisi o razini povoljne ili nepovoljne procjene tog istog ponašanja. Subjektivna norma odnosi se pak na društveni pritisak da se osoba ponaša na društveno prihvatljiv način (**Becker, Steele**, **1995**.). U sklopu teorije razložne akcije izučavaju se spremnost i odlučnost zaposlenika da svojevoljno razmjenjuju znanje. Dalo bi se stoga zaključiti da ovakav pristup veći naglasak daje psihološkim osobinama sudionika procesa dijeljenja znanja, dok se samom kontekstu ne pridaje veća pažnja. S druge strane, teorija društvene razmjene upravo stavlja naglasak na okruženje u kojemu se sama razmjena odvija, pa se tako spominju podrška drugih zaposlenika i nadređenih, međusobno povjerenje i sustav nagrađivanja, što sve predstavlja kontekstualno okruženje koje je sastavni dio konceptualnog modela. Polazeći dakle od istaknutih činjenica, teorija društvene razmjene prikladnija je u pojašnjavanju procesa dijeljenja znanja na način na koji se proces analizira u ovom radu.

3.2. DIJELJENJE ZNANJA KAO DUALNI PROCES

Dijeljenje znanja dualan je proces koji se sastoji od davanja i primanja znanja (**Sorakraikitikul**, **Siengthai**, **2014.**). Davanje znanja pritom se odnosi na dobrovoljno prenošenje znanja i intelektualnog kapitala drugima, dok prikupljanje znanja podrazumijeva dobrovoljno konzultiranje s drugim zaposlenicima, učenje od njih, te njihovo poticanje na dijeljenje znanja i intelektualnog kapitala. Prije je u radu spomenuto kako se tijekom razvoja koncepta upravljanja znanja proces dijeljenja znanja različito imenovao, te se uglavnom izučavao kao istovjetan ostalim fazama procesa upravljanja znanjem (**Gold, Malhotra** i **Segars, 2001**.; **McCann, Buckner**, **2004.**). Naknadno su autori poput **Van den Hooffa** i **de Leeuw van Weenan** (**2004.**), **Sorakraikitikula** i **Siengthaia** (**2014.**) i **Dysvika** i **dr.** (**2015.**) detaljnije

izučavali fazu dijeljenja znanja, te su joj postupno pridavali središnje mjesto u upravljanju znanjem. Međutim, dijeljenje znanja također je bitno izučavati i s aspekta podjele temeljnih dviju vrsta znanja, eksplicitnog i implicitnog, što većina autora nije činila, a što će se u radu učiniti.

U nastavku rada detaljnije se opisuju aktivnosti davanja i primanja eksplicitnog i implicitnog znanja, odnosno ukazuje se na potrebu zadovoljavanja određenih pretpostavki koje će pospješiti davanje, odnosno primanje znanja. Dijeljenje znanja središnja je komponenta konceptualnog modela te joj se stoga pridaje posebna pažnja. Kako je riječ o konceptualnom modelu temeljem kojeg se provelo empirijsko istraživanje, zaključno se nastojalo izvući opće smjernice i prijedloge koji mogu pomoći poduzećima da unaprijede kontekstualne čimbenike koji potencijalno pridonose učinkovitijem dijeljenju znanja izravno, a potencijalno neizravno i uspješnosti poslovanja poduzeća.

3.2.1. Davanje znanja

Dijeljenje znanja kao središnja komponenta konceptualnog modela obuhvaća procese davanja i primanja znanja. S obzirom na to da se u modelu čini krucijalna razlika između eksplicitnog i implicitnog znanja, tada se u ovome dijelu rada i navode primjeri aktivnosti koje zaposlenici primjenjuju prilikom davanja obiju vrsti znanja. Bez učinkovitog davanja znanja ne mogu se ostvariti temeljne pretpostavke za učinkovito primanje znanja, odnosno stavljanje primljenog znanja u kontekst. Slijedom navedenoga, iznose se zaključci recentnijih istraživanja iz područja davanja znanja temeljem kojih su definirane čestice davanja eksplicitnog i implicitnog znanja u anketnom upitniku.

Sorakraikitikul i **Siengthai** (**2014.**) definirali su davanje znanja kao dobrovoljno prenošenje znanja i intelektualnog kapitala drugim zaposlenicima. Dok znanje predstavlja vjerovanja i stavove pojedinaca koji se zasnivaju na smisleno organiziranom skupu informacija do kojih se dolazi iskustvom, komunikacijom i/ili zaključivanjem (**Zack**, **1999**.); intelektualni kapital definira se kao skrivena imovina poduzeća te predstavlja sveukupna tacitna i eksplicitna znanja koja postoje unutar poduzeća i koja se mogu koristiti za stvaranje konkurentskih prednosti (**Sundać** i **dr**., **2016**.). Prema **Linu** (**2007.**) svrha je samog procesa davanja znanja njegova transformacija iz individualnog u grupno i organizacijsko, čime se povećavaju zalihe dostupnog znanja u poduzeću. Primjerice, u anketnom upitniku korištene su čestice koje opisuju transformaciju individualnog znanja u grupno, odnosno organizacijsko na način da se ispitanike

propituje o njihovoj spremnosti da redovito pripremaju izvještaje o svojim postignućima, poput znanja, vještina i iskustava, a koji mogu poslužiti kao baza za učenje manje iskusnim zaposlenicima.

Prije no što se krenu izučavati sami modaliteti davanja znanja unutar poduzeća, svakako je korisno ispitati koje preduvjete valja razviti kako bi sam proces bio čim uspješniji. **Van Wijk** i **dr.** (**2008.**) analizirali su 75 studija učinkovitog prenošenja znanja temeljem kojih su definirali četiri organizacijske karakteristike koje mogu pospješiti sam proces: veličina poduzeća, starost poduzeća, stupanj decentraliziranosti strukture i apsorpcijski kapacitet. Zaključci istraživanja u pogledu veličine, starosti i decentralizacije uglavnom su kontradiktorni, međutim, postoji određeni konsenzus među istraživačima u pogledu apsorpcijskog kapaciteta. Naime, ovaj čimbenik značajno olakšava davanje znanja unutar poduzeća, odnosno između njih. Od ostalih čimbenika značajnih za učinkovito davanje znanja, autori još navode i intenzitet odnosa među zaposlenicima (pozitivni odnosi unapređuju davanje znanja); međusobno povjerenje među zaposlenicima te prisutnost i razumijevanje zajedničke vizije, odnosno normi koje promiču međusobno razumijevanje i uvažavanje. Osim organizacijskih karakteristika kao čimbenika koji mogu pridonijeti uspješnijem davanju znanja, potrebno je također analizirati i izvore generiranja znanja koje će se davati. Tako su npr. **Grigoriou** i **Rothaermel** (**2017.**) ispitivali na uzorku globalnih farmaceutskih poduzeća načine odabira između internih i eksternih izvora znanja prilikom susretanja s novom tehnološkom paradigmom. Učinkovitost oslanjanja na eksterne izvore znanja ovisi o značajkama internog razvijanja znanja. Autori su istraživanje bazirali na teoriji društvenih mreža te su zaključili da, ako poduzeće posjeduje mrežu znanja koja ima značajke klastera, utoliko poduzeće ima formirane velike timove koje sačinjavaju zaposlenici s različitim vrstama znanja. Na taj se način povećava mogućnost rekombiniranja znanja. U takvim su okolnostima strategije eksternog prikupljanja znanja manje učinkovite od internog generiranja novog znanja, budući da ga zaposlenici sami uspješno generiraju i predaju dalje. Jedan od najznačajnijih troškova eksternog prikupljanja znanja jest trošak koordinacije, s obzirom na to da poduzeća moraju pronalaziti partnere, s njima komunicirati, aktivno prenositi svoja saznanja, nadgledati napredak u suradnji, činiti potrebne prilagodbe itd. Prema tome, ako poduzeće već ima visoke troškove internog generiranja i davanja znanja, tada se eksterni trošak koordinacije dodatno povećava, pa je poduzeću isplativije samostalno rekombinirati i prenositi znanje. Anketnim upitnikom ispituje se mogućnost internog generiranja znanja kroz česticu kojom se mjeri spremnost zaposlenika da pohranjuju svoja znanja i iskustva, a što je posebno korisno kod poduzeća koja posluju na način da objedinjuju rad većeg broja timova.

Kontinuirano ažuriranje znanja u bazama znanja omogućuje rekombinaciju znanja unutar poduzeća, odnosno smanjuje potrebu pronalaženja eksternih izvora znanja.

Dok se eksplicitno znanje unutar poduzeća prenosi u većini slučajeva pomoću informacijsko-komunikacijske tehnologije, tacitna znanja moguće je prenijeti isključivo osobnim kontaktom zaposlenika. **Lecuona** i **Reitzig** (**2014**.) ispitivali su na uzorku 4.070 meksičkih poduzeća isplativost držanja viška radnika koji posjeduju specifična, tacitna znanja u smislu njihove sposobnosti daljnjeg prenošenja tacitnog znanja kolegama. Autori su empirijskim istraživanjem prikupljali podatke za period od 1991. do 2006. godina na uzorku od ukupno 5.451 tvornice, odnosno konačnom uzorku od 4.070 poduzeća nakon uklanjanja nepotpunih i neispravnih promatranja, usporedivši njihovo poslovanje s 2001. godinom koja je bila presudna s obzirom na promjene koje su nastupile na tržištu. Vrijednost viška zaposlenika povećava se u slučaju kada se poduzeća suoče s konkurentskim pritiscima, odnosno smanjuje u okolnostima stabilnog poslovanja. Zadržavanje viška radnika koji posjeduju većinom kodificirana znanja, neovisno o tome jesu li ta znanja općenita ili specifična, ne ostvaruje značajniju korist za poduzeće. Višak radne snage ostvaruje koristi za poduzeća kada ta radna snaga omogući poduzeću brzu prilagodbu neanticipiranim događajima koji mogu predstavljati skupe prijetnje ili izgubljene prilike, no u svakom slučaju poduzeća odluke o zadržavanju viška radne snage moraju temeljiti na procjeni nadilazi li korist njihova držanja trošak.

S obzirom na specifičnost prenošenja tacitnog znanja, no i njegov značaj za kreiranje dodane vrijednosti, sve veći broj istraživača bavi se upravo ispitivanjem modaliteta uspješnog prenošenja ove vrste znanja. **Joia** i **Lemos** (**2010.**) ispitivali su na uzorku od 139 zaposlenika odjela marketinga i prodaje brazilske naftne kompanije relevantne čimbenike za učinkovito davanje znanja. Zaključili su da je bitno da davatelj i primatelj znanja imaju dobro razrađen zajednički jezik u smislu terminologije i žargona te da među njima ne smije doći do značajnijeg prekida u komunikaciji. Osim toga, s aspekta redovitog cirkuliranja radne snage u smislu odljeva određenog broja zaposlenika i zapošljavanja novih, poduzeća se također susreću s problemima nesigurnosti i dvoznačnosti kod davanja znanja. Nesigurnost poduzeća reduciraju na način da uvode periodične izvještaje, pravila, operativne standarde, procedure i detaljnu obradu prikupljenih podataka, dok se dvoznačnost u davanju znanja reducira na način da se zaposlenike dodatno stimulira da sudjeluju u diskusijama, razmjeni subjektivnih stavova i mišljenja kako bi se konsenzusom došlo do rješenja. Jedan od načina uklanjanja prepreka učinkovitom davanju znanja jest organiziranje stručno vođenih edukacija unutar poduzeća

kojima će se zaposlenike dodatno podučiti načinima davanja znanja. U tom smislu, uvedena je čestica u anketnom upitniku kojom se mjeri upravo ovaj proces davanja znanja.

Problem davanja tacitnog znanja može doći do izražaja i u situacijama kada stariji, u većini slučajeva stručniji kadrovi, prenose znanje mlađim, neiskusnijim kolegama jer dolazi do problema u komunikaciji uslijed korištenja terminologije koja nije bliska novozaposlenim kadrovima ili kadrovima koji su promijenili radno mjesto unutar istog poduzeća. **Ackerman** i **dr.** (**2003**.) proveli su eksperiment s inženjerima elektrotehnike ne bi li provjerili koliko jasno i razumljivo iskusniji inženjeri prenose znanje tek zaposlenima. Zaključili su da inženjeri s više iskustva i duljim radnim stažem slabije prenose znanje jer koriste suviše naprednu terminologiju koja nije razumljiva mlađim kolegama. Nakon što su sugerirali iskusnijim inženjerima da pojednostave upute i terminologiju kojom su pojašnjavali postupke elektrifikacije pojedinih objekata, mlađi su inženjeri lakše i učinkovitije prihvaćali prenesena znanja. U cijelom postupku davanja znanja potrebno je, međutim, voditi računa i o kontekstu, jer se sadržaj znanja koje se prenosi adaptira promijenjenim okolnostima provedbe pojedinih projekata. Slijedom navedenog razvio se koncept „nije razvijeno ovdje“ (engl. *not invented here*), koji upravo ukazuje na važnost percipiranja kontekstualnih čimbenika koji zahtijevaju nužne prilagodbe davanja znanja.

Osim spomenutih preduvjeta učinkovitog davanja znanja, još jedan bitan čimbenik utječe na to koliko će se uspješno davati tj. prenositi znanje od jednog organizacijskog segmenta k drugome, a to su organizacijske granice. Temeljem uzorka od 276 djelatnika zaposlenih u 16 laboratorija odjela za istraživanje i razvoj međunarodnog tehnološkog poduzeća **Tortoriello** i **dr.** (**2012**.) ispitivali su kako jačina mreže, njezina kohezija i doseg utječu na davanje znanja od jednog odjela k drugome. Jačina međuljudskih odnosa utječe na predanost i trud zaposlenika koje oni ulažu u učinkovito davanje znanja. Zaposlenici koji pri izvršavanju svakodnevnih zadataka komuniciraju sa širim krugom suradnika ujedno razvijaju i veće kapacitete za davanje znanja. Ako snažne veze među zaposlenicima pridonose većem intenzitetu prenošenja znanja među odjelima, posljedično se može očekivati i heterogenost u davanju znanja i izvan organizacijskih granica. Prema tome, može se zaključiti da sva tri organizacijska atributa: jačina mreže zaposlenika, njezina kohezija i doseg, pozitivno utječu na davanje znanja. Ova je konstatacija dodatno ispitana u anketnom upitniku česticom kojom se mjeri davanje implicitnog znanja na način da se ispitanike pitalo prenose li rado svoja iskustva manje iskusnim kolegama suradnjom u timovima i neformalnim sastancima, odnosno kroz osobne kontakte.

Jedna od najčešće prisutnih prepreka uspješnog davanja znanja jest namjerno skrivanje znanja od strane zaposlenika. Kombinirajući dvije skupine ispitanika (studenti i zaposleni), **Babič** i **dr.** (**2019.**) pokušali su definirati uvjete koji potiču pojedince da namjerno uskrate svoje znanje kolegama. Skrivanje znanja uobičajeno se manifestira na tri načina: i) pretvaranjem zaposlenika da ne posjeduju relevantne informacije; ii) namjerno prikrivanje, odnosno davanje privida dijeljenja informacija, premda pojedinci to nemaju namjeru učiniti te iii) racionalizirano prikrivanje, pri čemu pojedinci navode konkretne razloge zašto ne žele dijeliti informacije. Istraživanje je pokazalo da zaposlenici u većini slučajeva znanje skrivaju od onih suradnika s kojima nisu u izravnom doticaju (primjerice rade u drugačijim timovima ili odjelima). Iz navedenog je razloga presudna uloga rukovodećih kadrova koji moraju stvoriti ozračje u kojemu će se cijeniti i nagrađivati davanje znanja. Ako rukovoditelji svojim ponašanjem pružaju primjer zaposlenicima da je davanje znanja poželjno, pa čak i stimulativno u smislu davanja prigodnih nagrada, tada će se i među zaposlenicima razviti kultura davanja znanja. Kako bi se vrednovao doprinos rukovoditelja davanju znanja, anketni upitnik sadrži česticu kojom se ispituje u kojoj mjeri zaposlenici slobodno iznose ideje i stavove na sastancima s nadređenima.

S druge strane, poduzeća su u pojedinim situacijama primorana razmotriti učinkovite mehanizme zaštite znanja, kao što je to primjerice u slučaju suradnje s drugim poduzećima na implementaciji određenih projekata. **Rouyre** i **Fernandez** (**2019.**) izučavali su načine zaštite znanja od strane poduzeća koja su surađivala u izradi satelitskog sustava pozicioniranja nazvanog *Galileo*. U izradi ovog sustava bilo je neophodno uspostaviti usku suradnju triju organizacija: europske multinacionalne tehnološke i svemirske korporacije (OHB), poduzeća koje se bavi razvojem satelitskih sustava (Thales Alenia Space) i poduzeća koje izučava tehnologije za razvoj satelitskih sustava (Airbus Defence and Space). Neformalni mehanizmi suradnje među navedenim organizacijama nisu polučili rezultate, pa je bilo nužno uspostaviti centraliziranu projektnu strukturu i formalne načine davanja znanja kako bi se zaštitilo sve partnere od neželjenog curenja znanja. Formalni mehanizmi zaštite znanja obuhvaćaju zaštitu intelektualnog vlasništva kroz licence, patente i poticaje za dijeljenje i zaštitu znanja u projektima koji se bave inovacijama. Formalna zaštita znanja može potaknuti još intenzivnije dijeljenje znanja koje može pridonijeti bržem razvoju inovacija. Neformalni oblici zaštite znanja obuhvaćaju povjerenje, te relacijske i individualne sposobnosti uklanjanja prepreka učinkovitom davanju znanja. S obzirom na to da neformalni oblici davanja znanja nisu imali

pozitivnog odjeka među partnerima uključenim u razvoj satelitskog sustava *Galileo,* pribjeglo se osnivanju centralizirane strukture koja je omogućila višu razinu povjerenja među partnerima i njihovo intenzivnije sudjelovanje u davanju znanja.

Dijeljenje znanja općenito, odnosno davanje i primanje znanja konkretnije, posebno su zanimljivo područje istraživanja u području visokog obrazovanja. **Gururajan** i **Fink** (**2010.**) ispitivali su stavove akademskog osoblja tehnološkog sveučilišta o dijeljenju znanja, pri čemu su definirali povjerenje i motivaciju za dijeljenje znanja kao najbitnije čimbenike utjecaja za davatelje znanja, dok su apsorpcijski kapacitet i sposobnost regeneriranja znanja najvažniji čimbenici koji utječu na ponašanje primatelja znanja. Zaključak istraživanja ukazao je na činjenicu da članovi akademske zajednice s duljim radnim stažem nisu adekvatno motivirani za davanje znanja, dok općenito prevelika opterećenost nastavnog osoblja ograničava njihovu apsorpcijsku sposobnost za primanje novog znanja. Što se tiče važnosti informacijsko-komunikacijske tehnologije u davanju znanja, zaključak je studije da se ona uglavnom koristi za prenošenje eksplicitnog znanja, dok se kod prenošenja tacitnog znanja koriste specifični IKT, poput diskusijskih lista i foruma, grafika poput CAD-a, telekonferencija i videokonferencija. Osim toga, neformalne mreže pokazale su se kao posebno učinkovit mehanizam davanja tacitnog znanja. U dijelu rada koji se bavi opisom konceptualnog modela učinkovitog dijeljenja znanja ponudit će se konkretniji opis mehanizama davanja eksplicitnog i implicitnog ili tacitnog znanja, dok se u Tablici 3. sumiraju općeniti mehanizmi davanja obiju vrsta znanja temeljem prethodno opisanih empirijskih istraživanja.

Tablica 3: Vrste mehanizama davanja eksplicitnog i implicitnog/tacitnog znanja

Proces	**Aktivnosti**
DAVANJE EKSPLICITNOG ZNANJA	1. Educiranje zaposlenika o načinima davanja znanja
	2. Iznošenje informacija o tržišnim trendovima i potrebama zaposlenicima
	3. Informacijsko-komunikacijske tehnologije (elektronička pošta, webinari, *online* sastanci putem platformi poput MS Teams, Zoom i sl.)
	4. Implementacija periodičnih izvještaja, pravila, operativnih standarda, procedura i sl.
	5. Sustavi nagrađivanja zaposlenika
	6. Kreiranje baza podataka koje sadrže znanja i iskustva zaposlenika prikazanih u obliku „najboljih praksi“
DAVANJE IMPLICITNOG ZNANJA	1. Osnivanje klastera (mreža) zaposlenika s različitim ekspertizama koje oni prenose drugim zaposlenicima
	2. Preraspoređivanje viška radne snage sa specifičnim znanjima koje zaposlenici prenose manje iskusnim suradnicima
	3. Oluja mozgova (engl. *brainstorming*)
	4. Komunikacija posredstvom informacijsko-komunikacijskih tehnologija: diskusijske liste, forumi, grafike poput CAD-a, telekonferencije i videokonferencije

Izvor: pripremila doktorandica

Navedena istraživanja omogućila su stjecanje uvida u aktivnosti koje se primjenjuju u poduzećima pri davanju eksplicitnog i implicitnog znanja. Izbjegavanje nesporazuma u komunikaciji podrazumijeva kvalitetnu pripremu zaposlenika za dijeljenje znanja, pa u tu svrhu poduzeća organiziraju edukacije o načinima davanja eksplicitnog znanja. Olakšano davanje eksplicitnog znanja također nalaže od zaposlenika da redovito sastavljaju izvješća za nadređene o vlastitim postignućima, te da pomognu pretočiti svoja znanja i iskustva u virtualna skladišta, čineći pritom eksplicitna znanja široko dostupnima i ostalim zaposlenicima. Davanje implicitnog znanja moguće je ako zaposlenici mogu slobodno iznositi svoje ideje i stavove u komunikaciji s nadređenima, odnosno kada su spremni pripomoći manje iskusnim kolegama osobnim kontaktom, radom u timu ili kroz neformalna druženja. U odnosu na ranija istraživanja davanja eksplicitnog i implicitnog znanja koja obrađuju proces davanja parcijalno, odnosno čine to ili na način da analiziraju objedinjeno davanje znanja ili da stavljaju veći fokus na pojedinu vrstu znanja, prednost konceptualnog modela prikazanog u radu je u objedinjavanju procesa davanja obiju vrsta znanja uz opis specifičnih aktivnosti koje se pritom mogu primijeniti. Sličan pristup koristi se i u sljedećem poglavlju koje se bavi tematikom primanja znanja.

3.2.2. Primanje znanja

Cjelokupan proces dijeljenja znanja podjednako je podložan učinkovitom davanju znanja, kao i njegovom primanju. Naime, ako primatelji znanja nisu u mogućnosti procesuirati i primijeniti primljeno znanje, tada su napori oko njegovog davanja uzaludni. Kako je već ranije spomenuto, primanje znanja podrazumijeva dobrovoljno konzultiranje s drugim zaposlenicima, učenje od njih, te njihovo poticanje na dijeljenje znanja i intelektualnog kapitala (**Sorakraikitikul**, **Sienghtai**, **2014**.). Osim toga, valja se osvrnuti i na činjenicu da je primanje znanja moguće i iz unutarnjih i iz vanjskih izvora, pa ono podrazumijeva i procese i mehanizme za prikupljanje znanja i informacija s aspekta svih dostupnih i relevantnih izvora (**Lin**, **2007.**). Poduzeća koja su vješta u prikupljanju i implementiranju eksplicitnog, a posebice i implicitnog znanja, ostvarit će s vremenom konkurentske prednosti jer će njihova znanja postati rijetka i jedinstvena, te stoga neće biti podložna oponašanju.

Učinkovito primanje znanja prije svega se povezuje s apsorpcijskim kapacitetom, pa se sve veći broj znanstvenika bavi izučavanjem uvjeta koji pospješuju ovu sposobnost pojedinaca, a posljedično i poduzeća u cjelini. Apsorpcijski kapacitet je organizacijska sposobnost koja se prema **Distelu** (**2019.**) manifestira kroz četiri različite dimenzije: generiranje znanja,

prilagođavanje znanja te njegova transformacija i eksploatacija. Prve dvije dimenzije pritom čine potencijalni apsorpcijski kapacitet, dok preostale dvije čine realizirani apsorpcijski kapacitet. Temeljem istraživanja apsorpcijske sposobnosti 106 farmaceutskih poduzeća, **Distel** (**2019**.) je došao do zaključka da su za učinkovito prikupljanje znanja posebno značajne kognitivne sposobnosti zaposlenika, odnosno njihova moć kreativnog razmišljanja prilikom prikupljanja znanja. Ova je činjenica posebno značajna ako se uzme u obzir da zaposlenici znanje prikupljaju istovremeno i iz unutarnjih izvora, kao što su kolege, podređeni i nadređeni, ali i vanjskih izvora, kao što su kupci, dobavljači i ostali partneri. Prema tome, bitno je prilikom prikupljanja znanja prvenstveno ocijeniti koje su informacije značajne za poslovne procese, a potom, temeljem vlastitih saznanja, no i razvijenih kognitivnih sposobnosti, znati primijeniti prikupljeno u postojećem kontekstu. Anketnim je upitnikom značaj ispravne interpretacije primljenog znanja opisan kroz česticu kojom se mjeri spremnost zaposlenika da redovito uče o načinima primanja znanja, vještina i iskustava. Značaj apsorpcijske sposobnosti zaposlenika također je prepoznat u okviru čestice za mjerenje primanja implicitnog znanja, koja sadrži tvrdnju da zaposlenici u timovima i posredstvom neformalnih kontakata rado prihvaćaju znanja i iskustva od kolega i poslovnih poznanika. Nadalje, zaposlenici koji su voljni usvojiti nova znanja i vještine moraju imati mogućnost kontaktiranja iskusnijih kolega koji će im voljno prenijeti svoja znanja.

Nickerson i **Zenger** (**2004.**) također su izučavali značaj internih i eksternih izvora prikupljanja znanja, te su u svojem istraživanju fokus stavili na vrste organizacijskih struktura i njihov učinak na prikupljanje znanja. Analizu su autori temeljili na kompleksnosti problema koja utječe na daljnje odlučivanje menadžera o načinu pronalaženja adekvatnih rješenja. Tržište, hijerarhija temeljena na autoritetu i hijerarhija temeljena na konsenzusu definirani su kao tri osnovna izvora prikupljanja znanja. Tržište kao mogući izvor prikupljanja znanja učinkovito je s aspekta prikupljanja informacija nužnih za redovito poslovanje, pri čemu tržište umanjuje opasnost od krađe znanja jer ograničava kvantum znanja koje se razmjenjuje. U anketnom se upitniku važnost znanja dostupnog na tržištu vrednuje u okviru čestice kojom se mjeri primanje implicitnog znanja na način da zaposlenici redovito primaju i analiziraju periodične izvještaje o tržišnim trendovima i potrebama. Hijerarhija utemeljena na autoritetu učinkovita je kada problemi postanu kompleksni, pa se autoritetom menadžera odlučuje o načinu postizanja konsenzusa pri iznalaženju adekvatnih rješenja. Premda je ova vrsta hijerarhije učinkovitija od tržišta kao izvora prikupljanja znanja, njezin je nedostatak što ne promiče horizontalnu komunikaciju. Hijerarhija temeljena na konsenzusu usmjerena je na odabir projekata kojima će

se baviti pojedinačni odjeli, no ne i na način realizacije samog projekta. Ova je vrsta hijerarhije prikladna za rješavanje kompleksnih problema jer promiče učinkovito primanje znanja poticanjem korištenja zajedničkog jezika i stvaranja zajedničkog identiteta među zaposlenicima. Prema tome, donošenje odluke o davanju prednosti internom ili eksternom izvoru znanja, jer je neosporno da će poduzeća u poslovanju koristiti oba izvora, svakako ovisi i o kompleksnosti zadataka koji se nastoji riješiti, ali i o formalnim odnosima među zaposlenicima koji mogu poticati, odnosno ograničavati njihovu sposobnost primanja znanja.

Menon i **Pfeffer** (**2003**.) ispitivali su modalitete odlučivanja kojima se menadžeri opredjeljuju za eksterne ili interne izvore znanja. Premda mnoga istraživanja ukazuju na prednosti internih izvora, autori su došli do zaključka da je relevantnost eksternih izvora podjednako bitna. Menadžeri odlučuju o eksternim, odnosno internim izvorima znanja ovisno o različitim implikacijama učenja iz tih dvaju izvora, odnosno dostupnosti ili nedostatku znanja unutar samog poduzeća. Menadžeri se češće okreću internim izvorima znanja pa interno generirano znanje većinom doživljavaju superiornim u odnosu na eksterno. Međutim, usprkos tome, američki menadžeri i znanstvenici razvili su temeljem izučavanja praksi japanskih menadžera određene koncepte, poput potpunog upravljanja kvalitetom (engl. *Total quality management*) kod kojih je eksterno znanje podjednako bitno kao i interno. Nerijetko se menadžeri pak suviše oslanjaju na eksterne izvore znanja okrećući se pritom vanjskim konzultantima kojima se daje prednost u odnosu na interne stručnjake. Općepoznati primjer ignoriranja internog znanja jest onaj u slučaju *Xeroxa* koji je odbio operacionalizirati inovacije razvijene u sklopu vlastitog znanstveno-istraživačkog centra (osobno računalo, Ethernet, računalni miš i softver za procesuiranje teksta). Gubici uzrokovani takvom odlukom višestruko su naštetili poslovanju. Problem se očituje u činjenici da menadžeri nerijetko imaju negativan stav prema inovativnim idejama zaposlenika ako one odmiču od srži poslovanja, dok su manje obrambenog stava ako te iste ideje potječu od vanjskih konzultanata. Česti previdi i nedostatak komunikacije mogu umanjiti vrijednost interno generiranog znanja u odnosu na široko dostupno eksterno znanje. Međutim, kako je povijest pokazala, inzistiranje na isključivo internom ili eksternom izvoru znanja može imati kobne posljedice za poslovanje poduzeća. Iz navedenog primjera da se zaključiti kako je bitno da zaposlenici imaju slobodu postavljanja upita kolegama i nadređenima pri održavanju poslovnih sastanaka, a što se i mjerilo u upitniku pri vrednovanju primanja implicitnog znanja.

Odabir između, uvjetno rečeno, internih i eksternih izvora znanja posebice je zanimljivo izučavati u kontekstu podružnica. Koristeći pristup višestrukih mreža **Hansen** i **dr.** (**2005.**) istražili su na uzorku 121 tima koji se bave razvojem novih proizvoda načine komunikacije i preuzimanja znanja među podružnicama. Pritom su autori istraživali tri podskupine mreža: mreže osnovane unutar tima, međupodružničke veze, odnosno veze između tima i drugih podružnica te dijadične odnose između timova ili transferne mreže. Međupodružničke veze značajnije su za prikupljanje znanja među podružnicama nego unutar tima, dok su se najkorisnijim alatom prikupljanja znanja pokazale transferne mreže. Primjerice, timovi koji se bave razvojem proizvoda mogu razviti međusobne veze prije samog početka razvoja novog proizvoda. Takve će veze ostvariti pozitivan odjek tijekom procesa razvoja novog proizvoda jer će članovi timova koristiti prethodno razvijenim poznanstvima kako bi unaprijed razriješili moguće sukobe u razvoju novih proizvoda. Suprotno tome, timovi koji su izolirani od eksternih interakcija mogu razviti negativne percepcije drugih timova. Ukupan broj međupodružničkih veza koje pojedini tim razvije može se pokazati korisnim jer se na taj način proširuju potencijalni izvori prikupljanja novih znanja.

Sličan princip istraživanja primijenili su i **Ambos** i **dr.** (**2013**.) koji su temeljem uzorka od 324 relacijska odnosa među podružnicama 48 multinacionalnih kompanija nastojali definirati načine na koje podružnice upravljaju zalihama znanja. Zalihe znanja podrazumijevaju akumulirano interno znanje, dok se tokovi znanja odnose na protok znanja između podružnica međusobno ili između podružnica i sjedišta. Istraživanje se temeljilo na dvije bitne pretpostavke: i) sukladno teoriji apsorpcijskog kapaciteta, opsežne zalihe znanja omogućuju veće koristi od tokova znanja; dok ii) sukladno teoriji međuovisnosti lanca vrijednosti, ako pošiljatelj i primatelj znanja ostvaruju različite funkcionalne zadatke, tada postoji veća mogućnost kombiniranja zaliha i tokova znanja. Zaključak je istraživanja da se zalihe i tokovi znanja međusobno upotpunjuju, pa se samim time ostvaruju veće koristi i za primatelja znanja.

Kao što je već navedeno, apsorpcijski kapacitet poduzeća svakako ovisi i o sposobnostima zaposlenika da uspješno primaju prenesena znanja. Polazeći od teorije mikrotemelja, **Yao** i **Chang** (**2017.**) ispitali su na uzorku 139 visokotehnoloških poduzeća koje karakteristike pojedinaca utječu na razvoj njihovih apsorpcijskih sposobnosti. Autori su istraživanje temeljili na pristupu odozdo prema gore, vodeći pritom računa o tri temeljna procesa: interakcija (međusobni odnosi zaposlenika); normalizacija (usvajanje određenih obrazaca ponašanja) i privlačenje radnika (neposredni oblici međusobne komunikacije i ponašanja). Građanske vrline

izučavane su kao moderacijska varijabla, a odnose se na ponašanje zaposlenika koje odlikuje odgovoran i konstruktivan angažman u svakodnevnom poslovanju. Individualna učeća orijentacija zaposlenika, te unapređenje kompetencija zaposlenika, odnosno njihove sposobnosti usvajanja novih spoznaja, unapređuju razvoj potencijalne i realizirane apsorpcijske sposobnosti. Drugim riječima, zaposlenici koji nisu u potpunosti preuzeli vladajuće obrasce ponašanja u poduzeću češće će tražiti nove izazove, nastojat će usvojiti učinkovitije strategije učenja i konstantnog unapređenja individualnog učinka. Čim je veći broj zaposlenika koji posjeduju navedene karakteristike, veća je vjerojatnost da će poduzeće prije ostvariti svoj potencijalni apsorpcijski potencijal.

Zhang i **Jiang** (**2015**.) također su istraživali individualne karakteristike zaposlenika koje predodređuju njihovu sposobnost učinkovitog primanja znanja. Pritom su posebnu pozornost pridali kompetencijama primatelja znanja, njihovu stavu prema učenju i osobnim vezama s davateljima znanja. Analizu su proveli na uzorku studenata (258 ispitanika) i zaposlenika jedne telefonske kompanije (20 ispitanika). Značajke primatelja znanja u smislu responzivnog i proaktivnog pristupanja dijeljenju znanja različito utječu na spremnost primatelja znanja da primljeno znanje dalje dijeli. Responzivan model dijeljenja znanja podrazumijeva da primatelj znanja prenosi stečeno znanje samo onda kada se to od njega zahtijeva, dok proaktivno dijeljenje znanja podrazumijeva samoinicijativno dijeljenje znanja od strane primatelja radi prikupljanja korisnih komentara i prijedloga. Kod responzivnog modela dijeljenja znanja, stav primatelja znanja prema učenju i jačina veze s davateljem znanja presudni su za daljnje dijeljenje znanja. Stoga bi menadžeri trebali pojačano motivirati zaposlenike da traže informacije od svojih kolega, dok poduzeće omogućuje kvalitetniju interakciju zaposlenika razvijanjem prikladnog okruženja.

S obzirom na karakteristike eksplicitnog i implicitnog znanja potrebno je voditi računa o prikladnosti pojedinih tehnika komunikacije za njihovo učinkovito primanje. Kod primanja tacitnog znanja, kao i kod njegovog davanja, bitno je da između davatelja i primatelja znanja bude uspostavljen osobni kontakt. Jedan od češće primjenjivanih izravnih oblika učenja jest naukovanje u kojemu se naučniku pruža mogućnost izravnog učenja od mentora na način da preslikava njegove vještine bez potrebe eksplicitnog izražavanja od strane mentora (**Ackerman** i **dr., 2003**.). Tako, primjerice, eksperti mogu osmisliti prototipove ili nacrte proizvoda, čime iskazuju svoje mišljenje o tome kako bi proizvod trebao izgledati ili kako bi trebao funkcionirati. Prototip sadrži sveobuhvatnu tacitnu dimenziju te može omogućiti temelj za

komunikaciju, raspravu i zaključivanje bez nužnog pojašnjavanja temeljnih značajki proizvoda. Dakle, osim prenošenja tacitnog znanja osobnim kontaktom, moguće je i poželjno koristiti i pomoćna sredstva komunikacije koja u sebi sadrže tacitnu dimenziju, te u tom smislu potpomažu proces učenja.

Za razliku od implicitnog znanja, učinak eksplicitnog znanja podložan je češćem ispitivanju u znanstvenim krugovima. **Oldroyd** i **dr.** (**2019.**) izučavali su povezanost različitih oblika eksplicitnog znanja i uspješnosti poslovanja temeljem uzorka od 237 konzultativnih projekata. Pritom je fokus bio usmjeren na dva osnovna oblika kodificiranog znanja: i) opće principe znanja, te ii) specifične obrasce znanja. Opći principi podrazumijevaju temeljne ili opće zakone i činjenice kojima se zaposlenici usmjeravaju u izvršavanju dnevnih zadataka. Tako se, primjerice, anketnim upitnikom mjerilo primanje eksplicitnog znanja pomoću čestice koja ispituje zaprimaju li zaposlenici i analiziraju periodične izvještaje o uspješnosti poslovanja, organizacijskim politikama i procedurama. Specifični obrasci znanja odnose se na uzorke ili modele kojima se omogućuje jednostavnije reproduciranje znanja. Individualne karakteristike zaposlenika, poput namjenskih edukacija povezanih s projektima ili iskustvom koje zaposlenici raspolažu, a vezano je za poslovanje unutar određene zemlje ili industrijske grane, povezuju se s korištenjem općih principa znanja, dok zemljopisne ili institucijske specifičnosti utječu na češću primjenu specifičnih obrazaca znanja. Menadžeri koji posjeduju bogata iskustva u lokalnom poslovanju učinkovitije će primijeniti znanje temeljeno na općim principima, dok će specifične obrasce znanja menadžeri češće primijeniti ako je njihovo poslovanje vezano za nadilaženje zemljopisnih, organizacijskih i institucijskih granica.

Razina do koje će organizacije uspješno dijeliti znanje podjednako ovisi i u učinkovitosti davanja i o učinkovitosti primanja znanja. Bitno je da sudionici procesa dijeljenja znanja s jedne strane znaju kako koncizno prenijeti svoja znanja, a s druge da ih znaju na ispravan način protumačiti i primijeniti gdje je to potrebno. Distinkcija između procesa davanja i primanja eksplicitnog i implicitnog znanja učinjena je upravo radi davanja naglaska na činjenicu da isti mehanizmi komunikacije neće polučiti iste rezultate primijene li se kod dijeljenja ovih dviju temeljnih vrsta znanja. Slično kao i u prethodnoj cjelini, objedinjavanjem istraživanja koja su izučavala aktivnosti primanja eksplicitnog i implicitnog znanja nastojalo se na jednom mjestu objediniti one aktivnosti za koje se smatra da su posebno značajne za primanje znanja. Ranije u radu opisuje se dijeljenje znanja kao dualan proces – slijedom toga, davanje i primanje znanja mogu se predočiti kao zrcalne aktivnosti jednog istog procesa. Tako je, primjerice, kod davanja

eksplicitnog znanja u konceptualnom modelu korištena čestica kojom se mjerilo davanje znanja, vještina i iskustava kroz organizirane edukacije, dok se kod primanja eksplicitnog znanja mjerila spremnost zaposlenika da kroz prisustvo na organiziranim edukacijama uče o načinima primanja znanja, vještina i iskustava. Slično je i s davanjem, odnosno primanjem implicitnog znanja. Zaposlenici daju implicitno znanje na način da slobodno izražavaju svoje ideje i stavove na poslovnim sastancima, dok kod primanja implicitnog znanja u anketnom upitniku čestica ispituje mogućnosti koje zaposlenici imaju za slobodno postavljanje pitanja kolegama i nadređenima.

Tablica 4: Vrste mehanizama primanja eksplicitnog i implicitnog/tacitnog znanja

PROCES	**AKTIVNOSTI**
PRIMANJE EKSPLICITNOG ZNANJA	1. Čitanje i analiziranje izvješća o organizacijskim politikama i procedurama
	2. Čitanje i analiziranje izvješća o poslovnim rezultatima
	3. Korištenje sustava sistematizacija zaliha (interne baze podataka) i tokova znanja (eksterno prikupljeni podaci) kako bi se zaposlenicima omogućio lakši pristup
	4. Korištenje sustava informacijsko-komunikacijskih tehnologija (*online* sastanci, diskusijske sobe, međuprostori za pohranjivanje podataka)
	5. Periodični sastanci zaposlenika
	6. Primanje znanja iz edukacija u svrhu kvalitetnijeg primanja znanja, poput razvijanja kognitivnih sposobnosti i kreativnosti
	7. Korištenje prototipova i nacrta proizvoda
PRIMANJE IMPLICITNOG ZNANJA	1. Učenje na tuđim pogreškama
	2. Izravno primanje znanja iz pojedinačnih iskustava mentora
	3. Poticanje na druženja zaposlenika radi prihvaćanja zajedničkog jezika i identiteta
	4. Rotacija zaposlenika.

Izvor: pripremila doktorandica

U odnosu na prethodna istraživanja doprinos konceptualnog modela i popratnog anketnog upitnika je u sistematičnom i jednostavnom opisu aktivnosti koje se poduzimaju u svrhu davanja, odnosno primanja obje vrste znanja. U nastavku se daje pregled aktivnosti za primanje eksplicitnog i implicitnog znanja.

3.3. KONTEKSTUALNI ČIMBENICI USPJEŠNOG DIJELJENJA ZNANJA U PODUZEĆU

Osim implementacije sustavno razrađenih aktivnosti davanja i primanja eksplicitnog i implicitnog znanja, učinkovito dijeljenje znanja zavisi i o kvalitetnoj razradi kontekstualnih čimbenika, koji su u konceptualnom modelu prepoznati u obliku organizacijske kulture, IKT-a i podrške vrhovnog menadžmenta. Zašto su odabrani baš ovi čimbenici, koje su njihove specifičnosti te kakav je njihov učinak na efikasno dijeljenje znanja opisuje se u cjelinama koje slijede.

Proces dijeljenja znanja može se implementirati na učinkovit način ako su za to zadovoljene određene pretpostavke. U prethodnim su poglavljima navedene neke od tih pretpostavki koje se mogu grupirati u sljedeće: percipirana podrška rukovodstva, norme koje podržavaju dijeljenje znanja, kvaliteta međuljudskih odnosa (**Ahsford** i **dr., 1998**.); dostupnost informacija (**Tan**, **Zhao, 2003**.); sustav nagrađivanja i korištenje IKT-a (**Lin, 2007**.) te organizacijska klima i povjerenje (**Al-Kurdi** i **dr., 2019**.). Istraživanjem implementacije procesa upravljanja znanjem u Republici Hrvatskoj bavi se sve veći broj autora, no ekstenzivnija istraživanja provele su dvije autorice čiji se zaključci navode u nastavku.

Vidović (2008.) je analizirala razvijenost procesa upravljanja znanjem na uzorku 76 velikih hrvatskih poduzeća (poduzeća koja zapošljavaju više od 1.000 radnika), pri čemu je evaluirala pet ključnih čimbenika koji utječu na uspješnost upravljanja znanjem: i) infrastrukturu za upravljanje znanjem; ii) nositelje procesa upravljanja znanjem; iii) organizacijsku kulturu za upravljanje znanjem; iv) informacijsku tehnologiju za upravljanje znanjem te v) mjerenje korisnosti procesa upravljanja znanjem. Rezultati provedenog istraživanja ukazali su na slabu razvijenost infrastrukture za upravljanje znanjem (način korištenja tehnologije, definiranje radnih procesa, te umrežavanje zaposlenih); slabu razvijenost nositelja procesa upravljanja znanjem (radnici znanja, menadžeri projekta uvođenja upravljanja znanjem i direktori upravljanja znanjem, engl. C*hief knowledge officer*); organizacijsku kulturu koja ne podržava proces upravljanja znanjem (uvažavanje značaja koji znanje ima za poduzeće te poticanje i nagrađivanje produbljivanja znanja i njegovog prenošenja); neprilagođenost informacijske tehnologije procesima upravljanja znanjem (u smislu olakšavanja prikupljanja, strukturiranja, pohranjivanja i distribucije znanja) te nepostojanje mjernih pokazatelja razvijenosti procesa upravljanja znanjem (opravdavanje investiranih sredstava u filozofiju poslovanja temeljenu na upravljanju znanjem). Zaključak istraživanja bio je da hrvatska poduzeća pripadaju prvoj generaciji upravljanja znanjem koju, prema **Milanović** (**2010.**) karakterizira:

1) fokus na informacijsku tehnologiju;
2) organizacijska kultura koja ne podržava procese upravljanja znanjem;
3) nedostatak kompenzacija zaposlenicima za njihov doprinos upravljanju znanjem te
4) nedostatak inicijative menadžmenta u promicanju praksi upravljanja znanjem.

Prilikom analiziranja primjene informacijske tehnologije za upravljanje znanjem na uzorku od 200 velikih, srednjih i malih hrvatskih poduzeća, **Milanović (2010.)** je definirala tri ključna čimbenika uspješnog upravljanja znanjem: i) ljudsku dimenziju, ii) organizaciju i iii)

informacijsku tehnologiju. Premda poduzeća koriste informacijske alate koji omogućuju učinkovit timski rad i pohranjivanje podataka, opće su ocjene primjene informacijske tehnologije za upravljanje znanjem relativno niske. Dok je **Vidović** (**2008.**) na temelju istraživanja čimbenika infrastrukture upravljanja znanjem, nositelja procesa upravljanja znanjem, organizacijske kulture za upravljanje znanjem, informacijske tehnologije i mjerenja korisnosti procesa upravljanja znanjem utvrdila da hrvatska poduzeća pripadaju prvoj generaciji upravljanja znanjem, zaključak je **Milanović** (**2010.**) da hrvatska poduzeća pripadaju drugoj generaciji upravljanja znanjem, koju karakterizira usredotočenost poduzeća dominantno na ljudsku i kulturološku dimenziju, pa visoke prosječne ocjene organizacijske kulture i ljudske dimenzije ukazuju na pripadnost hrvatskih poduzeća drugoj generaciji.

Izučavanjem znanstvenih radova kojima se detaljnije ispitivalo čimbenike upravljanja znanjem općenito, odnosno dijeljenja znanja kao središnje faze procesa upravljanja znanjem, došlo se do zaključka da bi kombinacija kontekstualnih čimbenika od utjecaja na učinkovitost dijeljenja znanja mogla predstavljati integraciju sljedećih čimbenika: organizacijske kulture, informacijsko-komunikacijskih tehnologija (IKT) i podrške vrhovnog menadžmenta. Zašto su odabrani upravo ovi čimbenici i principi njihova utjecaja na proces dijeljenja znanja obrazloženi su u nastavku rada.

3.3.1. Organizacijska kultura

Organizacijsku kulturu moguće je opisati kao naučen obrazac ponašanja koji se prenosi s jedne generacije na drugu te obuhvaća vrijednosti i pretpostavke zaposlenika o onome što je ispravno, dobro i poželjno (**Schein, 1992**.). Ona se može opisati i kao „ljepilo“ koje drži organizaciju cjelovitom jer joj osigurava identitet i razlikovne značajke. **Weihrich** i **Koontz** (**1994.**) tvrde kako se o organizacijskoj kulturi može zaključivati temeljem onoga što ljudi govore, čine i misle unutar organizacije. Ona obuhvaća učenje i prenošenje znanja, uvjerenja i obrazaca ponašanja tijekom nekog razdoblja, što znači da je organizacijska kultura prilično stabilna te da se ne mijenja brzo.

Značajke organizacijske kulture koje čine poduzeća jedinstvenim entitetima obuhvaćaju (**Schein, 2010**.):

- vidljive zakonitosti ponašanja među zaposlenicima poput jezika, običaja i rituala;
- grupne norme (implicitni standardi i vrijednosti koji se razvijaju unutar grupe);

- prihvaćanje vrijednosti kojima organizacija teži, poput cjenovnog vodstva;
- formalna filozofija (opći ideološki principi koji usmjeravaju aktivnosti prema različitim interesnim skupinama);
- pravila igre (nepisana pravila ponašanja koja su usvojili svi zaposlenici);
- klima (osjećaj zajedništva i identiteta među zaposlenicima);
- usvojene vještine (specifične kompetencije koje se prenose novim zaposlenicima);
- mentalni modeli i/ili lingvističke paradigme (opći stavovi koji se prenose novim zaposlenicima u ranim fazama socijalizacije);
- suštinske metafore ili integrativni simboli (izgled ureda ili kodeks odijevanja);
- formalni rituali i obilježavanja određenih događaja (završetak većeg projekta);
- strukturalna stabilnost te
- dubina (vrijednosti ukorijenjene među zaposlenicima) i širina (aktivnosti) djelovanja.

Ponešto sličan pristup koriste i **Bahtijarević-Šiber** i **dr.** (**1993.**) koji opisuju sljedeće sastavnice organizacijske kulture: i) vrijednosti (operacionalizacija strategije vezana za prioritete poslovanja koji su značajni za opstanak i razvoj organizacije); ii) norme (kakvo se ponašanje očekuje i nagrađuje u organizaciji, a kakvo se kažnjava); iii) stavovi i uvjerenja (osnovni ideali i načela ponašanja zaposlenika); iv) običaji i rituali (operativni i ustaljeni oblici ponašanja); v) jezik i komunikacija (jezik je znak određenog socijalnog statusa zaposlenika, dok komuniciranjem zaposlenici ili organizacija izražavaju svoj identitet) te vi) simboli (vanjski vizualni znakovi organizacije).

Temeljem svega prethodno navedenoga može se zaključiti da je organizacijska kultura prilično kompleksan pojam koji je teže jednoznačno definirati. Mnogi su autori pristupili analizi organizacijske kulture s aspekta dviju značajki definiranih teorijom konkurentskih vrijednosti (**Quinn, 1988**.), pa tako razlikuju vertikalnu dimenziju (fleksibilnost nasuprot kontrole) i horizontalnu dimenziju (interni nasuprot eksterni fokus djelovanja). **Suppiah** i **Sandhu** (**2011.**) i **Oh** i **Han** (**2020**.) razlikuju četiri temeljne vrste organizacijske kulture:

i) klansku kulturu (fleksibilnost s unutarnjim fokusom);
ii) adhokratsku kulturu (fleksibilnost s eksternim fokusom);
iii) hijerarhijsku kulturu (kontrola s internim fokusom) te
iv) tržišnu kulturu (kontrola s eksternim fokusom).

Klanska kultura često se opisuje i kao „model koji opisuje međuljudske odnose“ u smislu važnosti zajedničkog djelovanja. U takvoj se kulturi vrednuju moral, povjerenje i timski rad, pa se među zaposlenicima razvija osjećaj pripadnosti i zajedništva. Adhokratska kultura se još opisuje i kao „model otvorenog sustava“ u kojemu je glavni fokus na proaktivnom djelovanju. Također se vrednuju značajke kreativnosti, transformacije i rasta, čime se zaposlenici osposobljavaju za aktivno pristupanje promjenama u okolini. Tržišna kultura poznata je i kao „model racionalnih ciljeva“ s fokusom na vanjske odnose i unapređenje kompetencija. Potiču se vrijednosti poput kontrole, predvidljivosti, ostvarivanja ciljeva i uspješnog nadmetanja s konkurentima. Svi se zaposlenici potiču da se u svakodnevnom djelovanju povode principima konkurentnosti i produktivnosti. Njeguju se odnosi s vanjskim dionicima kako bi se lakše prikupili vanjski, inovativni resursi kojima se može ostvariti dodana vrijednost. Hijerarhijska kultura, poznata još i kao „model internih procesa“, fokusira se na interne odnose koje odlikuje formalizirana i hijerarhijska struktura. Pritom se uvažavaju vrijednosti poput kontrole, predvidljivosti, procjene i centralizacije. Ključni čimbenici poticanja kontinuiranog unapređenja jesu rutine, norme i standardizirane prakse. Komunikacija teče od vrha prema dnu, dok jasna pravila ponašanja pomažu zaposlenicima da izbjegnu sukobe te ostvare standardizirane rezultate i zajedničke ciljeve.

Analizom značajki organizacijske kulture koja potiče dijeljenje znanja u ovom će se radu istražiti pripada li takva kultura jednoj od navedenih četiriju vrsta organizacijske kulture ili je ona pak određeni hibrid među njima. Značaj koji jaka organizacijska kultura može imati na poslovanje poduzeća je višestruk, pri čemu su se mnogi radovi fokusirali na povezanost organizacijske kulture i učinkovitosti poslovanja. **Denison** i **Mishra** (**1995**.) ispitivali su ovaj odnos temeljem višegodišnjeg djelovanja 39 poduzeća iz 20 različitih industrijskih sektora. Pritom su zaključili da postoje četiri značajke organizacijske kulture koje su posebno značajne za učinkovitost poslovanja:

i) uključenost (participacija) zaposlenika;
ii) konzistentnost;
iii) adaptibilnost i
iv) misija.

Ova četiri obilježja organizacijske kulture bitna su za oblikovanje organizacije u procesu njenog suočavanja s poteškoćama eksterne adaptacije i interne integracije. Zaključak je provedene studije da svako od četiriju obilježja organizacijske kulture pokazuje signifikantnu pozitivnu

vezu s velikim brojem objektivnih i subjektivnih mjera organizacijske uspješnosti i učinkovitosti. Posebno su mjereni povrat na ukupnu imovinu (engl. ROA - *Return on assets*) i povrat na investicije (engl. ROI - *Return on investments*) te manje egzaktni pokazatelji poput razvoja i kvalitete proizvoda, rasta prodaje, tržišnog udjela i zadovoljstva zaposlenika. Misija poslovanja i konzistentnost najviše utječu na financijske pokazatelje uspješnosti poslovanja, dok uključenost i adaptabilnost omogućuju visoke razine proizvodnje i uslužne inovativnosti, kao i brzi odgovor na promjenjive potrebe kupaca i zaposlenika. Organizacijska kultura učinkovite organizacije mora odražavati sve navedene karakteristike, odnosno ona mora biti fleksibilna i adaptabilna. Isto tako, učinkovita organizacijska kultura mora u znatnoj mjeri biti i konzistentna i predvidljiva uz poticanje visokog stupnja participacije svih zaposlenika.

S obzirom na to da su **Denison** i **Mishra** (**1995.**) opisali organizacijsku kulturu u odnosu na značajke koje su vrednovane i u konceptualnom modelu, smatra se korisnim ponuditi sistematičan prikaz obilježja organizacijske kulture, kao i aktivnosti koje je nužno poduzeti kako bi se unaprijedila pojedina obilježja, te se u Tablici 5. sumiraju ova područja, prilagođena prema **Žugaj** i **dr.** (**2004.**).

Tablica 5: Obilježja organizacijske kulture prema Denisonu i Mishri (1995.)

Obilježje organizacijske kulture	**Aktivnosti za implementaciju pojedinog obilježja**
UKLJUČENOST (PARTICIPACIJA ZAPOSLENIKA)	1. Opunomoćenje (uključenost zaposlenika u vlastiti rad; odlučivanje na izvoru informacija; dostupnost informacija svim zaposlenicima; sudjelovanje zaposlenika u poslovnom planiranju)
	2. Timska orijentacija (suradnja različitih dijelova organizacije; prepoznavanje povezanosti individualnog rada s ciljevima organizacije)
	3. Razvoj sposobnosti/vještina (kontinuirano ulaganje u unapređivanje znanja i vještina zaposlenika; sposobnosti zaposlenika kao važan izvor komparativnih prednosti)
KONZISTENTNOST	1. Temeljne vrijednosti (jasan i konzistentan sustav vrijednosti koji upravlja načinom poslovanja)
	2. Suglasnost (lako postizanje konsenzusa, čak i kod kompleksnih problema)
	3. Koordinacija i integracija (ciljevi različitih razina organizacije dobro su usklađeni)
ADAPTABILNOST	1. Stvaranje promjena (kontinuirano usvajanje novih i poboljšanih načina poslovanja)
	2. Usmjerenost prema potrošačima (organizacija potiče direktan kontakt s potrošačima kako bi se uvažile njihove želje)
	3. Organizacijsko učenje (potiču se inovativnost i preuzimanje rizika)
MISIJA	1. Strateško usmjerenje (misija daje jasan smisao i pravac poslovanju)
	2. Ciljevi (postavljanje ambicioznih ali realističnih ciljeva)
	3. Vizija (jasna vizija o organizaciji stvara zadovoljstvo i motiviranost zaposlenika)

Izvor: prilagođeno prema: Žugaj i dr. (2004.)

Premda **Denison** i **Mishra** (**1995.**) ne kategoriziraju organizacijsku kulturu u specifične oblike, kako to čine, primjerice, **Suppiah** i **Sandhu** (**2011.**), oni opisuju sve bitne značajke organizacijske kulture koje mogu imati pozitivan učinak na proces dijeljenja znanja, odnosno posljedično na poslovni rezultat. Tako se, primjerice, konceptualni model nadovezuje na neke od opisanih obilježja, te kroz mjerene čestice obuhvaća kategoriju participacije zaposlenika kroz varijablu opunomoćivanje. Konzistentnost se vrednuje kroz varijablu poslovna misija (dosljedna posvećenost zaposlenika dijeljenju znanja koje se naglašava kroz poslovnu misiju). Adaptabilnost se reflektira kroz kontinuirano učenje (poticanje poduzetničkog ponašanja među zaposlenicima na način da im se toleriraju pogreške sve dok služe kao solidan temelj budućem učenju), te misija koja se izravno mjeri varijablom poslovna misija, a koja u konceptualnom modelu mjeri strateško usmjerenje kroz konstantnu posvećenost zaposlenika dijeljenju znanja kao bitnom segmentu poslovne misije.

Tijekom pandemije Covid-19 opći uvjeti poslovanja značajno su se promijenili. Zbog općeg *lockdowna* koji je uveden u većini europskih zemalja i šire, dogodile su se značajne promjene u izvedbi rutinskih zadataka: uveden je rad od kuće, komunikacija zaposlenika međusobno i prema trećim osobama svedena je striktno na komunikaciju na daljinu, dok je uvođenje socijalne distance uzrokovalo redukciju poslovnih prostora koje je bilo moguće koristiti. Sve su se te promjene višestruko odrazile na kulturu poduzeća. **Parker** (**2020.**) je istraživao učinke Covida na dizajn radnog mjesta i redovito poslovanje u odnosu na sigurnosne mjere propisane od strane nadležnih organa. Jedna od izravnih posljedica pandemije bila je uvođenje rada na daljinu. Međutim, rad na daljinu automatski za sobom povlači pitanje opremljenosti osobnih prostora radnika, kao i pitanje udjela troškova koji su poduzeća spremna sufinancirati. Osim pitanja vezanih za opskrbljenost radnika svom potrebnom tehnologijom, pojavila su se i pitanja vezana za dnevne obveze i stres radnika koji simultano s poslovnim zadacima moraju skrbiti o djeci ili pak psihološke posljedice pomanjkanja socijalne povezanosti. Većina poduzeća rješenje je pronašla u uvođenju hibridnih ureda na način da su se zaposlenici rotirali i kombinirali rad iz poduzeća i rad od kuće. Još jedno potencijalno rješenje o kojem se sve više raspravlja u struci jest uvođenje ureda/podružnica koji bi satelitski bili povezani sa svojim središnjicama, a zaposlenicima bi olakšali problem dislociranosti. Što se tiče redizajna ureda, mjere društvene distance podrazumijevaju reduciranje iskoristivih površina za 25 – 30 %, a što se prvenstveno odnosi na sobe za sastanke i urede otvorenog tipa koje je bilo nužno pregrađivati. Razmatraju se i mogućnosti instaliranja ulaza koji se otvaraju senzorima na glas ili pokrete ruku. Senzori pokreta mogu se primijeniti i na rasvjetu te namještaj u sanitarnim

čvorovima i čajnim kuhinjama, a sve s namjerom reduciranja fizičkog dodirivanja površina pogodnih za prijenos virusa. Spominju se i sljedeća tehnološka unapređenja: unaprijeđeni sustavi ventilacije, ultraljubičasta rasvjeta kojom je moguće dezinficiranje površina tijekom noći, sustavi nadzora vlage te indikatori iskorištenosti prostora. Preporučuje se ugradnja glatkih radnih površina, kao i nanoseptičkih vrata i kvaka jer su antibakterijske i samodezinficirajuće. Uspjeh svih navedenih mjera prije svega ovisi o kvalitetnoj komunikaciji rukovodstva sa zaposlenicima, što zahtijeva njihovu pravovremenu edukaciju i informiranje. U tom smislu zaposlenike je neophodno redovito informirati najnovijim aktivnostima poduzetima u svrhu minimiziranja zdravstvenih opasnosti uzrokovanih pandemijom, osigurati im materijale s odgovorima na „najčešće postavljena pitanja“, osigurati stalne kanale komunikacije te formalne edukacije. Sve navedene mjere ujedno podrazumijevaju i kolektivnu promjenu svijesti zaposlenika, odnosno adaptaciju kulture poduzeća „novom normalnom“, što nije moguće bez bliske suradnje rukovodstva i zaposlenika.

U prethodnom je primjeru opisana adaptacija organizacijske kulture u promijenjenim uvjetima poslovanja, iz čega je moguće zaključiti da je organizacijska kultura slojevit koncept koji se mijenja postepeno u svim svojim segmentima. Tablicom koja opisuje obilježja organizacijske kulture (**Denison**, **Mishra**, **1995.**) ukazalo se na sve njezine bitne značajke koje se moraju vrednovati u nastojanju da se razvije jaka organizacijska kultura koja se može prilagoditi novim uvjetima poslovanja i omogućiti poduzeću da postane dovoljno jako i fleksibilno u svojoj prilagodbi. Pritom se pažnja skreće na značajke organizacijske kulture koje su vrednovane i mjerene u sklopu konceptualnog modela, a za koje su recentna istraživanja ukazala da mogu unaprijediti organizacijsku kulturu s aspekta njezina utjecaja na dijeljenje znanja: poslovna misija, opunomoćivanje zaposlenika i kontinuirano učenje. Ove se varijable detaljnije opisuju u nastavku.

3.3.1.1. Poslovna misija

Jedno od obilježja suvremenog poslovnog okruženja je hiperkonkurencija – pojačano nadmetanje uzlazno rastućeg broja poduzeća koja se bore za naklonost kupaca. Poduzećima je pri tome bitno da među svojim kupcima razviju osjećaj privrženosti i pouzdanosti u kvalitetu proizvoda i usluga koje pružaju. **Denison** i **Mishra** (**1995.**) naveli su kako je među najznačajnijim obilježjima organizacijske kulture bitno pridati značaj upravo poslovnoj misiji koja odražava temeljni *credo* poslovanja, a zaposlenima omogućuje upoznavanje sa smjerom

razvoja poduzeća. **Donate** i **Guadamillas** (**2011.**) također smatraju da je jasna i opće prihvaćena misija poslovanja itekako značajna za sigurnost poslovanja. Stoga se u nastavku navode istraživanja koja su izučavala načine na koje poduzeća osmišljavaju izjave o poslovnoj misiji, odnosno koji su segmenti poslovanja prepoznati kao posebno značajni da bi i kod zaposlenika i kod kupaca razvili osjećaj privrženosti i odanosti poduzeću.

Izjave o misiji kratki su dokumenti koji eksplicitno navode svrhu poslovanja (**Bartkus** i **dr., 2000.**). One su istovremeno i kulturološki simbol poduzeća i tehnički element organizacijske strategije. Izjave o misiji definiraju sržne vrijednosti koje poduzeće promiče u odnosu na svoje investitore, dobavljače, zakonodavce, postojeće i potencijalne zaposlenike. **Biloslavo** i **Lynn** (**2007**.) usporedili su izjave o misiji nekolicine američkih poduzeća s izjavama 79 najvećih slovenskih poduzeća mjereno neto zaradom. Izjave o misiji slovenskih poduzeća u znatno manjoj mjeri naglašavaju kupce, dobavljače i druge interesne skupine nego što to čine američka poduzeća. Razlog tome autori pronalaze u nesigurnostima u makroekonomskom okruženju, strukturi industrije i ustroju institucijskog okruženja. Što se tiče institucijskog okruženja, većina slovenskih menadžera namjerno u svojim izjavama izostavlja one segmente poslovnih strategija za koje vjeruju da će ih revidirati financijske institucije čija se politika prvenstveno temelji na rezanju troškova.

S obzirom na to da se azijska poduzeća nerijetko spominju kao ona koja promiču visoka etička načela i principe poslovanja, mnogi su autori ispitivali njihove izjave o misiji. Primjerice, **Zulhamri** i **dr.** (**2013.**) analizirali su izjave o misiji objavljene na korporativnim mrežnim stranicama 300 malazijskih i 214 singapurskih poduzeća, pri čemu su se koristili Aakerovom ljestvicom[2] pri definiranju misije i vizije s aspekta razrade korporativnog identiteta. Korporativni identitet je način na koji poduzeća predstavljaju sržne vrijednosti, poslovnu filozofiju, proizvode i poslovnu strategiju prema eksternim interesnim skupinama (**Bick** i **dr**., **2003**.). Analiza organizacijskih sržnih vrijednosti koje se ogledaju u misiji, viziji i kulturi presudna je za razvijanje korporativnog identiteta jer izjave o misiji i viziji osiguravaju temelj motiviranja i fokusiranja zaposlenika. Analiza pet temeljnih dimenzija Aakertove ljestvice: iskrenost, uzbuđenje, sposobnost, konkurentnost i robusnost pokazala je da tek nekolicina ispitanih poduzeća koristi navedene atribute u definiranju misije. Stvaranje kvalitetnog korporativnog identiteta i prepoznatljive poslovne misije nalaže od poduzeća da redefiniraju

[2] David Aaker, marketinški stručnjak, razvio je model prepoznatljivosti brenda koji počiva na četiri premise: svjesnost o brendu, percipirana kvaliteta, prepoznatljivost i odanost brendu.

postojeće misije na način da one sadrže atribute Aakertove ljestvice kako bi time privukla još veći broj kupaca i poslovnih partnera.

Hirota i **dr.** (**2010**.) analizirali su izjave o misiji na temelju uzorka 64 japanskih poduzeća kako bi provjerili učinak misije na korporativnu politiku kojom se definiraju principi zapošljavanja, upravne i financijske strukture. Korporativna misija i na njoj temeljene politike poslovanja naglasak stavljaju na korištenje principa *Monozukurija*, odnosno angažiranja specijalizirane radne snage. Visokospecijalizirani radnici koji posjeduju značajna tacitna znanja razvijaju vještine poslovanja koje ih osposobljavaju za izvršavanje kompleksnih zadataka, a takvi su radnici i skloniji kontinuiranom učenju i unapređenju. Upravo iz navedenog razloga japanska poduzeća nisu, za razliku od europskih, krenula s drastičnim redukcijama radne snage nakon gospodarske krize 1990. - 2000., već upravo suprotno. Ona su nastavila poslovati po istim principima kao i prije gospodarske krize, što daje naslutiti da japanska poduzeća dosljedno podržavaju korporativnu misiju kao stalan izvor konkurentske prednosti.

Pandemija Covid-19 potaknula je brojna poduzeća da nanovo promisle svoju poslovnu misiju, te učine nužne preinake kako bi dugoročno sačuvala poslovanje. Temeljem podataka prikupljenih na uzorku hotelskih menadžera tijekom veljače i travnja 2020. godine u Macau, **Lai** i **Wong** (**2020.**) nastojali su prepoznati uzorak ponašanja u reakcijama hotelskog sektora na novonastale uvjete poslovanja. Temeljem anketnog istraživanja i dubinskih intervjua sa 179 ispitanika zaposlenih u hotelskim lancima Macaa autori su primijenili metodu analize utjecaja na poslovanje (engl. *Importance-Performance Analysis*) te su ispitali 30 pokazatelja svrstanih u šest skupina: cjenovna strategija, marketing, održavanje, prevencija epidemije, upravljanje ljudskim resursima te pomoć nadzornih vlasti u inicijalnoj i naprednoj fazi pandemije. Dok su se prethodna istraživanja većinom bazirala na pomoći nadzornih (državnih) organa, ovim je istraživanjem pozornost skrenuta na činjenicu da su hotelski menadžeri ti koji su preuzeli proaktivnu ulogu te su proveli odgovarajuće mjere u prevenciji epidemije (odgovarajuća edukacija osoblja); upravljanju ljudskim resursima (reorganizacija duljine trajanja radnog vremena i korištenja godišnjih odmora); praksama održavanja postojećih kapaciteta reduciranjem svih nepotrebnih troškova, te pojačane tržišne promidžbe usluga u trenucima općeg *lockdowna* (poput orijentiranja na buduće aranžmane nakon ukidanja zabrane putovanja). Prema tome, premda je pandemija uvelike unazadila turistički sektor, redefiniranjem misije poslovanja te uvažavanjem novonastale situacije ipak je moguće izvući i one pozitivne strane ograničenja nametnutih samom pandemijom.

Slijedom navedenoga, poduzeća koja žele ostvariti preduvjete razvijanja snažne organizacijske kulture svakako moraju nužnu pozornost posvetiti definiranju jasne poslovne misije koja će odražavati temeljna načela poslovanja kojima će među svojim zaposlenicima razviti osjećaj privrženosti i identiteta, a svojim kupcima i poslovnim partnerima odražavati principe pouzdanog i dugoročno održivog modusa poslovanja. Pridjevi kao što su iskrenost, sposobnost, uzbuđenje, konkurentnost i robusnost prepoznati su kao odlike priznatih robnih marki, pa bi ih poduzeća svakako trebala uzeti u obzir prilikom razvijanja svojih misija poslovanja. Kvalitetna poslovna misija koja omogućuje razvoj poduzeća u odnosu na prethodno navedene pridjeve mora vrednovati značaj dijeljenja znanja jer se sistematičnom provedbom aktivnosti davanja i primanja eksplicitnog i implicitnog znanja može među zaposlenicima razviti iskrenost i uzbuđenje kroz osvješćivanje njihova doprinosa razvoju poduzeća. Razvijanje zajedništva među zaposlenicima i poticanje odanosti poduzeću pridonose jačem angažmanu zaposlenika u procesima davanja i primanja znanja.

3.3.1.2. Opunomoćivanje zaposlenika

U prethodnim poglavljima naznačeno je da uspješnost provedbe procesa dijeljenja znanja velikim dijelom ovisi i o sudionicima samog procesa, odnosno zaposlenicima, neovisno o njihovu položaju u organizacijskoj hijerarhiji. Iz navedenog je razloga bitno održavati zaposlenike zadovoljnima, što se ostvaruje opipljivim i neopipljivim čimbenicima motivacije. Premda je uvriježeno mišljenje kako financijska stimulacija u najvećoj mjeri potiče angažiranost zaposlenika i njihovu predanost radu, takva je misao samo djelomično istinita. Zaposlenicima je podjednako bitno da se njihov doprinos cijeni na ispravan način, a što između ostaloga podrazumijeva i visoku razinu povjerenja te mogućnost samostalnog djelovanja. Opunomoćivanje ili osnaživanje zaposlenika (engl. *empowerment*) može se definirati kao proces implementacije uvjeta rada koji povećavaju osjećaj samoučinkovitosti i kontrole kod zaposlenika, odnosno uklanjanje radnih uvjeta koji nameću osjećaj bespomoćnosti (**Liden**, **Arad**, **1996**.). Zaposlenici koji djeluju u opunomoćenim timovima posjeduju više autonomije, usmjerenosti i kontrole nad svojim radnim okruženjem. Neki opunomoćeni timovi odlučuju čak i o smjenama i korištenju godišnjih odmora, naručivanju materijala i sirovina, zapošljavanju i otpuštanju radnika te povišicama plaća (**Liden**, **Tewksbury**, **1995.**). Uloga rukovoditelja u takvim timovima jest poticanje poželjnog ponašanja, pružanje društvene i emocionalne podrške, razvijanje povjerenja i otvorenosti, poticanje samopouzdanja, pružanje informacija i sredstava potrebnih za izvršavanje radnih zadataka te promicanje poslovne vizije i misije.

Dva su teorijska pristupa konceptu opunomoćivanja: prema prvom, opunomoćivanje se postavlja u organizacijski kontekst i predstavlja praksu ili skup praksi usmjerenih na delegiranje odgovornosti niže u hijerarhiji na način da zaposlenici imaju veću slobodu u odlučivanju. Prema drugom pristupu opunomoćivanje je psihološko stanje koje se povezuje s četiri dimenzije poslovanja: smislenost, kompetentnost, predanost i utjecaj (**Adhearne**, **2005.**).

Premda se čini jednostavnim pothvatom, sama realizacija opunomoćivanja nije uvijek jednostavna. Tako su, primjerice, **Stewart** i **dr.** (**2017.**) analizirali prepreke uspješnoj implementaciji opunomoćivanja unutar timova na primjeru američkog pružatelja zdravstvene zaštite. Liječnici/rukovoditelji ostvarili su slabiji utjecaj na članove tima od rukovoditelja koji nisu liječničke struke jer su se osjećali ugroženima na način da, osim farmaceutskog znanja, moraju dokazivati i svoje rukovodilačke vještine, dok druga skupina rukovoditelja to nije bila primorana činiti. Premda su se s jedne strane osjećali ugroženima zbog propitkivanja njihovih rukovodećih sposobnosti, s druge su se strane postavljali superiorno naspram svog znanja i položaja u hijerarhijskoj strukturi, čime su dodatno poticali nepovjerenje članova tima.

Da bi opunomoćivanje zaposlenika ostvarilo pozitivan utjecaj na proces dijeljenja znanja, ono se mora provesti na način da se u obzir uzmu čimbenici kao što su osobnost zaposlenika, radni staž i predanost ciljevima poslovanja proizašlima iz korporativne misije (**Carmeli** i **dr., 2011**.). Nadalje, samo opunomoćivanje će različito motivirati zaposlenike, pa su **Leach** i **dr.** (**2003.**) analizirali učinak opunomoćivanja na uzorku zaposlenika britanske tvornice fotografskog papira. Zaključili su da opunomoćivanje utječe na porast zadovoljstva kod novih zaposlenika, no ne i kod stručnjaka s duljim radnim stažem. Kreiranjem izazovnijih radnih zadataka moguće je potaknuti jači angažman stručnjaka, što ima učinka i na njihovo zadovoljstvo radnim mjestom. Opunomoćivanje će također povećati i zadovoljstvo novozaposlenih radnika jer će im omogućiti unapređenje vještina i mogućnost samostalnog odlučivanja.

Prema tome, implementacija koncepta opunomoćivanja nalaže i rukovoditeljima da se ponašaju na određeni način. Ispitivanjem rukovoditelja i članova timova deset poduzeća iz različitih industrijskih grana koja primjenjuju principe opunomoćivanja autori su došli do zaključka da postoji pet temeljnih indikatora rukovođenja temeljnog na opunomoćivanju: i) edukacija (skup tehnika kojima se podučavaju članovi timova kako da postanu samostalniji); ii) informiranje (dijeljene informacija o misiji i filozofiji poslovanja); iii) rukovođenje temeljeno na pružanju uzora zaposlenicima (skup tehnika kojima rukovoditelji pokazuju predanost vlastitom radu, kao

i radu članova tima); iv) iskazivanje brige i interesa za članove tima te v) participativno odlučivanje (odlučivanje potpomognuto informacijama prikupljenim od članova tima). **Carless** (**2004**.) navedenim osobinama rukovoditelja koji provode principe opunomoćivanja još pridodaje predanost rukovoditelja da aktivno uključuju zaposlenike u odlučivanje. Time zaposlenici stječu autonomiju nad izvođenjem radnih zadataka, dok im rukovoditelji iskazuju povjerenje u njihov rad uklanjanjem birokratskih ograničenja. *Laissez-faire* (franc. „neka teče, neka ide svojim tokom“) rukovođenje, odnosno *ad-hoc* rukovođenje, predstavlja suprotnost opunomoćenom rukovođenju jer rukovoditelji namjerno izbjegavaju suočavanje s problemima na način da ignoriraju potrebe zaposlenika (**Wong**, **Giessner**, **2018.**). S obzirom na činjenicu da sve veći broj poduzeća implementira plosnate organizacijske strukture, poželjno je da se zaposlenici angažiraju u čim većem obimu radnih zadataka, te da se njima u tom smislu osigura rad vođen principom opunomoćenja.

S aspekta dijeljenja znanja, opunomoćivanjem se zaposlenici dodatno motiviraju da podijele svoja znanja i iskustva s drugim zaposlenicima, jer se dodjeljivanjem veće autonomije među zaposlenicima razvijaju osjećaji usmjerenosti i kontrole nad radnim okruženjem (**Liden**, **Arad, 1996**.). U ovom je segmentu organizacijske kulture potrebno uzeti u obzir kompleksnost radnih zadataka čija se operacionalizacija prepušta zaposlenicima, jer su recentna znanstvena istraživanja pokazala da će opunomoćivanje ostvariti jače efekte kod iskusnijih zaposlenika jedino kroz dodjeljivanje kompleksnijih zadataka (**Leach i dr., 2003**.). Opunomoćivanjem se, prema tome, može utjecati na zadovoljstvo zaposlenika, a što posljedično pridonosi njihovu jačem angažmanu u aktivnostima dijeljenja znanja.

3.3.1.3. Kontinuirano učenje

Davanje znanja i primanje znanja podrazumijevaju da zaposlenici aktivno unapređuju svoja znanja i sposobnosti, odnosno da su posvećeni kontinuiranom učenju. Prema **Huberu** (**1991**.) učenje predstavlja potencijalnu promjenu u ponašanju zaposlenika koja je posljedica procesuiranja informacija. Organizacija uči kada bilo koja njezina sastavnica uči, odnosno prikuplja znanje koje ocjenjuje potencijalno korisnim za poslovanje. Kontinuirano učenje podrazumijeva da zaposlenici imaju razvijenu učeću orijentaciju, odnosno da spremno prihvaćaju izazovne zadatke na čijem rješavanju ustraju, a što posljedično povećava njihovo zadovoljstvo zbog unapređenja vlastitih sposobnosti (**Tan, Zhao, 2003**.).

Potrebno je također naglasiti da se učenje unutar poduzeća odvija na tri različite razine: individualnoj, grupnoj i organizacijskoj. Prema **Crossan** i **dr.** (**1999.**), model učenja „4i" nalaže da poduzeća uče kroz četiri procesa: intuiciju, interpretaciju, integraciju i institucionalizaciju, a koji podržavaju učenje na sve tri razine. Individualno učenje realizira se kroz intuiciju (osobna iskustva, slike i metafore) i interpretaciju (zajednički jezik, kognitivne mape i dijalog); grupno učenje ostvaruje se kroz proces integracije (zajedničko razumijevanje i usklađivanje pojmova te interakcija među zaposlenicima); dok se organizacijsko učenje ostvaruje kroz institucionalizaciju (rutine, pravila i procedure). U nastavku se navode primjeri učenja na sve tri razine.

Kako bi se pravovremeno izbjeglo starenje organizacijskog znanja, poduzeća moraju već prilikom zapošljavanja voditi računa o tome kakva znanja potražuju. Zapošljavanjem radnika koji posjeduju znanja bitno različita od onih kojima poduzeće u datom trenutku raspolaže može se pridonijeti daljnjem učenju na individualnoj razini posredstvom socijalizacije, ponovnoj uporabi već postojećeg znanja u novom kontekstu (**March, 1991**.) ili tehnološkom repozicioniranju **(Tzabbar, 2009**.). Novozaposleni radnici koji posjeduju specifična znanja mogu narušiti rutinu postojećih timova, odnosno umanjiti njihov otpor tehnološkim promjenama. Osim toga, novozaposleni radnici koji već posjeduju radni staž u drugim organizacijama imaju pozitivan stav prema učenju iz pokušaja i pogreške, te su prijateljski nastrojeni s aspekta prenošenja znanja kolegama (**Jain, 2016**.). Dok formalno učenje služi postavljanju temelja općeg znanja, informalno učenje smatra se podjednako bitnim za unapređenja znanja zaposlenika tijekom njihovog radnog vijeka. **Warsick** i **Marsick** (**1997.**) navode sljedeće oblike informalnog učenja: i) učenje temeljeno na iskustvu; ii) učenje orijentirano na aktivnosti; iii) učenje u nerutinskim uvjetima; iv) učenje temeljem implicitnog znanja koje je nužno učiniti eksplicitnim; v) učenje koje je ograničeno prirodom zadatka, načinom definiranja problema i radnim kapacitetom učenika te vi) učenje temeljeno na proaktivnosti, kritičkom razmišljanju i kreativnosti.

Myers (**2020**.) opisuje model indirektnog interaktivnog učenja kao relacijskog procesa učenja koje se ostvaruje kroz diskursnu interakciju dvaju zaposlenika. Ovaj model naglašava specifičan učinak koji indirektno učenje ima ne samo na znanje i sposobnosti svakog pojedinca uključenog u interakciju, već i na njihove sposobnosti budućeg učenja. Na taj način moguće je ishode učenja prikazati u promjenama *repertoara reakcija* pojedinaca, odnosno situacija u kojima pojedinci reagiraju na radne zadatke ili pritiske iz okoline na drugačiji način u odnosu

na prijašnje reakcije na isti zadatak ili iskustvo preneseno od strane kolega (**Weick**, **1991.**). Promjene u repertoaru reakcija odražavaju povećanje zaliha dostupnih odgovora, poput obrazaca ponašanja, rutina i navika, kao i sposobnost drugačijeg kombiniranja postojećih zaliha znanja.

Grupno ili kolektivno učenje može se definirati kao interaktivno učenje zaposlenika kroz zajednički rad (**Jeong, Shin**, **2019.**). Kako bi realizirala grupno ili kolektivno učenje, poduzeća mogu primijeniti nekoliko vrsta učenja takvog tipa, poput: rotacije radnih mjesta, angažmana u privremenim projektnim timovima, mentoriranja, obuke na radnom mjestu, samoupravljajućih timova, samoinicirajućih timova, participativne prakse te nagrađivanja zaposlenika koji prakticiraju prenošenje vlastitih iskustava. Rotacija radnih mjesta i sudjelovanje u privremenim projektnim timovima pomažu zaposlenicima da prošire opseg društvenih mreža s drugim zaposlenicima i da na taj način lakše dijele znanje. Mentoriranje olakšava učinkovito dijeljenje određenih pojmova, simbola i žargona među zaposlenicima. Obuka na radnom mjestu omogućuje zaposlenicima da usklade svoje učeće napore sa zalihama znanja kojima poduzeće raspolaže. Sudjelovanjem u radu samoupravljajućih timova zaposlenici razvijaju osjećaj vlasništva nad poduzećem, što ih dodatno motivira da razvijaju kreativnost u rješavanju svakodnevnih radnih zadataka. Samoinicirajući projekti nude zaposlenicima mogućnost testiranja širokog raspona ideja, koncepata i mogućnosti, odnosno ispitivanja njihove upotrebljivosti u novim kontekstima. Participativna praksa motivira zaposlenike da interaktivno sudjeluju u rješavanju pojedinih problema, pa se povećava mogućnost postizanja kolektivnog uspjeha, budući da se interesi pojedinca stavljaju u drugi plan. Nagrađivanje zaposlenika koji dijele znanje temeljeno na iskustvu unapređuje učeći kapacitet zaposlenika njihovim poticanjem na dijeljenje naučenoga, čak i kada se radi o učenju iz pogrešaka.

Edmondson (**2002.**) je istraživala učeće procese 12 zasebnih timova koji djeluju u američkom poduzeću koje se bavi proizvodnjom uredske opreme. Fokus istraživanja bio je na mogućim preprekama učinkovitom učenju na timskoj razini. Kolektivno učenje prvenstveno se realizira kroz refleksiju koja se ostvaruje međusobnom diskusijom članova tima, međutim, ako su članovi tima preopterećeni radnim zadacima ili su previše podložni rutinama, do učenja neće doći. Ako se grupne diskusije i prakticiraju, one se često pokažu neučinkovitima zbog zanemarivanja relevantnih informacija koje nisu podijeljene među članovima grupe. Također se može dogoditi da je među članovima grupe došlo do refleksije i posljedičnog učenja,

međutim, sama implementacija naučenoga nije uslijedila zbog prevelikog oslanjanja zaposlenika na rutine, odnosno zbog nedostatka potrebnih sredstava i motivacije.

Prethodno opisani oblici učenja pridonose razvijanju temeljnih preduvjeta za učenje na razini organizacije. **Baets** (**2006.**) opisuje organizacijsko učenje kao povećanje sposobnosti organizacije da poduzme učinkovitu akciju. Sposobnost organizacije da učinkovito posluje prvenstveno ovisi o tacitnom korporativnom znanju. Pritom se posebice misli na korporativne mentalne modele kojima se zaposlenicima eksplicitno opisuju načini na koje menadžment uključuje zaposlenike u poslovanje poduzeća. Da bi se to ostvarilo, potrebno je da menadžeri razviju jedinstven način razmišljanja zaposlenika, što se smatra naročito zahtjevnim zadatkom uzme li se u obzir činjenica da zaposlenici imaju bitno različite osobnosti, pa stoga i različit stav prema svojem radnom mjestu.

Jedna od najpoznatijih klasifikacija organizacijskog učenja je ona koju su opisali **Argyris** i **Schon** (**1996**.): učenje jednostrukom i dvostrukom petljom. Učenje jednostrukom petljom ostvaruje se kada zaposlenici mijenjaju aktivnosti (procesna petlja), no ne i prateće politike, vrijednosti i pretpostavke (petlja politike poslovanja). Problem kod ove vrste učenja je u tome da ono ne dovodi do inkrementalnih promjena. S druge strane, učenje dvostrukom petljom dovodi do promjene politika, vrijednosti i pretpostavki jer se učenje iz procesne petlje isprepleće s učenjem iz petlje politike poslovanja. Da bi se ovo učenje realiziralo, potrebno je razraditi učinkovite komunikacijske sustave i sposobnost učenja svih članova organizacije. Preopterećenost poduzeća dnevnim poslovanjem može otežati prijelaz iz procesne petlje u petlju politike poslovanja, te na taj način onemogućiti učenje dvostrukom petljom.

Organizacijsko učenje započinje u trenutku kada poduzeće ciljano osnuje tim čiji je zadatak kodifikacija znanja (**Bingham** i **dr., 2014**.). Kodifikacija se provodi na način da se dokumentira organizacijsko znanje u alatima kao što su pravilnici i priručnici (**Zollo**, **Singh, 2004**.). Kodifikacija omogućuje i kvalitetnije evidentiranje tacitnog znanja pojedinaca o operacionalizaciji pojedinih radnih procesa. Analizirajući dvadeset godina poslovanja međunarodne korporacije *Dow Chemicals*, **Bingham** i **dr.** (**2014**.) zaključili su kako se simultano učenje provodi u tri faze: osnivanje tima za kodifikaciju znanja, pojednostavnjivanje inicijalnih procedura kako bi bile razumljive čim većem broju korisnika (raspored aktivnosti, rokovi realizacije pojedinih aktivnosti i sl.), te kontinuirano unapređenje inicijalnih procedura.

Organizacijsko učenje svakako ovisi i o razvijanju odgovarajuće kulture koja će dodatno poticati zaposlenike na učenje i kontinuirano usavršavanje. Tako **Schein** (**2010**.) tvrdi da bi učeća kultura trebala imati sljedeće karakteristike: i) proaktivnost (naglasak na procesu učenja); ii) učenje o učenju (učenje o načinima na koje se poduzeće prilagođava promjenama u okolini); iii) pozitivne pretpostavke o ljudskoj prirodi (teorija Y – rukovoditelji moraju upravljati pod pretpostavkom da su zaposlenici voljni i spremni učiti ako se opskrbe potrebnim resursima); iv) pozitivan stav o prilagodbi promjenama u okruženju; v) predanost istini kroz pragmatizam (izbjegavanje pretpostavki o ispravnosti svake primjenjive metode); vi) pozitivan stav prema budućnosti; vii) predanost potpunoj i otvorenoj komunikaciji; viii) poštovanje kulturološke raznolikosti; ix) predanost sustavnom načinu razmišljanja te x) uvjerenje da je analiza kulture dostatan temelj razumijevanja i unapređenja svijeta.

U izvanrednim okolnostima poput pandemije Covid-19, kada su poduzeća suočena s ograničenim resursima i nesigurnim poslovnim okruženjem, potreba za poduzetničkim udruživanjima još je naglašenija. Temeljem istraživanja provedenog nad uzorkom od 228 norveških poduzetničkih udruženja temeljenih na znanju, **Haneberg** (**2020.**) je pokušao definirati četiri klastera poduzeća, ovisno o njihovoj sklonosti suradnji: i) suradnici; ii) podržavatelji; iii) respondenti i iv) žrtve. Problem rada poduzetničkih udruživanja za vrijeme nepredviđenih okolnosti, poput korone, je u tome što nemaju razvijena potrebna znanja, rutine, resurse ili pregovaračku moć potrebnu da bi se nosili s raznolikošću. Upravo suprotno: krizne situacije mogu dodatno pojačati ovisnost poduzeća da uče od eksternih dionika, poput kupaca, dobavljača i investitora. Kod međuorganizacijskog učenja, dva i više poduzeća međusobno dijele kompleksna i tacitna znanja, tako da ovaj proces ima odlike internog i eksternog učenja. Zaključak istraživanja je da povećanje različitosti uzrokovano krizom kao što je to korona smanjuje međuorganizacijsko učenje. Nepredvidive okolnosti poslovanja mogu uzrokovati ili pojačati međuovisnost poduzeća, naročito u uvjetima oskudnih resursa. Premda nije nužno pravilo da poduzeća imaju iste kupce, pred njih mogu biti postavljene iste prepreke uslijed pandemije, pa tako zaposlenici dobivaju paralelne suradnike s kojima moraju surađivati.

U Tablici 6. izvršena je sistematizacija modaliteta učenja na individualnoj, grupnoj i organizacijskoj razini.

Tablica 6: Sistematizacija vrsta učenja na individualnoj, grupnoj i organizacijskoj razini

Razine učenja u poduzeću	**Aktivnosti procesa upravljanja znanjem i izvori njihova generiranja**
Individualna razina	i) učenje temeljeno na iskustvu; ii) učenje orijentirano na aktivnosti; iii) učenje u nerutinskim uvjetima; iv) učenje temeljem implicitnog znanja koje je nužno učiniti eksplicitnim; v) učenje koje je ograničeno prirodom zadatka, načinom definiranja problema i radnim kapacitetom učenika; vi) učenje temeljeno na proaktivnosti, kritičkom razmišljanju i kreativnosti (Warsick i Marsick, 1992.); vii) rotacija radnih mjesta
Grupna/kolektivna razina	i) angažman u privremenim projektnim timovima; ii) mentoriranje; iii) obuka na radnom mjestu; iv) samoupravljajući timovi; v) samoinicirajući timovi; vi) participativna praksa; vii) nagrađivanje zaposlenika koji prakticiraju prenošenje vlastitih iskustava (Jeong, Shin, 2019.)
Organizacijska razina	i) učenje jednostrukom petljom ii) učenje dvostrukom petljom (Argyris, Schon, 1996.)

Izvor: pripremila doktorandica.

Kontinuirano učenje na svim organizacijskim razinama podjednako je bitno za procese davanja i primanja znanja. U konceptualnom modelu dijeljenja znanja kontinuirano učenje vrednovano je kroz čestice kojima se mjeri provedba edukacijskih programa namijenjenih razvoju specifičnih znanja i vještina među zaposlenicima, a što je bitno za učenje na svim organizacijskim razinama; prepoznavanje fleksibilnosti i želje za promjenom kao bitnih motivatora zaposlenika za njihovim aktivnim sudjelovanjem u formalnim i informalnim oblicima učenja; poticanje poduzetničkog ponašanja među zaposlenicima toleriranjem povremenih pogrešaka koje se dogode u samoj realizaciji poslova te omogućavanje zaposlenicima da uče na pogreškama. Omogućavanjem kontinuiranog učenja povećavaju se kapaciteti zaposlenika za učinkovitije davanje, ali i primanje znanja.

3.3.2. Informacijsko-komunikacijske tehnologije (IKT)

Osnovna svrha IKT-a jest olakšavanje komunikacije među zaposlenicima. Tehnologija može racionalizirati dijeljenje znanja u smislu bržeg davanja i primanja znanja, no pitanje je koliki je njezin realan učinak na uspješnost poslovanja. **Cavaliere** i **dr**. (**2015.**) ispitivali su temeljem uzorka od 23 znanjem-intenzivna poduzeća u Toskani povezanost procesa dijeljenja znanja s organizacijskim (podrška vrhovnog menadžmenta), individualnim (zadovoljstvo zbog pomaganja drugima) i tehnološkim čimbenicima (učinkovitost i uporaba IKT-a). Zaključili su da IKT ne mogu sami po sebi jamčiti da će se zaposlenici početi ponašati na način da aktivno

podržavaju dijeljenje znanja, no percepcije koje zaposlenici razviju oko učinkovitosti IKT-a mogu utjecati na razvijanje pozitivnih stavova zaposlenika prema jačem korištenju tehnologija. Intenzivnije korištenje tehnologija može posljedično dovesti do povećanih napora zaposlenika u dijeljenju znanja, pogotovo u slučaju kada zaposlenici IKT alate percipiraju kao podržavajuća sredstva olakšane podijele znanja.

Schiuma i **dr.** (**2021.**) ispitivali su značaj IKT-a u poduzećima u vrijeme pandemije Covid-19, te su došli do sljedećih zaključaka: poduzeća prakticiraju pojačani rad na daljinu i virtualnu komunikaciju; elektroničku trgovinu i digitalne transakcije te pojačano korištenje automatizacije i umjetne inteligencije. Prema ovim autorima, poduzeća će vjerojatno ubrzati uvođenje većeg broja robota u proizvodne pogone i skladišta, dok će se poslužni roboti uvesti u interakciji s kupcima. Dakle, neosporna je činjenica da se poduzeća moraju sve više oslanjati na digitalne alate, pa je korisno izučiti njihovu ulogu s aspekta dijeljenja znanja, naročito u smislu dokazanog doprinosa sveukupnom poslovnom rezultatu, što će u ovom radu biti i učinjeno.

Premda se u mnogim radovima informacijsko-komunikacijske tehnologije (IKT) navode kao jedan od ključnih čimbenika učinkovitog upravljanja i dijeljenja znanja (**McCann III**, **Buckner, 2004**.; **Lee, Kim**, **2009**.; **Milanović**, **2010.**; **Andreeva**, **Kianto, 2012**.; **Al-Busaidi**, **2014**.), ipak je ovaj čimbenik često bio i objektom kritiziranja, jer se smatra da prevelik naglasak na IT odvlači fokus od činjenice da su zaposlenici ti koji su najvrjedniji prenosioci znanja. Često se događa da poduzeća izdvajaju značajna sredstva za nabavku određenih IKT-a ili softverskih programa, no do vidljivog poboljšanja uspješnosti poslovanja ipak ne dođe. Bitno je prilikom donošenja odluke o implementaciji određenih IKT-a u poduzeću voditi računa o tri bitna čimbenika: investicijama u IKT, njihovim mogućnostima u odnosu na prepoznavanje poslovnih prilika u poslovnom okruženju te njihove sposobnosti unapređenja postojećih oblika komunikacije. U nastavku se opisuje učinak tehnologija na svaki prethodno definirani čimbenik zasebno.

3.3.2.1. Investicije u informacijsko-komunikacijske tehnologije

U uvjetima hiperkonkurencije kada poduzeća moraju racionalno upravljati sredstvima, donošenje odluke o visini sredstava koja će se usmjeriti u IKT nalaže pomno planiranje. Problem leži u činjenici da mnoga poduzeća ulažu značajna sredstva u intranete i portale za dijeljenje znanja, međutim gomilanje informacija od strane skupih i nerijetko nefleksibilnih IS/IT inicijativa otežava iskoristivost postojećeg znanja u odnosu na ostvareni poslovni rezultat.

Iz navedenog razloga mnoga poduzeća usvajaju izjave o intelektualnom kapitalu, kao i druge oblike mjera za preciznije utvrđivanje vrijednosti povrata investicija u IKT (**McCann**, **Buckner**, **2004**.). Svrha je izjave o intelektualnom kapitalu mjerenje svih oblika neopipljivog kapitala u poduzeću: ljudskog, strukturalnog (organizacijskog) i relacijskog (potrošačkog). Dakle, uspješnost poslovanja nije jednoznačan pokazatelj, već je kompleksan umnožak svih tvrdih i mekih kategorija poslovanja, onih koje se mogu direktno zabilježiti, no i onih kod kojih je mjerenje otežano.

S obzirom na to da specifičnosti eksplicitnog i implicitnog znanja, potrebno je implementaciju IKT-a prilagoditi i vrstama znanja koje se prenosi. **Johannessen** i **dr.** (**2001**.) razvili su model optimalnog ulaganja u IKT sustave s aspekta njihove učinkovitosti u dijeljenju eksplicitnog i implicitnog znanja. Premda komunikacijski alati poput elektroničke pošte mogu ubrzati prijenos značajne količine informacija, takvi alati ne jamče dobivanje neposredne povratne informacije od primatelja poruke, stoga je potrebno osigurati i izravnu komunikaciju sudionika razmjene podataka, a radi osiguranja pretvorbe tacitnog znanja u eksplicitno. Time se ujedno stvaraju preduvjeti za učenje dvostrukom petljom koje omogućuje stvaranje konkurentske prednosti. **Sher** i **Lee** (**2004**.) i **Phang** i **Foong** (**2010.**) smatraju kako poduzeća moraju pojačati investicije u baze podataka koje sadrže kompetencije zaposlenika, ekspertne mreže i opise najboljih praksi radi učinkovitijeg dijeljenja implicitnog znanja, dok bi se investicije trebale usmjeriti u *online* sustave pretraživanja, intranet i elektroničku poštu radi učinkovitijeg dijeljenja eksplicitnog znanja. Osim o vrsti znanja koje se prenosi, bitno je prilikom implementacije nove tehnologije voditi računa i o jednostavnosti uporabe. Što je viša percipirana jednostavnost uporabe novih tehnologija, odnosno znanja koje je kodificirano u njima, to je veća i spremnost krajnjih korisnika da koriste nove tehnologije (**Xu**, **Quaddas**, **2007**.).

Turulja, **Cinjarević** i **Veselinović** (**2020.**) istraživali su učinak implementacije elektroničkog sustava razmjene znanja u javnom zavodu za zdravstvo u Sarajevu. Autore je posebno interesiralo koliko učinkovitim zaposlenici ocjenjuju elektronički sustav pri razmjeni eksplicitnog i implicitnog znanja. Premda je glavni poticaj uvođenju elektroničkog sustava bio smanjenje radnog opterećenja zdravstvenih djelatnika, kao i unapređenje sveukupne zdravstvene usluge, sama je implementacija upućivala na višestruke prepreke: povećani radni pritisak svih involviranih u implementaciju, nedostatak potrebnih IKT alata te loša povezanost s internetom. Nasuprot tome, istraživanje je ukazalo da pojačano korištenje IKT aplikacija za

instant razmjenu poruka, poput društvenih mreža, *Wikija* i blogova značajno pridonosi razmjeni znanja. Umrežavanje zdravstvenih djelatnika iz različitih odjela i jedinica putem instant aplikacija za grupnu komunikaciju olakšava kreiranje i dijeljenje tacitnog znanja jer omogućuje razmjenu različitih znanja i iskustava među zdravstvenim djelatnicima koji su se otprije poznavali.

Visoke investicije u IKT sustave, kao i visok stupanj nesigurnosti povezan s implementacijom nove tehnologije, naglašavaju činjenicu da je mjerenje isplativosti takvih projekata itekako značajno (**Palvalin** i **dr., 2013**.). Nedostatak razumijevanja ukupnih prednosti nove tehnologije može navesti investitore da usmjere sredstva u neučinkovite tehnologije. Drugi bitan razlog nadzora investiranih sredstava u IKT je nemogućnost izravnog mjerenja njihove koristi. Uštede vremena koje se ostvare korištenjem novih tehnologija neće imati utjecaja na uspješnost poslovanja ako se vrijeme nad kojim se ušteda ostvarila ne iskoristi na pravilan način.

Prije samog ulaganja u IKT sustave poduzeća moraju pomno razmotriti prednosti i nedostatke takvih ulaganja. Informatički sustavi se u većini slučajeva implementiraju kao podrška organizacijskom planiranju (**Rainer, Turban, 2008.**). Samo se planiranje može realizirati u nekoliko koraka: i) priprema strateškog plana za implementaciju IKT-a; ii) osnivanje nadzornog odbora koji vodi računa o usklađenosti korporativne i IKT strategije; iii) analiza troškova i koristi; iv) odabir strategije za implementaciju IKT aplikacija; v) studija izvedivosti te vi) dizajniranje sustava.

Panian (**2010.**) koristi ponešto drugačiju klasifikaciju postupaka implementacije novih tehnologija, no načelno opisuje iste korake kao i prethodni autori: i) planiranje informacijskog sustava (IS-a), odnosno određivanje opsega, njegovih korisnika, nedostataka postojećeg sustava te plana razvoja novoga IS-a. Potrebno je ustrojiti projektni tim za koji je poželjno da angažira zaposlenike različitih odjela i informatičare; ii) analiza razvoja IS-a (ako ne postoji faza planiranja, tada se veća pozornost pridaje ovoj fazi, pri čemu se detaljno i precizno definiraju zahtjevi korisnika koji se mogu odnositi na poboljšanje i nadogradnju postojećeg sustava ili pak na razvoj potpuno novog sustava); iii) oblikovanje IS-a (misli se na logički model IS-a, pri čemu je potrebno odrediti strukturu podataka, strukturu procesa te tehnološke i organizacijske uvjete); iv) izrada i testiranje IS-a (fizički razvoj IS-a i testiranje kojemu je svrha potvrda kvalitete proizvoda, odnosno IS-a te njegovog unapređenja); v) uvođenje u rad (instaliranje

opreme i programske potpore, prijenos podataka u novi sustav te usvajanje novog načina rada); vi) održavanje IS-a (uklanjanje uočenih i prijavljenih pogrešaka i nedostataka).

U razvoju IKT-a poduzeća mogu koristiti jedan od četiri temeljna oblika njegova razvoja: i) vanjski razvoj / engl. *Outsourcing*: ii) vlastiti razvoj / engl. *Insourcing*; iii) kupnju gotovog rješenja ili iv) unajmljivanje gotovog rješenja / engl. *Hosting*. Dok vanjski razvoj garantira da će sustav biti prilagođen organizaciji i njenom poslovanju, postupak sam po sebi može biti prilično dugotrajan i skup. *Insourcing* podrazumijeva da poduzeće raspolaže dovoljnim brojem informatičara uz mogućnost angažiranja vanjskih stručnjaka. Angažman vlastitih informatičara može otežati redovito poslovanje. Prednost u kupnji gotovog proizvoda je u tome što se njegova funkcionalnost odmah može provjeriti, dok je ograničenje prisutno u potrebi prilagodbe kupljenog programa. Poduzeća se stoga sve češće opredjeljuju za unajmljivanje gotovog rješenja, pa održavanje opreme i programsku podršku prepuštaju specijaliziranim informatičkim poduzećima.

S obzirom na doprinos IKT alata dijeljenju znanja, a u odnosu na prethodno obrazložena istraživanja, pozitivna obilježja digitalizacije koja su prepoznata i implementirana u konceptualni model odnose se prije svega na činjenicu da IKT alati olakšavaju provedbu svakodnevnog poslovanja jer omogućuju fokusiranije korištenje postojećeg znanja (**Sher, Lee**, **2004**.; **Pfang, Foong**, **2010.**) i učenje na daljinu. IKT sustavi su u konceptualnom modelu vrednovani i u odnosu na njihovu usklađenost s potrebama zaposlenika (**Xu, Quaddas, 2007**.), a zasebnom se česticom vrednovala i mogućnost redovitog ažuriranja IKT alata, jer su istraživanja poput onoga koje su proveli **Turulja**, **Cinjarević** i **Veselinović** (**2010**.) ukazala na činjenicu da se digitalizacija provodi bez usporednog vrednovanja potreba zaposlenika.

3.3.2.2. Prepoznavanje poslovnih prilika

Jedna od najbitnijih prednosti kvalitetno implementiranih IKT sustava jest mogućnost pretraživanja internog i eksternog poslovnog okruženja radi definiranja poslovnih prilika, odnosno reagiranja na prijetnje iz okruženja (**Moffet** i **dr.**, **2002**.). Poslovno okruženje moguće je definirati kao „sveukupnost materijalnih i društvenih čimbenika koji se izravno uzimaju u obzir pri donošenju odluka u poduzeću“ (**Duncan**, **1972:314**). **Daft** i **dr.** (**1988**.) tvrde da se poslovno okruženje može razdijeliti u sektore koji imaju različit učinak na poslovanje poduzeća: okruženje zadatka je ono koje je najbliže poduzeću te obuhvaća sektore s kojima poduzeće obavlja transakcije; opće se okruženje pak odnosi na sektore koji imaju neposredan

utjecaj na poduzeće. Ovo okruženje obično podrazumijeva političko-pravni, demografski i ekonomski sektor. Menadžeri mogu donositi odluke o poslovnom okruženju temeljem internih i/ili eksternih informacija. Interni izvori obuhvaćaju podatke, izvještaje, memorandume ili rasprave s menadžerima i zaposlenicima o vanjskom okruženju. Eksterni izvori obuhvaćaju izlazak na teren, razgovor s kolegama zaposlenima u drugim poduzećima, stručne časopise, stručne publikacije, informativne servise te sastanke udruženja struke.

Sundać i **dr.** (**2016.**) navode tri dimenzije ili atributa poslovnog okruženja: kapacitet, kompleksnost i dinamičnost. Kapacitet podrazumijeva dostupnost resursa o čemu će ovisiti i intenzitet rivalstva među poduzećima. Kompleksnost poslovnog okruženja pretežno se povezuje s dimenzijama homogenosti i heterogenosti koje prvi spominje Thompson u svome djelu *Organizations in Action* (prema **Kreiser** i **dr.**, **2002:899**). Dok heterogeno poslovno okruženje čine brojni elementi koji su po svojoj prirodi različiti, homogeno poslovno okruženje sačinjeno je od sličnih elemenata. Prema **Aldrichu** (**1979.**), turbulentnost poslovnog okruženja povećava se paralelno s rastom međusobnih uzročno-posljedičnih veza između elemenata poslovnog okruženja. Ovaj atribut poslovnog okruženja posebno nameće poduzećima potrebu stalnog učenja i usavršavanja kako bi promjene iz okruženja s vremenom postale prilike, a ne prijetnje. Nepovoljni uvjeti iz okruženja mogu biti uzrokovani radikalnim promjenama u industriji, intenzivnim regulatornim promjenama ili jakim rivalstvom među konkurentima (**Zahra, Garvis**, **2000.**). Neprijateljsko okruženje također može biti rezultat percipiranih nesigurnosti vezanih za konkurenciju, tržište ili proizvode. Kvalitetno razrađen IKT sustav za praćenje djelatnosti poslovnih partnera i konkurenata omogućit će poduzećima pravovremeno regiranje na prilike i prijetnje u okruženju. Primjerice, **Leonardi** i **Bailey** (**2008.**) izučavali su primjenu transformacijskih tehnologija (računalno podržane inženjerske aplikacije) u prijenosu projekata između matičnih organizacija u SAD-u i Meksiku i podružnica u Indiji. Transformacijske tehnologije omogućuju kodiranje implicitnog znanja o proizvodima, kao što su dimenzije proizvoda i karakteristike materijala od kojih su proizvodi izrađeni u računalne modele koje je moguće prenijeti elektroničkim putem. Međutim, istraživanje je pokazalo da indijski inženjeri nisu imali početna znanja potrebna za ispravnu interpretaciju modela, pa su u suradnji s američkim i meksičkim partnerima definirali karakteristike transformacijskih tehnologija koje će omogućiti njihovu bolju eksploataciju: precizno definiranje zahtjeva proizvodnje, nadziranje faza proizvodnje; popravak uočenih pogrešaka, strateško pozicioniranje pojedinih etapa proizvodnje i nadzor kvalitete.

Pri analizi udaljenog poslovnog okruženja pretežno se koristi PEST analiza koja obuhvaća (**Škalamera-Alilović**, **2007**.): i) političko-pravni, ii) ekonomski, iii) sociokulturni i iv) tehnološki (IT) sektor. Političko-pravno okruženje odnosi se na promjene i trendove koje iniciraju i provode akteri političke scene u nacionalnoj ekonomiji (vlade, zakonodavna tijela, sudstvo, nevladine organizacije, interesne skupine i drugi), odnosno na regulaciju kojom država uređuje poslovanje poduzeća na način da ga ili potiče (npr. patenti, državni poticaji i sl.) ili ograničava (npr. propisi o zaštiti okoliša). U analizi ekonomskog okruženja naglasak se stavlja na analizu cikličkog kretanja gospodarstva. Sociokulturno okruženje se uglavnom izučava s aspekta triju podsektora: a) demografskog, b) društvene brige za okoliš i c) društvenog u užem smislu. U odnosu na dijeljenje znanja kao područja od središnjeg interesa ove disertacije, posebnu bi pažnju trebalo posvetiti upravo analizi sociokulturnog okruženja jer se ono bavi ljudskim potencijalima presudnima za generiranje i prenošenje znanja. Tako se, primjerice, unutar ovog sektora izučavaju varijable poput kvalitete obrazovnog sustava i odlijeva mozgova. **Aslam** i **dr.** (**2022.**) izučavali su načine na koje tehnološki naprednije zemlje, poput Kine, prenose implicitna tehnološka znanja manje razvijenim zemljama, poput Pakistana. U istraživanju su sudjelovali zaposlenici NESPAK-a, najvećeg konzultantsko-inženjerskog poduzeća u Pakistanu koji su surađivali s kineskim partnerskim poduzećem Norinko. Suradnja dvaju poduzeća na infrastrukturalnom projektu podrazumijevala je računalno podržanu razradu novih procedura za projektiranje, prijenos tehnologije, analizu detektiranih poteškoća u izvedbi projekta te načine efikasne isporuke usluge klijentima. Pakistanski inženjeri omogućili su kineskim projektantima da prilagode svoja tehnološka rješenja specifičnim infrastrukturalnim uvjetima u Pakistanu. Premda se odnos između partnera može precizirati ugovorom, zaključak je istraživača da će se dugoročno bolji rezultati ostvariti kroz razvijanje neformalnih odnosa i društvenih veza kojima se pridonosi uspostavljanju povjerenja u komunikaciji. Implicitno znanje koje pakistansko poduzeće stječe od strane kineskoga ne samo da omogućuje kreiranje konkurentskih prednosti na lokalnom tržištu, već osigurava kapacitete i za širenje poslovanja na nova tržišta.

Osim prepoznavanja prilika u vanjskome okruženju, poduzećima je izuzetno bitno i prepoznavanje vanjskih prijetnji na koje je potrebno čim prije reagirati. Svaki pojedinac, grupa ili poduzeće koji mogu ograničiti sposobnost poduzeća da ostvari konkurentsku prednost smatra se vanjskom prijetnjom (**Barney**, **2014.**). Neke od najčešće prepoznatih vanjskih prijetnji jesu: i) opasnost od novih ulazaka poduzeća, naročito u industrije koje im osiguravaju visoke profitne marže; ii) ekonomija obujma (novo poduzeće mora predstavljati relativno velik postotak nabave

u industriji); iii) diferencijacija proizvoda (prepoznatljivost robnih marki poduzeća koja već djeluju u pojedinoj industriji); iv) zakonom zaštićena tehnologija (nova poduzeća moraju razviti zamjensku tehnologiju); v) ekspertiza (engl. *know-how*), vidljiva prije svega u kvaliteti, kreativnosti i inovativnosti; vi) povoljan pristup sirovinama; vii) vladajuća politika (npr. trgovinske barijere). Da bi poduzeća neutralizirala ovakve prijetnje, ona mogu poduzeti sljedeće mjere: i) neutraliziranje prijetnje pomoću troškovnog vodstva ili diferencijacije proizvoda; ii) neutraliziranje prijetnje supstituta (isto kao i kod neutraliziranja konkurencije); iii) neutraliziranje prijetnje od strane dobavljača vertikalnom integracijom unazad; iv) neutraliziranje prijetnje od strane kupaca integracijom unaprijed ili potragom za novim kupcima; v) tehnološka prednost (niži troškovi proizvodnje); vi) pravo prvokupa strateški vrijednih resursa; vii) unapređenje postojećih proizvoda i/ili tehnologija te viii) naglasak na kvalitetniju uslugu.

Kada se poduzeća suoče s novom tehnološkom paradigmom nametnutom trendovima poslovanja u eksternom okruženju, ona se okreću ili internim ili eksternim izvorima dijeljenja znanja, pri čemu će odlučujuću ulogu imati dva čimbenika: potencijal poduzeća za rekombinaciju postojećeg znanja, odnosno visina troškova koordinacije znanja (**Grigoriou** i **Rothaermel**, **2017**.). Temeljem longitudinalnog istraživanja provedenog u razdoblju od 25 godina na uzorku 106 globalnih farmaceutskih poduzeća autori su zaključili da su informacije prikupljene iz eksternog okruženja manje učinkovite kada poduzeće raspolaže internom mrežom znanja koja pokazuje visok potencijal ili za rekombinaciju znanja ili kada poduzeće ima visoke troškove koordinacije znanja iz eksternog okruženja. Farmaceutska poduzeća obuhvaćena istraživanjem koriste intranete koji obuhvaćaju informacije o ključnim izumiteljima u farmaceutskoj industriji, odnosno baze znanja koje omogućuju rekombinaciju postojećeg znanja i projekciju troškova prikupljanja novog znanja. Odluka o intenzivnijem prikupljanju znanja iz eksternog okruženja ovisit će i o načinu organizacije odjeljka istraživanja i razvoja unutar poduzeća. **Argyres** i **Silverman** (**2004**.) zaključili su da poduzeća s centraliziranim odjelima za istraživanje i razvoj i centraliziranim odlučivanjem o proračunu namijenjenom istraživanju i razvoju ostvaruju inovacije šireg tehnološkog raspona od poduzeća koja imaju decentralizirane odjele za istraživanje i razvoj. Jača kontrola *R&D* odjela i njihovih proračuna posljedično vodi k širim tehnološkim inovacijama.

Osim što poduzeća individualno propituju mogućnosti unapređenja poslovanja temeljem prilika u internom i eksternom poslovnom okruženju, nerijetko se u tu svrhu i udružuju sa sebi srodnim

poduzećima. **Zhang** i **Baden-Fuller** (**2010.**) ispitivali su na uzorku farmaceutskih, kemijskih i poljoprivrednih poduzeća aktivnih u biotehnološkom sektoru koje interne značajke poduzeća utječu na osnivanje učećih integracija s drugim poduzećima. Poduzeća izbjegavaju sklapanje takvih udruženja kada posjeduju temeljita znanja iz određenog tehnološkog područja jer se boje curenja znanja ili nemogućnosti generiranja novog znanja iz sklopljenih partnerstava. Suprotno tome, kada poduzeća posjeduju široke baze znanja, moguće je da radije pristupaju istraživačkim alijansama jer su uvjerena da će iz njih generirati nova znanja. Naime, poduzeća sa širokim bazama znanja lakše nadgledaju promjene na tehnološkom tržištu u smislu prepoznavanja novih prilika; lakše ocjenjuju potencijalne koristi novih tehnoloških projekata, odnosno rizike investiranja u nove tehnološke projekte koje planiraju poduzeti s partnerima; šire baze znanja upućuju i na bolje apsorpcijske sposobnosti u smislu prepoznavanja poslovnih prilika u industrijama koje podrazumijevanju radikalne tehnološke inovacije, poput biotehnologije; ovakve baze omogućuju bolju integraciju znanja disperziranog kod poslovnih partnera. Također je zaključak studije da, ako poduzeća imaju centralizirane *R&D* odjeljke, učinkovitija komunikacija među laboratorijima i jača kontrola proračuna od strane sjedišta mogu smanjiti mogućnost *curenja* informacija ili otuđivanja inovacija. Kvaliteta znanja u smislu širine i dubine baze znanja kojom poduzeće raspolaže bitnija je od kvantitete znanja *R&D* odjeljaka. Znanje kojim poduzeće raspolaže i koje je dublje od znanja potencijalnih partnera negativno će utjecati na osnivanje istraživačkih alijansi.

Način na koji poduzeća djeluju u nepredvidljivim uvjetima poslovanja, a u vrijeme pisanja rada, posebno je bilo od interesa istraživati u okolnostima prouzrokovanim pandemijom Covid-19. Jedna od izravnih posljedica izbijanja ove pandemije bio je zastoj opskrbe koji se očitovao u prekidima lanaca nabave i posljedično manjkovima robe i materijala diljem svijeta. **Kunovjanek** i **Wankmüller** (**2020.)** ispitivali su na koji način aditivna proizvodnja (engl. *Aditive Manufacturing*, AM) može podržati opskrbu osiguravanjem alternativnih načina proizvodnje traženih artikala. Aditivna proizvodnja omogućuje proizvodnju artikala pomoću računalno podržanog dizajna dodajući jedan po jedan sloj završnog proizvoda, omogućujući pritom slobodu dizajna, učinkovitost resursa i fleksibilnost proizvodnje. Da bi se osigurala učinkovitost resursa nerijetko se poduzeća udružuju, što se i dogodilo tijekom Covida, pa je tako, primjerice, Škoda proizvela više od 240.000 respiratora i zaštitnih maskica, Volkswagen i Seat su zajedno razvili vlastiti model respiratora, dok je Ferrari započeo s reprodukcijom ventilatora za zaštitne maskice. Kolaborativne mogućnosti aditivne proizvodnje temeljene na *online* razmjeni nacrta proizvoda koji su se slobodno učitavali, otisnuli i unapređivali, osigurale

su zadovoljenje dodatne potražnje. Temeljem ispitivanja 289 artikala proizvedenih pomoću aditivne proizvodnje autori su zaključili da se ovakva vrsta proizvodnje koristi i za standardizirane medicinske proizvode, poput osobne zaštitne opreme, ali i za proizvode koji se koriste za strogo definirane namjene, poput simulatora uzoraka ili alata za brzu dijagnostiku. Premda ova vrsta proizvodnje ima brojne prednosti, istraživanje je ukazalo i na neke njezine nedostatke, poput loše kvalitete reprodukcije, nedostatne opskrbe sirovinama i raznolikosti tehnologija koje se nastoji oponašati.

Poduzeća su svakodnevno suočena s brojnim prilikama i prijetnjama poslovanju koje se nalaze kako unutar, tako i izvan poduzeća. Komunikacijske tehnologije koje pridonose kvalitetnijem dijeljenju znanja svakako će imati presudan značaj za alociranje vrijednoga znanja unutar, odnosno izvan poduzeća. Promjene uvjeta poslovanja, koje su uslijedile nakon pojave pandemije Covid-19, ukazale za na potrebu intenzivnijeg korištenja digitalnih alata prije svega za skeniranje poslovnih mogućnosti u okruženju i slijedom toga prepoznavanje novih poslovnih prilika, što se vrednovalo kroz zasebne čestice u konceptualnom modelu dijeljenja znanja. IKT alati mogu pripomoći učinkovitom objedinjavanju znanja generiranog temeljem internih i eksternih izvora znanja (**Daft** i **dr**., **1988.**), a što je naročito vrijedno u okolnostima negativnih promjena u poslovnom okruženju (**Zahra, Garvis, 2000**.). IKT alati također su u konceptualnom modelu dijeljenja znanja vrednovani s aspekta njihovog potencijala za prikupljanje podataka o aktivnostima konkurenata i poslovnih partnera (**Barney, 2014**.; **Aslam** i **dr.**, **2022**.). Prepoznavanje poslovnih prilika ovisi, između ostaloga, i o mogućnosti IKT alata da osiguraju preduvjete za poboljšanu komunikaciju, pa se ta mogućnost detaljnije obrazlaže u sljedećoj cjelini.

3.3.2.3. Poboljšana komunikacija

Informacijsko-komunikacijske tehnologije olakšavaju dijeljenje znanja na način da osiguravaju nove komunikacijske kanale, pa tako **Sundać** i **dr.** (**2016.**) spominju novu generaciju IKT platformi kao sustave koji okupljaju eksterne i interne, personalne i impersonalne izvore u virtualnom obliku, zbog čega ih se smatra jedinstvenom metodom skeniranja poslovnog okruženja. IKT prilagođeni poslovnim sustavima omogućuju bolju iskoristivost znanja kroz njegovo sažimanje, filtriranje i prezentiranje čime se ujedno skraćuje vrijeme odlučivanja (**Steyn**, **Kahn**, **2008**.). Kolaborativni softveri mogu, prema **Podrug** i **dr.** (**2017.**), skratiti vrijeme odlučivanja ako zadovolje četiri temeljna kriterija: i) prevladavanje vremenskih i prostornih ograničenja; ii) povećanje opsega i brzine pristupa informacijama; iii) unapređenje

kvalitete odlučivanja i iv) unapređenje metaznanja (lokacija i dostupnost relevantnih baza podataka). **Caldeira** (**2007**.) navodi osnovne vrste informacijskih sustava koji zaposlenicima omogućuju brže i lakše odlučivanje:

i) sustavi automatizacije uredskog poslovanja (engl. *Office Automation Systems,* OAS); koriste se za pripremu izvještaja, planiranje i komunikaciju;
ii) funkcionalni informacijski sustavi (engl. *Functional Area Information Systems,* FAIS); omogućuju sumiranje podataka i pripremu izvještaja;
iii) sustavi poslovne inteligencije (engl. *Business Intelligence,* BI); pružaju računalnu podršku kompleksnom odlučivanju;
iv) ekspertni sustavi (engl. *Expert Systems*, EI); temelje se na oponašanju ljudske ekspertize korištenjem mogućnosti rezoniranja;
v) nadzorne ploče (engl. *Dashboards*); omogućuju direktan pristup strukturiranim informacijama u obliku izvještaja.

Kod organizacijskog učenja poduzeća moraju koristiti tehnologije koje omogućuju simultano učenje. U tu svrhu može se koristiti sustav rezoniranja baziran na različitim primjerima iz prakse (engl. *Case-based Reasoning System,* CBRS), koji se sastoji od baze podataka i softvera za povlačenje i analiziranje sličnih primjera iz prakse i njima pripadajućih podataka (**Baets, 2006**.). Baza podataka sadrži širok izbor primjera iz različitih industrija, pri čemu svaki slučaj sadrži opis okruženja, iskustva i vrijednosti koje motiviraju menadžere da promiču određene strategije, kao i presudne trenutke bitne za grupno učenje. Sustavi podrške grupnom odlučivanju (engl. *Group Decision Support Systems,* GDSS) razvili su se kao participativna metoda upravljanja potaknuta japanskim i nizozemskim metodama upravljanja. GDSS je računalni sustav koji se sastoji od softvera, hardvera, jezičnih komponenti, procedura i alata koji omogućuju zajedničko formiranje strategije. Ovakav sustav podržava automatsku „oluju mozgova“ radi pronalaženja odgovora na pitanja poput: „Što bi poduzeće trebalo poduzeti da postane učeće poduzeće u sljedećih pet godina?“ Temeljni zadatak GDSS-a je uklanjanje komunikacijskih prepreka pružanjem tehničkih mogućnosti, poput prikazivanja većeg broja prijedloga istovremeno, pružanja mogućnosti glasovanja, kompilacije prijedloga, anonimnih interakcija, modeliranja odluka i sl. (**Panian, 2010**.). Jedna od najvećih mana ovih sustava je ta da njegovi korisnici moraju mijenjati aplikacije ako žele promijeniti modalitet međusobnog komuniciranja (**Ackerman** i **dr., 2003**.). Alternativno rješenje može se pronaći u *TeamWave Workplaceu* koji predstavlja računalni sustav koji se bazira na odnosu klijent - server, pri čemu

server sadrži veći broj „soba“ namijenjenih komunikaciji. Administratori definiraju kriterije pristupanja zaposlenika pojedinim sobama temeljem tematskih područja koje sobe pokrivaju. Svim korisnicima programa dostupna je informacija o svim sudionicima komunikacije, kao i o njihovim aktivnostima u pojedinim sobama. Prednost ovog sustava je i mogućnost automatskog pohranjivanja zadataka obavljenih u svim sobama, kao i povijest korištenih aplikacija. Elektroničke telekonferencije (engl. *Tele- and Videoconferences*) podrazumijevaju elektroničku komunikaciju koja omogućuje većem broju zaposlenika na različitim lokacijama da se u isto vrijeme povežu. Videokonferencije predstavljaju iskorak u odnosu na telekonferencije jer omogućuju povezivanje zaposlenika uz simultano dijeljenje dokumenata. Posljednja verzija videokonferencija predstavlja *Telepresence* koji omogućuje da korisnici razmjenjuju podatke, audiozapise, slike, grafike i animacije. Međutim, ograničenje ovih sustava jesu visoke početne investicije – njihova implementacija može stajati do 400.000 USD uz mjesečno održavanje od 18.000 USD. Poduzeća poput Hewlett-Packard (Halo Systems), Cisca (TelePresence 3000) i Polycom (HDX) uspješno koriste ove sustave (**Caldeira, 2007**.).

Kako bi učenje bilo čim jednostavnije, mnoga poduzeća nerijetko koriste prednosti poslovne inteligencije. U najjednostavnijem određenju, poslovna inteligencija (engl. *Business Intelligence*) predstavlja ranije prikriveno znanje koje se otkriva iz operativnih, rutinski prikupljenih poslovnih podataka primjenom odgovarajućih računsko-logičkih metoda (**Panian, 2010.**). S obzirom na to da se *BI* tijekom razvoja koristi internim i eksternim izvorima podataka, moguće je razlikovati dvije osnovne podvrste poslovne inteligencije: tržišnu inteligenciju i unutarnju inteligenciju tvrtke. Tri su glavna izvora tržišne inteligencije: kupci, konkurenti i poslovni partneri.

Koncept koji je dosta blizak BI-ju jesu umjetne neuronske mreže (engl. *Artificial Neural Networks,* ANN) koje predstavljaju alate nastale iz umjetne inteligencije (AI). ANN su ujedno dio informacijsko-procesne paradigme koja simulira rad ljudskog mozga. Smatraju se izrazito značajnim alatom s aspekta pronalaženja uzoraka i strukturiranja bez prethodno dostupnih informacija. Omogućuju strukturiranje tacitnog znanja bez njegova kodiranja. Pomoću njih se razvijaju najbolji principi iz najboljih praksi. *ANN* su se pokazale naročito uspješnima u kreiranju brendova, vizualiziranju procesa upravljanja promjenama i identifikaciji profila kupaca (**Baets, 2006**.).

Umjetna inteligencija (engl. *Artificial Intelligence*) potkategorija je računalne znanosti koja izučava način procesuiranja informacija od strane ljudi te ih reproducira primjenom računalnih programa i robota. Pritom reproduciranje ljudskog ponašanja mora sadržavati elemente inteligencije (**Caldeira, 2007**.): i) učenje ili razumijevanje temeljem iskustva; ii) pronalaženje smisla u višeznačnim i kontradiktornim porukama te iii) učinkovito reagiranje na nove situacije. Najčešće primjenjivani sustavi AI-ja su: ekspertni sustavi, programi za procesuiranje prirodnog jezika, programi za prepoznavanje glasa te umjetne neuralne mreže. Kolaborativna tehnologija, poznata kao umjetna inteligencija močvare (engl. *Artificial Swarm Intelligence*, ASI) uklanja ograničenja vezana za grupno odlučivanje na način da omogućuje sudionicima interaktivne diskusije uz istovremeni pristup multimedijskim datotekama (**Metcalf** i **dr**., **2019.**). ASI omogućuje umreženim pojedincima da kombiniraju svoja eksplicitna i tacitna znanja u realnom vremenu, odnosno da rade sinkronizirano kako bi omogućili predviđanja, procijenili alternative i lakše donijeli odluke.

S obzirom na to da je već ranije naglašeno da se za prijenos tacitnog znanja mogu koristiti i određene informacijske tehnologije, **Panahi** i **dr.** (**2013**.) nastojali su istražiti koji mediji podržavaju lakše kreiranje i dijeljenje tacitnog znanja. Autori su zaključili da je tacitno znanje moguće dijeliti pomoću sljedećih društvenih medija: i) blogovi i mikroblogovi; ii) *Wiki* (društvene interakcije u svrhu grupnog dijeljenja znanja; iii) društvene mreže; iv) multimedijski alati za dijeljenje znanja (zaposlenici međusobno komentiraju i ocjenjuju znanja prikupljena u multimedijskim datotekama); v) RSS aplikacije (prikupljanje i distribuiranje znanja objavljenog na drugim lokacijama, poput blogova); vi) društveno povezivanje (engl. *Social Bookmarking*); povezivanje zaposlenika sličnih interesa na način da im se omogući da međusobno uređuju i dijele osobna znanja i iskustva).

Na uzorku od 200 velikih, srednjih i malih hrvatskih poduzeća **Milanović** (**2010.**) je ispitivala razvijenost sustava upravljanja znanjem s naglaskom na uporabu IKT-a. Autorica je analizu temeljila na deset softverskih alata koji se koriste za upravljanje znanjem u poduzećima: i) sustavi bazirani na intranetu; ii) sustavi za upravljanje dokumentima; iii) sustavi za potporu radu u skupinama (engl. *Groupware*); iv) sustavi bazirani na umjetnoj inteligenciji; v) sustavi za mapiranje znanja (žute stranice koje sadrže popis eksperata koji posjeduju određena znanja); vi) portali znanja (pristup različitim vrstama informacija sa svrhom edukacije korisnika); vii) sustavi za upravljanje poslovnim tijekovima (podrška standardiziranim poslovnim procesima); viii) poslovna inteligencija; ix) alati za potporu inovacijama (temelje se na znanstvenom

sadržaju ili patentnim bazama podataka koje omogućuju pronalazak novog proizvoda ili unapređenje postojećih); x) kompetitivna inteligencija (znanje o sveukupnoj konkurenciji koje olakšava odlučivanje). Zaključak je autorice da hrvatska poduzeća bazično koriste neophodne IKT alate, no s obzirom na to da istovremeno ulažu napore u razvoj ljudske i kulturološke dimenzije kao nužnih preduvjeta učinkovite primjene IKT-a, tada ona pripadaju drugoj generaciji upravljanja znanjem. Prelazak na treću fazu upravljanja znanjem zahtijeva definiranje strategije upravljanja znanjem i jače poznavanje i primjenu softvera za upravljanje znanjem.

Osim za upravljanje internim poslovanjem, komunikacijske tehnologije koriste se i za upravljanje međuorganizacijskim poslovanjem. **Al-Busaidi** (**2014**.) je istraživala sklonost zaposlenika prihvaćanju međuorganizacijskih sustava za dijeljenje znanja (engl. *Inter-organisational Knowledge Sharing Systems*, IOKSS) na temelju uzorka 42 liječnika dviju omanskih bolnica. IOKSS su sustavi koji omogućuju diseminaciju eksplicitnog i implicitnog znanja između dviju ili više organizacija s ciljem povezivanja poslovnih procesa obiju organizacija radi obostranog unapređenja poslovanja. Uvažavanjem višestrukih koristi takvih sustava, poduzeća će biti potaknuta provesti *cost-benefit* analizu radi potencijalne implementacije sustava. U slučaju omanskih liječnika, korištenje IOKSS-a omogućilo je ostvarivanje individualnih koristi, koristi od uspješnijeg dijeljenja znanja, koristi za pacijente, organizaciju i sektor.

Premda načelno implementacija IKT-a donosi višestruke koristi, postoje i određene negativne strane, pa tako **Kaplan** i **Ansoff** (**1996**.) navode da sustavi koji loše funkcioniraju uzrokuju frustracije i neučinkovitost kod mnogih zaposlenika. IKT su i glavni izvori curenja informacija. Dostupnost prevelikoj količini informacija uzrokuje neučinkovitost kod zaposlenika te im pojačava stres. Prema tome, pri implementaciji IKT-a općenito poduzeća moraju voditi računa da nove tehnologije odražavaju potrebe korisnika, da su jednostavne za uporabu, te da uistinu omogućuju bolju i učinkovitiju komunikaciju. U suprotnome, negativne strane IKT-a mogu nadjačati pozitivne.

U nastavku se nudi pregled temeljnih vrsta IKT-a relevantnih za proces dijeljenja znanja uz kratki opis načina njihova korištenja.

Tablica 7: IKT alati za dijeljenje znanja i opis njihovih temeljnih značajki

SUSTAVI KOJI PODRŽAVAJU DIJELJENJE EKSPLICITNOG ZNANJA	
Case-based Reasoning System – CBRS (Baets, 2006.)	Sustav namijenjen izvlačenju sličnih primjera iz baze podataka te njihovoj analizi
Group Decision Support Systems – GDSS (Baets, 2006.)	Sustav koji omogućuje interaktivnu komunikaciju većeg broja sudionika u pripremi zajedničkih dokumenata (npr. izrada poslovne strategije)
TeamWave Workplace (Panian i dr., 2010.)	Sustav baziran na odnosu klijent - server, pri čemu server nudi mogućnost individualnog rada u većem broju „soba“, kao i kolektivnog rada na razini sustava
Tele- and Videoconferences (Caldeira, 2007.)	Komunikacijski sustavi za simultano povezivanje većeg broja dislociranih zaposlenika uz mogućnost interaktivnog dijeljenja dokumenata (videokonferencije)
SUSTAVI BAZIRANI NA UMJETNOJ INTELIGENCIJI	
Poslovna inteligencija - BI (Panian i dr., 2010.)	Računsko-logičke metode za pretraživanje podataka korištenih u svakodnevnom poslovanju
Artificial Neural Networks – ANN (Baets, 2006.)	Informacijsko-procesni algoritmi koji simuliraju rad ljudskog mozga
Artificial Swarm Intelligence – ASI (Metcalf i dr., 2019.)	Kolaborativna tehnologija koja olakšava grupno odlučivanje na način da podržava dijeljenje eksplicitnog i implicitnog znanja
SUSTAVI KOJI PODRŽAVAJU DIJELJENJE TACITNOG/IMPLICITNOG ZNANJA	
Social Web Tools (Panahi i dr., 2013.)	Blogovi i mikroblogovi; *Wiki*; Društvene mreže; Multimedija; RSS aplikacije; Društveno povezivanje (engl. *Social Bookmarking*)

Izvor: pripremila doktorandica.

Sumiraju li se prethodna istraživanja u odnosu na konceptualni model dijeljenja znanja, tada se mogu specificirati temeljna obilježja digitalnih alata za komunikaciju koja su prepoznata i evaluirana kroz čestice objedinjene u anketom upitniku. Ponajprije se tu misli na sposobnost IKT-a da olakša operacionalizaciju poslovanja primjenom sustava koji podržavaju dijeljenje znanja. Značajan doprinos IKT alata je i njihova podrška učenju na daljinu, što se također mjerilo i vrednovalo zasebnom česticom (**Baets, 2006**.). Dijeljenje znanja značajno je unaprijeđeno i primjenom sustava baziranih na umjetnoj inteligenciji koji olakšavaju pronalaženje potrebnog znanja (**Caldeira, 2007**.). Ažuriranje baza podataka radi osiguravanja pristupa točnim i relevantnim podacima još je jedna prednost IKT-a s aspekta unaprijeđene komunikacije među zaposlenicima, pa je i ta čestica zasebno mjerena i vrednovana u empirijskom istraživanju. Koristi IKT-a su brojne, međutim, one same po sebi ne mogu jamčiti napredak s aspekta dijeljenja znanja i uspješnosti poslovanja poduzeća, ako nisu dodatno poduprte i drugim čimbenicima, a jedan od njih jest podrška vrhovnog menadžmenta koja se opisuje u nastavku rada.

3.3.3. Podrška vrhovnog menadžmenta

Među čimbenicima koji potencijalno unapređuju dijeljenje znanja poseban značaj pridan je podršci vrhovnog menadžmenta. Naime, u ranijim se istraživanjima čimbenika u kojima se

izučavalo upravljanje znanjem, pa shodno tome i dijeljenje znanja kao njegovu središnju fazu, podrška vrhovnog rukovodstva uglavnom izučavala u okviru organizacijske kulture. Međutim, u ovom se radu čimbenik podrške rukovoditelja premješta u poziciju moderacijske varijable, te njegovo postojanje i jačina njegova utjecaja itekako mogu imati učinka na proces dijeljenja znanja. Posljednjih se godina broj teorija o rukovođenju znatno povećao. Teorije, koje se još nazivaju suvremenim teorijama, temelje se uglavnom na situacijskom pristupu rukovođenju, pa se tako razlikuju transakcijski i transformacijski pristup rukovodstvu. Osim na situacijskom pristupu, suvremene se teorije još temelje i na jedinstvenim osobinama rukovoditelja, pa se spominje i karizmatski pristup vodstvu (**Žugaj** i **dr**., **2004.**).

Transakcijsko rukovodstvo prisutno je kada jedna osoba preuzima inicijativu u međusobnom djelovanju s drugom osobom radi postizanja željenog cilja, pa se izučava kako poboljšati kvalitetu i kvantitetu učinka, kako zamijeniti jedan cilj drugim, kako smanjiti otpor pojedinaca prema samostalnom radu i sl. Transakcijski vođe oslanjaju se na ovisnost podređenih: sljedbenicima daju ono što sljedbenici žele (npr. nagrade) u zamjenu za ono što sami žele (npr. uspješno izvršenje zadataka). Transformacijski vođe uglavnom uspijevaju potaknuti svoje kolege, sljedbenike, kupce i dobavljače da pojačaju svijest o ciljevima važnim za organizaciju. To jačanje svijesti zahtijeva vođu s vizijom budućnosti, samopouzdanjem i unutarnjom snagom da se izbori za ono što je u skladu s temeljnim postavkama poslovne politike. Za razliku od transakcijskih vođa, transformacijski vođe vrlo malo pažnje poklanjaju razmjeni usluga. Njihovo vodstvo temelji se na mijenjanju sustava vrijednosti zaposlenih radi postizanja zajedničkih ciljeva.

Karizmatsko vodstvo je kombinacija određenih vizija budućnosti vođe i stupnja identificiranja podređenih s ciljevima poslovanja. U novijim društvenim znanostima karizmatski vođa se opisuje kao vođa koji snagom vlastitih sposobnosti može izrazito utjecati na sljedbenike tako da ga oni percipiraju kao osobu koja posjeduje neku vrstu nadnaravnih sposobnosti. Takvi vođe imaju veliku želju za moći, učinkovitosti i uvjerenje u etičku ispravnost svojih ciljeva. Osjećaj učinkovitosti čini takvu osobu vrhunskom vođom. Osobine koje čine karizmatskog vođu jesu: postavljanje zahtjevnih ciljeva, iskazivanje povjerenja zaposlenicima, motiviranje zaposlenika i velika očekivanja u smislu izvedbe zaposlenika. Negativna karizmatska ličnost u prvi plan stavlja svoju vlastitu moć (A. Hitler), dok pozitivna karizmatska ličnost utječe na sljedbenike na način da naglašava njihovu moć (M. L. King).

Slijedom općih zaključaka donesenih u cjelinama koje se bave opisom organizacijske kulture, pa i korištenja informacijskih tehnologija kao potencijalnih čimbenika koji unapređuju učinkovitost procesa dijeljenja znanja, moguće je pretpostaviti da menadžeri koji stvaraju pozitivno ozračje za dijeljenje znanja jesu oni menadžeri koji imaju odlike transformacijskih rukovoditelja, premda u kontekstu dijeljenja znanja može biti poželjno da rukovoditelji posjeduju i odlike karizmatskih vođa. Konceptualnim modelom dijeljenja znanja obuhvaćene su varijable za koje se pretpostavilo da, u odnosu na transformacijsko i dijelom karizmatsko rukovodstvo, mogu imati najpozitivnije učinke na dijeljenje znanja: otvorenost idejama zaposlenika, razvijanje međusobnog povjerenja između menadžera i zaposlenika te mentoriranje.

3.3.3.1. Otvorenost idejama zaposlenika

Tan i **Zhao** (**2003.**) definirali su podršku vrhovnog menadžmenta kao intenzitet poticanja zaposlenika na izlaganje ideja i davanje prijedloga. Otvorenost idejama podređenih nalaže od menadžera da imaju karakteristike transformacijskih rukovoditelja u smislu promicanja autonomije, predanosti i visoke razine povjerenja. **Bass** i **Rigio** (**2006.**) opisuju transformacijske rukovoditelje kao rukovoditelje koji razvijaju jak osjećaj odgovornosti prema zaposlenicima i radnim zadacima. Odanost zaposlenika transformacijskim rukovoditeljima postiže se temeljem dvije pretpostavke:

i) idealiziranim utjecajem (poistovjećivanje zaposlenika s ciljevima, interesima i vrijednostima rukovoditelja) te
ii) intelektualnom stimulacijom (poticanje zaposlenika da određeni dio vremena posvete projektima od vlastitog interesa).

Transformacijsko rukovodstvo ima četiri dimenzije (**Žugaj** i **dr**., **2004**.):

1. karizma (vođe stvaraju viziju budućnosti, daju zaposlenicima osjećaj ponosa i svrhovitosti);
2. inspiracija (vođe postavljaju visoke ciljeve, no prikazuju ih na jednostavan i ostvariv način);
3. stimulacija intelekta (potiče se daljnje razvijanje kognitivnih sposobnosti);
4. briga o pojedincu.

Purvanova i **Bono** (**2009**.) ispitivali su utjecaj transformacijskog rukovođenja u dvama različitim uvjetima: direktnoj komunikaciji suradnika osobnom kontaktom, odnosno virtualnoj

komunikaciji suradnika u virtualnom okruženju. Prema teoriji komunikacije determiniranoj tehnologijom tvrdi se da će transformacijsko rukovođenje biti slabije zastupljeno u virtualnom okruženju zbog izostanka vizualnih i audiopodražaja. Poticanje zaposlenika da preispitaju svoje odluke također se može činiti suviše izazovnim i vremenski zahtjevnim u virtualnom okruženju. Suprotno očekivanjima, rezultati studije pokazali su da su najučinkovitiji bili oni rukovoditelji koji su prakticirali osobine transformacijskih rukovoditelja u virtualnim timovima, pa su time i timovi ostvarivali bolje rezultate.

Transformacijski rukovoditelji uspostavljaju norme ponašanja posredstvom načina na koji se ophode prema zaposlenicima, pa na taj način određuju koliko slobode zaposlenici mogu imati u iznošenju vlastitih ideja i prijedloga, potiču li se na preuzimanje rizika, koje će se inicijative od strane zaposlenika vrednovati, u smislu povišice plaće, napredovanja i drugih nagrada (**Carmali** i **dr., 2011**.). **Coun** i **dr.** (**2019**.) istraživali su na uzorku od 163 zaposlenika nizozemske kompanije načine na koje dijeljeno i transformacijsko rukovođenje pridonose motivaciji zaposlenika da dijele znanje. Koncept dijeljenog rukovodstva podrazumijeva da zaposlenici zajedno preuzimaju odgovornost za aktivnosti koje inače preuzima formalni rukovoditelj. Međutim, time se ne umanjuje značaj koji formalni rukovoditelj ima u podučavanju, motiviranju i stimuliranju neformalne suradnje među zaposlenicima. Premda su dijeljeno i transformacijsko upravljanje konceptualno različiti, oni nisu i isključivi. **Coun** i **dr**. (**2019**.) zaključili su da transformacijsko rukovođenje mora biti razvijeno da bi se moglo operacionalizirati dijeljeno upravljanje, odnosno da bi se razvila klima otvorenog odnosa između menadžera i zaposlenika.

Kark i **dr.** (**2003**.) analizirali su na uzorku 888 bankarskih službenika koliko transformacijsko rukovođenje utječe na njihovu identifikaciju s rukovoditeljima, oslanjanje na rukovoditelje, te opunomoćivanje zaposlenika. Autori su zaključili da osobna identifikacija zaposlenika s rukovoditeljima predstavlja medijacijsku varijablu između transformacijskog rukovođenja i oslanjanja zaposlenika na rukovoditelje, dok socijalna identifikacija predstavlja medijacijsku varijablu između transformacijskog rukovođenja i opunomoćivanja zaposlenika. Zaposlenici koji imaju razvijenu jaku osobnu identifikaciju percipiraju sebe kao važne, sposobne i učinkovite zaposlenike, pa ih i rukovoditelji doživljavaju kao motivirane i odgovorne suradnike. Socijalna identifikacija podrazumijeva da se članovi tima poistovjećuju s timom kao cjelinom, pa zajednički uspjeh ili neuspjeh doživljavaju kao vlastita dostignuća.

Transformacijsko rukovođenje snažno je povezano s osobnom identifikacijom s rukovoditeljem i socijalnom identifikacijom s timom.

Usporede li se transformacijsko i transakcijsko rukovođenje, obično se nameće zaključak kako je transformacijsko rukovođenje prihvatljivije u nepredvidivim uvjetima poslovanja, dok se transakcijsko rukovođenje primjenjuje u *business as usual* modalitetu poslovanja. **Lee** i **dr.** (**2020.**) su istraživali koje je rukovodstvo najprikladnije u uvjetima pandemije Covid-19, te su došli do zaključka da bi to bilo rukovođenje koje se temelji na različitosti (engl. *diversity-oriented leadership*) potpomognuto strateškom internom komunikacijom među zaposlenicima. Rukovođenje temeljeno na različitosti podrazumijeva da rukovoditelji aktivno uključuju u odluke zaposlenike različitih podrijetla i karakteristika. Autori su također prepoznali i značaj potrebe zadovoljenja intrinzičnih motiva zaposlenika koji se javljaju u ulozi medijacije između dvaju definiranih čimbenika. Podržavanje različitosti ne samo da motivira organizacije da sagledaju situaciju iz različitih perspektiva, već ih i potiče da prihvate različite, no svejedno korisne prijedloge. Temeljem istraživanja provedenog na uzorku od 490 zaposlenika zaposlenih u 20 različitih industrija, autori su zaključili da rukovođenje temeljeno na različitosti pozitivno utječe na transparentnu internu komunikaciju i zadovoljenje intrinzičnih motiva zaposlenika, a što posljedično utječe na kvalitetnije dijeljenje znanja među zaposlenicima. Premda su zaključci provedenog istraživanja načelno prihvatljivi, glavna su mu ograničenja činjenica da nije provedeno longitudinalno istraživanje te da su poduzeća primijenila prilično različite pristupe prilikom odlučivanju o provedbi poslovanja u smislu zadržavanja radne snage u uredu ili poticanja radne snage da prakticira rad na daljinu. Slično su istraživanje proveli i **Schiuma**, **Jackson** i **Lönnqvist** (**2022**.) koji su analizirali vještine rukovoditelja u doba pandemije Covid-19. Prema ovim autorima, rukovoditelji su se za vrijeme pandemije susreli s tri kritična poslovna trenda: rad na daljinu odnosno virtualne interakcije; e-poslovanje odnosno digitalne transakcije te implementacija pojačane automatizacije i umjetne inteligencije. Takve su promjene poslovanja zahtijevale od rukovoditelja razvijanje odgovarajućih vještina, poput: kombiniranje strateške izvedbe s vizijom; donošenje radikalnih odluka vodeći pritom računa o inkluziji zaposlenika; uvažavanje potreba zaposlenika uz istovremeni naglasak na digitalizaciji; uvažavanje dugoročnih ciljeva poslovanja uz istovremeno poticanje inovativnosti te razvijanje vještina globalnog promišljanja uz lokalno djelovanje. Navedene karakteristike rukovođenja prigodnog u doba kriza poput pandemije Covid-19 nalažu kombiniranje nekoliko vrsta rukovođenja, od ranije opisanog transformacijskog rukovođenja, rukovođenja temeljenog na različitosti, no i adaptivnog rukovođenja u smislu prilagodbe „novom normalnom“.

Učinkovito dijeljenje znanja uslijedit će ako zaposlenici imaju razvijenu percepciju da se njihovo znanje i vještine poštuju i uvažavaju od strane nadređenih. Stoga se otvorenost menadžera idejama zaposlenika mjeri česticama koje ukazuju na to promoviraju li menadžeri sustav poslovanja u kojemu se cijene ideje svih zaposlenika, odnosno omogućuju li zaposlenicima da slobodno izražavaju svoje ideje i prijedloge na sastancima s nadređenima. Iznenadne promjene načina poslovanja zahtijevaju od menadžera da prilagode načine komunikacije sa zaposlenicima, a što je iskazano u čestici koja prati primjenu formalnih i informalnih oblika komunikacije. Socijalna identifikacija koja je bitna s aspekta povezivanja zaposlenika i njihovog poistovjećivanja s poduzećem mjerila se česticom koja iskazuje podršku menadžera osnivanju grupa za učenje radi učenja samoga, ali i generiranja novih ideja. Svi navedeni oblici razvijanja otvorenog odnosa menadžera i zaposlenika ujedno predstavljaju i temelj razvijanja međusobnog povjerenja koje se detaljnije opisuje u nastavku.

3.3.3.2. Razvijanje međusobnog povjerenja

Teorija društvene razmjene koja predstavlja, kako je već prije rečeno, teorijsko uporište koncepta dijeljenja znanja počiva na pretpostavci da među zaposlenicima postoji visoka razina povjerenja. Naime, ako povjerenje nije razvijeno, zaposlenici će svoja znanja povezivati s nadmoći nad drugim kolegama, te će češće pribjegavati skrivanju nego dijeljenju znanja. Da bi pojedinci dobrovoljno dijelili znanje potrebno je da razviju povjerenje u tuđe sposobnosti, dobronamjernost i integritet (**Cheng**, **Hung, 2010**.). Okruženje koje potiče visoku razinu povjerenja vrlo se često dovodi u vezu s predanošću zaposlenika organizaciji (engl. *Organisational commitment*), što podrazumijeva poistovjećivanje zaposlenika s poduzećem te samoinicijativno ulaganje dodatnih napora u učinkovito izvršavanje zadataka (**Van den Hoof**, **de Leeuw van Weenen**, **2004.; Carmeli** i **dr., 2011**.).

Tan i **Zhao** (**2003.**) izučavali su sklonost zaposlenika preuzimanju rizika kao jednu od značajki sklonosti zaposlenika učenju, zajedno s učećom orijentacijom i samoučinkovitošću. Konceptualnim modelom pretpostavlja se da učeća organizacija čini atribut organizacijske kulture, dok samoučinkovitost spada u psihološke komponente koje nisu predmet izučavanja ovog rada, te se jedino sklonost preuzimanju rizika izučava kao bitan segment konceptualnog modela. Prema **Tan** i **Zhao** (**2003.**) pojedinci koji su skloni preuzimanju rizika rado se prihvaćaju izazovnih zadataka jer je njihova pozitivna sklonost preuzimanju rizika povezana s očekivanom nagradom koju mogu prisvojiti po uspješnom izvršenju zadataka. **Bryant** (**2003**.)

tvrdi da transformacijski rukovoditelji mogu motivirati zaposlenike na preuzimanje rizika na dnevnoj bazi jer ih potiču da pomiču vlastite granice sposobnosti kroz kontinuirani doticaj s intelektualnim izazovima.

S obzirom na to da je sklonost pojedinaca da budu (ne)povjerljivi velikim dijelom odraz i karakternih osobina na nacionalnoj razini, **Ermisch** i **dr**. (**2009.**) analizirali su razinu povjerenja na uzorku od 372 pripadnika britanskih kućanstava. Viša razina povjerenja može sniziti transakcijske troškove jer potiče zaposlenike na neformalnu komunikaciju i izbjegavanje kompleksnih ugovornih odnosa. Autori su zaključili da čak 40 % ispitanika više vjeruje strancima, premda je njihovo povjerenje opravdano tek u polovici slučajeva. Općenito ljudi više vjeruju kada su zrelije životne dobi, kada su financijski dobro situirani, imaju riješeno stambeno pitanje, nisu vjenčani ili žive u suživotu s partnerom.

Premda se transformacijsko rukovođenje pretežno povezuje s njegovim pozitivnim učinkom na rukovoditelje i zaposlenike, takvo rukovođenje može imati i negativne konotacije ako rukovoditelji kod zaposlenika naiđu na nepovjerenje. Polazeći od *teorije očuvanja resursa*, **Lin** i **dr.** (**2019**.) analizirali su negativne posljedice transformacijskog rukovođenja. S obzirom na to da se od transformacijskih rukovoditelja očekuje da pronađu modalitete motiviranja zaposlenika da usmjere vlastite ciljeve ciljevima poslovanja, to od njih iziskuje značajan udio vremena i energije. Sukladno teoriji očuvanja resursa, transformacijski rukovoditelji koji ne nailaze na povjerenje zaposlenika u većini slučajeva daju ostavku jer im je puno teže vratiti izgubljene resurse nego pronaći nove. Prema tome, da bi transformacijsko rukovođenje bilo učinkovito, nužno je razviti visoku razinu povjerenja između rukovoditelja i zaposlenika, te između zaposlenika međusobno.

Razvijanje međusobnog povjerenja moguće je ako su menadžeri otvoreni idejama zaposlenika, pa se i ova varijabla, odnosno čestice kojima se ona mjerila, idejno nadovezuju na prethodnu varijablu. Primjerice, mjeri se identifikacija zaposlenika s poduzećem na način da se vrednovalo poimanje poslovnog uspjeha od strane menadžera kao vlastitog uspjeha, odnosno da se osobno cijenila reputacija koju poduzeće ima kod vanjskih dionika. Razvijeno povjerenje podrazumijeva da menadžeri djeluju kao savjetnici, a ne nadzor, odnosno da potiču zaposlenike na bavljenje rizičnim zadacima čak i pod cijenu neuspjeha. U okolnostima razvijenog povjerenja i suradnje menadžeri nerijetko preuzimaju i ulogu mentora, što se detaljnije opisuje u nastavku.

3.3.3.3. Mentoriranje zaposlenika

Iako je razvijanje visoke razine povjerenja kod zaposlenika poželjno jer se oni time motiviraju na samoinicijativno preuzimanje rizika pri izvršavanju poslovnih zadataka, u određenim je okolnostima kompleksnih zadataka poželjno da menadžeri potpomažu zaposlenike pri izvršavanju radnih zadataka, odnosno da primjenjuju mentorski odnos (**Singh** i **dr**., **2019.**). Rukovoditelji bi trebali redovito podučavati zaposlenike jer takvim ponašanjem dodatno ukazuju na značaj koji dijeljenje znanja ima za uspješnost poslovanja, posebno u uvjetima kada se izostanak podrške menadžera u podučavanju podređenih pokazao kao jedan od temeljnih uzroka neuspješnog dijeljenja znanja (**Lee** i **dr., 2012**.).

Podrška rukovoditelja podjednako je bitna pri mentoriranju novozaposlenih radnika, kao i pri usmjeravanju zaposlenika koji mijenjaju radno mjesto. Prema **Ackerman** i **dr.** (**2003.**) zaposlenici koji su suočeni s novim radnim zadacima moraju se podučiti o načinu izvršavanja novih radnih zadataka i o interakciji s ostalim radnicima o kojima ovisi uspješno izvršavanje zadataka. S obzirom na to da se prilagodba čini izravno na radnom mjestu, nerijetko se u tu svrhu primjenjuju formalni i informalni oblici učenja. Kao orijentacijski alat u mentoriranju zaposlenika rukovoditelji često koriste mape znanja koje predstavljaju grafički prikaz distribucije znanja u poduzeću, odnosno nude opis lokacija gdje se znanje nalazi, za što se ono koristi i tko je odgovoran za njega. Rukovoditelji također mogu prakticirati mentoriranje korištenjem simulacija i alata za modeliranje bazirane na modulima za podučavanje. Jedan takav alat, GuSS (engl. *Guided Social Simulation*) podučava kompleksne društvene vještine, poput podučavanja i nadgledanja. Programom rukovoditelji dobivaju uvid u mogući redoslijed događanja, odnosno u moguće reaktivne radnje koje mogu primijeniti u određenim okolnostima.

Učinkovito mentoriranje zaposlenika osigurava višestruke koristi: rukovoditeljima jamči da će zaposlenici predano izvršavati radne zadatke na način na koji se to od njih očekuje, zaposlenicima pomaže u unapređivanju njihovih vještina, potiče intrinzičnu motivaciju i bolji odnos s nadređenima te općenito poboljšava koordinaciju poslova na razini poduzeća kvalitetnijim korištenjem znanja i vještina zaposlenika (**Akinola** i **dr., 2018**.). Međutim, isti su autori temeljem svojeg istraživanja došli do zaključka da ženski rukovoditelji ostvaruju slabije koristi pri mentoriranju od muških jer su *apriori* manje skloni delegiranju radnih zadataka zaposlenicima koje mentoriraju. Razlog tome leži u činjenici da ženski rukovoditelji pri delegiranju poslova glavnu motivaciju iznalaze u društvenoj koristi koja će se ostvariti, dok se

njihovi muški kolege uglavnom orijentiraju na učinkovito obavljanje zadataka, odnosno vlastiti radni učinak, pa shodno tome mentoriranje provode na način da se zaposlenici upoznaju s izvršavanjem čim većeg opsega radnih zadataka.

Međuodnos okruženja u kojemu se zaposlenicima kroz mentoriranje omogućuje da sami izvršavaju radne zadatke i okruženja u kojemu se radna opterećenja izravno delegiraju bez posebnog mentoriranja izučavali su **Adhearne** i **dr.** (**2005.**) Mentoriranjem se zaposlenicima omogućuje da oslobode svoj potencijal na način da šire vlastite interese pri izvršavanju pojedinih zadataka, pa se time unapređuje njihovo zadovoljstvo, omogućuje im se da budu adaptabilniji i receptivniji naspram okruženja te se umanjuju birokratske prepreke učinkovitoj komunikaciji. Zaposlenici kojima se posredstvom mentoriranja delegiraju novi radni zadaci u pravilu pokazuju više razine učinkovitosti jer ulažu više napora u izvršavanje dodijeljenih zadataka, te su ustrajniji i učinkovitiji u rješavanju mogućih prepreka. Učinkovitost je pritom dodatno determinirana znanjem koje zaposlenici posjeduju o proizvodima, a koje je moguće unaprijediti kroz mentoriranje, te duljinom radnog staža kod pojedinog poslodavca. Autori su do zaključaka došli kombiniranjem ankete provedene nad 231 prodajnim predstavnikom u farmaceutskoj industriji i eksternom ocjenom zadovoljstva od strane 864 kupca. Zaposlenici s najnižom razinom znanja o proizvodima, odnosno industriji te s relativno skromnim iskustvom ostvarili su najveće prednosti od mentoriranja, jer im je omogućeno izvršavanje novih, izazovnijih radnih zadataka čijoj su operacionalizaciji prilazili s dodatnim radnim elanom.

Handžić (**2011.**) smatra da među društveno-tehnološkim čimbenicima koji pridonose učinkovitom dijeljenju znanja posebnu pažnju treba posvetiti podršci vrhovnog menadžmenta koja se očituje na više mogućih načina, pa tako i kroz mentoriranje zaposlenika. Autorica je istraživanje provela nad 185 zaposlenika koji rade u javnim službama BiH na razini lokalne uprave, na razini kantona i na razini regionalne vlasti. Analizom dobivenih rezultata, **Handžić** (**2011.**) je zaključila kako je značaj društvenih čimbenika, odnosno podrške vrhovnog menadžmenta daleko signifikantniji od tehnoloških čimbenika. Pritom je naglasila kako se podrška menadžmenta može operacionalizirati kroz primjenu raznih modaliteta mentoriranja zaposlenika jer se na taj način osigurava unapređenje postojećih kompetencija zaposlenika, a što je moguće implementacijom razvojnih planova odjela upravljanja ljudskih resursima. Naime, zaposlenike koji pokazuju pozitivne učinke mentoriranja potrebno je dodatno nagraditi poštujući pritom njihove aspiracije u odnosu na intrinzične i ekstrinzične motivatore.

U smislu konceptualnog modela dijeljenja znanja, mentoriranje zaposlenika značajno je jer se njime dodatno naglašava važnost dijeljenja znanja u poduzeću. Mentoriranje je podjednako bitno za novozaposlene jer im se time olakšava period prilagodbe i upoznavanja s poduzećem i kolegama, no bitno je i za zaposlenike koji se preraspoređuju na nova radna mjesta kako bi se lakše nosili s promjenama i naučili nove procedure. Osim ovim česticama, mentoriranje se također mjerilo i spremnošću poduzeća da provode rotacije zaposlenika kako bi im se omogućilo proširenje postojećih znanja i iskustava kroz interakciju s menadžerima drugih odjela. Mentoriranje je interaktivan proces, te od njega koristi imaju i mentori i osobe koje se mentoriraju, pa se na taj način dodatno podržavaju procesi dijeljenja znanja, a što može imati pozitivan utjeaj i na ukupnu uspješnost poslovanja poduzeća.

3.4. UTJECAJ DIJELJENJA ZNANJA NA USPJEŠNOST POSLOVANJA PODUZEĆA

Praćenje uspješnosti poslovanja poduzeća kompleksna je aktivnost, posebno ako se uzme u obzir činjenica da ne postoje jednoznačni pokazatelji uspješnosti poslovanja. Premda se unazad tridesetak godina prednost uglavnom davala financijskim pokazateljima uspješnosti poslovanja, dinamičnost i nepredvidivost poslovnog okruženja potvrdila je da praćenje isključivo financijskih pokazatelja nije dovoljno pouzdano. Uz standardne, računovodstvene pokazatelje uspješnosti poslovanja, kao što su rast prodaje ili indikatori profitabilnosti, **Sundać** i **dr.** (**2016.**) navode i indikatore sveukupne uspješnosti koji se dobivaju mjerenjem percepcija donositelja odluka. Ovi su autori analizirali konstrukt uspješnosti poslovanja na uzorku od 24 članka, te su zaključili da su autori čak 16 članaka formirali pokazatelje uspješnosti koje su temeljili na percepcijama donositelja odluka. Prema tome, poduzeća sve više uviđaju potvrdu dodatne verifikacije financijskih pokazatelja i to iz nekoliko razloga (**Buble** i **dr**., **1997**.): i) financijske mjere uspješnosti poslovanja odražavaju financijske rezultate odluka donesenih u prošlosti; ii) zaostaju u odnosu na potrebe donositelja odluka te su iii) podložne postupcima kreativnog računovodstva.

Pokazatelji uspješnosti poslovanja trebaju biti točni i pouzdani, no ti se kriteriji različito vrednuju s aspekta vlasnika i menadžera. Interesi vlasnika definiraju osnovnu svrhu upravljanja poduzećem, koja je u tradicionalnom smislu uvijek bila usmjerena na financijski rezultat. Financijske mjere uspješnosti poslovanja poduzeća jesu one koje se izračunavaju na temelju monetarnih ekonomskih kategorija te su izražene u monetarnom obliku (**Buble** i **dr., 2003.**). Uobičajeno se analiziraju povrat na imovinu (engl. ROA – *Return on Assets*) i povrat na

vlasnički kapital (engl. ROE – *Return on Equity*). Pokazatelj ROA izračunava se pomoću računovodstvene vrijednosti imovine, dok se pokazatelj ROE temelji na vlasničkom dijelu kapitala. Povrat na investirano (ROI) je mjera koja se koristi za: mjerenje profitabilnosti, prognoziranje zarade i planiranje i kontrolu (**Buble** i **dr., 2003**.). Opći obrazac za izračunavanje povrata na investirano glasi:

$$ROI = \frac{\text{Profit}}{\text{Investirano}}$$

Razvijeni opći obrazac za izračunavanje povrata na investirano glasi:

$$ROI = \frac{\text{Prihod od investicije - rashod koji treba odbiti od prihoda}}{\text{Vrijednost (trošak) investicije}}$$

ROI se može računati za svaku pojedinačnu investiciju i za svako vremensko trajanje.

Povrat na vlasnički kapital je značajna mjera za mjerenje profitabilnosti poduzeća s gledišta vlasnika koji su investirali svoj kapital i temeljna mjera za planiranje profita. Ta je mjera posebno bitna za poduzeća koja nemaju značajnijih svota drugih vrsta dugoročnih izvora financiranja kao što su dugoročni krediti ili obveznice.

Temeljni obrazac za izračunavanje pokazatelja ROE glasi:

$$ROE = \frac{\text{Neto profit}}{\text{Vlasnički kapital}}$$

U preciznijim analizama koristi se prosječan vlasnički kapital koji se računa na sljedeći način:

$$\text{Prosječan vlasnički kapital} = \frac{\text{Vl. kapital na početku razdoblja} + \text{Vl. kapital na kraju razdoblja}}{2}$$

No, u eksternim analizama se, radi pojednostavljenja, najčešće računa samo s vlasničkim kapitalom na kraju razdoblja.

Financijske mjere uspješnosti poslovanja koje se koriste u novije vrijeme razlikuju se od tradicionalnih jer, za razliku od tradicionalnih, nisu računovodstvene mjere te su usmjerene na tržište kapitala. U tom smislu, kao alternativni pokazatelji mogu se koristiti zarada po dionici (engl. EPS – *Earnings per Share*) i odnos cijena dionice/zarada (engl. P/E ratio). Međutim, s

obzirom na to da je hrvatsko tržište kapitala još uvijek u ranoj fazi razvoja, navedene je pokazatelje vrlo teško koristiti u praćenju uspješnosti poslovanja hrvatskih poduzeća (**Sundać** i **dr., 2016.**). Drugi bitan nedostatak ovih financijskih mjera jest taj što su vezane za računovodstvenu dobit. Dividende ne odražavaju uvijek uspješan poslovni rezultat, te bi ih kao takve trebalo izbjegavati kao temeljne pokazatelje uspješnosti poslovanja. Ekonomska dodana vrijednost (engl. EVA - *Economic value added*) je noviji financijski pokazatelj uspješnosti poslovanja koji obuhvaća trošak kapitala i duga, te predstavlja alternativni pokazatelj za ROA. Međutim, nedostatak ovog pokazatelja vezuje se uz poteškoće u izračunavanju ponderiranog prosječnog troška kapitala (engl. WACC - *Weighted average cost of capital*). Da bi se uklonili nedostaci navedenih financijskih mjera uspješnosti poslovanja, u novije se vrijeme sve češće primjenjuju financijski pokazatelji uspješnosti koji su povezani s tijekom novca, poput stabilnosti tijeka novca, rasta tijeka novca ili dostupne gotovine. Naime, dok se zarada može poimati kao percepcija menadžmenta o poslovnom rezultatu, gotovina se može poimati kao činjenično stanje, te je bolji pokazatelj ostvarenog rezultata jer nije podložna računovodstvenim manipulacijama kao što je to zarada (**Buble** i **dr**., **2003.**).

U novoj ekonomiji uočena je nužnost rješavanja dvaju osnovnih problema funkcioniranja profitnih i neprofitnih organizacija i to (**Kaplan, Norton, 1992.)**

1. Uspješna provedba strategije i
2. Adekvatno mjerenje performansi.

Rješavanje tih dvaju osnovnih problema predstavljaju temeljne izvore razvijanja modela *Balanced Scorecard* (BSC). Naziv BSC nema dobrog prijevoda na hrvatski jezik. Taj bi se izraz približno mogao prevesti kao „bilanca postignuća“ ili „model uravnoteženih postignuća“. Model BSC razvili su Robert Kaplan, profesor s Harvarda i David Norton, konzultant iz Bostona (**Ibidem**). Oni su 1990. godine istražili i razvili novu metodu mjerenja performansi za suvremene uvjete poslovanja koji je kasnije dopunjen i povezan sa strategijom poduzeća. Kaplan i Norton su kompletirali tu koncepciju i opisali je u knjizi „*The Balanced Scorecard – Translating Strategy Into Action*“. Model BSC nastoji financijskim pokazateljima i mjerama pridružiti i nefinancijske pokazatelje te jedne i druge povezati sa strategijom poduzeća. Ono što je najviše utjecalo na promjenu pristupa u mjerenju postignuća poduzeća je drukčiji način stvaranja vrijednosti u novoj ekonomiji. Naime, dok se u prošlosti vrijednost stvarala prevladavajuće na osnovi materijalne i ostale imovine iskazane u računovodstvenoj bilanci, u

današnje se vrijeme vrijednost prevladavajuće ostvaruje na osnovi neopipljive imovine koja se ne iskazuje u računovodstvenoj bilanci. To se ponajprije odnosi na neopipljivu imovinu koja proizlazi iz intelektualnog kapitala.

Jezgru konstrukcije modela BSC-a čini definiranje misije, vizije i strategije poduzeća na temelju kojih se definiraju planovi, zadaci, mjerila i budžeti u četiri sljedeće perspektive (**Kaplan**, **Norton**, **1996**.):

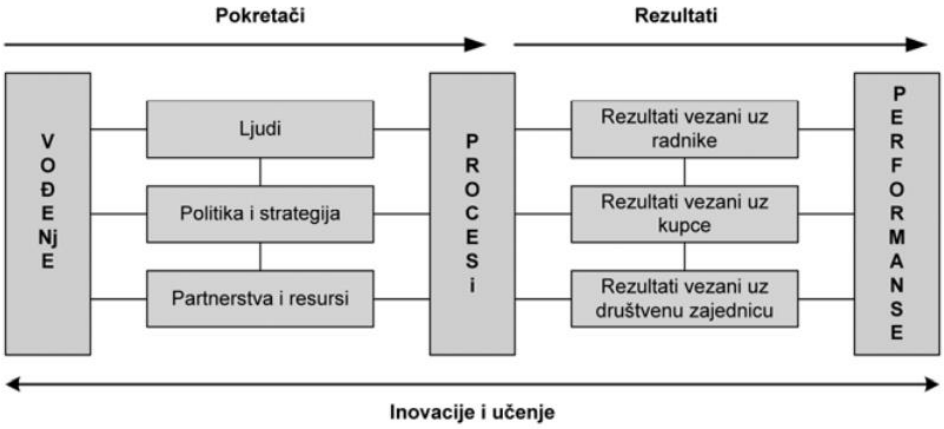
1. Financijska perspektiva (engl. *Financial Perspective*)
2. Perspektiva kupaca (engl. *Customer Perspective*)
3. Perspektiva internog poslovnog procesa (engl. *Internal Process Perspective*)
4. Perspektiva učenja i rasta (engl. *Learning and Growth Perspective*).

Poduzeća koja nastoje ostvariti dugoročnu održivost poslovanja, moraju pridati podjednaku pozornost svim navedenim perspektivama (**Ibidem**). U okviru financijske perspektive formuliraju se osnovni strateški ciljevi koji daju odgovor na pitanje: što bi poduzeće trebalo zaraditi u financijskom smislu i što će pripasti dioničarima ili vlasnicima poduzeća? Financijske mjere su iznimno bitne komponente BSC-a, a posebno u profitnim organizacijama. Te mjere govore kako se ostvaruje strategija u financijskom smislu. One su ujedno odraz ostvarenja mjera iz ostalih perspektiva koje su se tamo ranije iskazivale kao usmjeravajući pokazatelji. Perspektiva kupaca naglašava važnost zadovoljenja potreba kupaca i značenje zadovoljstva kupaca za provedbu strategije te stvaranje uspješnog poduzeća. U posljednje vrijeme to se područje menadžmenta naziva „menadžment usmjeren prema kupcima“ (engl. *Customer Relationship Management* – CRM) ili „menadžment utemeljen na zadovoljstvu kupaca“ (engl. *Customer Satisfaction Based Management*). Perspektiva internog procesa ogleda se u ciljevima i mjerama koje trebaju oslikati kako treba izgledati interni proces i kako ga treba unapređivati da bi zaposlenici, dioničari (vlasnici) i kupci bili zadovoljni. Cilj je identificirati ključne procese koji će kontinuirano dodavati vrijednost kupcima, zaposlenicima i dioničarima. Perspektiva usavršavanja i rasta efektivne snage zaposlenih kroz svoje pokazatelje treba odgovoriti na pitanje: „Kako unaprijediti ljudske resurse za postizanje vizije?“ Jedan od značajnih preduvjeta za postizanje rezultata u ostalim perspektivama je posjedovanje i razvijanje ljudskih resursa koji će te rezultate ostvariti. Naime, kada se postave ciljevi i odrede poticajne aktivnosti u perspektivi kupaca i perspektivi internog procesa, može se dogoditi da se pojavi jaz između postojeće organizacijske infrastrukture, znanja i vještina zaposlenih te postojećeg informacijskog sustava i razine potrebne za postizanje ciljnih rezultata. Mjere i ciljna

postignuća u perspektivi usavršavanja i rasta efektivne snage zaposlenih moraju pomoći da se premosti taj jaz, odnosno da se postigne odgovarajuće unapređenje u ovom području.

S obzirom na to da poduzeća sve više u redovitom poslovanju nastoje ostvariti poslovnu izvrsnost, a što uostalom nalažu i kriteriji vrednovanja definirani od strane Europske zaklade za kvalitetu (engl. *European Foundation for Quality Management* – EFQM), razvijen je model EFQM poslovne izvrsnosti kao unificirano mjerilo dosegnute kvalitete poslovanja (**Rusjan, 2005.**). Danas se ovim modelom koristi oko 30.000 europskih poduzeća. Iako se model EFQM koristi za dodjeljivanje europske nagrade za poslovnu izvrsnost, njegov je osnovni cilj stalno poboljšanje poslovne izvrsnosti poduzeća pomoću samostalne vlastite procjene. Model se sastoji od ukupno 9 kriterija od kojih se pomoću prvih pet mjere čimbenici koji potpomažu poslovnu izvrsnost, dok se s preostale 4 mjere rezultati. U nastavku je prikazan EFQM model izvrsnosti s pripadajućim čimbenicima.

Slika 2: Izvorni EFQM model poslovne izvrsnosti (1992. godina)



Izvor: Schreurs, Moreau, 2006.

Slično kao i kod drugih alata za mjerenje uspješnosti poslovanja koji kombiniraju financijske i nefinancijske pokazatelje, model EFQM često je bio predmet debata u znanstvenim radovima iz razloga što ne postoji jedinstven način praćenja poslovanja prema ovome modelu. Primjerice, **Samuelsson** i **Nilsson** (**2002.**) ispitivali su dosegnutu razinu poslovne izvrsnosti korištenjem polustrukturiranih upitnika na uzorku devet poduzeća, pri čemu su prikupljali mišljenja uprave i radnika. Autori su zaključili da poduzeća mogu primjenjivati različite pristupe mjerenju poslovne izvrsnosti sukladno ovom modelu dokle god primijenjeni pristup odgovara potrebama organizacije, koristi se kontinuirano, te promiče sudjelovanje svih interesenata. Svrha je ovog modela da poduzeća prepoznaju potrebu ustrojavanja strukturiranog pristupa definiranju aktivnosti koje je nužno poduzeti radi unapređenja poslovanja. U tom smislu, prilikom

planiranja samoprocjene potrebno ju je prilagoditi potrebama poduzeća, te ju implementirati na način da zaposlenici koji će u njoj sudjelovati budu pravovremeno educirani i informirani.

Prilikom provedbe samoprocjene moguće je koristiti bodovanje, što nije i pravilo, no pravilo je ustrojiti prioritete u provedbi odgovarajućih mjera za unapređenje. Provedba mjera za unapređenje nalaže izradu akcijskog plana i educiranja zaposlenika za provedbu akcijskog plana. Neophodno je pritom dijeliti znanja i iskustva, jer samoprocjena omogućuje internu i eksternu usporedbu poslovanja (engl. *Benchmarking*). U konačnici, ishod samoprocjene mora biti razvijanje i unapređenje radnih procedura. Prema tome, da bi poduzeća bila u stanju predočiti objektivan prikaz ostvarene razine izvrsnosti poslovanja, bitno je da mjerenju izvrsnosti sukladno EFQM modelu pristupaju holistički. U nastavku se navode primjeri pitanja koja poduzeća mogu koristiti prilikom samoprocjene bazirane na EFQM modelu poslovne izvrsnosti.

Tablica 8: Primjeri pitanja kojima se mjere potkriteriji vrednovanja postignuća prema EFQM modelu

R.b.	Potkriterij za vrednovanje poduzeća	Primjeri pitanja kojima se mjeri razvijenost određenog potkriterija
1.	Vođenje	Na koji način menadžment potiče razvijanje kulture kontinuiranog unapređenja? Kako menadžment provodi aktivnosti usmjerene na poboljšanje poslovanja? Kako menadžment motivira i ocjenjuje zaposlenike?
2.	Politika i strategija	Na koji se način formulira strategija? Na koji se način implementira strategija? Na koji se način komunicira strategija među zaposlenicima? Na koji se način nadzire provedba strategije?
3.	Upravljanje ljudskim resursima (naknadno dodano)	Na koji se način upravlja ljudskim resursima? Potiče li se zaposlenike na usavršavanje? Sudjeluju li zaposlenici u upravljanju poduzećem?
4.	Partnerstva i resursi	Koriste li se dovoljna financijska sredstva za osiguranje rasta i razvoja? Koliko su učinkovite informacije prikupljene od partnera? Koliko su kvalitetni odnosi s dobavljačima?
5.	Procesi	Jesu li procesi su sustavno oblikovani i upravljani? Primjenjuju li se standardi kao što su ISO standardi? Koriste li se poticaji za poticanje inovacija?
6.	Rezultati vezani za kupce	Jesu li kupci zadovoljni kvalitetom proizvoda i usluga? Jesu li kupci zadovoljni odnosom cijene i kvalitete? Jesu li usluge servisa dovoljno kvalitetne?
7.	Rezultati vezani za radnike	Koliki je indeks motivacije zaposlenika? Jesu li zaposlenici zadovoljni sigurnošću radnih mjesta?
8.	Rezultati vezani za društvenu zajednicu	Kakav je odnos poduzeća sa zajednicom? Sudjeluje li poduzeće u aktivnostima zajednice?
9.	Poslovni rezultati (naknadno dodani)	Koliki je ROE (profitabilnost)? Kakav je tekući odnos (likvidnost)? Koliki je stupanj zaduženosti (solventnost)? Kakav je odnos tržišne dodane vrijednosti (MVA odnos)? Koliki je BEX (indeks poslovne izvrsnosti)?

Izvor: prilagođeno prema Schreurs, Moreau, 2006.

Iz navedenih pitanja moguće je zaključiti da se veći dio modela orijentira na perceptivne pokazatelje, dok relativno manji dio mjeri izravno arhivske pokazatelje uspješnosti poslovanja.

Rusjan (**2005.**) je analizirao mogući utjecaj EFQM modela na odlučivanje i posljedično unapređenje uspješnosti poslovanja. Temeljem primjene EFQM modela autor je pristupio ocjeni izvrsnosti na način da je definirao objekt analize i odlučivanja (obično je to poduzeće kao strateška poslovna jedinica), relevantne kriterije odlučivanja za objekt te relevantne ciljeve vezane za objekt kojima se vrednuju kriteriji odlučivanja. Ciljevi se vezuju za ona područja poslovanja čije poboljšanje može unaprijediti poslovnu izvrsnost. Autor u radu koristi 32 potkriterija vrednovanja poslovanja, te naglašava kako međusobne veze pojedinih potkriterija mogu bili komplementarne ili oprečne. Tako je, primjerice veza između potkriterija Upravljanje ljudskim potencijalima i Rezultati kod zaposlenika komplementarna, dok je veza između potkriterija Društveni rezultati i Poslovni rezultati moguće i oprečna. Međutim, nedostatak modela jest u tome što ne nudi konkretne smjernice o mogućem otklanjanju uočenih nedostataka, poput strukturiranog načina eksploatacije onih segmenata poslovanja koji predstavljaju „korporativne snage“ ili definiranja prioritetnih područja mogućih unapređenja. Prema tome, nužno je preispitati temeljne postavke modela kojima se mjeri sama izvrsnost, odnosno do koje je mjere uopće moguće vršiti usporedbu odlučivanja temeljem EFQM-a modela i ostalih strateških, poslovnih i operativnih odluka.

Zaključno se može rezimirati da objektivno mjerenje uspješnosti poslovanja svakako nalaže kombiniranje financijskih i nefinancijskih pokazatelja uspješnosti poslovanja, te da poduzeća moraju samostalno učiniti odabir prikladnih alata za mjerenje poslovne uspješnosti temeljem specifičnih uvjeta u kojima njihova poduzeća posluju. Ocjena koja će se pritom generirati samo je smjernica daljnjeg djelovanja, a svrha cijelog postupka ocjenjivanja je prije svega definiranje jakih aspekata poslovanja koje je potrebno dalje unapređivati, odnosno onih slabijih područja djelovanja kod kojih je nužno sprovesti određene mjere koje će slabosti pretvoriti u snage. S aspekta dijeljenja znanja i njegovog mogućeg utjecaja na poslovni rezultat, konceptualnim modelom mjereni su perceptivni financijski i nefinancijski pokazatelji prije i nakon (odnosno tijekom) pandemije Covida. Učinila se i usporedba s arhivskim pokazateljima, no kako statističke analize nisu pokazale povezanost, daljnje se istraživanje fokusiralo samo na perceptivne pokazatelje. Naime, i u recentnoj literaturi koja se bavi izučavanjem i mjerenjem upravljanja znanjem, prvenstveno se koriste perceptivni pokazatelji uspješnosti poslovanja, čija se primjena dokazala svrsishodnom i u konceptualnom modelu za mjerenje dijeljenja znanja.

Čestice kojima su se mjerili perceptivni financijski pokazatelji ispitale su rast prodaje, optimiranje troškova, opće financijsko poslovanje i rast profitabilnosti. Čestice za mjerenje perceptivnih nefinancijskih pokazatelja obuhvatile su razinu kvalitete proizvoda i usluga, jačinu reputacije poduzeća, rast poduzeća i zadovoljstvo zaposlenika.

U sljedećem poglavlju opisana je provedba istraživanja te su prezentirani rezultati istraživanja.

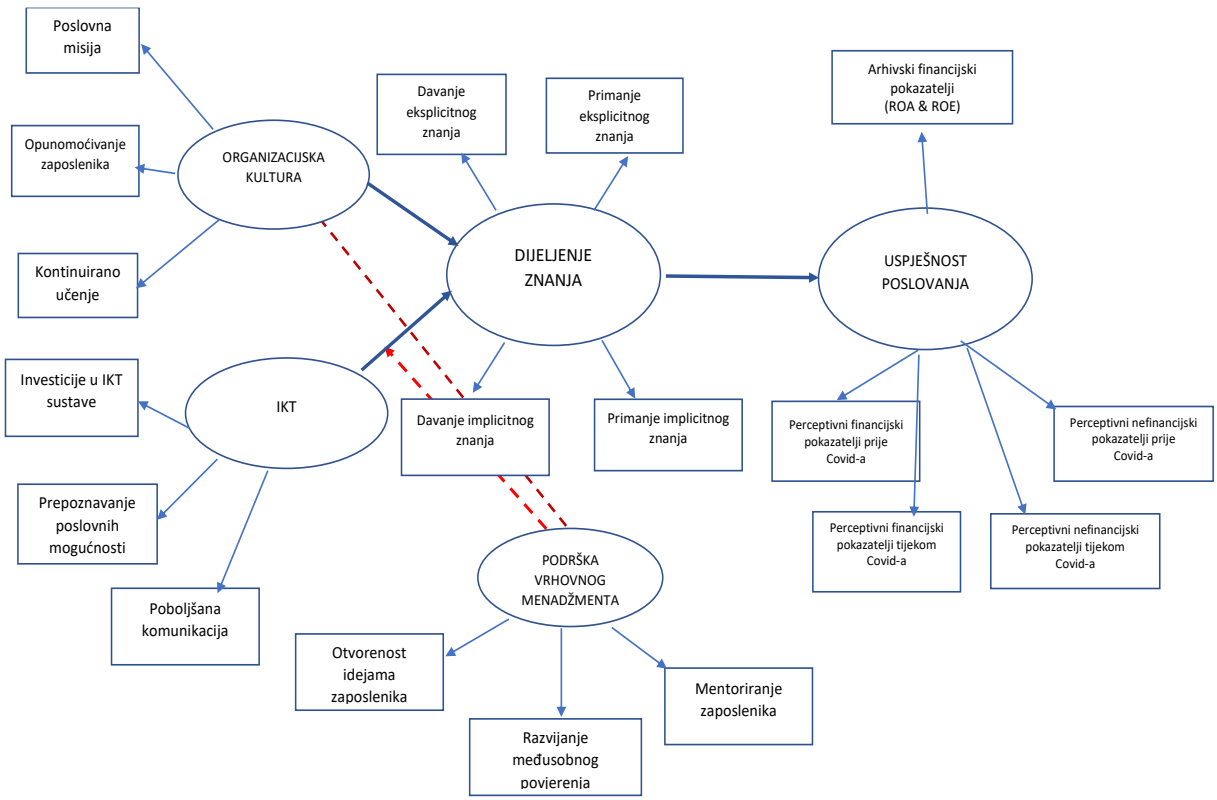
4. METODOLOGIJA ISTRAŽIVANJA MEĐUZAVISNOSTI DIJELJENJA ZNANJA I USPJEŠNOSTI POSLOVANJA PODUZEĆA

U ovoj cjelini detaljno će se opisati konceptualni model istraživanja, način operacionalizacije varijabli koje čine njegov sastavni dio, način definiranja uzorka istraživanja, način pripreme i diseminacije istraživačkog instrumenta, te će se prikazati i objasniti rezultati istraživanja.

4.1. KONCEPTUALNI MODEL ISTRAŽIVANJA UČINKA DIJELJENJA ZNANJA NA USPJEŠNOST POSLOVANJA PODUZEĆA

Doktorska disertacija obuhvaća konceptualni i empirijski dio istraživanja s ciljem testiranja konceptualnog modela dijeljenja znanja. Model je prikazan na Slici 1. i sastoji se od sljedećih varijabli: organizacijske kulture, informacijsko-komunikacijske tehnologije (IKT), podrške vrhovnog menadžmenta, dijeljenja znanja te uspješnosti poslovanja. Organizacijska kultura i IKT čine latentne prediktorske varijable, podrška vrhovnog menadžmenta predložena je u funkciji latentne moderacijske varijable, dijeljenje znanja predstavlja latentnu varijablu višeg reda koja ujedno predstavlja medijator između organizacijske kulture i IKT-a s jedne strane i rezultata uspješnosti poslovanja s druge.

Slika 3. Prikaz konceptualnog modela dijeljenja znanja



Izvor: izradila doktorandica.

Empirijski dio doktorske disertacije temelji se na prikupljanju primarnih podataka metodom anketiranja. U tu svrhu razvijen je mjerni instrument (anketa) koji se sastoji od šest cjelina. Upitnik je dizajniran kako bi mjerio koncepte u predloženom konceptualnom modelu i temelji se na relevantnoj literaturi. Prvih pet cjelina sadrži čestice kojima se mjere pojedini konstrukti na način da je svaka varijabla koja čini konstrukt opisana pomoću četiri čestice, izuzev središnje varijable dijeljenje znanja koja čini varijablu višeg reda. U prvoj cjelini mjeri se organizacijska kultura pomoću tri manifestne varijable: poslovna misija, opunomoćivanje zaposlenika i kontinuirano učenje. Sve se varijable mjere pomoću čestica djelomično preuzetih iz postojeće literature (**Sorakraikitikul**, **Siengthai, 2014**., **Oh, Han**, **2019.**), odnosno samostalno razrađenih ako ne postoji odgovarajući mjerni pokazatelj. Poslovna misija opisana je česticama/tvrdnjama koje obuhvaćaju sljedeće: transparentno promicanje poslovne misije, razvijanje zajedništva, odanost zaposlenika misiji poslovanja te naglasak na dijeljenju znanja kao bitnom segmentu poslovne misije. Opunomoćivanje zaposlenika opisano je česticama/tvrdnjama koje se odnose na: preuzimanje inicijativa od strane zaposlenika, aktivno sudjelovanje u donošenju odluka, visoki angažman u dijeljenju znanja međusobno unutar istog odijela, kao i sa zaposlenicima drugih odjela te mogućnost obavljanja izazovnih zadataka. Kontinuirano učenje opisano je česticama/tvrdnjama koje se odnose na: investiranje u edukativne i razvojne programe, motiviranje zaposlenika za kontinuirano učenje, uvažavanje pogrešaka i pokušaja kod zaposlenika te primjenu timskog rada i konsenzusa.

Potom slijedi informacijsko-komunikacijska tehnologija (IKT) koja se mjeri pomoću tri manifestne varijable: investicije u IKT sustave, prepoznavanje poslovnih prilika i moguće poboljšanje komunikacije čije su čestice djelom preuzete (**Gold, Malhotra** i **Segars**, **2001**.; **Phang, Foong, 2010**., **Andreeva, Kianto, 2012**.), a djelom samostalno osmišljene temeljem izučavane literature (**Handžić, 2010.; Oztekin** i **dr., 2015.; Mirzaee, Ghaffari, 2018.)**. Investicije u IKT sustave mjerile su se pomoću sljedećih čestica: implementacija sustava poslovne inteligencije, korištenje računalnih programa za učenje na daljinu, prilagođavanje IKT sustava potrebama zaposlenika te njihovo redovito ažuriranje. Prepoznavanje poslovnih prilika mjerilo se sljedećim česticama/tvrdnjama: korištenje IKT alata za prepoznavanje poslovnih prilika/pretraživanje relevantnih izvora; korištenje IKT-a za praćenje konkurencije; korištenje IKT-a za praćenje aktivnosti poslovnih partnera te primjena IKT-a među zaposlenicima radi širenja poslovnih kontakata. Moguće poboljšanje komunikacije mjerilo se česticama/tvrdnjama: primjena IKT alata pri zajedničkom izvršavanju zadataka; učenje na

daljinu uz pomoć IKT-a, lociranje potrebnih izvora podataka pomoću IKT-a te dostupnost točnih i relevantnih informacija zahvaljujući korištenju IKT-a.

U trećoj cjelini mjeri se podrška vrhovnog menadžmenta pomoću triju manifestnih varijabli: otvorenost menadžera idejama i prijedlozima zaposlenika, razvijanje međusobnog povjerenja i mentoriranje zaposlenika (**Lee**, **Kim, 2001.**; **Carmeli, Atwater** i **Levi**, **2011.**). Otvorenost menadžera idejama i prijedlozima zaposlenika mjerila se pomoću sljedećih tvrdnji: promicanje sustava vrijednosti u kojemu se cijeni mišljenje svih zaposlenika, poticanje zaposlenika na otvoreno iznošenje ideja i prijedloga, poticanje formalne i neformalne komunikacije u poduzeću od strane menadžera te povezivanje zaposlenika u grupe radi učenja. Razvijanje međusobnog povjerenja definiralo se kroz sljedeće tvrdnje: poistovjećivanje zaposlenika s uspjesima poduzeća, značaj koji zaposlenici pridaju reputaciji poduzeća među vanjskim subjektima, savjetodavna uloga menadžera te poticanje zaposlenika na bavljenje zahtjevnijim zadacima, čak i uz mogućnost neuspjeha. Mentoriranje zaposlenika opisalo se i mjerilo sljedećim tvrdnjama, odnosno česticama: prakticiranje redovitog mentoriranja radi isticanja važnosti znanja, organiziranje perioda orijentacije za nove zaposlenike, mentoriranje zaposlenika koji preuzimaju nove dužnosti te rotiranje zaposlenika radi prikupljanja novih znanja i vještina.

Četvrta cjelina obuhvaća središnju varijablu dijeljenje znanja koja ujedno predstavlja varijablu višeg reda, te obuhvaća davanje eksplicitnog i implicitnog znanja, kao i primanje eksplicitnog i implicitnog znanja. Davanje i primanje znanja mjere se svako zasebno pomoću šest čestica (**de Vries, Van den Hooff** i **de Ridder, 2006.; Lin, 2007.; Dysvik, Buch** i **Kuvaas, 2015.**). Davanje eksplicitnog znanja mjerilo se tvrdnjama: prenošenje znanja, vještina i iskustava kroz organizirane edukacije, pohranjivanje znanja i iskustava u virtualna skladišta, sastavljanje izvješća od strane zaposlenika o vlastitim postignućima. Davanje implicitnog znanja obuhvatilo je sljedeće čestice: iznošenje ideja i stavova zaposlenika na sastancima s nadređenima, pomaganje manje iskusnim zaposlenicima osobnim kontaktom, savjetovanje kolega u timovima. Čestice kojima se opisalo primanje eksplicitnog znanja obuhvatile su sljedeće: educiranje zaposlenika o načinima prijenosa znanja, vještina i iskustava, analiziranje izvještaja o tržišnim trendovima i potrebama od strane zaposlenika, te analiziranje periodičnih izvještaja o rezultatima poslovanja, organizacijskim politikama i procedurama. Primanje implicitnog znanja opisano je kroz sljedeće tvrdnje: postavljanje pitanja od strane zaposlenika na sastancima s nadređenima, obraćanje iskusnijim kolegama u slučaju potrebe za usvajanjem novih vještina te primanje savjeta od kolega u okruženju neformalnih timova.

Peta cjelina obuhvaća varijable kojima se mjerila uspješnost poslovanja. Pri definiranju kriterijske varijable Uspješnost poslovanja poduzeća korišteni su perceptivni financijski i nefinancijski pokazatelji uspješnosti poslovanja poduzeća prije i nakon pandemije. Perceptivni financijski pokazatelji prije/tijekom pandemije Covid-19 mjerili su se česticama: rast prodaje u odnosu na konkurenciju; uspješnost optimizacije troškova u odnosu na konkurenciju; financijsko poslovanje u odnosu na prethodne godine te profitabilnost u odnosu na konkurenciju. Perceptivni nefinancijski pokazatelji prije i tijekom pandemije Covid-19 mjereni su na sljedeći način: kvaliteta proizvoda i/ili usluga u odnosu na konkurenciju; reputacija u odnosu na konkurenciju; rast poslovanja u odnosu na konkurenciju te zadovoljstvo zaposlenika u odnosu na konkurenciju. Osim perceptivnih financijskih i nefinancijskih pokazatelja, modelom su obuhvaćeni i arhivski financijski pokazatelji: ROA (povrat na imovinu, engl. ROA - *Return on Asset*) i ROE (povrat na vlasnički kapital, engl. ROE - *Return on Equity*) (**Buble** i **dr.**, **2003**.; **DeSarbo** i **dr.**, **2004.**; **Oztekin** i **dr.**, **2015.**). Pokazatelj ROA prikazan je za svako poduzeće u digitalnom repozitoriju HGK-a, dok se pokazatelj ROE izračunao za svako poduzeće korištenjem dostupnih podataka iz iste baze, odnosno računanjem odnosa neto dobiti/gubitka i ukupnog kapitala.

Za perceptivne pokazatelje uspješnosti poslovanja (financijske i nefinancijske) podaci su se prikupili anketiranjem (**Oh, Han, 2019**.; **Singh** i **dr., 2019.**). Pritom je važno naglasiti da većina istraživanja iz područja dijeljenja znanja obuhvaća perceptivne financijske i nefinancijske pokazatelje uspješnosti poslovanja, dok se arhivski pokazatelji uopće ne koriste za mjerenje zavisne varijable (**Denison, Mishra**, **1995.**; **Chen, Mohamed**, **2008**.; **Zheng, Yang** i **McLean 2009**.; **Suppiah, Sandhu**, **2011**.; **Andreeva, Kianto, 2012**.; **Podrug, Filipović** i **Kovač, 2017**.; **Oh, Han, 2018**.; **Oyemomi** i **dr., 2019**.; **Singh** i **dr., 2019**.). Slijedom navedenoga, a temeljem provedenog istraživanja, došlo se do zaključka da je za analizu dobivenih rezultata dovoljno bilo izučiti perceptivne financijske i nefinancijske pokazatelje, premda se usporedba učinila i s arhivskim financijskim pokazateljima radi dodatnog ispitivanja povezanosti arhivskih i perceptivnih pokazatelja. U svrhu daljnje analize prikupljenih podataka, proveden je paired Sample T-test na perceptivnim i arhivskim pokazateljima koji je pokazao nepostojanje veze te se dalje u istraživanje išlo samo s perceptivnim pokazateljima, poduprijeto gore navedenim argumentima.

Završni dio upitnika sastoji se od ukupno deset čestica, od kojih se šest odnosi na ispitanike: struktura zaposlenika (spol, dob, radni staž, najviši završeni stupanj obrazovanja, položaj u

poduzeću, te radno iskustvo na trenutnom radnom mjestu), dok se četiri demografske varijable odnose na poduzeća (vlasnička struktura, veličina poduzeća, djelatnost poslovanja i djelokrug poslovanja poduzeća). Pri analizi prikupljenih odgovora za svaku fazu istraživanja ponudila se i analiza sudionika. Primjerice, sveukupni uzorak uglavnom čine muškarci starosti od 40 do 49 godina, koji su u radnom odnosu najčešće manje od 10 godina, imaju visoku stručnu spremu, obnašaju funkciju vrhovnog menadžmenta te su na toj poziciji manje od 10 godina. Poduzeća u uzorku uglavnom su mala, u privatnom vlasništvu, te su orijentirana na domaće tržište.

Moguće ograničenje pri mjerenju je pristranost ispitanika, što se pokušalo ublažiti na način da su upitnik mogli ispuniti menadžeri svih razina, kao i zaposlenici koji po opisu radnog mjesta ne spadaju u menadžerski kadar.

S obzirom na to da je upitnik obuhvatio mjerne varijable koje su dijelom izravno preuzete iz relevantne literature, dijelom prilagođene, no u određenim slučajevima gdje nije postojala razvijena varijabla, i novokreirane, smatra se vrijednim doprinosom ovog istraživanja ponuditi detaljan prikaz izvora čestica obuhvaćenih mjernim instrumentom, što se i čini u tablici koja slijedi.

Tablica 9: Analitički prikaz mjernih varijabli korištenih u anketnom upitniku i izvora njihovog kreiranja

NAZIV MJERNE VARIJABLE	IZVOR
ORGANIZACIJSKA KULTURA	
POSLOVNA MISIJA	
Naše poduzeće na transparentan način promiče poslovnu misiju.	Prilagođeno prema: Gold, Malhotra i Segars (2001.); Bartkus i dr. (2000.)
Jasno definirana misija potpomaže razvijanje zajedništva.	Prilagođeno prema: Carmeli, Atwater i Lewi (2011.); Lin (2007.); Chen, Hung (2010.); Gold, Malhotra i Segars (2001.); Hirota i dr. (2010.)
Zaposlenici razumiju smisao poslovanja, te su odani misiji poslovanja.	Prilagođeno prema: Donate, Guadamillas (2011.); Suppiah, Sandhu (2017.); Lu, Leung i Koch (2006.); Kuvaas i dr. (2017.); Chen, Hung (2010.); Carmeli, Atwater i Lewi (2011.); Lai, Wong (2020.)
U našem je poduzeću dijeljenje znanja značajan segment poslovne misije.	Prilagođeno prema: Lu, Leung i Koch (2006.); Kuvaas i dr. (2017.); Lin (2007.); Chen, Hung (2010.); Bock, Kim (2001); Handžić (2011.), Zulhamri i dr. (2013.)
OPUNOMOĆIVANJE ZAPOSLENIKA	
Naše poduzeće potiče preuzimanje inicijativa od strane zaposlenika.	Prilagođeno prema: Donate, Guadamillas (2011.); Lu, Leung i Koch (2006.); Bock, Kim (2001);
Zaposlenici se aktivno potiču da sudjeluju u donošenju odluka.	Prilagođeno prema: Donate, Guadamillas (2011.); Lu, Leung i Koch (2006.)
Od zaposlenika se očekuje visok osobni angažman u dijeljenju znanja.	Preuzeto od: Gold, Malhotra i Segars (2001.); Slične čestice u: Chen, Hung (2010.); Bock, Kim (2001.)

Zaposlenici visoko vrednuju mogućnost obavljanja izazovnih zadataka.	Prilagođeno prema: Donate, Guadamillas (2011.); Lu, Leung i Koch (2006.); Handžić (2011.)
KONTINUIRANO UČENJE	
Poduzeće izdvaja značajna sredstva za edukativne i razvojne programe kako bi unaprijedilo specifična znanja i vještine zaposlenika.	Preuzeto od: Kuvaas i dr. (2017.); Slične čestice u: Lu, Leung i Koch (2006.); Chen, Mohamed (2008.); Gold, Malhotra i Segars (2001.); Lee, Kim i Kim (2001)
Fleksibilnost i želja za promjenama temeljni su motivi kontinuiranog učenja u poduzeću.	Preuzeto od: Handžić (2011.) Slične čestice u: Kuvaas i dr. (2017.); Chen, Hung (2010.)
Naše poduzeće potiče poduzetničko ponašanje, zbog čega se zaposlenicima toleriraju povremene pogreške i eksperimenti.	Prilagođeno prema: Lu, Leung i Koch (2006.); Kuvaas i dr. (2017.); Lin (2007.); Gold, Malhotra i Segars (2001.)
Učenje iz pogrešaka omogućava se kroz timski rad i konsenzus.	Prilagođeno prema: Donate, Guadamillas (2011.); Gold, Malhotra iSegars (2001.)
IKT	
INVESTICIJE U IKT SUSTAVE	
Sustav poslovne inteligencije u našem poduzeću efikasno podržava svakodnevno poslovanje.	Prilagođeno prema: Andreeva, Kianto (2012.)
Računalni programi koji omogućuju učenje na daljinu unapređuju poslovanje.	Prilagođeno prema: Gold, Malhotra i Segars (2001.); Chen, Mohamed (2008.); Lee, Kim i Kim (2001.)
IKT sustavi u našem poduzeću prilagođeni su potrebama zaposlenika.	Preuzeto od: Chong (2006.); Handžić (2011.)
IKT sustavi u našem poduzeću redovito se ažuriraju.	Prilagođeno prema: Handžić (2011.)
PREPOZNAVANJE POSLOVNIH MOGUĆNOSTI	
IKT sustavi se u našem poduzeću koriste za otkrivanje poslovnih prilika.	Prilagođeno prema: Lee, Kim i Kim (2001.)
Naše poduzeće koristi IKT sustave koji omogućuju praćenje konkurencije.	Prilagođeno prema: Chen, Mohamed (2008.)
Naše poduzeće koristi IKT sustave koji omogućuju praćenje aktivnosti poslovnih partnera.	Preuzeto od: Gold, Malhotra i Segars (2001.)
IKT sustavi u našem poduzeću olakšavaju zaposlenicima korištenje društvenih kontakata u svrhu prikupljanja relevantnih informacija o novim prilikama na tržištu.	Prilagođeno prema: Andreeva, Kianto (2011); Chen, Mohamed (2008.); Handžić (2011.)
POBOLJŠANA KOMUNIKACIJA	
U našem poduzeću zaposlenici redovito komuniciraju *e-mailom* i sličnim alatima radi zajedničkog obavljanja radnih zadataka.	Preuzeto od: Suppiah, Sandhu (2011.)
IKT u našem poduzeću omogućuju zaposlenicima na različitim radnim mjestima i/ili lokacijama da zajedno uče na daljinu.	Preuzeto od: Gold, Malhotra i Segars (2001.)
IKT u našem poduzeću omogućuje zaposlenicima da u kratkom roku lociraju nužan izvor znanja, poput specifične baze podataka.	Prilagođeno prema: Donate, Guadamillas (2011.); Chen, Mohamed (2008.); Gold, Malhotra i Segars (2001.); Lee, Kim i Kim (2001.), Handžić (2011.)
IKT sustavi u našem poduzeću osiguravaju pristup točnim i pravodobnim podatcima.	Prilagođeno prema: Donate, Guadamillas (2011.); Gold, Malhotra i Segars (2001.);
PODRŠKA VRHOVNOG MENADŽMENTA	
OTVORENOST MENADŽERA IDEJAMA I PRIJEDLOZIMA ZAPOSLENIKA	
Menadžeri promiču sustav vrijednosti u kojem se cijeni mišljenje svakog zaposlenika.	Prilagođeno prema: Suppiah, Sandhu (2011.); Lu, Leung i Koch (2006.); Van den Hooff, Huysman (2009.); Gold, Malhotra i Segars (2001.); Handžić (2011.)
Zaposlenici mogu otvoreno iznositi ideje/prijedloge na sastancima s nadležnima.	Prilagođeno prema: Chong (2006.); Lee, Kim i Kim (2001.)
Menadžeri potiču zaposlenike na formalnu i neformalnu komunikaciju unutar poduzeća.	Prilagođeno prema: Suppiah, Sandhu (2011.)

Menadžeri potiču povezivanje zaposlenika u grupe radi učenja i generiranja novih ideja.	Prilagođeno prema: Donate, Guadamillas (2011.); Lu, Leung i Koch (2006.); Gold, Malhotra i Segars (2001.)
RAZVIJANJE POVJERENJA IZMEĐU ZAPOSLENIKA I MENADŽERA	
Zaposlenici doživljavaju uspjeh poduzeća kao vlastiti uspjeh.	Prilagođeno prema: Suppiah, Sandhu (2011.); Lu, Leung i Koch (2006.); Lin (2007.); Van den Hooff, Huysman (2009.)
Zaposlenicima je važna reputacija koju njihovo poduzeće ima među vanjskim subjektima.	Prilagođeno prema: Suppiah, Sandhu (2011.); Van den Hooff, Huysman (2009)
Menadžeri se ponašaju kao savjetnici te prakticiraju kontrolu isključivo za procjenu dostignuća zaposlenika.	Prilagođeno prema: Donate, Guadamillas (2011.); Chong (2006.), Suppiah, Sandhu (2011.); Lin (2007.)
Zaposlenici se potiču na bavljenje zahtjevnijim zadacima, čak i kada postoji mogućnost neuspjeha.	Prilagođeno prema: Suppiah, Sandhu (2011.); Kuvaas i dr. (2017.); van den Hooff, Huysman (2009.)
MENTORIRANJE (PODUČAVANJE) ZAPOSLENIKA	
Redovitim mentoriranjem zaposlenika menadžeri dodatno ističu važnost znanja za uspješnost poslovanja poduzeća.	Prilagođeno prema: Kuvaas i dr. (2017.); Lu, Leung i Koch (2006.); Handžić (2011.)
Novim zaposlenicima omogućen je period orijentacije radi upoznavanja organizacijske strukture i sistematizacije poslova.	Preuzeto od: Suppiah, Sandhu (2011.)
Zaposlenicima, koji preuzimaju nove dužnosti, omogućeno je mentoriranje, neovisno o tome koliko dugo rade u poduzeću.	Preuzeto od: Suppiah, Sandhu (2011.)
Primjenjuju se programi rotiranja zaposlenika pomoću kojih menadžeri različitih odjela pomažu zaposlenicima unaprijediti svoja znanja i vještine.	Prilagođeno prema: Kuvaas i dr. (2017.); Suppiah, Sandhu (2011); van den Hooff, Huysman (2009.)
DIJELJENJE EKSPLICITNOG I IMPLICITNOG ZNANJA	
DAVANJE EKSPLICITNOG ZNANJA	
Zaposlenici redovito kroz organizirane edukacije prenose znanja, vještine i iskustva drugim zaposlenicima.	Prilagođeno prema: Donate, Guadamillas (2011.)
Zaposlenici koriste virtualna spremišta za pohranjivanje znanja i iskustava koja time postaju dostupna drugim zaposlenicima.	Novokreirana čestica
Zaposlenici redovito pišu izvješća nadređenima o vlastitim postignućima (stečena znanja, vještine i iskustva).	Prilagođeno prema: Lu, Leung i Koch (2006.)
DAVANJE IMPLICITNOG ZNANJA	
Zaposlenici slobodno iznose ideje i stavove na poslovnim sastancima s nadređenima.	Prilagođeno prema: Donate, Guadamillas, (2011.)
Zaposlenici se trude osobnim kontaktom pomoći manje iskusnim kolegama.	Novokreirana čestica
Zaposlenici u timovima i u neformalnim kontaktima rado daju savjete kolegama/prijateljima.	Prilagođeno prema: Suppiah, Sandhu, (2011.)
PRIMANJE EKSPLICITNOG ZNANJA	
Zaposlenici se redovito educiraju o načinima prenošenja znanja, vještina i iskustava drugim zaposlenicima.	Novokreirana čestica
Zaposlenici organizirano primaju i analiziraju periodična izvješća o tržišnim trendovima i potrebama.	Prilagođeno prema: Chen, Hung, (2010.)
Zaposlenici organizirano primaju i analiziraju periodična izvješća o rezultatima poslovanja, te organizacijskim politikama i procedurama.	Prilagođeno prema: Suppiah, Sandhu, (2011.)
PRIMANJE IMPLICITNOG ZNANJA	
Tijekom poslovnih sastanaka zaposlenici slobodno postavljaju pitanja kolegama i nadređenima.	Prilagođeno prema: Gold, Malhotra i Segars, (2001.)

Zaposlenici koji žele usvojiti nove vještine otvoreno upitaju iskusnije kolege da im ih prenesu.	Prilagođeno prema: Donate, Guadamillas, (2011.)
Zaposlenici u timovima i u neformalnim kontaktima rado primaju savjete vlastitih kolega i prijatelja.	Novokreirana čestica
USPJEŠNOST POSLOVANJA PODUZEĆA	
FINANCIJSKI POKAZATELJI USPJEŠNOSTI POSLOVANJA (prije i tijekom Covida)	
U odnosu na prosjek djelatnosti, naše poduzeće je zabilježilo rast prodaje.	Prilagođeno prema: Prieto, Revilla (2006); Gold, Malhotra i Segars (2001.)
U odnosu na prosjek djelatnosti, naše poduzeće ostvaruje niže troškove poslovanja.	Prilagođeno prema: Singh i dr. (2019.); Chong (2006.)
Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina.	Prilagođeno prema: Prieto, Revilla (2006); Singh i dr. (2019.)
U odnosu na prosjek djelatnosti, naše poduzeće ostvaruje bolju profitabilnost.	Prilagođeno prema: Prieto, Revilla (2006.); Singh i dr. (2019.)
NEFINANCIJSKI POKAZATELJI USPJEŠNOSTI POSLOVANJA (prije i tijekom Covida)	
U odnosu na konkurenciju, kvaliteta naših proizvoda/usluga znatno je bolja.	Prilagođeno prema: Prieto, Revilla (2006.); Singh i dr. (2019.); Gold, Malhotra i Segars (2001.); Suppiah, Sandhu (2011.)
U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju.	Preuzeto od: Prieto, Revilla (2006.)
U odnosu na konkurenciju, naše poduzeće brže raste.	Prilagođeno prema: Suppiah, Sandhu (2011.); Gold, Malhotra i Segars (2001.); Singh i dr. (2019.)
U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike.	Preuzeto od: Prieto, Revilla (2006.); Singh i dr. (2019.)

Izvor: pripremila doktorandica.

Prethodna tablica nudi detaljan pregled čestica kojima su se mjerile manifestne varijable i to na sljedeći način: upitnik obuhvaća 64 pitanja koja se odnose na proces dijeljenja znanja i 10 pitanja kojima se mjere demografske varijable. Od 64 pitanja 4 su čestice u potpunosti izvorne, 41 čestica je prilagođena prema izvorima, a 11 ih je direktno preuzeto iz izvornih istraživanja. Potrebno je skrenuti pažnju na činjenicu kako su isti (perceptivni) financijski i nefinancijski pokazatelji uspješnosti poslovanja korišteni u dva navrata: prije i poslije pandemije Covida. Najveće prepreke pri definiranju čestica uočene su kod varijabli davanje i primanje znanja, a što dodatno naglašava značaj i doprinos razvijenog mjernog instrumenta.

4.2. ODREĐIVANJE UZORKA ZA EMPIRIJSKO ISTRAŽIVANJE POVEZANOSTI DIJELJENJA ZNANJA I USPJEŠNOSTI POSLOVANJA PODUZEĆA

Radi smanjivanja broja pitanja u upitniku, a posljedično i broja varijabli koje su se analizirale u istraživanju, upitnik je prvo testiran na ciljnoj skupini koju su činili zaposlenici sustava visokog obrazovanja: šest profesora iz područja srodnih predmetu istraživanja, dvoje statističara, jedan matematičar i jedan psiholog. Oni su zajednički pridonijeli jasnijem definiranju pojedinih pitanja, te su se sukladno njihovim prijedlozima pojedine čestice

objedinile: kod organizacijske kulture objedinjene su čestice kontinuirano učenje i učenje iz pogrešaka u zajedničku česticu kontinuirano učenje; kod IKT-a poboljšana komunikacija i brže odlučivanje u zajedničku česticu poboljšana komunikacija te kod podrške vrhovnog menadžmenta razvijanje povjerenja te poticanje zaposlenika na preuzimanje rizičnih zadataka u zajedničku česticu razvijanje povjerenja. Radi daljnjeg reduciranja broja varijabli obuhvaćenih konceptualnim modelom, rezultati na svakom indikatoru izračunati su kao prosječna vrijednost svih čestica koje pripadaju tom indikatoru. Naime, pri kreiranju latentnih varijabli, indikatori mogu biti čestice ili parcele čestica, a u slučaju predloženog konceptualnog modela, model je adekvatno pristajao podacima kada su u obzir uzete parcele čestica.

Istraživanje se provelo na uzorku velikih, srednjih i malih hrvatskih poduzeća prema popisu poduzeća Hrvatske gospodarske komore za područje cijele Republike Hrvatske, a ciljna skupina bili su vrhovni menadžeri ili njima bliski suradnici koji dijele njihova saznanja. Međutim, upitnik su mogli ispuniti i zaposlenici koji ne pripadaju menadžerskom kadru. Pretraživanje digitalne arhive Hrvatske gospodarske komore po kriterijima ukupnog prihoda i statusu „aktivnog poslovnog subjekta“ rezultiralo je popisom od 85.220 poduzetnika (na dan 10. 9. 2020.). Daljnjim uređivanjem tablice na način da se izluče velika, srednja i mala poduzeća, a uklone mikropoduzeća u inicijalnom uzorku od 10.000 poduzeća, došlo se do rezultata da je među 10.000 poduzeća 360 velikih (4 % inicijalnog uzorka), 1.435 srednjih (20 % inicijalnog uzorka) i 7.359 malih (76 % inicijalnog uzorka), dok su preostala poduzeća iz skupine mikropoduzeća koja ne ulaze u uzorak. Na taj način smanjen je inicijalni uzorak od 10.000 poduzeća na 9.154 poduzeća. Slučajan (engl. *random*) uzorak sastavio se na način da se vodilo računa o ukupnom uzorku nužnom za provođenje modeliranja strukturalnim jednadžbama, a koji se izračunao na način da je za svaku varijablu potrebno prikupiti oko 15 jedinica (anketnih upitnika). S obzirom na to da konceptualni model sadrži 24 varijable, nužno je bilo prikupiti uzorak od približno 360 jedinica. Prilikom generiranja uzorka od 1.500 poduzeća za *online* istraživanje, slučajan uzorak uređen je iteracijom 9.154 poduzeća po sljedećim kriterijima: 1. poduzorak – prvo poduzeće osmo po redu, a potom svako osamnaesto (sveukupno 500 poduzeća); 2. poduzorak – prvo poduzeće trideseto po redu, pa potom svako trideseto (sveukupno 301 poduzeće); 3. poduzorak – prvo poduzeće dvadesetpeto i potom svako dvadesetpeto sljedeće (sveukupno 361 poduzeće) te četvrti poduzorak – prvo poduzeće dvadeseto po redu, pa potom svako dvadeseto nadalje (sveukupno 452 poduzeća). Na taj način došlo se do uzorka od 1.614 poduzeća, međutim, kako većina poduzeća registriranih u digitalnom repozitoriju HGK-a nije imala prikazane elektroničke adrese, iste su se morale

pronaći pretraživanjem dostupnih *web*-stranica. S obzirom na to da je preliminarnim istraživanjem planirano obuhvatiti 1.500 poduzeća, kod viška od 114 poduzeća nisu uspješno pronađene *e-mail* adrese (anketni upitnici su se vraćali u sustav LimeSurveya). Distribucija *online* upitnika preko sustava LimeSurvey izvršena je na sljedeći način: u periodu od 11. 5. 2021. do 17. 6. 2021. godine odaslano je sveukupno 1.500 upitnika, pri čemu su podsjetnici odaslani u prosjeku tjedan dana nakon slanja prvog poziva. Prikupljena su sveukupno 282 upitnika, od čega su 126 bila potpuno ispunjena, dok ih je 156 bilo djelomično ispunjeno. Prilikom slanja upitnika korišteni su tokeni, tako da su se dobiveni odgovori u konačnici mogli povezati s respondentima radi lakšeg prikupljanja odgovarajućih arhivskih (financijskih) pokazatelja. Kod poštanskog istraživanja uzorak je generiran na način da se odabralo svako šesto poduzeće po redu, počevši od trećega. Poštanskim istraživanjem prikupljena su ukupno 224 kompletna upitnika, dok ih je 11 vraćeno zbog nepoznate adrese, te su kao takvi isključeni iz uzorka.

Slučajan odabir poduzeća pri generiranju uzorka nije rijetka pojava u istraživanjima koja se bave izučavanjem dijeljenja znanja, odnosno njegovih preduvjeta i ishoda (**Lin, 2007**.; **Migdadi, 2009**.; **Oztekin** i **dr., 2015.**). Osim toga, istraživanja se često provode na način da se ispitanicima otpreme otisnuti upitnici u zapečaćenim kovertama s popratnim pismom koje pojašnjava svrhu istraživanja, pri čemu je odaziv ispitanika zadovoljavajući (**Lin, 2007. –** 34,4 %; **Handžić, 2011**. – 42,63 %; **Oztekin** i **dr.**, **2015**. – 49 %; **Kim, Kim** i **Yun**, **2015**. – 51 %). Iz navedenog razloga velikim, srednjim i malim poduzećima koja sačinjavaju slučajan uzorak odaslali su se otisnuti primjerci anketnih upitnika u frankiranim kovertama s popratnim pismom.

Nakon što je testnom analizom dodatno unaprijeđen anketni upitnik, istraživanje se provelo u dvije faze: *online* upitnikom kojim je prikupljeno ukupno 126 potpuno ispunjenih upitnika, te slanjem otisnutog upitnika s plaćenim povratom, kojim su prikupljena dodatna 224 upitnika. S obzirom na to da se glavna hipoteza u istraživanju dokazuje korištenjem tehnike modeliranja strukturalnim jednadžbama, veličina uzorka odredila se sukladno preporukama **Hair** i **dr.** (**2010.**): uzorak između 100 i 400 ispitanika smatra se dovoljnim za analizu ove vrste. Analiza prikupljenih podataka izvršena je za uzorak od ukupno 350 jedinica. Naime, nakon testiranja anketnog upitnika na manjoj fokusnoj grupi od deset zaposlenika u sustavu visokog obrazovanja, pristupilo se *online* predistraživanju radi daljnjeg testiranja upitnika. Pritom valja naglasiti da se ovdje namjerno koristi termin predistraživanje, a ne pilot istraživanje, jer se već

u ovoj fazi istraživanja upitnik pokazao valjanim u smislu dobrog pristajanja uzorka podacima. Prema tome, kako je upitnik dokazan valjanim, te nisu bile nužne nikakve modifikacije u smislu daljnjeg istraživanja, podaci prikupljeni u predistraživanju mogli su se objediniti s podacima iz glavnog istraživanja radi provođenja sveobuhvatne analize (**Birkett, Day, 1994**.; **Lancaster, Dodd** i **Williamson, 2002**.; **Van Teijlingen, Hundley, 2013**.; **Whitehead, Sully** i **Campbell, 2014**.)

4.3. ISTRAŽIVAČKI INSTRUMENT I PRIKUPLJANJE PODATAKA ZA MJERENJE DOPRINOSA DIJELJENJA ZNANJA OSTVARENOM POSLOVNOM REZULTATU

U analizi i obradi prikupljenih primarnih podataka koristili su se statistički programi SPSS, Lisrel i R. Metode deskriptivne statističke analize koristile su se za opis uzorka i glavnih koncepata u predloženom konceptualnom modelu. Radi usporedbe operacionalizacije procesa dijeljenja znanja u poduzećima koristile su se metode bivarijatne statističke analize (T-test, Anova), dok su se metode multivarijatne statističke analize koristile radi analize pouzdanosti pojedinih ljestvica i mjernog instrumenta (Cronbach alpha, modeliranje strukturalnim jednadžbama - SEM). SEM se ujedno koristio za testiranje osnovne i pomoćnih hipoteza, odnosno u svrhu testiranja cijelog konceptualnog modela.

Modeliranje strukturalnim jednadžbama ili strukturalno modeliranje je skup modela kojima se nastoje objasniti uzročno-posljedične povezanosti između više varijabli. Predstavlja kombinaciju zavisnih i međuzavisnih tehnika, jer se oslanja na analizu višestruke regresije i faktorsku analizu (**Hair** i **dr.**, **2010.**). Strukturalno modeliranje sastoji se od dva modela: mjerni model je rezultat faktorske analize i predstavlja operacionalizaciju latentnih varijabli; strukturalni model definira uzročno-posljedične povezanosti između latentnih varijabli i ukazuje na količinu neobjašnjene varijance (**Diamanatopoulos**, **Siguaw, 2007.**). Postupak provedbe modeliranja strukturalnim jednadžbama može se podijeliti u šest glavnih koraka (**Hair** i **dr.**, **2010.**): i) definiranje pojedinih koncepata; ii) oblikovanje mjernog modela; iii) određivanje istraživanja za dobivanje empirijskih rezultata; iv) ocjena valjanosti mjernog modela; v) oblikovanje strukturalnog modela te vi) ocjena valjanosti strukturalnog modela.

U nastavku se ukratko opisuju pojedini koraci (**Hair** i **dr.**, **2010.**):

Definiranje pojedinih koncepata odnosi se na kvalitetu mjernog instrumenta koji se mora temeljiti na teorijskim spoznajama. U ovom je koraku neophodno definirati mjerne varijable te odrediti ljestvicu mjerenja, pri čemu se najčešće koristi ljestvica Likertovog tipa ili ljestvica semantičkog diferencijala. Većina koncepata koja se ispitivala temeljem anketnog upitnika razrađena je temeljem analizirane literature, odnosno ako je to bilo potrebno, pojedini su koncepti redefinirani na način da odgovaraju potrebama predmeta istraživanja. U radu se primijenila Likertova ljestvica s pet stupnjeva slaganja, odnosno neslaganja s ponuđenim tvrdnjama (1 = uopće se ne slažem; 5 = u potpunosti se slažem).

Oblikovanje mjernog modela podrazumijeva definiranje latentnih varijabli i njima pripadajućih manifestnih (mjernih) varijabli. Potrebno je također odrediti i povezanosti između koncepata i njihovih indikatora, korelacijske odnose između koncepata te reziduale (pogreške) za mjerne varijable. U konceptualnom modelu latentne varijable obuhvaćaju organizacijsku kulturu, IKT, podršku vrhovnog menadžmenta, dijeljenje znanja i uspješnost poslovanja. Pritom su organizacijska kultura i IKT prediktorske varijable latentnoj varijabli dijeljenje znanja, dok je podrška vrhovnog menadžmenta moderacijska varijabla između organizacijske kulture i IKT-a s jedne strane te dijeljenja znanja s druge. Dijeljenje znanja je ujedno medijacijska varijabla između organizacijske kulture i IKT-a s jedne strane te uspješnosti poslovanja s druge. Manifestne varijable za organizacijsku kulturu obuhvaćaju: poslovnu misiju, opunomoćivanje i kontinuirano učenje; za IKT: investicije u IKT sustave, prepoznavanje poslovnih prilika i poboljšanu komunikaciju; za podršku vrhovnog menadžmenta: otvorenost zaposlenicima, razvijanje povjerenja i mentoriranje; za dijeljenje znanja: davanje i primanje eksplicitnog i implicitnog znanja, te za uspješnost poslovanja perceptivne financijske i nefinancijske pokazatelje prije i tijekom pandemije. Arhivski financijski pokazatelji (ROA i ROE) direktno su preuzeti iz digitalnog repozitorija HGK-a.

Određivanje istraživanja za dobivanje empirijskih rezultata odnosi se na vrstu podataka, nedostajuće vrijednosti, veličinu uzorka, metodu procjene i statistički program za provedbu SEM analize. Veličina uzorka u SEM analizi ovisi o nekoliko faktora. Kako bi se smanjio utjecaj nenormalnosti podataka, za svaki parametar koji je procijenjen u modelu poželjno je imati 15 ispitanika. Najčešće korištena metoda procjene (metoda najveće vjerojatnosti) daje valjane rezultate na uzorku između 100 i 400 ispitanika. Istraživanje se planiralo provesti na uzorku od najmanje 240 jedinica, odnosno velikih, srednjih i malih poduzeća za područje

Republike Hrvatske. Predistraživanjem je prikupljeno ukupno 126 kompletnih odgovora, dok se glavnim istraživanjem prikupilo 224 kompletna odgovora. Statističke analize izvršene su za oba uzorka zasebno, kao i na cijelom uzorku od 350 jedinica, što se smatra kvalitetnim uzorkom za SEM analizu.

Ocjena valjanosti mjernog modela provodi se pomoću pokazatelja podudaranja (engl. *goodness-of-fit* – GOF; *fit indices*) koji pokazuju u kojoj se mjeri podudaraju empirijska i teorijska matrica kovarijanci. Hi-kvadrat (engl. *chi-square*) temeljni je pokazatelj podudarnosti, te pokazuje u kojoj je mjeri teorijski (hipotetički) model u skladu s empirijskim (stvarnim) podacima. Osim hi-kvadrata postoje još apsolutni pokazatelji, inkrementalni pokazatelji, te pokazatelji parsimonije. Za određivanje prihvatljive prikladnosti istraživanog modela, potrebno je pored hi-kvadrata navesti barem još jedan apsolutni i jedan inkrementalni pokazatelj. Navedeni pokazatelji izračunali su se pomoću statističkih programa Lisrel i R na način da se kao ulazna varijabla pripremi odgovarajuća matrica kovarijanci koja sadrži temeljne numeričke vrijednosti za izračun navedenih pokazatelja. Sam izračun pokazatelja determinira se na način da se računalno odrede odnosi između latentnih i manifestnih varijabli, kao i međusobno između latentnih varijabli.

Oblikovanje strukturalnog modela podrazumijeva određivanje uzročno-posljedične povezanosti između koncepata definiranih u mjernom modelu. Te su povezanosti definirane u obliku hipoteza koje treba testirati. Prilikom unosa vrijednosti u Lisrel potrebno je voditi računa o tome da se na ispravan način definiraju odnosi između pojedinih latentnih varijabli, odnosno koje se varijable pojavljuju u funkciji prediktora, a koje u funkciji medijatora.

Ocjena valjanosti strukturalnog modela provodi se na identičan način kao i kod mjernog modela. Što su pokazatelji podudaranja strukturalnog modela bliže pokazateljima mjernog modela, bolja je prikladnost strukturalnog modela.

U konceptualnom modelu varijabla podrška vrhovnog menadžmenta javlja se u ulozi moderatora. U analizi moderacije ispituje se ovisi li odnos dviju varijabli o vrijednosti treće varijable. Ako je moderacijski učinak prisutan, model multiple regresije ukazat će na postojanje dodatne linearne interakcije. Iz navedenog se razloga često moderacija naziva i moderirana multipla regresija (engl. MMR – *Moderated multiple regression*). (**Aguinis**, **2004.**)

4.4. REZULTATI ISTRAŽIVANJA DOPRINOSA DIJELJENJA ZNANJA USPJEŠNOSTI POSLOVANJA HRVATSKIH PODUZEĆA

U svrhu izrade hipotetskog konceptualnog modela, koji za cilj ima objasniti ulogu pojedinih varijabli u objašnjavanju uspjeha poslovanja poduzeća, potrebno je bilo validirati sve *ad-hoc* sastavljene skale kojima se mjere sljedeće latentne varijable: organizacijska kultura, informacijsko-komunikacijske tehnologije (IKT), podrška vrhovnog menadžmenta, dijeljenje znanja i uspješnost poslovanja poduzeća.

Najprije su se testirali preduvjeti za provođenje eksploratorne faktorske analize skala *Organizacijska kultura*, *Informacijsko-komunikacijske tehnologije*, *Podrška vrhovnog menadžmenta*, *Dijeljenje znanja* i skale *Uspješnost poslovanja poduzeća.* S obzirom na to da su u istraživanju korištene *ad-hoc* konstruirane skale, u prvom je koraku bilo potrebno provesti eksploratorne faktorske analize svih korištenih skala kako bi se utvrdila faktorska struktura te na temelju iste računao mjerni model. S obzirom na to da faktorska analiza počiva na Pearsonovim koeficijentima korelacije (**Fulgosi, 1988.**), na samom početku je testirana normalnost distribucija svih čestica svih korištenih skala. Shapiro-Wilk testom utvrđeno je kako čestice na svim korištenim skalama statistički značajno odstupaju od normalne distribucije. Stoga su izračunati i parametri asimetričnosti i zakrivljenosti. Ovi se parametri za sve čestice kreću u dozvoljenom rasponu od -2 do +2 (**Kline, 2005.**), što znači da primjena faktorske analize na ovakvim podacima neće utjecati na rezultate obrade. Drugim riječima, ako je odstupanje od normalne distribucije blizu očekivanih vrijednosti, parametrijski statistički postupci kao što je faktorska analiza neće dovesti do značajnih posljedica na rezultate (**Howell, 2010.**).

Nakon provjere normalnosti distribucija, provjereno je i zadovoljavaju li podaci osnovne preduvjete provođenja faktorske analize. Točnije, primijenjeni su Kaiser-Mayer-Olkinov test i Bartlettov test sfericiteta na svim korištenim skalama. Prema **Fieldu** (**2009.**) zbirna vrijednost KMO testa između .50 i .70 su osrednje, između .70 i .80 dobre, između .80 i .90 velike, a iznad .90 izvrsne u ekstrakciji faktora. Bartlettovim testom sfericiteta provjerava se jesu li čestice u skali u dovoljno visokoj korelaciji jedna s drugom, što je jedan od preduvjeta za provedbu faktorske analize. Ako su čestice, pak, u previsokoj korelaciji ($r > .85$ ili $r < -.85$), postaje nemoguće odrediti jedinstveni doprinos faktora varijablama koje su previsoko korelirane. Stoga je nakon provjere značajnosti Bartlettova testa pregledana i korelacijska matrica svih čestica na svakoj skali zasebno.

Tablica 10: Testiranje preduvjeta za provođenje eksploratorne faktorske analize za skale *Organizacijska kultura*, *IKT*, *Podrška vrhovnog menadžmenta*, *Dijeljenje znanja* i skale *Uspješnost poslovanja poduzeća* Kaiser-Mayer-Olkin testom te Bartlettovim testom sfericiteta

IME SKALE	Kaiser-Mayer-Olkin test	Bartlettov test sfericiteta
Organizacijska kultura	0,91	$\chi 2 = 1107$; df = 66; $p < ,01$
Informacijsko--komunikacijske tehnologije	0,92	$\chi 2 = 1109$; df = 66; $p < ,01$
Podrška vrhovnog menadžmenta	0,90	$\chi 2 = 1285$; df = 66; $p < ,01$
Dijeljenje znanja	0,87	$\chi 2 = 1121$; df = 66; $p < ,01$
Uspješnost poslovanja poduzeća	0,87	$\chi 2 = 2102$; df = 66; $p < ,01$

Izvor: pripremila doktorandica.

Budući da je vrijednost Kaiser-Mayer-Olkin testa za sve skale iznosila minimalno 0,87, može se zaključiti kako je prvi preduvjet provođenja eksploratorne faktorske analize zadovoljen. Nadalje, na svim skalama Bartlettov test sfericiteta bio je statistički značajan uz razinu rizika od pogrešnog zaključivanja manju od 1 %.

Tablica 11: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Organizacijska kultura u objedinjenom istraživanju

	PM1	PM2	PM3	PM4	OZ1	OZ2	OZ3	OZ4	KU1	KU2	KU3	KU4
PM1	-											
PM2	,520	-										
PM3	,594	,433	-									
PM4	,584	,421	,576	-								
OZ1	,424	,287	,406	,522	-							
OZ2	,426	,277	,417	,504	,670	-						
OZ3	,403	,345	,388	,619	,582	,622	-					
OZ4	,207	,173	,278	,268	,312	,333	,349	-				
KU1	,484	,255	,366	,540	,410	,375	,424	,238	-			
KU2	,473	,373	,420	,523	,464	,455	,446	,263	,615	-		
KU3	,277	,241	,313	,399	,509	,529	,459	,193	,386	,463	-	
KU4	,367	,324	,321	,451	,492	,513	,492	,238	,418	,546	,684	-

Izvor: pripremila doktorandica**.**

Tablica 12: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Informacijsko--komunikacijske tehnologije u objedinjenom istraživanju

	IS1	IS2	IS3	IS4	PPP1	PPP2	PPP3	PPP4	PK1	PK2	PK3	PK4
IS1	-											
IS2	,460	-										
IS3	,607	,542	-									
IS4	,538	,522	,756	-								
PPP1	,478	,377	,515	,464	-							
PPP2	,444	,285	,417	,356	,701	-						
PPP3	,435	,362	,444	,426	,646	,780	-					
PPP4	,419	,382	,521	,460	,617	,675	,645	-				
PK1	,309	,340	,378	,408	,266	,166	,214	,274	-			
PK2	,438	,501	,504	,499	,450	,415	,440	,484	,514	-		
PK3	,509	,446	,585	,549	,580	,527	,531	,580	,414	,686	-	
PK4	,513	,429	,668	,647	,515	,439	,456	,507	,396	,553	,728	-

Izvor: pripremila doktorandica.

Tablica 13: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Podrška vrhovnog menadžmenta u objedinjenom istraživanju

	OMI1	OMI2	OMI3	OMI4	RP1	RP2	RP3	RP4	MZ1	MZ2	MZ3	MZ4
OMI1	-											
OMI2	,768	-										
OMI3	,706	,787	-									
OMI4	,574	,591	,682	-								
RP1	,500	,462	,458	,446	-							
RP2	,400	,360	,379	,392	,723	-						
RP3	,565	,553	,543	,528	,492	,473	-					
RP4	,448	,525	,476	,495	,423	,370	,645	-				
MZ1	,576	,593	,567	,531	,462	,420	,629	,536	-			
MZ2	,532	,512	,530	,458	,398	,421	,519	,391	,565	-		
MZ3	,563	,523	,573	,559	,428	,365	,616	,459	,654	,707	-	
MZ4	,320	,301	,354	,427	,356	,288	,426	,434	,455	,414	,505	-

Izvor: pripremila doktorandica

Tablica 14: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Dijeljenje znanja u objedinjenom istraživanju

	DEZ1	DEZ2	DEZ3	DII1	DII2	DII3	PEZ1	PEZ2	PEZ3	PIZ1	PIZ2	PIZ3
DEZ1	-											
DEZ2	,602	-										
DEZ3	,539	,608	-									
DII1	,430	,339	,286	-								
DII2	,454	,342	,276	,565	-							
DII3	,460	,354	,306	,524	,766	-						
PEZ1	,666	,511	,548	,416	,438	,404	-					
PEZ2	,586	,524	,574	,303	,337	,335	,723	-				
PEZ3	,532	,432	,470	,332	,356	,397	,560	,796	-			
PIZ1	,404	,268	,217	,658	,483	,457	,337	,261	,355	-		
PIZ2	,428	,383	,298	,498	,526	,530	,329	,273	,305	,590	-	
PIZ3	,490	,395	,330	,471	,600	,610	,405	,346	,366	,474	,705	-

Izvor: pripremila doktorandica.

Tablica 15: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Uspješnost poslovanja poduzeća u objedinjenom istraživanju

	FP1	FP2	FP3	FP4	FP5	FP6	FP7	FP8	NFP1	NFP2	NFP3	NFP4	NFP5	NFP6	NFP7	NFP8
FP1	-															
FP2	,689	-														
FP3	,698	,576	-													
FP4	,750	,732	,664	-												
FP5	,638	,494	,551	,552	-											
FP6	,550	,739	,542	,640	,622	-										
FP7	,479	,437	,562	,438	,776	,585	-									
FP8	,566	,546	,549	,644	,809	,721	,776	-								
NFP1	,425	,489	,379	,434	,302	,400	,232	,319	-							
NFP2	,387	,490	,331	,449	,316	,400	,210	,317	,730	-						
NFP3	,624	,594	,541	,658	,527	,580	,438	,571	,530	,541	-					
NFP4	,416	,539	,389	,477	,314	,429	,286	,343	,610	,574	,578	-				
NFP5	,444	,514	,393	,477	,367	,461	,297	,388	,763	,667	,523	,554	-			
NFP6	,409	,495	,378	,457	,392	,469	,293	,396	,665	,823	,569	,590	,787	-		
NFP7	,595	,548	,527	,580	,661	,601	,584	,673	,452	,460	,794	,502	,530	,598	-	
NFP8	,376	,513	,396	,450	,387	,461	,344	,428	,529	,523	,542	,799	,612	,635	,632	-

Izvor: Pripremila doktorandica.

Pregledom korelacijskih matrica (Tablice 11 - 15) utvrđeno je kako su čestice na skalama Organizacijska kultura, IKT sustavi, Podrška vrhovnog menadžmenta, Dijeljenje znanja i Uspješnost poslovanja u umjereno visokim korelacijama (ne višim od r > ,85 ili r < - ,85), čime je zadovoljen i drugi preduvjet provođenja eksploratorne faktorske analize.

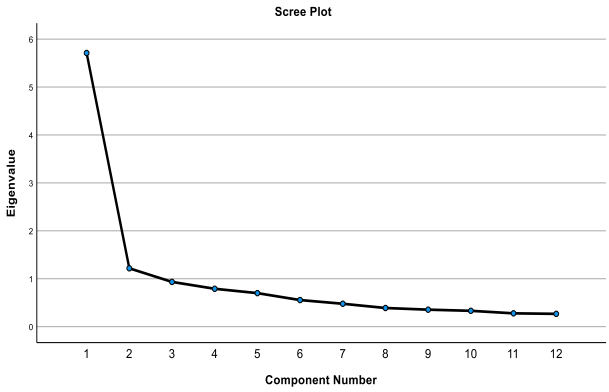
4.4.1. Eksploratorna faktorska analiza korištenih skala u konceptualnom modelu dijeljenja znanja

S ciljem ispitivanja faktorske strukture skala provedena je eksploratorna faktorska analiza metodom maksimalne vjerojatnosti. Ova je metoda odabrana jer su **Fabrigar** i **dr. (1999.)** utvrdili da je, ako su podaci relativno normalno distribuirani, metoda maksimalne vjerojatnosti najbolji izbor jer omogućuje izračunavanje širokog raspona indeksa pristajanja modela te dopušta testiranje statističke značajnosti faktorskih zasićenja i korelacija među faktorima. Kao kriteriji broja faktora koji će se zadržati uzete su vrijednosti karakterističnog korijena koje trebaju iznositi najmanje 1 (Kaiser-Guttmanov kriterij), postotak objašnjene varijance koji se može pripisati pojedinom faktoru, Catellov *Scree plot* test i interpretabilnost faktora.

4.4.1.1. *Eksploratorna faktorska analiza za skalu Organizacijska kultura*

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 47,6 % varijance rezultata skale Organizacijska kultura. Karakteristični korijen faktora iznosi 5,71. Većina čestica ima zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50).

Slika 4: *Scree plot* indikatora Organizacijska kultura (objedinjeno istraživanje)



Izvor: pripremila doktorandica.

Scree plot je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Tablica 16: Faktorska zasićenja na skali Organizacijska kultura (objedinjeno istraživanje)

*	Faktor / 1	Unikvitet
Naše poduzeće na transparentan način promiče poslovnu misiju.	0,701	0,491
Jasno definirana misija potpomaže razvijanje zajedništva.	0,549	0,302
Zaposlenici razumiju smisao poslovanja, te su odani misiji poslovanja.	0,666	0,444
U našem je poduzeću dijeljenje znanja značajan segment poslovne misije.	0,790	0,624
Naše poduzeće potiče preuzimanje inicijativa od strane zaposlenika.	0,749	0,562
Zaposlenici se aktivno potiču da sudjeluju u donošenju odluka.	0,754	0,569
Od zaposlenika se očekuje visok osobni angažman u dijeljenju znanja.	0,754	0,569
Zaposlenici visoko vrednuju mogućnost obavljanja izazovnih zadataka.	0,433	0,187
Poduzeće izdvaja značajna sredstva za edukativne i razvojne programe kako bi unaprijedilo specifična znanja i vještine zaposlenika.	0,674	0,454
Fleksibilnost i želja za promjenama temeljni su motivi kontinuiranog učenja u poduzeću.	0,740	0,548
Naše poduzeće potiče poduzetničko ponašanje zbog čega se zaposlenicima toleriraju povremene pogreške i eksperimenti.	0,670	0,448
Učenje iz pogrešaka omogućava se kroz timski rad i konsenzus.	0,717	0,514

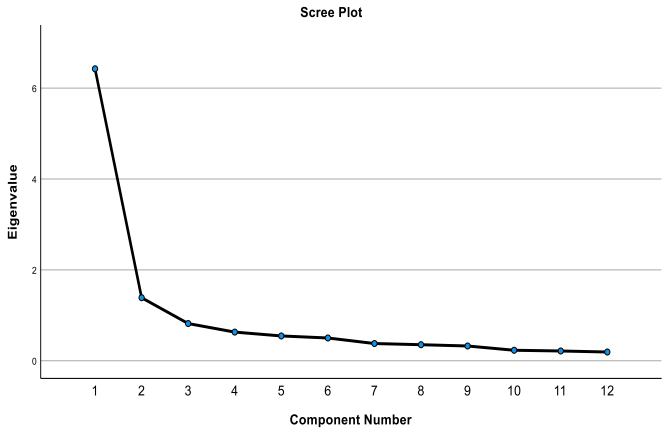
Izvor: pripremila doktorandica.

Svi su faktori na skali Organizacijska kultura visoko zasićeni pretpostavljenim česticama. Isto se odnosi na česticu o vrednovanju izazovnih zadataka od strane zaposlenika, jer se prema **Hairu** (**2010.**), zasićenost od 0,3 smatra statistički signifikantnom.

4.4.1.2. Eksploratorna faktorska analiza za skalu IKT

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 53,54 % varijance rezultata skale Informacijsko-komunikacijske tehnologije. Karakteristični korijen faktora iznosi 6,43. Sve čestice imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50).

Slika 5: *Scree plot* indikatora Informacijsko-komunikacijske tehnologije (objedinjeno istraživanje)



Izvor: pripremila doktorandica.

Scree plot je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Tablica 17: Faktorska zasićenja na skali Informacijsko-komunikacijske tehnologije (objedinjeno istraživanje)

	Faktor / 1	**Unikvitet**
Sustav poslovne inteligencije* u našem poduzeću efikasno podržava svakodnevno poslovanje.	0,702	0,493
Računalni programi koji omogućuju učenje na daljinu unapređuju poslovanje.	0,636	0,404
IKT sustavi u našem poduzeću prilagođeni su potrebama zaposlenika.	0,798	0,637
IKT sustavi u našem poduzeću redovito se ažuriraju.	0,760	0,578
IKT se u našem poduzeću koriste za otkrivanje poslovnih prilika.	0,762	0,581
Naše poduzeće koristi IKT sustave koji omogućuju praćenje konkurencije.	0,716	0,513
Naše poduzeće koristi IKT sustave koji omogućuju praćenje aktivnosti poslovnih partnera.	0,734	0,539
IKT u našem poduzeću olakšavaju zaposlenicima korištenje društvenih kontakata u svrhu prikupljanja relevantnih informacija o novim prilikama na tržištu.	0,757	0,573
U našem poduzeću zaposlenici redovito komuniciraju *e-mailom* i sličnim alatima radi zajedničkog obavljanja radnih zadataka.	0,510	0,260
IKT u našem poduzeću omogućuju zaposlenicima na različitim radnim mjestima i/ili lokacijama da zajednički uče na daljinu.	0,738	0,544
IKT u našem poduzeću omogućuju zaposlenicima da u kratkom roku lociraju nužan izvor znanja, poput specifične baze podataka.	0,823	0,678
IKT sustavi u našem poduzeću osiguravaju pristup točnim i pravodobnim podacima.	0,791	0,626

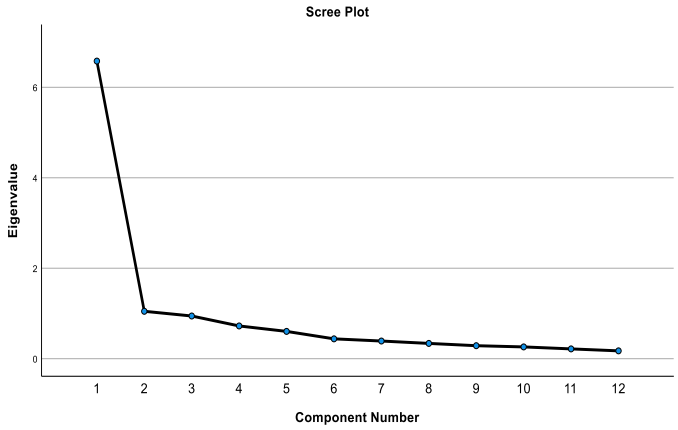
Izvor: pripremila doktorandica

4.4.1.3. Eksploratorna faktorska analiza za skalu Podrška vrhovnog menadžmenta

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 54,83 % varijance rezultata skale

Informacijsko-komunikacijske tehnologije. Karakteristični korijen faktora iznosi 6,58. Sve čestice imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50).

Slika 6: *Scree plot* indikatora Podrška vrhovnog menadžmenta (objedinjeno istraživanje)



Izvor: pripremila doktorandica

Scree plot je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Tablica 18: Faktorska zasićenja na skali Podrška vrhovnog menadžmenta (objedinjeno istraživanje)

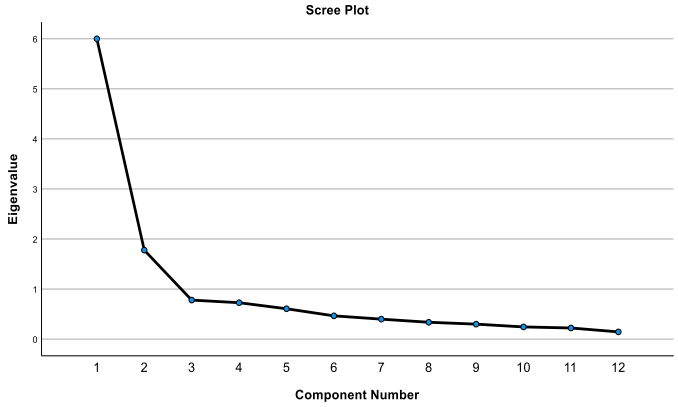
	Faktor / 1	**Unikvitet**
Menadžeri promiču sustav vrijednosti u kojem se cijeni mišljenje svakog zaposlenika	0,796	0,634
Menadžeri potiču zaposlenike na otvoreno iznošenje ideja/prijedloga na sastancima s nadležnima.	0,801	0,641
Menadžeri potiču zaposlenike na formalnu i neformalnu komunikaciju unutar poduzeća.	0,808	0,654
Menadžeri potiču povezivanje zaposlenika u grupe radi učenja i generiranja novih ideja	0,759	0,576
Zaposlenici doživljavaju uspjeh poduzeća kao vlastiti uspjeh.	0,682	0,465
Zaposlenicima je važna reputacija koju njihovo poduzeće ima među vanjskim subjektima.	0,615	0,378
Menadžeri se ponašaju kao savjetnici te prakticiraju kontrolu isključivo za procjenu dostignuća zaposlenika.	0,792	0,627
Menadžeri potiču zaposlenike na bavljenje zahtjevnijim zadacima, čak i kada postoji mogućnost neuspjeha.	0,697	0,486
Redovitim mentoriranjem zaposlenika menadžeri dodatno ističu važnost znanja za uspješnost poslovanja poduzeća.	0,794	0,631
Novim zaposlenicima omogućen je period orijentacije radi upoznavanja organizacijske strukture i sistematizacije poslova.	0,729	0,532
Zaposlenicima koji preuzimaju nove dužnosti omogućeno je mentoriranje, neovisno o tome koliko dugo rade u poduzeću.	0,789	0,623
Primjenjuju se programi rotiranja zaposlenika pomoću kojih menadžeri različitih odjela pomažu zaposlenicima unaprijediti svoja znanja i vještine	0,578	0,335

Izvor: pripremila doktorandica.

4.4.1.4. Eksploratorna faktorska analiza za skalu Dijeljenje znanja

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 49,99 % varijance rezultata skale Dijeljenje znanja. Karakteristični korijen faktora iznosi 5,99. Sve čestice imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50).

Slika 7: *Scree plot* indikatora Dijeljenje znanja (objedinjeno istraživanje)



Izvor: pripremila doktorandica

Scree plot je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Tablica 19: Faktorska zasićenja na skali Dijeljenje znanja (objedinjeno istraživanje)

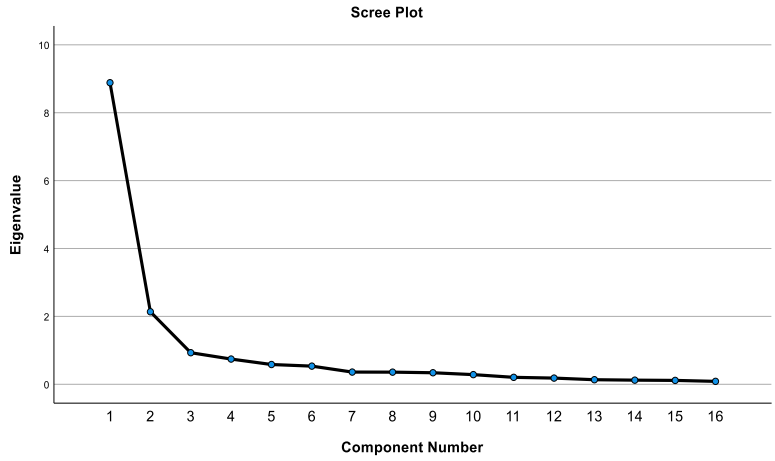
	Faktor / 1	**Unikvitet**
Zaposlenici redovito kroz organizirane edukacije prenose znanja, vještine i iskustva drugim zaposlenicima.	0,784	0,614
Zaposlenici koriste virtualna spremišta* za pohranjivanje znanja i iskustava koja time postaju dostupna drugim zaposlenicima.	0,677	0,459
Zaposlenici redovito pišu izvješća nadređenima o vlastitim postignućima (stečena znanja, vještine i iskustva).	0,639	0,408
Zaposlenici slobodno iznose ideje i stavove na poslovnim sastancima s nadređenima.	0,683	0,467
Zaposlenici se trude osobnim kontaktom pomoći manje iskusnim kolegama.	0,728	0,530
Zaposlenici u timovima i u neformalnim kontaktima rado daju savjete kolegama/prijateljima.	0,728	0,530
Zaposlenici se redovito educiraju o načinima prenošenja znanja, vještina i iskustava drugim zaposlenicima.	0,753	0,567
Zaposlenici organizirano primaju i analiziraju periodična izvješća o tržišnim trendovima i potrebama	0,717	0,514
Zaposlenici organizirano primaju i analiziraju periodična izvješća o rezultatima poslovanja, te organizacijskim politikama i procedurama.	0,697	0,486
Tijekom poslovnih sastanaka zaposlenici slobodno postavljaju pitanja kolegama i nadređenima.	0,643	0,413
Zaposlenici koji žele usvojiti nove vještine otvoreno upitaju iskusnije kolege da im ih prenesu.	0,689	0,475
Zaposlenici u timovima i u neformalnim kontaktima rado primaju savjete vlastitih kolega i prijatelja.	0,733	0,537

Izvor: pripremila doktorandica.

4.4.1.5. Eksploratorna faktorska analiza za skalu Uspješnost poslovanja poduzeća

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 55,52 % varijance rezultata skale Uspješnost poslovanja. Karakteristični korijen faktora iznosi 8,88. Sve čestice imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50).

Slika 8: *Scree plot* indikatora Uspješnost poslovanja poduzeća (objedinjeno istraživanje)



Izvor: pripremila doktorandica

Scree plot je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora. U sljedećoj tablici (Tablica 20) navode se faktorska zasićenja za skalu Uspješnost poslovanja poduzeća, te se također može zaključiti da se zasićenja kreću u visokim rasponima.

Tablica 20: Faktorska zasićenja na skali Uspješnost poslovanja poduzeća (objedinjeno istraživanje)

	Faktor / 1	Unikvitet
U odnosu na konkurenciju, naše poduzeće je zabilježilo veći rast prodaje. (PRIJE PANDEMIJE)	0,764	0,584
U odnosu na konkurenciju, naše poduzeće je bolje optimiziralo troškove. (PRIJE PANDEMIJE)	0,793	0,629
Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina. (PRIJE PANDEMIJE)	0,712	0,507
U odnosu na konkurenciju, naše poduzeće je ostvarilo veću profitabilnost. (PRIJE PANDEMIJE)	0,795	0,633
U odnosu na konkurenciju, naše poduzeće je zabilježilo rast prodaje. (NAKON PANDEMIJE)	0,732	0,536
U odnosu na konkurenciju, naše poduzeće bolje je optimiziralo troškove. (NAKON PANDEMIJE)	0,777	0,603
Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina. (NAKON PANDEMIJE)	0,647	0,418
U odnosu na konkurenciju, naše poduzeće je ostvarilo veću profitabilnost. (NAKON PANDEMIJE)	0,762	0,581
U odnosu na konkurenciju, kvaliteta naših proizvoda/usluga je bolja. (PRIJE PANDEMIJE)	0,688	0,473
U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju. (PRIJE PANDEMIJE)	0,685	0,469
U odnosu na konkurenciju, naše poduzeće brže raste. (PRIJE PANDEMIJE)	0,813	0,660
U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike. (PRIJE PANDEMIJE)	0,702	0,492
U odnosu na konkurenciju, kvaliteta naših proizvoda/usluga je bolja. (NAKON PANDEMIJE)	0,734	0,538
U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju. (NAKON PANDEMIJE)	0,749	0,561
U odnosu na konkurenciju, naše poduzeće brže raste. (NAKON PANDEMIJE)	0,822	0,676
U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike. (NAKON PANDEMIJE)	0,722	0,521

Izvor: pripremila doktorandica.

Kako bi se provjerila pouzdanost korištenih skala izračunat je Cronbach alpha koeficijent unutarnje konzistencije za svaku skalu pojedinačno, a rezultati su prikazani u Tablici 21.

Tablica 21. Prikaz koeficijenata unutarnje konzistencije (Cronbach alpha)

	Organizacijska kultura	**Informacijsko--komunikacijske tehnologije**	**Podrška vrhovnog menadžmenta**	**Dijeljenje znanja**	**Uspješnost poslovanja poduzeća**
Cronbach alpha	**0,94**	**0,93**	**0,94**	**0,92**	**0,95**

Izvor: pripremila doktorandica.

Vrijednosti koeficijenata unutarnje konzistencije su vrlo visoke, čime se dodatno potvrdila kvaliteta razrade i primjene čestica za mjerenje doprinosa pojedinih varijabli uspješnoj primjeni dijeljenja znanja u poduzeću.

4.4.2. Prikaz rezultata istraživanja i njihovih implikacija na postavljene hipoteze o međuzavisnosti kontekstualnih čimbenika i dijeljenja znanja te njihovog učinka na uspješnost poslovanja

U nastavku će se prikazati rezultati istraživanja za svaku od provedenih faza: predistraživanje, glavno istraživanje i objedinjeni rezultati. Za svaki od analiziranih uzoraka prikazat će se rezultati konfirmatorne faktorske analize (CFA), analiza konceptualnog modela s čistom medijacijom i analiza konceptualnog modela s moderacijom. Također će se ispitati rezultati istraživanja uvrštavanjem kontrolnih varijabli (veličina poduzeća i djelatnost) radi lakšeg generiranja zaključaka i smjernica za buduća istraživanja.

4.4.2.1. Rezultati ispitivanja povezanosti arhivskih i perceptivnih pokazatelja uspješnosti poslovanja poduzeća

Kriterijska varijabla Uspješnost poslovanja mjerila se u konceptualnom modelu pomoću arhivskih (ROA – povrat na imovinu; ROE – povrat na glavnicu) i perceptivnih pokazatelja uspješnosti poslovanja (financijski pokazatelji prije i nakon, odnosno tijekom pandemije Covid-19, te nefinancijski pokazatelji prije i nakon, odnosno tijekom pandemije Covid-19). Istraživački radovi iz područja upravljanja znanjem / dijeljenje znanja koji mjere konstrukt Upravljanje znanjem pretežno se ograničavaju na perceptivne pokazatelje, no u analizi konceptualnog modela ispitani su i arhivski i perceptivni pokazatelji uspješnosti poslovanja kako bi se provjerila njihova povezanost. U slučaju da među arhivskim i perceptivnim pokazateljima uspješnosti poslovanja ima statistički značajnih razlika, opravdano je koristiti samo perceptivne pokazatelje.

Tablica 22: Usporedba arhivskog pokazatelja ROA i perceptivnih financijskih pokazatelja prije pandemije Covida-19

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	ROA	,0628	350	,24095	,01286
	FinPreCov	3,8834	350	,88410	,04719

Paired Samples Correlations				
		N	Correlation	Sig.
Pair 1	ROA & FinPreCov	350	,214	,000

Promatrane varijable nisu statistički značajno povezane.

Tablica 23: Usporedba arhivskog pokazatelja ROA i perceptivnih financijskih pokazatelja nakon pandemije Covida-19

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	ROA	,0627	350	,24130	,01290
	FinPreCov	3,5964	350	1,03146	,05513

Paired Samples Correlations				
		N	Correlation	Sig.
Pair 1	ROA & FinPreCov	350	,242	,000

Promatrane varijable nisu statistički značajno povezane.

Tablica 24: Usporedba arhivskog pokazatelja ROA i perceptivnih nefinancijskih pokazatelja prije pandemije Covida-19

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	ROA	,0628	350	,24095	,01286
	FinPreCov	3,9262	350	,79791	,04259

Paired Samples Correlations				
		N	Correlation	Sig.
Pair 1	ROA & FinPreCov	350	,227	,000

Promatrane varijable nisu statistički značajno povezane.

Tablica 25: Usporedba arhivskog pokazatelja ROA i perceptivnih nefinancijskih pokazatelja nakon pandemije Covida-19

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	ROA	,0628	350	,24095	,01286
	FinPreCov	3,8917	350	,84009	,04484

Paired Samples Correlations				
		N	Correlation	Sig.
Pair 1	ROA & FinPreCov	350	,245	,000

Promatrane varijable nisu statistički značajno povezane.

Tablica 26: Usporedba arhivskog pokazatelja ROE i perceptivnih financijskih pokazatelja prije pandemije Covida-19

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	ROA	-,170442	350	8,5109707	,4542820
	FinPreCov	3,8834	350	,88410	,04719

Paired Samples Correlations				
		N	Correlation	Sig.
Pair 1	ROA & FinPreCov	350	,096	,071

Promatrane varijable nisu statistički značajno povezane.

Tablica 27: Usporedba arhivskog pokazatelja ROE i perceptivnih financijskih pokazatelja nakon pandemije Covida-19

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	ROA	-,171243	350	8,5231421	,4555811
	FinPreCov	3,5964	350	1,03146	,05513

Paired Samples Correlations				
		N	Correlation	Sig.
Pair 1	ROA & FinPreCov	350	,070	,191

Promatrane varijable nisu statistički značajno povezane.

Tablica 28: Usporedba arhivskog pokazatelja ROE i perceptivnih nefinancijskih pokazatelja prije pandemije Covida-19

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	ROA	-,171243	350	8,5231421	,4555811
	FinPreCov	3,5964	350	1,03146	,05513

Paired Samples Correlations				
		N	Correlation	Sig.
Pair 1	ROA & FinPreCov	350	,070	,191

Promatrane varijable nisu statistički značajno povezane.

Tablica 29: Usporedba arhivskog pokazatelja ROE i perceptivnih nefinancijskih pokazatelja nakon pandemije Covida-19

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	ROA	-,170442	350	8,5109707	,4542820
	FinPreCov	3,8917	350	,84009	,04484

Paired Samples Correlations				
		N	Correlation	Sig.
Pair 1	ROA & FinPreCov	350	,118	,028

Izvor Tablica 22 – 29: pripremila doktorandica.

Promatrane varijable nisu statistički značajno povezane.

Dobiveni rezultati potvrđuju zaključke **Buble i dr.** (**1997.**) glede neprikladnosti mjerenja arhivskih financijskih pokazatelja jer ne odražavaju realno stanje poslovanja, podložni su kreativnom računovodstvu te ukazuju na posljedice poslovnih odluka donesenih u prošlosti.
Također se ispitala i povezanost perceptivnih financijskih pokazatelja uspješnosti poslovanja poduzeća prije i nakon pandemije Covida-19. Dobiveni rezultati potvrdili su značajnu povezanost između perceptivnih financijskih i nefinancijskih rezultata. S obzirom na to da se istraživanje provodilo u vrijeme dok pandemija Covid-19 još nije službeno proglašena okončanom, tada se ovi rezultati moraju interpretirati na način da se uzme u obzir i činjenica kako realne financijske posljedice „poremećaja“ u poslovanju postaju vidljive tek s vremenskim odmakom, što su potvrdili **Buble i dr.** (**1997**.), pa bi ovu analizu trebalo ponoviti nakon, primjerice, pet godina.

Tablica 30: Usporedba perceptivnih financijskih pokazatelja prije i nakon, odnosno tijekom pandemije Covida-19

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	ROA	3,8860	350	,88410	,04726
	FinPreCov	3,5964	350	1,03146	,05513

Paired Samples Correlations				
		N	Correlation	Sig.
Pair 1	ROA & FinPreCov	350	,716	,000

Promatrane varijable statistički su značajno povezane.

Tablica 31: Usporedba perceptivnih nefinancijskih pokazatelja prije i nakon, odnosno tijekom pandemije Covida-19

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	ROA	3,9262	350	,79791	,04259
	FinPreCov	3,8917	350	,84009	,04484

Paired Samples Correlations				
		N	Correlation	Sig.
Pair 1	ROA & FinPreCov	350	,859	,000

Izvor Tablica 30-31: pripremila doktorandica.

Promatrane varijable statistički su značajno povezane.

4.4.2.2. Rezultati predistraživanja temeljem analize online *upitnika o učinku dijeljenja znanja na uspješnost poslovanja poduzeća*

Predistraživanje je provedeno temeljem distribucije *online* upitnika na 1.500 ispitanika, koji čine velika, srednja i mala poduzeća. Prikupljeno je ukupno 126 kompletno ispunjenih upitnika od kojih 11 pripada velikim poduzećima (8 %), sljedećih 31 srednjim poduzećima (25 %), dok preostalih 84 ispitanika pripada skupini malih poduzeća (67 %).

Radi usporedbe modela s podacima provelo se testiranje linearno-strukturalnog modeliranja (SEM), pri čemu su se koristili softverski program Lisrel i R. S obzirom na to da potpuni model obuhvaća mjerni i strukturalni dio, najprije je provedena konfirmatorna faktorska analiza (CFA) kako bi se testirao mjerni model. Analiza strukturalnog modela slijedi nakon CFA-a, a njome se testiraju relacije među latentnim varijablama koje su pretpostavljene konceptualnim modelom. Pomoću CFA-a se ispituju relacije između latentnih varijabli i njihovih manifestnih indikatora. CFA uključuje sve faktore i indikatore prikazane u shemi konceptualnog modela. Rezultati na svakom indikatoru (poslovna misija, opunomoćivanje zaposlenika, kontinuirano učenje, investicije u IKT sustave, prepoznavanje poslovnih prilika, poboljšana komunikacija itd.) izraženi su kao prosječna vrijednost svih čestica koje pripadaju tom indikatoru. Primjerice, indikator poslovna misija sadrži 4 čestice. Rezultat na indikatoru poslovna misija za svakog ispitanika izračunat je kao prosječna vrijednost tih četiriju čestica. Naime, u kreiranju latentnih varijabli, indikatori mogu biti čestice ili parcele čestica. Radi adekvatnog pristajanja modela podacima, pri analizi su korištene parcele, odnosno prosjeci čestica.

Kako bismo odgovorili na postavljene hipoteze koje zahtijevaju složene statističke parametrijske postupke, neophodno je testirati normalnost distribucija. Shapiro-Wilk testom provjerena je normalnost distribucija te su izračunate mjere spljoštenosti i asimetričnosti. Navedeni rezultati prikazani su u Tablici 32, kao i ostali deskriptivni parametri.

Tablica 32: Normalnost distribucije u *online* istraživanju

Varijabla	K	M	SD	Asimetričnost (SE)	Spljoštenost (SE)	Shapiro-Wilk (W)
Poslovna misija	4	4,21	0,79	-1,62 (0,22)	3,19 (0,43)	0,84**
Opunomoćivanje zaposlenika	4	4,11	0,89	-1,39(0,22)	1,70(0,43)	0,85**
Kontinuirano učenje	4	3,86	0,88	-0,88(0,22)	0,54 (0,43)	0,93**
Investicije u IKT sustave	4	3,75	1,07	-0,05(0,22)	-0,64(0,43)	0,97**
Prepoznavanje poslovnih prilika	4	3,09	1,07	-0,06 (0,22)	-0,64(0,43)	0,97**
Poboljšana komunikacija	4	3,91	0,96	-1,11 (0,22)	0,91(0,43)	0,89**
Davanje eksplicitnog znanja	3	3,16	1,13	-0,32 (0,22)	-0,79(0,43)	0,95**
Davanje implicitnog znanja	3	4,20	0,81	-1,08(0,22)	0,80(0,43)	0,87**
Primanje eksplicitnog znanja	3	3,23	1,05	-0,34 (0,22)	-0,36(0,43)	0,96**
Primanje implicitnog znanja	3	4,32	0,75	-1,73(0,22)	3,69(0,43)	0,80**
Otvorenost menadžera idejama zaposlenika	4	4,31	0,86	-1,59 (0,22)	2,54 (0,43)	0,79**
Razvijanje povjerenja menadžera i zaposlenika	4	4,08	0,81	-0,89 (0,22)	0,24(0,43)	0,90**
Mentoriranje zaposlenika	4	3,82	0,92	-0,82 (0,22)	0,18 (0,43)	0,93**
Nefinancijski pokazatelji prije Covida	4	3,91	0,87	-0,88(0,22)	0,65(0,43)	0,92**
Nefinancijski pokazatelji nakon Covida	4	3,84	0,90	-0,91 (0,22)	0,78(0,43)	0,93**
Financijski pokazatelji prije Covida	4	3,78	0,95	-0,66 (0,22)	0,12(0,43)	0,94**
Financijski pokazatelji nakon Covida	4	3,46	1,03	-0,24(0,22)	-0,70(0,43)	0,96**

Legenda: K - broj čestica, M - aritmetička sredina, SD - standardna devijacija ** $p < 0.01$

Izvor: pripremila doktorandica.

Prema tabličnom prikazu rezultata može se primijetiti kako je Shapiro-Wilk test za sve varijable pokazao značajno odstupanje rezultata od normalne distribucije ($p < 0,01$). Međutim, provjerene su i mjere asimetričnosti i spljoštenosti koje ne prelaze vrijednosti od 3 i 10, respektivno, što znači da su rezultati, prema **Kline** (**2010.**) kriteriju prihvatljivi i upotrebljivi za daljnju obradu. Nakon deskriptivnih parametara kvantitativnih varijabli, izračunate su korelacije između varijabli prikazanih u Tablici 32. Utvrđeno je da sve korištene varijable statistički značajno koreliraju ($p < 0,01$). Prije izračuna CFA-a napravljena je analiza demografskih varijabli koja je prikazana u sljedećoj tablici.

Tablica 33: Deskriptivni pokazatelji uzorka iz *online* istraživanja

VARIJABLA	REFERENTNE VRIJEDNOSTI	FREKVENCIJA	POSTOTAK
SPOL	M Ž	74 52	58,7 41,3
DOBNA SKUPINA	1. 20 - 29 2. 30 - 39 3. 40 - 49 4. 50 - 59 5. 60 - 64 6. 65 i više	4 30 45 34 9 4	3,2 23,8 35,7 27,0 7,1 3,2
RADNI STAŽ U PODUZEĆU	1. < 10 godina 2. 10 - 20 godina 3. > 20 godina	39 48 39	31,0 38,0 31,0
NAJVIŠI ZAVRŠENI STUPANJ OBRAZOVANJA	1. osnovna škola 2. srednja škola 3. viša stručna sprema / prvostupnik 4. visoka stručna sprema / stručni magisterij 5. znanstven magisterij / doktorat	0 19 25 72 10	0 15,1 19,8 57,1 7,9
POLOŽAJ U PODUZEĆU	1. vrhovni menadžment 2. srednji menadžment 3. niži menadžment 4. nemenadžerska razina	78 28 7 13	61,9 22,2 5,6 10,3
GODINE RADNOG ISKUSTVA NA TRENUTNOJ POZICIJI	1. < 10 godina 2. 10 – 20 godina 3. > 20 godina	45 50 31	35,7 39,7 24,6
VLASNIČKA STRUKTURA	1. privatno vlasništvo 2. državno vlasništvo 3. mješovito vlasništvo	117 7 2	92,9 5,6 1,6
VELIČINA PODUZEĆA MJERENA BROJEM ZAPOSLENIH	1. veliko poduzeće (> 250 zaposlenika) 2. srednje poduzeće (50 – 250 zaposlenika) 3. malo poduzeće (< 50 zaposlenika)	11 31 84	8,7 24,6 66,7
DJELATNOST POSLOVANJA	1. pretežno proizvodnja 2. pretežno usluge 3. kombinacija proizvodnje i usluga	20 91 15	15,9 72,2 11,9
DJELOKRUG POSLOVANJA PODUZEĆA	1. pretežno domaće tržište 2. pretežno inozemno tržište 3. kombinacija domaćeg i inozemnog tržišta	68 28 30	54,0 22,2 23,8

Izvor: pripremila doktorandica.

Iz tablice je vidljivo kako je u uzorku više muškaraca nego žena, najčešće dobi između 40 i 49 godina, a u radnom odnosu su najčešće između 10 i 20 godina. Ispitanici u uzorku uglavnom su visoke stručne spreme te obnašaju funkciju vrhovnog menadžera u poduzeću, a najviše njih je na ovoj poziciji zaposleno između 10 i 20 godina. Poduzeća u uzorku su većinom mala, privatna, te nude pretežno usluge na domaćem tržištu. Kako bi se provjerila latentna struktura skala konstrukata *Organizacijska kultura, Informacijsko-komunikacijske tehnologije, Podrška vrhovnog menadžmenta, Dijeljenje eksplicitnog i implicitnog znanja* te *Uspješnosti poslovanja*

poduzeća, provedena je konfirmatorna faktorska analiza uz primjenu metode maksimalne vjerojatnosti prilikom procjene parametara u modelu.

Stupanj slaganja modela s podacima procijenjen je pomoću parametara: omjer χ^2 i stupnjeva slobode, inkrementalnih indeksa slaganja CFI (engl. *Comparative fit index*) i TLI (engl. *Tucker-Lewis index*) te pomoću indeksa RMSEA (engl. *Root-mean-square error of approximation*) i SRMR (engl. *Standardized-root-mean-residual*). Prema **Hu** i **Bentler** (**1999.**) vrijednosti χ^2/df manje od 3, CFI i TLI veći od 0,90 te RMSEA i SRMR manje od 0,10 ukazuju na prihvatljivo slaganje modela s podacima, dok omjer χ^2/df manje od 3, CFI i TLI veći od 0,95 te RMSEA manji od 0,06 i SRMR manji od 0,08 upućuju na dobro slaganje modela s podacima.

Slaganje modela s podacima bilo je zadovoljavajuće, $\chi 2 = 282,21$, df = 109, $p < 0,01$; $\chi 2$/df = 2,59; CFI = 0,91 i TLI = 0,90; RMSEA = 0,11 (0,01 - 0,13) i SRMR = 0,06. Pritom je veličina indeksa AIC = 4000,67, BIC = 4125,11. Sve čestice u modelu su bile zadovoljavajuće visoko zasićene pretpostavljenim faktorima. Pregledom *modification indicesa* iz prethodnog modela utvrđeno je da bi se moglo poboljšati slaganje modela s podacima dodatnom procjenom kovarijance indikatora Dijeljenje znanja te Uspješnost poslovanja poduzeća (**Kline, 2015.**). U nastavku su prikazani rezultati nakon provedenog postupka.

Tablica 34: Slaganje modela iz *online* istraživanja s podacima

Indeks	Referentna vrijednost	Izračunata vrijednost	Interpretacija (slaganje s podacima)
$\chi 2$/df $\chi 2 = 172,44$, df =105, $p < 0,01$	< 3	1,63	Zadovoljavajuće
CFI	> 0,9	0,96	Zadovoljavajuće
TLI	> 0,9	0,95	Zadovoljavajuće
RMSEA	< 0,10	0,07 (0,05-0,09)	Zadovoljavajuće
SRMR	< 0,10	0,05	Zadovoljavajuće

AIC= 3920,24, BIC= 4056,69

Izvor: pripremila doktorandica.

Sve čestice u modelu su bile zadovoljavajuće visoko zasićene pretpostavljenim faktorima, što se može vidjeti u sljedećoj tablici.

Tablica 35: Zasićenost čestica pripadajućim faktorima u *online* istraživanju

Latentna varijabla	Indikator	Zasićenje
Organizacijska kultura	Poslovna misija	0,85
Organizacijska kultura	Opunomoćivanje zaposlenika	0,90
Organizacijska kultura	Kontinuirano učenje	0,88
Informacijsko-komunikacijska tehnologija	IKT investicije	0,86
Informacijsko-komunikacijska tehnologija	Poslovne prilike	0,73
Informacijsko-komunikacijska tehnologija	Poboljšana komunikacija	0,94
Podrška vrhovnog menadžmenta	Otvorenost menadžera idejama zaposlenika	0,86
Podrška vrhovnog menadžmenta	Razvijanje povjerenja	0,88
Podrška vrhovnog menadžmenta	Mentoriranje zaposlenika	0,85
Dijeljenje znanja	Davanje eksplicitnog znanja	0,79
Dijeljenje znanja	Davanje implicitnog znanja	0,67
Dijeljenje znanja	Primanje eksplicitno znanje	0,69
Dijeljenje znanja	Primanje implicitnog znanja	0,77
Uspješnost poslovanja poduzeća	Financije prije 2020.	0,76
Uspješnost poslovanja poduzeća	Financije poslije 2020.	0,55
Uspješnost poslovanja poduzeća	Nefinancije prije 2020.	0,96
Uspješnost poslovanja poduzeća	Nefinancije poslije 2020.	0,93

Izvor: pripremila doktorandica

Iako je osnovna ideja analize bila provjera moderirane medijacije, prvo je analiziran medijacijski model u kojem su Organizacijska kultura i Informacijsko-komunikacijske tehnologije bili prediktori, Dijeljenje znanja medijator, a Uspješnost poslovanja poduzeća kriterij.

Tablica 36: Interpretacija medijacijskog modela za *online* istraživanje

Indeks	Referentna vrijednost	Izračunata vrijednost	Interpretacija (slaganje s podacima)
χ^2/df χ^2 = 179,43, df = 110, p < 0,01	< 3	1,63	Dobro
CFI	> 0,9	0,96	Dobro
TLI	> 0,9	0,95	Dobro
RMSEA	< 0,10	0,07 (0,05-0,09)	Dobro
SRMR	< 0,10	0,05	Dobro

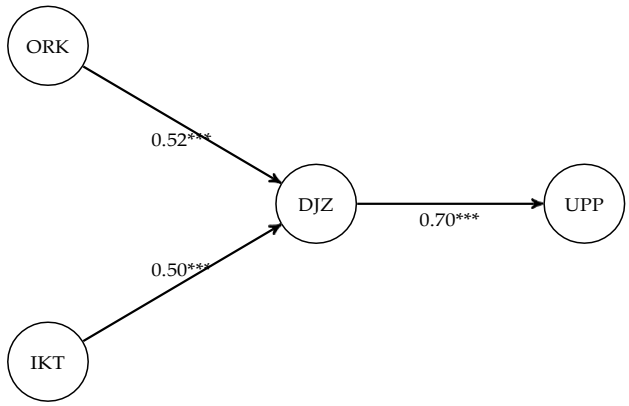
AIC= 3917,54, BIC= 4039,50

Izvor: pripremila doktorandica.

Utvrđena je povezanost između Organizacijske kulture i Dijeljenja znanja (p < 0,001), te između IKT-a i Dijeljenja znanja (p < 0,001). Također, utvrđena je povezanost između Dijeljenja znanja i Uspješnosti poslovanja poduzeća (p < 0,001). Utvrđena je medijacijska uloga Dijeljenja znanja između Organizacijske kulture i Uspješnosti poslovanja poduzeća (β = 0,39, p < 0,001), te IKT-a i Uspješnosti poslovanja poduzeća (β = 0,32, p < 0,001). Porastom vrijednosti mjere Organizacijske kulture rast će i vrijednost mjere Dijeljenje znanja, što će povećavati Uspješnost poslovanja poduzeća. Porastom vrijednosti mjere IKT-a rast će

vrijednost mjere Dijeljenje znanja, što će biti povezano s porastom Uspješnosti poslovanja poduzeća. Na donjoj slici prikazani su beta-ponderi između prediktora i medijatora, te medijatora i kriterija.

Slika 9: Jačina veza u medijacijskom modelu (Maximum Likelihood Method sa standardiziranim koeficijentima)



Izvor: pripremila doktorandica.

Potom je testiran moderacijski model za varijablu Podrška vrhovnog menadžmenta. Modelom je zamišljeno da Podrška vrhovnog menadžmenta moderira odnos između Organizacijske kulture i Dijeljenja znanja te IKT-a i Dijeljenja znanja. Moderatori su uključeni u model kao latentne varijable. Konstruirane su nove manifestne varijable kao umnožak svake parcele prediktora sa svakom parcelom moderatora. Novonastale manifestne varijable su centrirane na reziduale i korištene u strukturnom modelu da bi se dobila latentna varijabla moderatora. Provjereno je slaganje modela s podacima, te su zadržane manifestne varijable latentnog moderatora s najvećim zasićenjem, nakon čega je ponovno provjeren model moderirane medijacije.

U izradi konačnog modela uzeti su u obzir *modification indices*, što je isključivo empirijski utemeljen postupak i odnosi se na procjenu kovariranja između indikatora Uspješnost poslovanja poduzeća i Dijeljenje znanja.

Tablica 37: Slaganje moderacijskog modela s podacima za *online* istraživanje

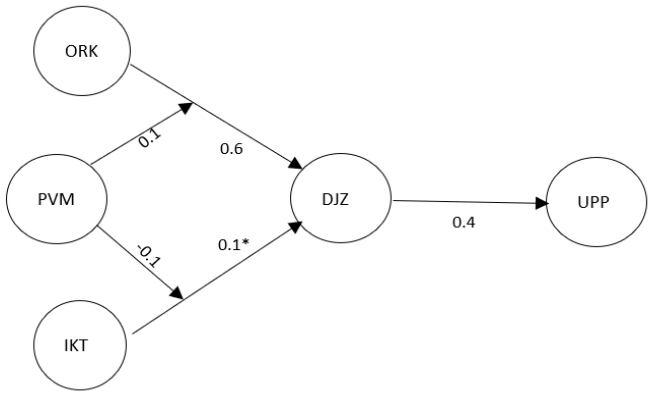
Indeks	Referentna vrijednost	Izračunata vrijednost	Interpretacija (slaganje s podacima)
χ^2/df χ^2 = 404,55, df = 212, p < 0,01	< 3	1,90	Zadovoljavajuće
CFI	> 0,9	0,92	Zadovoljavajuće
TLI	> 0,9	0,91	Zadovoljavajuće
RMSEA	< 0,10	0,08 (0,07-0,09)	Zadovoljavajuće
SRMR	< 0,10	0,05	Zadovoljavajuće

AIC = 5364,62, BIC = 5546,15

Izvor: pripremila doktorandica.

U modelu nije utvrđen moderacijski efekt Podrške vrhovnog menadžmenta na odnos Organizacijske kulture i Dijeljenja znanja te na odnos IKT-a i Dijeljenja znanja. Medijacijski efekt Dijeljenja znanja na odnos između Organizacijske kulture i Uspješnosti poslovanja nije utvrđen, ali je utvrđen medijacijski efekt Dijeljenja znanja na odnos IKT-a i Uspješnosti poslovanja poduzeća (p < 0,001). U ovom slučaju nije utvrđen totalni efekt na objašnjenje Uspješnosti poslovanja poduzeća.

Slika 10: Jačina veza u moderacijskom modelu za *online* istraživanje (Maximum Likelihood Method sa standardiziranim koeficijentima)



Izvor: pripremila doktorandica.

S obzirom na to da su veličina poduzeća i djelatnost poslovanja bile kontrolne varijable, ispitao se njihov utjecaj na model. Međutim, moderiranu medijaciju s kategorijalnim moderatorima (veličina poduzeća i djelatnost poslovanja) nije bilo moguće provesti zbog nejednake veličine podgrupa u svakoj od ovih varijabli. Naime, ima 67 % (84) malih poduzeća, 25 % (31) srednjih poduzeća i 8 % (11) velikih poduzeća. Kod djelatnosti poslovanja bilo je 71 % (90) uslužnih poduzeća, 17 % (21) poduzeća koja pružaju pretežno proizvodnju, te 12 % (15) poduzeća koja nude podjednako proizvodnju i usluge.

4.4.2.3. Rezultati glavnog istraživanja temeljem analize odaslanih tiskanih upitnika o učinku dijeljenja znanja na uspješnost poslovanja poduzeća

U poštanskom istraživanju odaslano je ukupno 1.500 upitnika u frankiranim kovertama s plaćenim odgovorom, od čega ih se 11 vratilo zbog nepoznate adrese, dok ih je 224 vraćeno u potpunosti ispunjeno. Od 224 zaprimljena odgovora, 33 pripada velikim poduzećima (14 %), 64 srednjim poduzećima (29 %), dok ih 127 pripada malim poduzećima (57 %).

Shapiro-Wilk testom provjerena je normalnost distribucija te su izračunate mjere spljoštenosti i asimetričnosti. Navedeni rezultati prikazani su u Tablici 10, kao i ostali deskriptivni parametri.

Tablica 38: Normalnost distribucije u poštanskom istraživanju

Varijabla	K	M	SD	Asimetričnost (SE)	Spljoštenost (SE)	Shapiro--Wilk (W)
Poslovna misija	4	4,39	0,54	-0,85	0,26	0,90**
Opunomoćivanje zaposlenika	4	4,25	0,86	2,66	2,84	0,75**
Kontinuirano učenje	4	3,96	0,77	-0,54	-0,55	0,94**
Investicije u IKT sustave	4	3,97	0,79	-1,00	1,16	0,92**
Prepoznavanje poslovnih prilika	4	3,40	0,99	-0,16	-0,59	0,97**
Poboljšana komunikacija	4	4,25	0,74	-1,21	1,69	0,87**
Davanje eksplicitnog znanja	3	4,32	0,73	-1,31	1,65	0,85**
Davanje implicitnog znanja	3	4,04	0,68	-0,78	0,67	0,94**
Primanje eksplicitnog znanja	3	4,03	0,77	-0,94	0,81	0,92**
Primanje implicitnog znanja	3	3,30	0,97	-0,24	-0,58	0,97**
Otvorenost menadžera idejama zaposlenika	4	4,32	0,68	-1,26	2,36	0,86**
Razvijanje povjerenja menadžera i zaposlenika	4	3,37	0,97	-0,17	-0,56	0,97**
Mentoriranje zaposlenika	4	4,40	0,65	-1,32	1,75	0,83**
Nefinancijski pokazatelji prije Covida	4	3,95	0,84	-0,78	0,38	0,93**
Nefinancijski pokazatelji nakon Covida	4	3,68	1,03	-0,46	-0,66	0,94**
Financijski pokazatelji prije Covida	4	3,94	0,75	-0,83	1,47	0,94**
Financijski pokazatelji nakon Covida	4	3,92	0,80	-0,73	0,80	0,94**

Legenda: K - broj čestica, M - aritmetička sredina, SD - standardna devijacija ** $p < 0.01$

Izvor: pripremila doktorandica.

Prema tabličnom prikazu rezultata može se primijetiti kako je Shapiro-Wilk test za sve varijable pokazao značajno odstupanje rezultata od normalne distribucije ($p < 0,01$). Međutim, provjerene su i mjere asimetričnosti i spljoštenosti koje ne prelaze vrijednosti od 3 i 10, respektivno, što znači da su rezultati prema **Kline** (**2010.**) kriteriju prihvatljivi i upotrebljivi za daljnju obradu.

Prije izračuna CFA-a, napravljena je analiza demografskih varijabli ispitanika koji su bili obuhvaćeni poštanskim istraživanjem, a koja je prikazana u sljedećoj tablici.

Tablica 39: Deskriptivni pokazatelji uzorka iz poštanskog istraživanja

VARIJABLA	REFERENTNE VRIJEDNOSTI	FREKVENCIJA	POSTOTAK
SPOL	N/A M Ž	2 108 115	0,9 48,0 51,1
DOBNA SKUPINA	N/A 1. 20 - 29 2. 30 - 39 3. 40 - 49 4. 50 - 59 5. 60 - 64 6. 65 i više	1 10 59 79 45 22 9	0,4 4,4 26,2 35,1 20,0 9,8 4,0
RADNI STAŽ U PODUZEĆU	1. < 10 godina 2. 10 – 20 godina 3. > 20 godina	95 69 61	42,2 30,7 27,1
NAJVIŠI ZAVRŠENI STUPANJ OBRAZOVANJA	N/A 1. osnovna škola 2. srednja škola 3. viša stručna sprema / prvostupnik 4. visoka stručna sprema / stručni magisterij 5. znanstveni magisterij / doktorat	1 0 26 41 139 18	0,4 0 11,6 18,2 61,8 8,0
POLOŽAJ U PODUZEĆU	N/A 1. vrhovni menadžment 2. srednji menadžment 3. niži menadžment 4. nemenadžerska razina	1 121 71 10 22	0,4 53,8 31,6 4,4 9,8
GODINE RADNOG ISKUSTVA NA TRENUTNOJ POZICIJI	N/A 1. < 10 godina 2. 10 – 20 godina 3. > 20 godina	2 101 67 55	0,9 44,9 29,8 24,4
VLASNIČKA STRUKTURA	N/A 1. privatno vlasništvo 2. državno vlasništvo 3. mješovito vlasništvo	2 202 14 7	0,9 89,8 6,2 3,1
VELIČINA PODUZEĆA MJERENA BROJEM ZAPOSLENIH	N/A 1. veliko poduzeće (> 250 zaposlenika) 2. srednje poduzeće (50 – 250 zaposlenika) 3. malo poduzeće (< 50 zaposlenika)	1 33 65 126	0,4 14,7 28,9 56,0
DJELATNOST POSLOVANJA	N/A 1. pretežno proizvodnja 2. pretežno usluge 3. kombinacija proizvodnje i usluga	2 43 120 60	0,9 19,1 53,3 26,7
DJELOKRUG POSLOVANJA PODUZEĆA	N/A 1. pretežno domaće tržište 2. pretežno inozemno tržište 3. kombinacija domaćeg i inozemnog tržišta	1 93 24 107	0,4 41,3 10,7 47,6

Izvor: pripremila doktorandica.

Iz tablice je vidljivo kako je u uzorku više žena nego muškaraca, najčešće dobi između 40 i 49 godina, a u radnom odnosu su najčešće manje od 10 godina. Ispitanici u uzorku uglavnom su

visoke stručne spreme te obnašaju funkciju vrhovnog menadžera u poduzeću, a najviše njih je na ovoj poziciji zaposleno manje od 10 godina. Uzorkom su većinom obuhvaćena mala poduzeća u privatnom vlasništvu koja nude usluge na domaćem i međunarodnom tržištu. Podaci prikupljeni temeljem povrata otisnutih upitnika analizirani su po istom principu kao i podaci u *online* istraživanju. Inicijalno slaganje modela s podacima u poštanskom istraživanju nije bilo prihvatljivo: $\chi 2 = 327{,}75$, df = 109, $p < 0{,}00$; $\chi 2/df = 3$; CFI = 0,87 i TLI = 0,86; RMSEA = 0,09 (0,08 - 0,11) i SRMR = 0,06. Pritom je veličina indeksa AIC = 6367,12, BIC = 6513,33. Pregledom *modification indices* utvrđeno je da bi se moglo poboljšati slaganje modela s podacima dodatnom procjenom kovarijance indikatora Dijeljenje znanja te Uspješnost poslovanja poduzeća.

Tablica 40: Slaganje modela s podacima za poštansko istraživanje

Indeks	Referentna vrijednost	Izračunata vrijednost	Interpretacija (slaganje s podacima)
χ^2/df $\chi^2 = 235{,}24$, df = 107, $p < 0{,}01$	< 3	2,19	Zadovoljavajuće
CFI	> 0,9	0,93	Zadovoljavajuće
TLI	> 0,9	0,91	Zadovoljavajuće
RMSEA	< 0,10	0,07 (0,06-0,09)	Zadovoljavajuće
SRMR	< 0,10	0,05	Zadovoljavajuće

AIC = 6.278,60, BIC = 6.431,47

Izvor: pripremila doktorandica.

Sve čestice u modelu su bile zadovoljavajuće visoko zasićene pretpostavljenim faktorima, što se može vidjeti u tablici 41.

Tablica 41: Faktorska zasićenja indikatora (parcela) s pripadajućom latentnom varijablom u poštanskom istraživanju

Latentna varijabla	Indikator	Zasićenje
Organizacijska kultura	Poslovna misija	0,61
Organizacijska kultura	Opunomoćivanje zaposlenika	0,61
Organizacijska kultura	Kontinuirano učenje	0,77
Informacijsko komunikacijska tehnologija	IKT investicije	0,77
Informacijsko komunikacijska tehnologija	Poslovne prilike	0,72
Informacijsko komunikacijska tehnologija	Poboljšana komunikacija	0,79
Podrška vrhovnog menadžmenta	Otvorenost menadžera idejama zaposlenika	0,79
Podrška vrhovnog menadžmenta	Razvijanje povjerenja	0,79
Podrška vrhovnog menadžmenta	Mentoriranje zaposlenika	0,80
Dijeljenje znanja	Davanje eksplicitnog znanja	0,75
Dijeljenje znanja	Davanje implicitno znanje	0,67
Dijeljenje znanja	Primanje eksplicitno znanje	0,68
Dijeljenje znanja	Primanje implicitno znanje	0,65
Uspješnost poslovanja poduzeća	Financije prije 2020.	0,61
Uspješnost poslovanja poduzeća	Financije poslije 2020.	0,60
Uspješnost poslovanja poduzeća	Nefinancije prije 2020.	0,86
Uspješnost poslovanja poduzeća	Nefinancije poslije 2020.	0,95

Izvor: pripremila doktorandica.

Na isti način kao i u *online* istraživanju, prvo je ispitana medijacija, a potom i moderacija. Medijacijski model analiziran je na podacima prikupljenim u poštanskom istraživanju u kojem su Organizacijska kultura i IKT bili prediktori, Dijeljenje znanja medijator, a Uspješnost poslovanja poduzeća kriterij. Medijacijski model proveden je na latentnim varijablama i pokazao je dobro pristajanje podacima.

Tablica 42: Slaganje medijacijskog modela s podacima za poštansko istraživanje

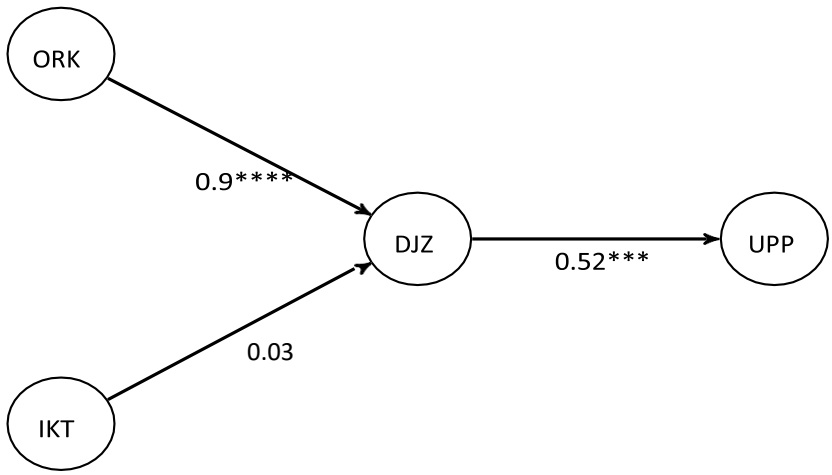
Indeks	Referentna vrijednost	Izračunata vrijednost	
χ^2/df χ^2 = 210,32, df = 110, p < 0,01	< 3	1,9	Dobro
CFI	> 0,9	0,94	Dobro
TLI	> 0,9	0,93	Dobro
RMSEA	< 0,10	0,06 (0,08-0,08)	Dobro
SRMR	< 0,10	0,05	Dobro

AIC = 6.247,70, BIC = 6.390,59

Izvor: pripremila doktorandica.

Utvrđena je povezanost između Organizacijske kulture i Dijeljenja znanja (p < 0,001), ali ne između IKT-a i Dijeljenja znanja (p = 0,76). Također, utvrđena je povezanost između Dijeljenja znanja i Uspješnosti poslovanja poduzeća (p < 0,001). Utvrđena je medijacijska uloga Dijeljenja znanja između Organizacijske kulture i Uspješnosti poslovanja poduzeća (β = 0,53, p < 0,001), ali ne i IKT-a i Uspješnosti poslovanja poduzeća (p = 0,76). Porastom mjere Organizacijske kulture rast će i mjera varijable Dijeljenje znanja, što će povećavati mjeru varijable Uspješnost poslovanja poduzeća. Na donjoj slici su prikazani ponderi između prediktora i medijatora te medijatora i kriterija.

Slika 11: Jačina veza u medijacijskom modelu za poštansko istraživanje (Maximum Likelihood Method sa standardiziranim koeficijentima)



Izvor: pripremila doktorandica.

Moderacijski model u glavnom istraživanju je djelomično zadovoljavajuće pristajao podacima.

Tablica 43: Slaganje moderacijskog modela s podacima za poštansko istraživanje

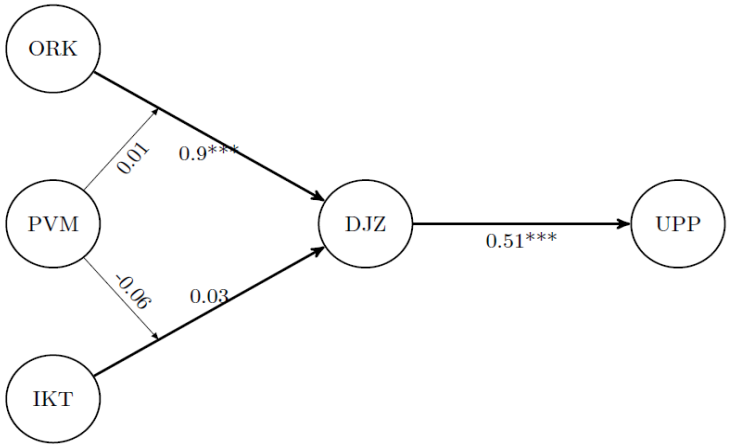
Indeks	Referentna vrijednost	Izračunata vrijednost	Interpretacija (slaganje s podacima)
χ^2/df χ^2 = 300,73, df = 141, p < 0,01	< 3	2,12	Zadovoljavajuće
CFI	> 0,9	0,92	Zadovoljavajuće
TLI	> 0,9	0,90	Zadovoljavajuće
RMSEA	< 0,10	0,07 (0,06 - 0,08)	Zadovoljavajuće
SRMR	< 0,10	0,1	Zadovoljavajuće

AIC = 6.237,20, BIC = 6.390,0

Izvor: pripremila doktorandica.

U modelu je utvrđena povezanost između Organizacijske kulture i Dijeljenja znanja (p < 0,001) te Dijeljenja znanja i Uspješnosti poslovanja poduzećem (p < 0,001), te je utvrđen medijacijski efekt Dijeljenja znanja između Organizacijske kulture i Uspješnosti poslovanja poduzeća (β = 0,53, p < 0,001). Međutim, nije utvrđena interakcija između Podrške vrhovnog menadžmenta i Organizacijske kulture te Podrške vrhovnog menadžmenta i IKT-a na Dijeljenje znanja. Također, nije utvrđen moderacijski efekt Podrške vrhovnog menadžmenta na odnos između prediktora i kriterija posredovan dijeljenjem znanja.

Slika 12: Moderacijski model i jačina veza za poštansko istraživanje (Maximum Likelihood Method sa standardiziranim koeficijentima)



Izvor: pripremila doktorandica.

4.4.2.4. Rezultati sveukupnog istraživanja temeljem objedinjenih uzoraka o učinku dijeljenja znanja na uspješnost poslovanja poduzeća

Objedinjenim istraživanjem obuhvaćeno je sveukupno 3.000 poduzeća, od čega je prikupljeno 350 kompletnih odgovora sljedeće strukture: 44 velikih poduzeća (13 %), 95 srednje velikih

poduzeća (27 %) i 211 malih poduzeća (60 %). Među ispitanicima ukupno je 52 % muškaraca, 35 % ih je u dobi od 40 do 49 godina s manje od 10 godina radnog staža (38 %), visoke su stručne spreme (60 %), 56 % ispitanika pripada vrhovnom menadžmentu s radnim iskustvom na istom radnom mjestu manjim od 10 godina (42 %), dok ispitana poduzeća pripadaju privatnom sektoru (90 %), male su veličine (62 %) te uglavnom pružaju usluge (60 %) na domaćem tržištu (46 %).

Shapiro-Wilk testom provjerena je normalnost distribucija te su izračunate mjere spljoštenosti i asimetričnosti. Navedeni rezultati prikazani su u Tablici 44, kao i ostali deskriptivni parametri.

Tablica 44: Normalnost distribucije za objedinjeno istraživanje

Varijabla	K	M	SD	Asimetričnost (SE)	Spljoštenost (SE)	Shapiro--Wilk (W)
Poslovna misija	4	4,32	0,64	-1,51	3,54	0,86**
Opunomoćivanje zaposlenika	4	4,20	0,87	1,11	1,85	0,80**
Kontinuirano učenje	4	3,92	0,81	-0,72	0,08	0,94**
Investicije u IKT sustave	4	3,89	0,84	-0,97	0,78	0,92**
Prepoznavanje poslovnih prilika	4	3,28	1,02	-0,15	-0,60	0,97**
Poboljšana komunikacija	4	4,12	0,84	-1,26	1,66	0,87**
Davanje eksplicitnog znanja	3	4,31	0,78	-1,45	2,18	0,83**
Davanje implicitnog znanja	3	4,05	0,73	-0,82	0,48	0,93**
Primanje eksplicitnog znanja	3	3,95	0,83	-0,93	0,61	0,92**
Primanje implicitnog znanja	3	3,25	1,03	-0,31	-0,61	0,97**
Otvorenost menadžera idejama zaposlenika	4	4,27	0,72	-1,21	1,67	0,86**
Razvijanje povjerenja menadžera i zaposlenika	4	3,32	0,99	-0,26	-0,43	0,97**
Mentoriranje zaposlenika	4	4,37	0,68	-1,53	2,84	0,82**
Nefinancijski pokazatelji prije Covida	4	3,88	0,88	-0,75	0,30	0,93**
Nefinancijski pokazatelji nakon Covida	4	3,59	1,03	-0,37	-0,71	0,95**
Financijski pokazatelji prije Covida	4	3,93	0,79	-0,86	1,11	0,93**
Financijski pokazatelji nakon Covida	4	3,89	0,84	-0,82	0,84	0,93**

Legenda: K-broj čestica, M - aritmetička sredina, SD - standardna devijacija ** $p < 0.01$

Izvor: pripremila doktorandica.

Prema tabličnom prikazu rezultata može se primijetiti kako je Shapiro-Wilk test za sve varijable pokazao značajno odstupanje rezultata od normalne distribucije ($p < 0,01$). Međutim, provjerene su i mjere asimetričnosti i spljoštenosti koje ne prelaze vrijednosti od 3 i 10, respektivno, što znači da su rezultati, prema **Kline** (**2010.**) kriteriju prihvatljivi i upotrebljivi za daljnju obradu. Prije izračuna CFA-a, napravljena je analiza demografskih

varijabli ispitanika koji su bili obuhvaćeni predistraživanjem i glavnim istraživanjem, a koja je prikazana u sljedećoj tablici.

Tablica 45: Deskriptivni pokazatelji uzorka iz objedinjenog istraživanja

VARIJABLA	REFERENTNE VRIJEDNOSTI	FREKVENCIJA	POSTOTAK
SPOL	N/A M Ž	2 182 167	0,6 51,9 47,6
DOBNA SKUPINA	N/A 1. 20 - 29 2. 30 - 39 3. 40 - 49 4. 50 - 59 5. 60 - 64 6. 65 i više	1 14 89 124 79 31 13	0,3 4,0 25,4 35,3 22,5 8,8 3,7
RADNI STAŽ U PODUZEĆU	1. < 10 godina 2. 10 – 20 godina 3. > 20 godina	134 117 100	38,2 33,3 28,5
NAJVIŠI ZAVRŠENI STUPANJ OBRAZOVANJA	N/A 1. osnovna škola 2. srednja škola 3. viša stručna sprema / prvostupnik 4. visoka stručna sprema / stručni magisterij 5. znanstveni magisterij / doktorat	1 0 45 66 211 28	0,3 0 12,8 18,8 60,1 8,0
POLOŽAJ U PODUZEĆU	N/A 1. vrhovni menadžment 2. srednji menadžment 3. niži menadžment 4. nemenadžerska razina	1 199 99 17 35	0,3 56,7 28,2 4,8 10,0
GODINE RADNOG ISKUSTVA NA TRENUTNOJ POZICIJI	N/A 1. < 10 godina 2. 10 – 20 godina 3. > 20 godina	2 146 117 86	0,6 41,6 33,3 24,5
VLASNIČKA STRUKTURA	N/A 1. privatno vlasništvo 2. državno vlasništvo 3. mješovito vlasništvo	2 319 21 9	0,6 90,9 6,0 2,6
VELIČINA PODUZEĆA MJERENA BROJEM ZAPOSLENIH	N/A 1. veliko poduzeće (> 250 zaposlenika) 2. srednje poduzeće (50 – 250 zaposlenika) 3. malo poduzeće (< 50 zaposlenika)	1 44 96 210	0,3 12,5 27,4 59,8
DJELATNOST POSLOVANJA	N/A 1. pretežno proizvodnja 2. pretežno usluge 3. kombinacija proizvodnje i usluga	2 63 211 75	0,6 17,9 60,1 21,4
DJELOKRUG POSLOVANJA PODUZEĆA	N/A 1. pretežno domaće tržište 2. pretežno inozemno tržište 3. kombinacija domaćeg i inozemnog tržišta	1 161 52 137	0,3 45,9 14,8 39,0

Izvor: pripremila doktorandica.

Pregledom *modification indicesa* u konfirmatornom faktorskom modelu napravljenom na podacima iz predistraživanja i glavnog istraživanja, utvrđeno je da bi se moglo poboljšati slaganje modela s podacima dodatnom procjenom kovarijance indikatora Dijeljenja znanja te Uspješnost poslovanja poduzeća. Slaganje takvog modela s podacima je zadovoljavajuće.

Tablica 46: Slaganje modela s podacima za objedinjeno istraživanje

Indeks	Referentna vrijednost	Izračunata vrijednost	Interpretacija (slaganje s podacima)
χ^2/df χ^2 = 260,09, df = 106, p < 0,01	< 3	2,45	Zadovoljavajuće
CFI	> 0,9	0,96	Zadovoljavajuće
TLI	> 0,9	0,94	Zadovoljavajuće
RMSEA	< 0,10	0,06 (0,05-0,07)	Zadovoljavajuće
SRMR	< 0,10	0,04	Zadovoljavajuće

AIC = 10.241,38, BIC = 10.420,08

Izvor: pripremila doktorandica.

Sve čestice u modelu su bile zadovoljavajuće visoko zasićene pretpostavljenim faktorima, što se može vidjeti u tablici 47.

Tablica 47: Faktorska zasićenja indikatora (parcela) s pripadajućom latentnom varijablom za sve podatke

Latentna varijabla	Indikator	Zasićenje
Organizacijska kultura	Poslovna misija	0,74
Organizacijska kultura	Opunomoćivanje zaposlenika	0,74
Organizacijska kultura	Kontinuirano učenje	0,83
Informacijsko komunikacijska tehnologija	IKT investicije	0,82
Informacijsko komunikacijska tehnologija	Poslovne prilike	0,72
Informacijsko komunikacijska tehnologija	Poboljšana komunikacija	0,87
Podrška vrhovnog menadžmenta	Otvorenost menadžera idejama zaposlenika	0,82
Podrška vrhovnog menadžmenta	Razvijanje povjerenja	0,82
Podrška vrhovnog menadžmenta	Mentoriranje zaposlenika	0,82
Dijeljenje znanja	Davanje eksplicitnog znanja	0,71
Dijeljenje znanja	Davanje implicitno znanje	0,66
Dijeljenje znanja	Primanje eksplicitno znanje	0,63
Dijeljenje znanja	Primanje implicitno znanje	0,70
Uspješnost poslovanja poduzeća	Financije prije 2020.	0,69
Uspješnost poslovanja poduzeća	Financije poslije 2020.	0,58
Uspješnost poslovanja poduzeća	Nefinancije prije 2020.	0,91
Uspješnost poslovanja poduzeća	Nefinancije poslije 2020.	0,53

Izvor: pripremila doktorandica.

S obzirom na to da u *online* i poštanskom istraživanju nije bila moguća usporedba dobivenih rezultata temeljem kontrolnih varijabli, analiza se ponovila na objedinjenom uzorku. Najprije se učinila usporedba dobivenih rezultata korištenjem kontrolne varijable djelatnost poduzeća. Napravljena je konfirmatorna faktorska analiza za model u kojem nisu fiksirana faktorska

zasićenja, konfirmatorna faktorska analiza za model u kojem su fiksirana sva faktorska opterećenja, zatim je napravljena konfirmatorna faktorska analiza za model u kojem su fiksirana faktorska opterećenja i nagibi pravca pri čemu su se provjeravali parametri u svakoj grupi ispitanika.

U inicijalnom modelu, u kojem nisu fiksirana zasićenja, a provjeravala su se za svaku grupu ispitanika, pristajanje modela podacima je bilo dobro - χ^2 = 557,56, df = 318, p < 0,001; χ^2/df = 1,7; CFI = 0,93 i TLI = 0,92; RMSEA = 0,08 (0,07-0,09) i SRMR = 0,05. Pritom je veličina indeksa AIC = 10291,52, BIC = 11020,36.

U modelu u kojem su fiksirana faktorska zasićenja, pristajanje modela podacima je bilo dobro - χ^2 = 582,59, df = 342, p < 0,001; χ^2/df = 1,7; CFI = 0,93 i TLI = 0,92; RMSEA = 0,08 (0,06 - 0,09) i SRMR = 0,06. Pritom je veličina indeksa AIC = 10268,54, BIC = 10906,28.

U modelu u kojem su fiksirana faktorska zasićenja i nagibi pravca, pristajanje modela podacima je bilo dobro -χ^2 = 601,0, df = 366, p < 0,001; χ^2/df = 1,64; CFI = 0,93 i TLI = 0,93; RMSEA = 0,07 (0,06 - 0,08) i SRMR = 0,06. Pritom je veličina indeksa AIC = 10238,96, BIC = 10785,59.

Usporedbom prosjeka latentnih varijabli ispada da nema razlike među djelatnostima poduzeća na proučavanim latentnim dimenzijama (Tablica 48 i Tablica 49).

Tablica 48: Prosječne vrijednosti latentnih varijabli za tri grupe poduzeća koje se razlikuju po djelatnosti

Latentna varijabla	Pretežno usluge	Pretežno proizvodnja	Podjednako usluge i proizvodnja
Organizacijska kultura	0	-0,13	0,00
IKT	0	-0,32	0,12
Podrška vrhovnog menadžmenta	0	-0,17	-0,03
Dijeljenje znanja	0	-0,24	0,03
Uspješnost poslovanja poduzeća	0	0,01	0,13

Izvor: pripremila doktorandica

Tablica 49: Hi-kvadrat test za CFA model za tri grupe poduzeća koje se razlikuju po djelatnosti

CFA model	Df	AIC	BIC	Chisq	Chisq diff	Df diff	Pr(>Chisq)
CFA model	318	10291,52	11020,36	557,56	N/A	N/A	N/A
Fiksirana zasićenja	342	10268,55	10906,29	582,59	25,03	24	0,40
Fiksirana zasićenja i nagibi	366	10238,96	10785,59	601,00	18,41	24	0,78

Izvor: pripremila doktorandica.

Ista analiza potom je učinjena i za kontrolnu varijablu veličina poduzeća. Napravljena je konfirmatorna faktorska analiza za model u kojem nisu fiksirana faktorska zasićenja, konfirmatorna faktorska analiza za model u kojem su fiksirana sva faktorska opterećenja, zatim je napravljena konfirmatorna faktorska analiza za model u kojem su fiksirana faktorska opterećenja i nagibi pravca, pri čemu su se provjeravali parametri u svakoj grupi ispitanika. U inicijalnom modelu, u kojem nisu fiksirana zasićenja, a provjeravala su se za svaku grupu ispitanika, pristajanje modela podacima je bilo dobro - χ^2 = 590,45, df = 318, p < 0,001; χ^2/df = 1,85; CFI = 0,93 i TLI = 0,91; RMSEA = 0,08 (0,07-0,09) i SRMR = 0,05. Pritom je veličina indeksa AIC = 10271,33, BIC = 11000,76.

U modelu u kojem su fiksirana faktorska zasićenja, pristajanje modela podacima je bilo dobro - χ^2 = 616,79, df = 342, p < 0,001; χ^2/df = 1,8; CFI = 0,93 i TLI = 0,91; RMSEA = 0,08 (0,07 - 0,09) i SRMR = 0,06. Pritom je veličina indeksa AIC = 10249,67, BIC = 10887,92.

U modelu u kojem su fiksirana faktorska zasićenja i nagibi pravca, pristajanje modela podacima je bilo dobro -χ^2 = 657,43, df = 366, p < 0,001; χ^2/df = 1,79; CFI = 0,93 i TLI = 0,92; RMSEA = 0,08 (0,07-0,09) i SRMR = 0,06. Pritom je veličina indeksa AIC = 10242,31, BIC = 10789,38. Usporedbom prosjeka latentnih varijabli ispada da postoji razlika među veličinama poduzeća na proučavanim latentnim dimenzijama (Tablica 50 i Tablica 51), međutim, odstupanja su vrlo mala, što govori u prilog da su razlike među grupama gotovo zanemarive.

Tablica 50: Prosječne vrijednosti latentnih varijabli za tri grupe poduzeća koje se razlikuju po veličini

Latentna varijabla	Malo poduzeće	Srednje poduzeće	Veliko poduzeće
Organizacijska kultura	0,08	0	0,05
IKT	-0,05	0	-0,07
Podrška vrhovnog menadžmenta	0,11	0	-0,04
Dijeljenje znanja	-0,03	0	0,16
Uspješnost poslovanja poduzeća	0,07	0	0,16

Izvor: pripremila doktorandica.

Tablica 51: Hi-kvadrat test za CFA model za tri grupe poduzeća koje se razlikuju po veličini

CFA model	Df	AIC	BIC	Chisq	Chisq diff	Df diff	Pr(>Chisq)
CFA model	318	10271,34	11000,76	590,45	N/A	N/A	N/A
Fiksirana zasićenja	342	10249,68	10887,92	616,79	26,34	24	0,34
Fiksirana zasićenja i nagibi	366	10242,32	10789,39	657,43	40,64	24	0,02

Izvor: pripremila doktorandica.

Usporedbom tablica za kontrolne varijable djelatnost i veličina poduzeća moguće je zaključiti da među poduzećima iz uzorka ne postoje razlike s aspekta analiziranih korelacija, odnosno ispitivanja medijacije i moderacije. Procesi dijeljenja znanja identični su u svim izučavanim poduzećima neovisno o njihovoj veličini i djelatnosti.

Potom se ispitivala medijacija i moderacija kao i u prethodnim istraživanjima (*online* i poštansko istraživanje). Prvo je napravljen medijacijski model na podacima prikupljenim u *online* i poštanskom istraživanju u kojem su Organizacijska kultura i IKT bili prediktori, Dijeljenje znanja medijator, a Uspješnost poslovanja poduzeća kriterij. Medijacijski model je proveden na latentnim varijablama i pokazao je zadovoljavajuće pristajanje podacima.

Tablica 52: Slaganje medijacijskog modela s podacima za objedinjeno istraživanje

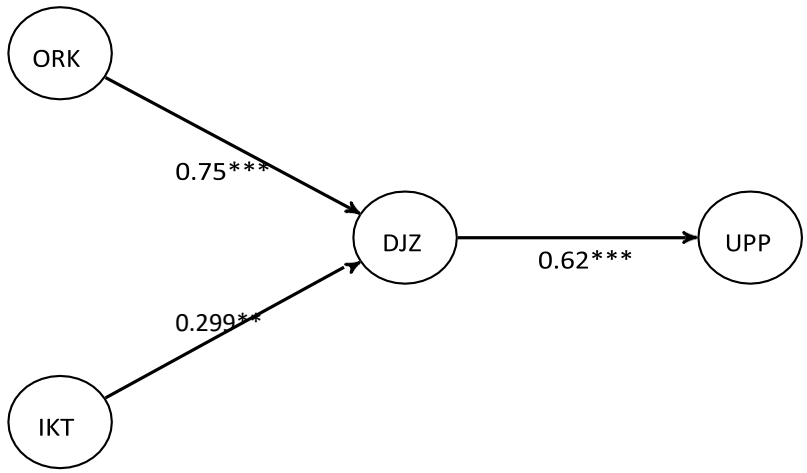
Indeks	Referentna vrijednost	Izračunata vrijednost	Interpretacija (slaganje s podacima)
$\chi 2/df$ $\chi 2 = 263{,}55$, df = 110, $p < 0{,}00$	< 3	2,39	Zadovoljavajuće
CFI	> 0,9	0,96	Zadovoljavajuće
TLI	> 0,9	0,95	Zadovoljavajuće
RMSEA	< 0,10	0,06 (0,05-0,07)	Zadovoljavajuće
SRMR	< 0,10	0,04	Zadovoljavajuće

AIC = 10.236,84, BIC = 10.400,33

Izvor: pripremila doktorandica.

Utvrđena je povezanost između Organizacijske kulture i Dijeljenja znanja ($p < 0{,}001$), te između IKT-a i Dijeljenja znanja ($p < 0{,}001$). Također je utvrđena povezanost između Dijeljenja znanja i Uspješnosti poslovanja poduzeća ($p < 0{,}001$). Utvrđena je medijacijska uloga Dijeljenja znanja između Organizacijske kulture i Uspješnosti poslovanja poduzeća ($\beta = 0{,}47$, $p < 0{,}001$) te medijacijska uloga Dijeljenja znanja između IKT-a i Uspješnosti poslovanja poduzeća ($\beta = 0{,}18$, $p < 0{,}001$). Porastom vrijednosti mjere Organizacijske kulture rast će i vrijednost mjere Dijeljenje znanja, što će povećavati Uspješnost poslovanja poduzeća, a porastom vrijednosti mjere IKT-a rast će i vrijednost mjere Dijeljenje znanja, što će povećavati Uspješnost poslovanja poduzeća. Na slici 13 su prikazani beta-ponderi između prediktora i medijatora te medijatora i kriterija.

Slika 13: Medijacija i jačina veza u objedinjenom istraživanju (Maximum Likelihood Method sa standardiziranim koeficijentima)



Izvor: pripremila doktorandica.

Moderacijski model u glavnom istraživanju je djelomično zadovoljavajuće pristajao podacima.

Tablica 53: Slaganje moderacijskog modela s podacima za objedinjeno istraživanje

Indeks	Referentna vrijednost	Izračunata vrijednost	Interpretacija (slaganje s podacima)
$\chi 2/df$ $\chi 2 = 476{,}89$, df = 141, $p < 0{,}01$	< 3	3,38	Dobro
CFI	> 0,9	0,92	Dobro
TLI	> 0,9	0,90	Dobro
RMSEA	< 0,10	0,08 (0,07-0,09)	Dobro
SRMR	< 0,10	0,16	Dobro

AIC = 10.236,84, BIC = 10.400,33

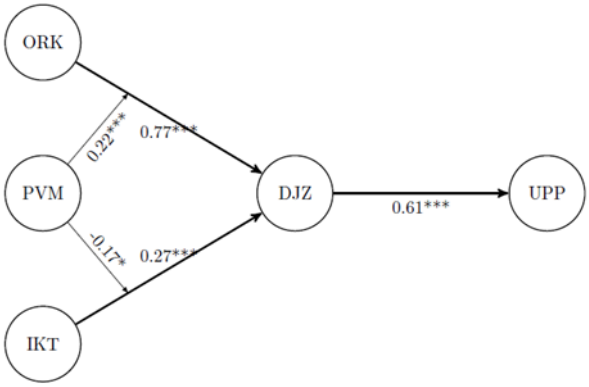
Izvor: pripremila doktorandica.

U modelu je utvrđena povezanost između Organizacijske kulture i Dijeljenja znanja ($p < 0{,}001$) te Dijeljenja znanja i Uspješnosti poslovanja poduzeća ($p < 0{,}001$), te je utvrđen medijacijski efekt Dijeljenja znanja između Organizacijske kulture i Uspješnosti poslovanja poduzeća ($\beta = 0{,}48$, $p < 0{,}001$). U modelu je utvrđenapovezanost između IKT-a i Dijeljenja znanja ($p < 0{,}001$) te je utvrđen medijacijski efekt Dijeljenja znanja između IKT-a i Uspješnosti poslovanja poduzeća ($\beta = 0{,}17$, $p < 0{,}001$).

Utvrđena je interakcija između Podrške vrhovnog menadžmenta i Organizacijske kulture ($\beta = 0{,}16$, $p < 0{,}001$) te interakcija između IKT-a i Podrške vrhovnog menadžmenta ($\beta = -0{,}12$, $p < 0{,}05$) na Dijeljenje znanja. Utvrđena je moderirana medijacija ($\beta = 0{,}10$, $p < 0{,}001$), što znači

da Podrška vrhovnog menadžmenta određuje vezu između Organizacijske kulture i Dijeljenja znanja koja posreduje između Organizacijske kulture i Uspješnosti upravljanja poduzeća.

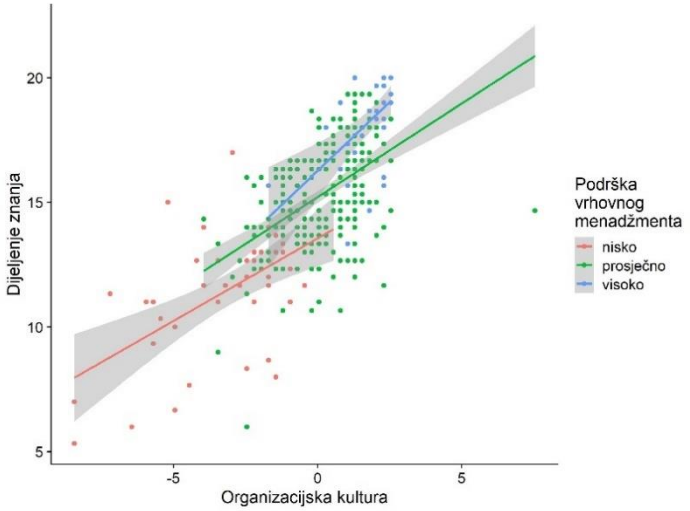
Slika 14: Moderacija i jačina veza u objedinjenom istraživanju (Maximum Likelihood Method sa standardiziranim koeficijentima)



Izvor: pripremila doktorandica.

Radi lakše interpretacije veza između prediktora, medijatora i kriterija, u nastavku se daje i grafički prikaz pojedinih relacija. Kada je riječ o interakciji između Podrške vrhovnog menadžmenta i Organizacijske kulture na Dijeljenje znanja, može se vidjeti da prosječna Podrška vrhovnog menadžmenta i visoka Organizacijska kultura rezultiraju najvišim Dijeljenjem znanja, visoka Podrška vrhovnog menadžmenta i umjerena Organizacijska kultura rezultiraju visokim Dijeljenjem znanja, dok niska Podrška vrhovnog menadžmenta i niska Organizacijska kultura rezultiraju slabim Dijeljenjem znanja.

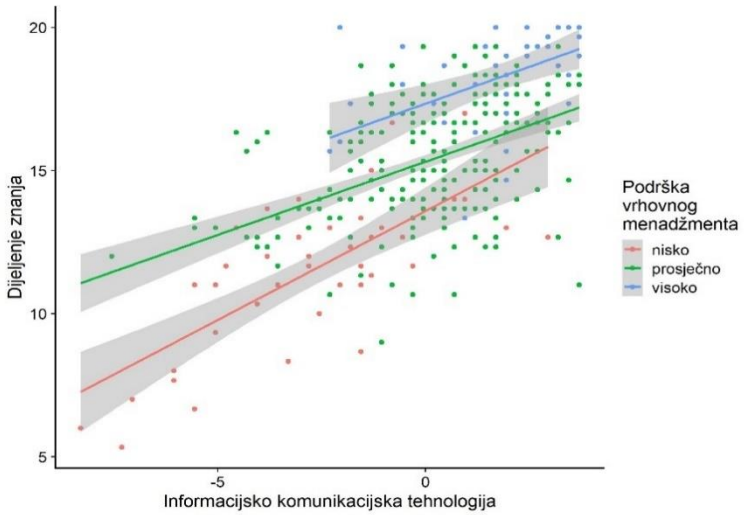
Slika 15: Interakcija između Podrške vrhovnog menadžmenta i Organizacijske kulture na Dijeljenje znanja



Izvor: pripremila doktorandica.

Kada je riječ o interakciji između Podrške vrhovnog menadžmenta i IKT-a na Dijeljenje znanja, može se vidjeti da visoka Podrška vrhovnog menadžmenta i blago pozitivni IKT-i rezultiraju najvišim Dijeljenjem znanja, prosječna Podrška vrhovnog menadžmenta i blago pozitivni IKT-i rezultiraju umjerenim Dijeljenjem znanja, dok niska Podrška vrhovnog menadžmenta i niski IKT-i rezultiraju slabim dijeljenjem znanja.

Slika 16: Interakcija izmeću Podrške vrhovnog menadžmenta i IKT-a na Dijeljenje znanja



Izvor: pripremila doktorandica.

Prema tome, zaključno se može utvrditi da je analizom moderacije dokazan značajan utjecaj Podrške vrhovnog menadžmenta na odnos između IKT-a, Dijeljenja znanja i Uspješnosti poslovanja poduzeća, dok je Podrška vrhovnog menadžmenta manje značajna pri determiniranju odnosa između Organizacijske kulture, Dijeljenja znanja i Uspješnosti poslovanja poduzeća. Drugim riječima, ako je Organizacijska kultura dovoljno jaka da motivira zaposlenike na Dijeljenje znanja, zaposlenici neće pridavati poseban značaj Podrški vrhovnog menadžmenta pri Dijeljenju znanja. Jaka Organizacijska kultura dovoljno je influentan čimbenik da samostalno pridonosi Dijeljenju znanja među zaposlenicima, a onda posljedično i Uspješnosti poslovanja poduzeća.

4.4.3. Analiza učinka prediktorskih varijabli na proces dijeljenja znanja u odnosu na potprocese davanje i primanje znanja i vrste znanja (eksplicitno i implicitno znanje)

Nakon provjere slaganja konceptualnog modela s podacima, daljnja analiza prikupljenih podataka obuhvatila je ispitivanje interakcija između prediktorskih varijabli (Organizacijska kultura i IKT) i podčestica faktora Dijeljenje znanja: Davanje eksplicitnog znanja, Davanje

implicitnog znanja, Primanje eksplicitnog znanja i Primanje implicitnog znanja, Dijeljenje eksplicitnog znanja (davanje i primanje eksplicitnog znanja), Dijeljenje implicitnog znanja (davanje i primanje implicitnog znanja) te Davanje znanja (eksplicitnog i implicitnog) i Primanje znanja (eksplicitnog i implicitnog). U nastavku se navodi analitika svake podčestice zasebno, kao i kumulativni prikaz doprinosa prediktorskih varijabli razvijenosti pojedinih procesa (davanja i primanja), odnosno vrsta znanja (eksplicitno i implicitno znanje).

Tablice 54: Utjecaj prediktorskih varijabli na Davanje eksplicitnog znanja

Koeficijenti					
Model	Nestandardzirani koeficijenti		Standardizirani koeficijenti	t	Sig.
	B	Stand. greška	Beta		
Davanje eksp. znanja	-,832	,286		-2,906	,004
Posl. misija	,165	,084	,104	1,969	,050
Opunomoćivanje zaposlenika	,016	,061	,014	,259	,796
Kont. učenje	,233	,073	,184	3,198	,002
Investicije u IKT	,065	,073	,053	,896	,371
Prep. posl. prilika	,228	,052	,228	4,371	,000
Poboljšana komunikacija	,335	,077	,275	4,334	,000

Sažetak modela

Model	R	R kvadrat	Prilagođeni R kvadrat	Stand. greška procjene
1	,691[a]	,478	,469	,75025

a. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

ANOVA

Model	Zbroj kvadrata	df	Prosjek kvadrata	F	Sig.
Regresija	176,198	6	29,366	52,172	,000[b]
Rezidual	192,502	342	,563		
Ukupno	368,700	348			

a. Zavisna varijabla: DavEkspZn
b. Prediktori: (Konstanta), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

Rezultati multiple regresije za podčesticu Davanje eksplicitnog znanja pokazali su da je ukupno 48 % varijance objašnjeno kombinacijom nezavisnih varijabli. Tablicom koeficijenata utvrđeno je da zavisnoj varijabli podjednako pridonose sve podčestice. U odnosu na mjerene podčestice, podčestica Opunomoćivanje zaposlenika pokazuje neznatno manji doprinos, što se može pretpostaviti činjenicom da neki zaposlenici smatraju da nisu obvezni dijeliti eksplicitna znanja. Slično je i s podčesticom Investicije u IKT sustave, pa se može pretpostaviti da pojedina poduzeća nisu u potpunosti prilagodila svoje IKT sustave potrebama poslovanja.

Tablice 55: Utjecaj prediktorskih varijabli na Davanje implicitnog znanja

Koeficijenti					
Model	Nestandardzirani koeficijenti		Standardizirani koeficijenti	t	Sig.
	B	Stand. greška	Beta		
Davanje impl. znanja	1,259	,212		5,946	,000
Posl. misija	,201	,062	,179	3,243	,001
Opunomoćivanje zaposlenika	,251	,045	,303	5,547	,000
Kont. učenje	,217	,054	,242	4,032	,000
Investicije u IKT	,042	,054	,049	,784	,434
Prep. posl. prilika	-,089	,039	-,125	-2,307	,022
Poboljšana komunikacija	,088	,057	,102	1,546	,123

Sažetak modela

Model	R	R kvadrat	Prilagođeni R kvadrat	Stand. greška procjene
1	,656a	,430	,420	,55483

a. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

ANOVA

Model	Zbroj kvadrata	df	Prosjek kvadrata	F	Sig.
Regresija	79,542	6	13,257	43,064	,000b
Rezidual	105,282	342	,308		
Ukupno	184,823	348			

a. Zavisna varijabla: DavImplZn
b. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

Rezultati multiple regresije za podčesticu Davanje implicitnog znanja pokazali su da je ukupno 43 % varijance objašnjeno kombinacijom nezavisnih varijabli. Tablicom koeficijenata utvrđeno je da zavisnoj varijabli podjednako pridonose sve podčestice. Malo manji je doprinos primjetan je kod podčestice Investicije u IKT sustave, što bi dalo naslutiti da većina zaposlenika ipak preferira davati implicitno znanje osobnim kontaktom. Slično je i s podčesticom Poboljšana komunikacija, pri čemu se može pretpostaviti da se pojedini zaposlenici previše oslanjaju na IKT sustave pri davanju implicitnog znanja.

Tablice 56: Utjecaj prediktorskih varijabli na Primanje eksplicitnog znanja

Koeficijenti					
Model	Nestandardzirani koeficijenti		Standardizirani koeficijenti	t	Sig.
	B	Stand. greška	Beta		
Primanje eksp. znanja	-,292	,292		-,998	,319
Posl. misija	,136	,086	,089	1,592	,112
Opunomoćivanje zaposlenika	,092	,062	,082	1,477	,140
Kont. učenje	,255	,074	,208	3,429	,001
Investicije u IKT	,056	,074	,048	,760	,448
Prep. posl. prilika	,283	,053	,292	5,310	,000
Poboljšana komunikacija	,117	,079	,099	1,478	,140

Sažetak modela

Model	R	R kvadrat	Prilagođeni R kvadrat	Stand. greška procjene
1	,646a	,417	,407	,76595

a. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

ANOVA

Model	Zbroj kvadrata	df	Prosjek kvadrata	F	Sig.
Regresija	143,373	6	23,895	40,730	,000b
Rezidual	200,646	342	,587		
Ukupno	344,019	348			

a. Zavisna varijabla: PrimEkspZn

b. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

Rezultati multiple regresije za podčesticu Primanje eksplicitnog znanja pokazali su da je ukupno 42 % varijance objašnjeno kombinacijom nezavisnih varijabli. Tablicom koeficijenata utvrđeno je da zavisnoj varijabli podjednako pridonose sve podčestice. Ako se vrši detaljna usporedba, može se primijetiti ponešto slabiji, no i nadalje značajan doprinos Investicija u IKT sustave, Opunomoćivanje zaposlenika (manji broj zaposlenika smatra da imaju dostatna znanja) te Poboljšana komunikacija (nekolicina zaposlenika se moguće previše oslanja na digitalne alate, bez potrebnog tumačenja zaprimljenih informacija).

Tablice 57: Utjecaj prediktorskih varijabli na Primanje implicitnog znanja

Koeficijenti					
Model	Nestandardzirani koeficijenti		Standardizirani koeficijenti	t	Sig.
	B	Stand. greška	Beta		
Primanje imp. znanja	1,379	,199		6,942	,000
Posl. misija	,194	,058	,182	3,337	,001
Opunomoćivanje zaposlenika	,153	,042	,195	3,597	,000
Kont. učenje	,145	,051	,171	2,869	,004
Investicije u IKT	,114	,050	,139	2,250	,025
Prep. posl. prilika	-,088	,036	-,131	-2,433	,015
Poboljšana komunikacija	,191	,054	,235	3,572	,000

Sažetak modela

Model	R	R kvadrat	Prilagođeni R kvadrat	Stand. greška procjene
1	,663a	,439	,429	,52057

a. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

ANOVA

Model	Zbroj kvadrata	df	Prosjek kvadrata	F	Sig.
Regresija	72,550	6	12,092	44,620	,000b
Rezidual	92,680	342	,271		
Ukupno	165,231	348			

a. Zavisna varijabla: PrimImplZn
b. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

Rezultati multiple regresije za podčesticu Primanje implicitnog znanja pokazali su da je ukupno 44 % varijance objašnjeno kombinacijom nezavisnih varijabli. Tablicom koeficijenata utvrđeno je da zavisnoj varijabli sve analizirane varijable značajno pridonose.

Tablice 58: Utjecaj prediktorskih varijabli na Dijeljenje eksplicitnog znanja (davanje i primanje)

Koeficijenti					
Model	Nestandardizirani koeficijenti		Standardizirani koeficijenti	t	Sig.
	B	Std. error	Beta		
Dijeljenje eksp. znanja	-,562	,250		-2,247	,025
Posl. misija	,151	,073	,104	2,058	,040
Opunomoćivanje zaposlenika	,054	,053	,051	1,012	,312
Kont. učenje	,244	,064	,211	3,835	,000
Investicije u IKT	,061	,064	,055	,957	,339
Prep. posl. prilika	,256	,046	,280	5,607	,000
Poboljšana komunikacija	,226	,067	,204	3,345	,001

Sažetak modela

Model	**R**	**R kvadrat**	**Prilagođeni R kvadrat**	**Stand. greška procjene**
1	,720a	,518	,510	,65520

a. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

ANOVA

Model	**Zbroj kvadrata**	**df**	**Prosjek kvadrata**	**F**	**Sig.**
Regresija	157,958	6	26,326	61,326	,000b
Rezidual	146,814	342	,429		
Ukupno	304,772	348			

a. Zavisna varijabla: Dij.Eksp.Zn

b. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

Rezultati multiple regresije za podčesticu Dijeljenje eksplicitnog znanja pokazali su da je ukupno 52 % varijance objašnjeno kombinacijom nezavisnih varijabli. Tablicom koeficijenata utvrđeno je da zavisnoj varijabli sve analizirane varijable značajno pridonose. Podčestica Opunomoćivanje zaposlenika značajno pridonosi , premda nešto slabije u odnosu na druge mjerene podčestice, a moguće pojašnjenje nalazi se u činjenici da pojedinačni zaposlenici smatraju da sami posjeduju dostatna znanja te da im nije potrebno dijeliti eksplicitno znanje s kolegama. Ponešto slabiji, no i dalje signifikantan doprinos primjetan je kod podčestice Investicije u IKT sustave, s mogućim pojašnjenjem da u manjem broju promatranih poduzeća IKT sustavi nisu u potpunosti prilagođeni potrebama zaposlenika.

Tablice 59: Utjecaj prediktorskih varijabli na Dijeljenje implicitnog znanja (davanje i primanje)

Koeficijenti					
Model	Nestandardzirani koeficijenti		Standardizirani koeficijenti	t	Sig.
	B	Stand. greška	Beta		
Dijeljenje impl. znanja	1,319	,181		7,304	,000
Posl. misija	,198	,053	,194	3,736	,000
Opunomoćivanje zaposlenika	,202	,039	,269	5,231	,000
Kont. učenje	,181	,046	,223	3,942	,000
Investicije u IKT	,078	,046	,100	1,697	,091
Prep. posl. prilika	-,089	,033	-,138	-2,690	,007
Poboljšana komunikacija	,140	,049	,179	2,871	,004

Sažetak modela

Model	R	R kvadrat	Prilagođeni R kvadrat	Stand. greška procjene
1	,703a	,494	,485	,47324

a. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

ANOVA

Model	Zbroj kvadrata	df	Prosjek kvadrata	F	Sig.
Regresija	74,719	6	12,453	55,606	,000b
Rezidual	76,593	342	,224		
Ukupno	151,312	348			

a. Zavisna varijabla: DijImplZn

b. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

Rezultati multiple regresije za podčesticu Dijeljenje implicitnog znanja pokazali su da je ukupno 49 % varijance objašnjeno kombinacijom nezavisnih varijabli. Tablicom koeficijenata utvrđeno je da zavisnoj varijabli sve čestice pridonose. U odnosu na ostale podčestice, puno manji je doprinos podčestice Investicije u IKT sustave, uz pretpostavku da veći broj zaposlenika primat u dijeljenju implicitnog znanja daje ipak osobnom kontaktu s kolegama.

Tablice 60: Utjecaj prediktorskih varijabli na Davanje znanja (eksplicitnog i implicitnog)

Koeficijenti					
Model	Nestandardzirani koeficijenti		Standardizirani koeficijenti	t	Sig.
	B	Stand. greška	Beta		
Davanje znanja	,213	,197		1,084	,279
Posl. misija	,183	,058	,155	3,172	,002
Opunomoćivanje zaposlenika	,133	,042	,154	3,168	,002
Kont. učenje	,225	,050	,239	4,489	,000
Investicije u IKT	,054	,050	,059	1,072	,285
Prep. posl. prilika	,070	,036	,094	1,936	,054
Poboljšana komunikacija	,212	,053	,234	3,979	,000

Sažetak modela

Model	**R kvadrat**	**Prilagođeni R kvadrat**	**Stand. greška procjene**	**R kvadrat**
1	,741a	,549	,541	,51641

a. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

ANOVA

Model	**Zbroj kvadrata**	**df**	**Prosjek kvadrata**	**F**	**Sig.**
Regresija	111,055	6	18,509	69,407	,000b
Rezidual	91,203	342	,267		
Ukupno	202,257	348			

a. Zavisna varijabla: DavZn
b. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

Rezultati multiple regresije za podčesticu Davanje znanja pokazali su da je ukupno 55 % varijance objašnjeno kombinacijom nezavisnih varijabli. Tablicom koeficijenata utvrđeno je da zavisnoj varijabli podjednako značajno pridonose sve nezavisne, prediktorske varijable. Malo je slabiji doprinos primjetan kod podčestice Investicije u IKT sustave, uz pretpostavku da IKT sustavi kod manjeg broja promatranih poduzeća nisu u potpunosti prilagođeni potrebama zaposlenika.

Tablice 61: Utjecaj prediktorskih varijabli na Primanje znanja (eksplicitnog i implicitnog)

Koeficijenti					
Model	Nestandardzirani koeficijenti		Standardiziran i koeficijenti	t	Sig.
	B	Stand. greška	Beta		
Primanje znanja	,544	,187		2,901	,004
Posl. misija	,165	,055	,148	3,011	,003
Opunomoćivanje zaposlenika	,122	,040	,150	3,059	,002
Kont. učenje	,200	,048	,225	4,195	,000
Investicije u IKT	,085	,048	,099	1,785	,075
Prep. posl. prilika	,097	,034	,139	2,852	,005
Poboljšana komunikacija	,154	,051	,181	3,046	,002

Sažetak modela

Model	**R kvadrat**	**Prilagođeni R kvadrat**	**Stand. greška procjene**	**R kvadrat**
1	,737a	,543	,535	,49106

b. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

ANOVA

Model	**Zbroj kvadrata**	**df**	**Prosjek kvadrata**	**F**	**Sig.**
Regresija	97,997	6	16,333	67,731	,000b
Rezidual	82,471	342	,241		
Ukupno	180,468	348			

a. Zavisna varijabla: PrimZn
b. Prediktori: (Konstante), PobKom, OpunomZap, PoslMis, PrepPoslPr, KontUc, InvIKT

Izvor Tablica 54 – 61: pripremila doktorandica.

Rezultati multiple regresije za podčesticu Primanje znanja pokazali su da je ukupno 54 % varijance objašnjeno kombinacijom nezavisnih varijabli. Tablicom koeficijenata utvrđeno je da zavisnoj varijabli podjednako značajno pridonose sve nezavisne, prediktorske varijable.

Tablica 62: Analitika interakcija prediktori – podčestice Dijeljenje znanja (postotak objašnjene varijance)

	Davanje ekspl. znanja	**Davanje impl. znanja**	**Primanje ekspl. znanja**	**Primanje impl. znanja**	**Dijeljenje ekspl. znanja**	**Dijeljenje impl. znanja**	**Davanje znanja**	**Primanje znanja**
Prediktori	48%	43%	42%	44%	49%	52%	55%	54%

Izvor: pripremila doktorandica

Zaključno se može potvrditi kako među podčesticama Dijeljenja znanja ne postoje značajne razlike, što znači da su sve podčestice podjednako bitne za dijeljenje znanja općenito, odnosno davanje i primanje znanja. Pritom se usporedba čini između procesa davanja eksplicitnog i implicitnog znanja, primanja eksplicitnog i implicitnog znanja, dijeljenja eksplicitnog i

implicitnog znanja i općenito davanja i primanja znanja. Najveća uočena razlika je između davanja eksplicitnog i davanja implicitnog znanja, no i u ovom slučaju se radi o relativno malih 5 postotnih bodova. Poduzeća slijedom toga moraju ulagati podjednake napore u procese davanja i primanja znanja, a što i jest sama srž procesa dijeljenja znanja s obzirom na definiciju koncepta koja naglašava dualnost. Aktivnosti koje se poduzimaju radi davanja i primanja eksplicitnog i implicitnog znanja međusobno se razlikuju, pa poduzeća svakako pri provedbi procesa dijeljenja znanja moraju prilagoditi specifične procese, alate, inicijative i metode dijeljenja znanja ovisno o vrsti znanja koje se dijeli. Primjerice, pri davanju eksplicitnog znanja može se primjenjivati educiranje zaposlenika o načinima davanja znanja, iznošenje informacija o tržišnim trendovima, IKT tehnologije, sustavi nagrađivanja zaposlenika i sl. Davanje implicitnog znanja poduzeća mogu ostvariti osnivanjem klastera zaposlenika s različitim ekspertizama koje oni prenose drugim zaposlenicima, olujom mozgova, komunikacijom pomoću IKT sustava i sl. Eksplicitno znanje u poduzeću prima se čitanjem i analiziranjem izvješća o organizacijskim politikama i procedurama, korištenjem sustava sistematizacije zaliha i tokova znanja, kroz periodične sastanke zaposlenika i sl. Implicitno znanje zaposlenici mogu primiti učenjem na tuđim pogreškama, kroz rotaciju zaposlenika ili kroz druženja radi prihvaćanja zajedničkog jezika i identiteta.

4.4.4. Klaster analiza poduzeća s aspekta razvoja kontekstualnih čimbenika koji pridonose učinkovitom dijeljenju znanja

Napravljena je *kmeans* klaster analiza kako bi se odredio broj klastera na indikatorima Organizacijska kultura, Podrška vrhovnog menadžmenta i IKT koji služe za definiranje pripadnosti poduzeća jednoj od triju generacija upravljanja znanjem. Korišten je *NbClust* za procjenu optimalnog broja klastera na temelju kombinacije različitih mjera distance, broja klastera i metoda klasteriranja. Prema ovoj metodi dva klastera daju najparsimoničnije rješenje.

Slika 17: Definiranje broja klastera

```
## Among all indices:
## ==================
## * 2 proposed  0 as the best number of clusters
## * 1 proposed  1 as the best number of clusters
## * 9 proposed  2 as the best number of clusters
## * 2 proposed  3 as the best number of clusters
## * 2 proposed  4 as the best number of clusters
## * 4 proposed  5 as the best number of clusters
## * 1 proposed  8 as the best number of clusters
## * 5 proposed  9 as the best number of clusters
##
## Conclusion
## ==========================
## * According to the majority rule, the best number of clusters is  2 .
```

Izvor: pripremila doktorandica

Prilikom određivanja broja klastera korištena je *elbow* metoda s *within sum of squares* koji generira klastere na temelju najmanjeg unutargrupnog varijabiliteta i najvećeg mogućeg međugrupnog varijabiliteta. Prema ovoj metodi, dva klastera daju najparsimoničnije rješenje.
Iz Tablice 63 može se vidjeti da klaster 2 ima N = 234 jedinice analize te da ima prosječne vrijednosti puno veće od klastera 1 koji ima N = 111 jedinica analize. U oba klastera gotovo svaka ispitivana varijabla je negativno asimetrična, jedino je iznimka Organizacijska kultura u klasteru 2 koja je pozitivno asimetrična.

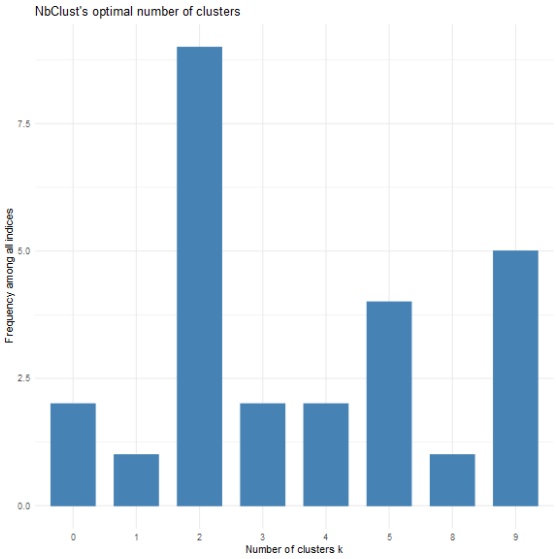
Tablica 63: Deskriptivna statistika za dva klastera

Klaster	Varijabla	Sredina	Stand. dev.	Min	Maks	Asimetričnost	Spljoštenost	Br. valjanih jedinica
2								
2	IKT	0,43	0,71	-2,35	1,57	-0,62	0,76	234
2	Org. Kult.	0,51	0,55	-0,85	3,80	0,58	4,28	234
2	Pod. Vrh. Men.	0,51	0,52	-1,00	1,28	-0,56	-0,27	234
1								
1	IKT	-0,89	0,93	-3,51	1,25	-0,60	0,34	111
1	Org. Kult.	-1,06	0,89	-4,25	0,66	-1,38	2,31	111
1	Pod. Vrh. Men.	-.,03	0,91	-4,00	0,44	-1,03	1,07	111

Izvor: pripremila doktorandica.

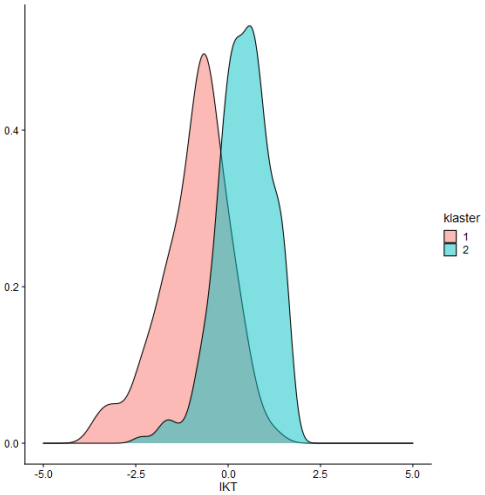
Klasteri se razlikuju statistički značajno po prosječnim vrijednostima na varijablama Organizacijska kultura, IKT i Podrška vrhovnog menadžmenta. Iz slika koje slijede može se vidjeti da postoji preklapanje između distribucija ispitivanih varijabli između klastera te da je ono najveće za IKT.

Slika 18: Određivane optimalnog broja klastera



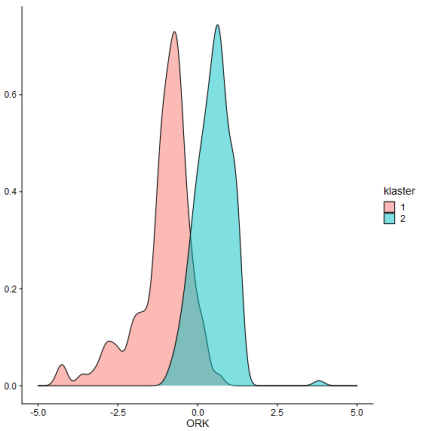
Izvor: pripremila doktorandica

Slika 19: Distribucija IKT varijable izražene na z-skali za dva klastera



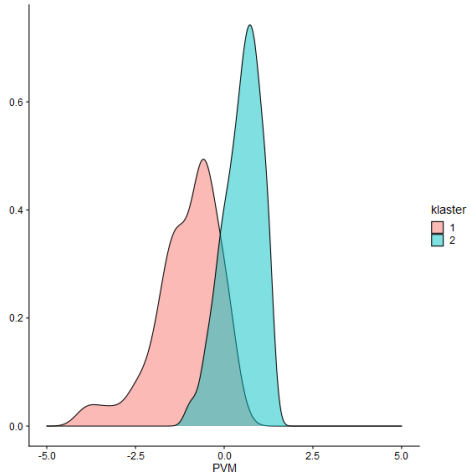
Izvor: pripremila doktorandica.

Slika 20: Distribucija ORK varijable izražene na z-skali za dva klastera



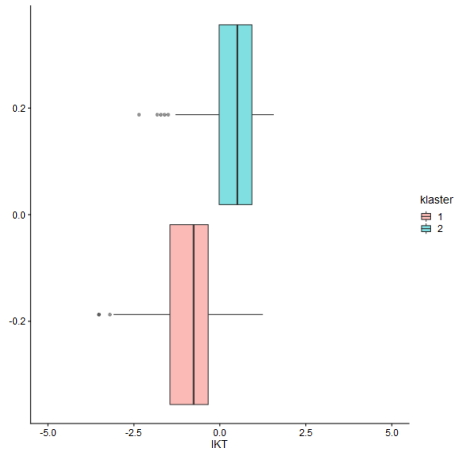
Izvor: pripremila doktorandica.

Slika 21: Distribucija PVM varijable izražene na z-skali za dva klastera



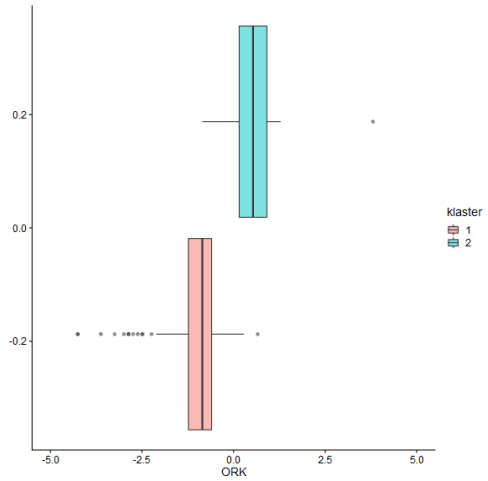
Izvor: pripremila doktorandica.

Slika 22: Boxplot za varijablu IKT izraženu na z-skali za dva klastera



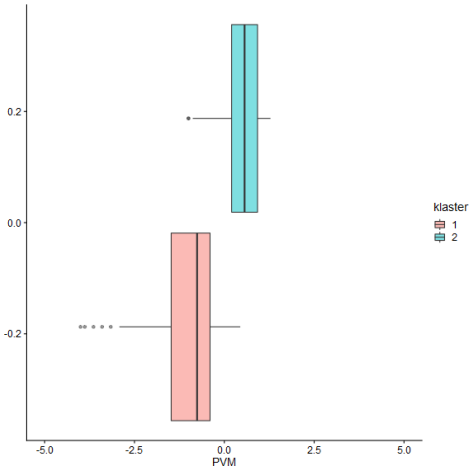
Izvor: pripremila doktorandica.

Slika 23: Boxplot za varijablu ORK izraženu na z-skali za dva klastera



Izvor: pripremila doktorandica.

Slika 24: Boxplot za varijablu PVM izraženu na z-skali za dva klastera



Izvor: pripremila doktorandica.

Ispitanici iz drugog klastera imaju u prosjeku statistički značajno veće procjene organizacijske kulture u odnosu na ispitanike iz prvog klastera. Također, ispitanici iz drugog klastera imaju u prosjeku statistički značajno veće procjene IKT-a u odnosu na ispitanike iz prvog klastera. Konačno, ispitanici iz drugog klastera imaju u prosjeku statistički značajno veće procjene PVM-a u odnosu na ispitanike iz prvog klastera.

Tablica 64: T-test za nezavisne uzorke (dva klastera) na varijabli Organizacijska kultura

Statistic	p. value
-17,16	0

Tablica 65: T-test za nezavisne uzorke (dva klastera) na varijabli IKT

Statistic	p. value
-13,23	0

Tablica 66: T-test za nezavisne uzorke (dva klastera) na varijabli Podrška vrhovnog menadžmenta

Statistic	p. value
-16,51	0

Izvor Tablica 64 - 66: pripremila doktorandica.

Rezultati klaster analize ukazuju da od sveukupno 350 ispitanih poduzeća njih 234 pripada klasteru koji ima snažno razvijene organizacijsku kulturu i podršku vrhovnog menadžmenta, što su ujedno odlike druge generacije upravljanja znanjem (**Milanović, 2010.**). U odnosu na prvi klaster, drugome pripada 111 ispitanih poduzeća ili 39 % ispitanih poduzeća kod kojih je primjetna snažna razvijenost IKT-a, a što je odlika prve generacije upravljanja znanjem. Prema

tome, usporedbom dvaju dobivenih klastera nameće se zaključak da veći dio ispitanih poduzeća pripada drugoj generaciju upravljanja znanjem, pri čemu su karakteristike ovih poduzeća sljedeće: poduzeća su većinom u privatnom vlasništvu te nude kombinaciju proizvodne i uslužne djelatnosti.

5. KRITIČKI OSVRT NA EMPIRIJSKO ISTRAŽIVANJE O MEĐUZAVISNOSTI DIJELJENJA ZNANJA, PODRŽAVAJUĆIH KONTEKSTUALNIH ČIMBENIKA I USPJEŠNOSTI POSLOVANJA PODUZEĆA

U nastavku se opisuju glavni zaključci izvedeni temeljem objedinjavanja rezultata ostvarenih u sve tri faze provedbe istraživanja: *online*, poštanskoj i objedinjenoj. U prethodnom su poglavlju rezultati prikazani za svaku fazu zasebno, te se njihovom usporedbom dalo zaključiti kako rezultati prvih dviju faza djelomično dokazuju postavljene hipoteze, a što je bilo uzrokovano relativno malim uzorkom za statističku obradu podataka i dobivanje relevantnih rezultata istraživanja. Objedinjavanjem dvaju uzoraka bilo je moguće provesti statističke analize na zadovoljavajuće velikom uzorku poduzeća i temeljem njih generirati osnovne zaključke istraživanja.

5.1. ZAKLJUČNA RAZMATRANJA O REZULTATIMA ISTRAŽIVANJA GENERIRANIM U OBJEDINJENOM ISTRAŽIVANJU TE NJIHOVE IMPLIKACIJE ZA PROCESE DIJELJENJA ZNANJA U ODNOSU NA OSTVARENJE POSLOVNOG REZULTATA

Objedinjavanjem rezultata istraživanja provedenog u *online* i poštanskoj fazi istraživanja može se utvrditi da je istraživanje obuhvatilo sveukupno 350 poduzeća, od kojih su 44 velika, 95 srednje velika, dok ih je 211 malih. Provedenim analizama modela medijacije i moderirane medijacije potvrdila se pozitivna veza između organizacijske kulture i IKT-a s jedne strane, te dijeljenja znanja s druge, što se pozitivno manifestira i na uspješnost poslovanja poduzeća. Analiza modela moderirane medijacije također je potvrdila i pozitivan učinak podrške vrhovnog menadžmenta na odnos između prediktorskih varijabli i uspješnosti poslovanja poduzeća s dijeljenjem znanja kao medijacijskom varijablom.

Modelom moderirane medijacije dokazana je pozitivna i signifikantna veza (β = 0,77***, p < 0,001) između organizacijske kulture i dijeljenja znanja. Konfirmatornom faktorskom analizom dokazalo se da organizacijsku kulturu čine tri statistički značajne varijable: poslovna misija, opunomoćivanje zaposlenika i kontinuirano učenje. Snažna poslovna misija koja naglašava značaj dijeljenja znanja potaknut će među zaposlenicima razvijanje osjećaja privrženosti i identiteta. Poslovne misije uspješnih poduzeća sadrže obično atribute kao što su iskrenost, sposobnost, uzbuđenje i konkurentnost, jer na taj način prenose svojim klijentima sliku jake i pouzdane organizacije koja podjednaku pozornost vodi o zaposlenicima i o vanjskim dionicima

(**Bick** i **dr., 2003**.). Razvijanje zajedništva među zaposlenicima i poticanje odanosti poduzeću pridonose jačem angažmanu zaposlenika u procesima davanja i primanja znanja. Zaposlenici se mogu dodatno potaknuti na dijeljenje znanja opunomoćivanjem, jer dodjeljivanje veće autonomije podrazumijeva razvijanje osjećaja usmjerenosti i kontrole među zaposlenicima u odnosnu na njihovo radno okruženje (**Liden**, **Arad, 1996**.). Opunomoćivanje kod zaposlenika s kraćim radnim stažem moguće je kroz dodjeljivanje veće autonomije i kontrole, međutim, kod starijih zaposlenika ono se provodi na način da im se dodjeljuju kompleksniji radni zadaci (**Leach** i **dr., 2003**.). Kapaciteti zaposlenika za jači angažman u dijeljenju znanja mogu se unaprijediti i organizacijom i provedbom kontinuiranog učenja na svim organizacijskim razinama. Pritom se operacionalizacija kontinuiranog učenja ostvaruje provedbom edukacijskih programa namijenjenih razvoju specifičnih znanja i vještina među zaposlenicima, a što je bitno za učenje na svim organizacijskim razinama (**Warskick, Marsick, 1997.**); prepoznavanjem fleksibilnosti i želje za promjenom kao bitnih motivatora zaposlenika za njihovim aktivnim sudjelovanjem u formalnim i informalnim oblicima učenja (**Jeong, Schein, 2019**.); poticanje poduzetničkog ponašanja među zaposlenicima toleriranjem povremenih pogrešaka koje se dogode u samoj realizaciji poslova te omogućivanje zaposlenicima da uče na pogreškama (**Myers, 2020.**).

Modelom moderirane medijacije dokazana je statistički signifikantna veza između IKT sustava i dijeljenja znanja (β = 0,27***, p < 0.001). S aspekta procesa dijeljenja znanja tri su bitne sastavnice (varijable) IKT sustava, što je dokazano konfirmatornom faktorskom analizom: investicije u IKT sustave, mogućnost prepoznavanja poslovnih prilika i poboljšana komunikacija zahvaljujući primjeri IKT alata. Investicije u IKT sustave moraju se provoditi na način da se usmjeravaju u baze podataka koje sadrže kompetencije zaposlenika, ekspertne mreže i opise najboljih praksi radi učinkovitijeg dijeljenja implicitnog znanja, dok učinkovito dijeljenje eksplicitnog znanja podrazumijeva jače investicije u *online* sustave pretraživanja, intranet i elektroničku poštu (**Sher**, **Lee, 2004.**; **Phang**, **Foong, 2010.**). Promjene uvjeta poslovanja, koje su uslijedile nakon pojave pandemije Covid-19, ukazale su na potrebu intenzivnijeg korištenja digitalnih alata prije svega za skeniranje poslovnih mogućnosti u okruženju i slijedom toga prepoznavanje novih poslovnih prilika. IKT alati mogu pripomoći učinkovitom objedinjavanju znanja generiranog temeljem internih i eksternih izvora znanja (**Daft** i **dr**., **1988**.), a što je naročito vrijedno u okolnostima negativnih promjena u poslovnom okruženju (**Zahra, Garvis, 2000**.). Poboljšanu komunikaciju moguće je ostvariti razvijanjem nekih od sljedećih medija: blogovi i mikroblogovi; grupni portali za dijeljenje znanja, kao što

je *Wiki*, društvene mreže, RSS aplikacije za dijeljenje znanja objavljenog na drugim lokacijama, društveno povezivanje u smislu povezivanja zaposlenika sličnih interesa na način da im se omogući međusobno uređivanje i dijeljenja znanja i iskustava (**Panahi** i **dr.**, **2013.**).

Modelom moderirane medijacije utvrđena je interakcija između podrške vrhovnog menadžmenta i organizacijske kulture (β = 0,22, p < 0,001), te interakcija između IKT sustava i podrške vrhovnog menadžmenta (β = -0,17, p < 0,001) na dijeljenje znanja. Klaster analizom dodatno su pojašnjene ove interakcije: dijeljenje znanje bit će najučinkovitije uz jaku organizacijsku kulturu i nešto nižu podršku menadžmenta. Međutim, podrška menadžmenta značajnija je u interakciji IKT-a i dijeljenja znanja, te će zaposlenici efikasno koristiti IKT sustave jedino uz jaku podršku top menadžmenta. Za ovu je moderatorsku varijablu konfirmatorna faktorska analiza potvrdila da obuhvaća tri bitne varijable: otvorenost menadžera idejama i prijedlozima zaposlenika, razvijanje povjerenja između menadžera i zaposlenika, te mentoriranje. Otvorenost menadžera idejama zaposlenika ostvaruje se njihovom intelektualnom stimulacijom, odnosno pružanjem mogućnosti da otvoreno iznose svoja mišljenja (**Bass, Rigio**, **2006.**) te poticanjem zaposlenika da sudjeluju u formalnim i informalnim oblicima učenja kako bi ih se osposobilo da razvijaju i slobodno izražavaju svoje ideje i stavove (**Purvanova, Bono, 2009**.). Razvijanje međusobnog povjerenja moguće je ako se među zaposlenicima uspije razviti osjeća pripadnosti poduzeću jer u tom slučaju lakše dijele svoja znanja i iskustva (**Chen, Hung, 2010**.) ili ako se zaposlenicima pruži prilika da sudjeluju u realizaciji izazovnijih zadataka (**Tan, Zhao, 2003**.). Mentoriranje zaposlenika nužno je provoditi jer je dokazano da njegov izostanak može utjecati na neuspješno dijeljenje znanja (**Lee** i **dr., 2012**.). Mentoriranje rukovoditelji moraju provoditi i prilikom zapošljavanja novih djelatnika, kao i prilikom premještanja zaposlenika na nova radna mjesta (**Ackerman** i **dr., 2003**.). Mentoriranjem se zaposlenici osposobljuju da budu fleksibilniji naspram svojeg radnog okruženja, te su ustrajniji i učinkovitiji u rješavanju radnih zadataka (**Adhearne** i **dr., 2005**.). Osobine rukovoditelja koje su bitne za pružanje podrške organizacijskoj kulturi i provedbi sustava IKT-a upućuju na to da je riječ o transformacijskim rukovoditeljima, koji ujedno imaju i određene značajke adaptivnih i karizmatskih rukovoditelja (**Žugaj i dr**., **2004**.).

S obzirom na mogući utjecaj određenih kontekstualnih čimbenika na sposobnost poduzeća da učinkovito provode procese dijeljenja znanja, ovdje je potrebno skrenuti pozornost na kontrolne varijable čiji se učinak testirao u završnoj fazi obrade rezultata, jer u prethodnim fazama uzorak nije bio dovoljno značajan za provedbu ove vrste analize. Kao kontrolne varijable definirane su

veličina poduzeća te djelatnost poslovanja poduzeća. U odnosu na konceptualni model, utvrđeno je kako niti veličina poduzeća niti djelatnost poslovanja ne utječu na procese dijeljenja znanja. Što se tiče veličine poduzeća, tvrdnja da veličina poduzeća nije relevantna pri ocjenjivanju učinkovitosti dijeljenja znanja reflektira slične zaključke do kojih su došli i drugi autori koji su izučavali problematiku dijeljenja znanja s aspekta veličine poduzeća (**Chong, 2006**.; **Prieto, Revilla, 2006**.; **Chen, Mohamed**, **2008.**; **Andreeva, Kianto, 2011**.; **Singh** i **dr., 2019**.), odnosno djelatnosti poslovanja (**Prieto, Revilla, 2006**.; **Donate, Guadamillas, 2011**.; **Andreeva, Kianto, 2011**.).

S obzirom na to da je konstrukt dijeljenje znanja medijacijska varijabla od središnjeg interesa za ovo istraživanje, tada je nužno prokomentirati i zaključke istraživanja u odnosu na procese dijeljenja pojedinih vrsta znanja. Usporedbom postotka pojašnjene varijance za sve modalitete dijeljenja znanja došlo se do zaključka kako ne postoje značajne razlike ili odstupanja između analiziranih procesa dijeljenja znanja. Davanje eksplicitnog i implicitnog znanja podjednako je bitno kao i primanje eksplicitnog i implicitnog znanja. **Van Wijk** i **dr.** (**2008.**) zaključili su da su čimbenici koji pridonose učinkovitom davanju znanja sljedeći: intenzitet pozitivnih odnosa među zaposlenicima, međusobno povjerenje te prisutnost i razumijevanje zajedničke vizije, odnosno normi koje promiču međusobno razumijevanje i uvažavanje. Prema **Tortoriello** i **dr.** (**2012.**), čimbenik koji također značajno pridonosi učinkovitom davanju znanja jest širina međuljudskih kontakata među zaposlenicima u poduzeću. Naime, zaposlenici koji pri izvršavanju svakodnevnih zadataka komuniciraju sa širim krugom suradnika, ujedno razvijaju i veće kapacitete za davanje znanja. **Bingham** i **dr.** (**2015.**) opisali su načine kodifikacije znanja u poduzeću kojima se također osigurava učinkovitije davanje, odnosno primanje znanja. Osnivanjem timova za kodifikaciju znanja osigurava se pojednostavnjivanje opisa radnih procesa na način da postanu razumljiviji većem broju zaposlenika, a interakcijom sa zaposlenicima omogućuje se kontinuirano unapređenje istih.

Dijeljenje eksplicitnog i dijeljenje implicitnog znanja također nemaju značajne razlike u njihovu doprinosu učinkovitom dijeljenju znanja, a sličan je zaključak moguć i kod davanja i primanja (obje vrste) znanja, što je i logično s obzirom na to da se radi o potprocesima dijeljenja znanja. S obzirom na to da su svi ovi modaliteti davanja i primanja eksplicitnog i implicitnog znanja, odnosno njihova dijeljenja već detaljno razrađeni u prethodnim teorijskim cjelinama, a radi izbjegavanja suvišne ekstenzivnosti rada, smatra se nepotrebnim ponavljati već opisane aktivnosti dijeljenja znanja. Zaključno se može napomenuti da je za rukovoditelje poduzeća

koja nastoje provoditi procese dijeljenja znanja na učinkovit način bitno da ne stavljaju naglasak niti na eksplicitno niti na implicitno znanje, jer slabijom provedbom dijeljenja jedne ili druge vrste znanja, posljedično umanjuju i mogućnosti učinkovite operacionalizacije sveukupnog procesa dijeljenja znanja.

5.2. TEORIJSKI I PRAKTIČNI DOPRINOS ISTRAŽIVANJA KONTEKSTUALNIH ČIMBENIKA KOJI OMOGUĆUJU DIJELJENJE ZNANJA I UNAPREĐENJE POSLOVNE USPJEŠNOSTI

Ispitivanjem modela medijacije u empirijskom istraživanju konceptualnog modela dijeljenja znanja dokazana je pozitivna veza između organizacijske kulture i dijeljenja znanja te između IKT-a sustava i dijeljenja znanja. Modelom moderirane medijacije dokazan je pozitivan utjecaj podrške vrhovnog menadžmenta na povezanost oba prediktora s varijablom dijeljenje znanja, odnosno dokazana je signifikantnost i organizacijske kulture i IKT-a. Odnosi između prediktora i procesa dijeljenja znanja, kao i moderatora i dijeljenja znanja, opisani su u prethodnim cjelinama, pa je slijedom toga moguća konstatacija o dokazivanju glavne hipoteze:

H0: **Postoji pozitivna veza između organizacijske kulture i IKT-a s jedne strane te dijeljenja znanja s druge, što se manifestira na uspješnost poslovanja, dok podrška vrhovnog menadžmenta pojačava vezu između organizacijske kulture i IKT-a s jedne strane i procesa dijeljenja znanja s druge**.

Nadalje, konceptualnim modelom i temeljem njega provedenim istraživanjem, potvrdile su se pomoćne hipoteze koje opisuju kontekstualne čimbenike čija implementacija podržava učinkovito dijeljenje znanja, a posljedično i uspješnost poslovanja poduzeća:

H1. Organizacijsku kulturu koja podržava dijeljenje znanja odlikuje: jasna misija, kontinuirano učenje i opunomoćivanje zaposlenika.
Eksploratorom faktorskom analizom dokazano je da sve čestice koje opisuju varijable unutar organizacijske kulture imaju visoka zasićenja: njihove se vrijednosti kreću od 0,433 do 0,790 (prema **Hairu** (**2010**.), sva su zasićenja iznad 0,30 dovoljno signifikantna). Detaljnim izučavanjem recentnih istraživanja o organizacijskoj kulturi, odnosno njenim bitnim odrednicama, uočene su bitne značajke organizacijske kulture koja podržava dijeljenje znanja, a koje se opisuju u nastavku. Poslovna misija u poduzeću koje podržava dijeljenje znanja mora biti definirana na jasan i transparentan način, mora potpomagati razvijanje zajedništva te

promicati dijeljenje znanja kao jednu od najznačajnijih premisa u poslovanju poduzeća. Zaposlenici će rado pripomagati dijeljenju znanja ako se provodi opunomoćivanje, na način da se zaposlenici dodatno potiču na preuzimanje inicijativa, na aktivno sudjelovanje u donošenju odluka, no isto tako na aktivno sudjelovanje u odlučivanju o rizičnim zadacima. Kontinuirano učenje također je značajan aspekt dijeljenja znanja, pa poduzeća moraju redovito investirati u edukativne i razvojne programe kako bi unaprijedila specifična znanja i sposobnosti zaposlenika; trebaju se poticati fleksibilnost i želja za promjenama kod zaposlenika kao glavni motivatori kontinuiranog učenja, te se zaposlenicima mora omogućiti da uče iz pogrešaka kroz timski rad i konsenzus.

H2. Značajke IKT-a koji podržava dijeljenje znanja jesu: kontinuirane investicije u IKT, prepoznavanje poslovnih prilika i unaprijeđena komunikacija.
Eksploratorna faktorska analiza ove prediktorske varijable također je ukazala na činjenicu da sve čestice koje pripadaju varijablama unutar IKT sustava imaju dovoljno visoka zasićenja koja ih čine signifikantnima: vrijednosti se kreću u rasponu od 0,510 do 0,823. Usporedbom relevantnih istraživanja iz područja IKT sustava izvedeni su zaključci o najbitnijim značajkama ove varijable s aspekta dijeljenja znanja. S obzirom na to da su IKT sustavi uglavnom kompleksni sustavi koji podrazumijevaju značajne investicije, poduzeća moraju voditi računa o tome da takvi sustavi svojim značajkama odgovaraju svakodnevnom poslovanju, odnosno da su prilagođeni potrebama zaposlenika, da omogućuju učenje na daljinu, te da se redovito ažuriraju. Nadalje, kvalitetni IKT sustavi moraju osigurati prepoznavanje poslovnih prilika u okruženju, praćenje aktivnosti konkurencije i poslovnih partera te omogućiti zaposlenicima korištenje društvenih kontakata u svrhu prikupljanja relevantnih informacija o tržištu. Komunikaciju u poduzeću moguće je unaprijediti redovitim korištenjem *e-maila,* intraneta i sličnih alata grupne komunikacije, korištenjem različitih alata koji omogućuju učenje na daljinu, brzo i kvalitetno lociranje baze znanja koja sadrži relevantne informacije, kao i pristup točnim i pravodobnim podacima.

H3. Podršku vrhovnog menadžmenta dijeljenju znanja identificira se u: otvorenosti idejama podređenih, razvijanju visoke razine povjerenja i redovitom mentoriranju suradnika.
Zasićenost čestica koje opisuju moderatorsku varijablu ispitana je eksploratornom faktorskom analizom, te je i kod ove varijable ukazala na visoke vrijednosti koje se kreću od 0,578 do 0,808. Usporedbom recentnih istraživanja podrške vrhovnog menadžmenta definirane su značajke moderatorske varijable koje pridonose učinkovitijem dijeljenju znanja. Podrška vrhovnog

menadžmenta često se izučava u okviru organizacijske kulture, no određeni autori poput **Lee, Kim** i **Kim** (**2001.**), **Donate** i **Guadamillas** (**2011.**) i **Handžić** (**2011.**) razdvojili su čimbenik organizacijske kulture od podrške vrhovnog menadžmenta, s time da je u konceptualnom modelu taj čimbenik izučavan kao moderacijska varijabla, što ni ovi autori nisu učinili, već su podršku vrhovnog menadžmenta izučavali kao prediktorsku varijablu. Podrška vrhovnog menadžmenta konkretno znači da menadžeri promiču sustav vrijednosti u kojem se cijeni mišljenje svakog zaposlenika, zaposlenici mogu otvoreno iznositi prijedloge i mišljenja na sastancima s menadžerima, zaposlenici se potiču na formalnu i neformalnu komunikaciju s menadžerima, kao i na osnivanje grupa za učenje. Razvijanje povjerenja kod zaposlenika podrazumijeva da zaposlenici doživljavaju uspjeh poduzeća kao vlastiti uspjeh, da im je važna reputacija koju poduzeće ima među vanjskim dionicima, da se zaposlenici potiču na bavljenje zahtjevnim zadacima čak i uz mogućnost neuspjeha, te da menadžeri rijetko prakticiraju kontrolu i to isključivo za procjenu dostignuća zaposlenika. Važnost znanja za uspješno poslovanje poduzeća dodatno se naglašava kroz redovito mentoriranje zaposlenika, omogućavanje perioda orijentacije novim zaposlenicima radi kvalitetnog upoznavanja sa sustavom, osiguravanje mentoriranja svim zaposlenicima prilikom preuzimanja novih dužnosti te rotiranje zaposlenika među odjelima kako bi oni unaprijedili svoja znanja i vještine uz nadzor menadžera.

Konceptualnim modelom dijeljenja znanja nastojalo se objediniti recentna znanstvena istraživanja iz dijeljenja znanja, no i ponuditi svojevrsne preinake u svrhu daljnjeg ispitivanja fenomena dijeljenja znanja. Usporede li se istraživanja koja su izučavala upravljanje znanjem, poput **Gold**, **Malhotre** i **Segars** (**2001.**) i način na koji oni mjere organizacijsku kulturu, može se zaključiti da su autori objedinili pitanja koja se dijelom odnose na poslovnu misiju, dijelom na rukovođenje, a pojedine čestice opisuju i modalitete davanja i primanja znanja. Premda ovi autori jesu ispitivali utjecaj upravljanja znanjem, što je s teorijskog stajališta koncept koji je sveobuhvatniji i kompleksniji od dijeljenja znanja, smatra se da bi detaljnije ispitivanje moglo dovesti do konkretnijih zaključaka. Zato se u konceptualnom modelu eksplicite navodi poslovna misija, koju spominje tek nekolicina autora, premda u svojim anketnim upitnicima koriste čestice u kojima se opisuju značajke poslovne misije (**Gold, Malhotra** i **Segars**, **2001**.) u sklopu organizacijske kulture; **Handžić** (**2011**.) u sklopu podrške vrhovnog menadžmenta). Slično je i s opunomoćivanjem zaposlenika – premda istraživači navode u anketnim upitnicima čestice kojima opisuju aktivnosti opunomoćivanja, rijetki ga eksplicite definiraju. Lu i suradnici (2006.) opisuju opunomoćivanje u sklopu podrške vrhovnog menadžmenta, dok Suppiah i

Sandhu (2017.) navode opunomoćivanje u sklopu varijable komunikacija. Premda je kontinuirano učenje posebno značajno za dijeljenje znanja, tek rijetki autori ga navode (**Lu**, **2006.**). Iako su IKT sustavi predmet rasprava u mnogim istraživanjima u području dijeljenja znanja jer istraživači vjeruju da stavljanje prejakog naglaska na IKT može umanjiti napore zaposlenika u dijeljenju znanja, potrebno je naglasiti da većina analiziranih radova pristupa problematici IKT-a uglavnom s aspekta njihova učinka na poboljšanu komunikaciju, odnosno rijetki autori analiziraju problematiku investiranja u IKT sustave ili pak njihovu sposobnost prepoznavanja poslovnih prilika u okruženju poduzeća (**Gold, Malhotra** i **Segars, 2001**.; **Chen**, **Mohamed**, **2008.**; **Handžić, 2011**.). Podršku vrhovnog menadžmenta izučavali su mnogi autori, no kako je ranije spomenuto, to se činilo uglavnom u sklopu organizacijske kulture. U konceptualnom modelu podrška vrhovnog menadžmenta izdvaja se kao moderatorska varijabla, te je u odnosu na organizacijsku kulturu jednoznačno definirana (visoka zasićenja pripadajućih čestica). Također je prednost konceptualnog modela, što konciznije definira sastavnice prediktorskih varijabli te načine njihova mjerenja. Svakako najveći doprinos konceptualnog modela proizlazi iz činjenice da ne precizira dijeljenje znanja samo u odnosu na njegove temeljne aktivnosti davanja i primanja znanja, već i u odnosu na vrste znanja, a što se smatra značajnim odmakom od većine izučavanih istraživanja iz područja upravljanja znanjem, odnosno dijeljenje znanja.

Zaključno se može utvrditi da su provedenim istraživanjem ostvareni sljedeći znanstveni pridonosi :

1. Dokazan je integrativni model mjerenja razvijenosti procesa dijeljenja znanja koji istovremeno izučava čimbenike koji utječu na sam proces dijeljenja znanja, ali i učinak procesa dijeljenja znanja na poslovni rezultat poduzeća na način na koji to do sada još nije učinjeno. Varijabla podrška vrhovnog menadžmenta izdvojena je u svojstvu moderatorske varijable, što je svakako novina u odnosu na radove koji izučavaju problematiku dijeljenja znanja. Varijable organizacijska kultura i IKT sustavi vrednovane su i mjerene u odnosu na kriterije koje drugi istraživači dijelom obuhvaćaju, no u rijetkim slučajevima eksplicite navode (npr. poslovna misija i opunomoćivanje ili investicije u IKT sustave i prepoznavanje prilika u poslovnom okruženju). Najveći odmak u istraživanju učinjen je u odnosu na izučavanje dijeljenja znanja s aspekta davanja i primanja eksplicitnog i implicitnog znanja, dok se učinak dijeljenja znanja na poslovni rezultat učinio usporedbom perceptivnih i arhivskih pokazatelja uspješnosti poslovanja poduzeća.

1.1. Nadograđen je model upravljanja znanjem koji se temelji na organizacijskim sposobnostima razvijen od strane **Gold**, **Malhotra** i **Segars** (**2001.**). Ovi su autori zaključili da učinkovitost poslovanja ovisi o infrastrukturi koja podržava upravljanje znanjem, a koja obuhvaća tehnološku strukturu, ustroj upravljanja poduzećem i kulturološku strukturu, odnosno infrastrukture koja obuhvaća procese upravljanja znanjem: prikupljanje znanja, preoblikovanje znanja, primjena i zaštita znanja. Slično ovim autorima, konceptualni model također pozicionira organizacijsku kulturu i IKT sustave u funkciju prediktorskih varijabli, međutim isključivo u odnosu na dijeljenje znanja kao središnji proces upravljanja znanjem koje je pritom još studioznije analizirano u odnosu na vrste znanja: eksplicitno i implicitno, ali i s aspekta davanja i primanja znanja.

1.2. Repozicionirana je podrška vrhovnog menadžmenta u odnosu na prethodne radove koji su svrstali podršku vrhovnog menadžmenta u organizacijsku kulturu (**Lu, Leung** i **Koch, 2006**.; **Lin, 2007**., **Suppiah, Sandhu**, **2010.**; **Sorakraikitikul**, **Siengthai, 2014.**). Smatra se da je podrška vrhovnog menadžmenta dovoljno značajan čimbenik da se izučava zasebno, no ne i odvojeno od organizacijske kulture i IKT-a, jer upravo učinak ove varijable može značajno pridonijeti učinkovitijem korištenju organizacijske kulture i IKT sustava, a što je u konceptualnom modelu dokazano ispitivanjem moderirane medijacije koja je ukazala na postojanje veza između podrške vrhovnog menadžmenta i organizacijske kulture, kao i podrške vrhovnog menadžmenta i IKT sustava. Osim toga, eksploratornom faktorskom analizom dokazano je da podrška vrhovnog menadžmenta konceptualno može i treba biti izdvojena od organizacijske kulture s obzirom na njezin značaj za dijeljenje znanja. Analizom interakcija između moderatorske varijable i prediktorskih varijabli zaključeno je da prosječna podrška vrhovnog menadžmenta i jaka organizacijska kultura rezultiraju najvišim dijeljenjem znanja, dok visoka podrška vrhovnog menadžmenta i blago pozitivni IKT sustavi rezultiraju najvišim dijeljenjem znanja.

1.3. Redefinirano je mjerenje utjecaja upravljanja znanjem na uspješnost poslovanja poduzeća – uvođenjem multidimenzionalnih pokazatelja uspješnosti poslovanja (**Andreeva, Kianto, 2012.**) Ranije u tekstu navedeno je kako su **Buble** i **dr.** (**2008.**) zaključili da oslanjanje isključivo na arhivske pokazatelje uspješnosti poslovanja može dovesti do pogrešnih zaključaka jer arhivski pokazatelji prikazuju učinke odluka donesenih u prošlosti, a i podložni su kreativnom računovodstvu. Iz navedenog razloga konceptualnim modelom su obuhvaćeni perceptivni financijski i nefinancijski

pokazatelji, te je testiranjem utvrđeno kako ne postoji statistički signifikantna povezanost između ovih vrsta pokazatelja i da je za mjerenje uspješnosti poslovanja poduzeća s aspekta dijeljenja znanja svakako djelotvornije koristiti perceptivne pokazatelje uspješnosti. Pritom su definirani i korišteni perceptivni financijski pokazatelji uspješnosti poslovanja: rast prodaje u odnosu na konkurenciju, bolja optimizacija troškova u odnosu na konkurenciju, bolje financijsko poslovanje u odnosu na prethodne godine i veća profitabilnost u odnosu na prethodne godine (pokazatelji su mjereni prije i nakon pandemije Covid-19). Nefinancijski perceptivni pokazatelji definirani su kako slijedi: viša razina kvalitete usluga i proizvoda u odnosu na konkurenciju, bolja reputacija u odnosu na konkurenciju, brži rast u odnosu na konkurenciju te zadovoljniji zaposlenici u odnosu na konkurenciju (mjereni prije i nakon pandemije Covid-19).

2. Unaprijeđena je literatura o načinu provedbe procesa dijeljenja znanja, pogotovo s obzirom na činjenicu da ovaj koncept nije istraživan u Republici Hrvatskoj. Naime, autorice koje su provele slična istraživanja (**Vidović, 2008**.; **Milanović, 2010**.) izučavale su modalitete upravljanja znanjem, a ne dijeljenje znanja. U odnosu na njihova istraživanja, produbio se koncept dijeljenja znanja njegovom raščlambom na davanje i primanje eksplicitnog i implicitnog znanja. Nadalje, autorica **Vidović** (**2008**.) istraživanje je provela samo na velikim hrvatskim poduzećima i to u turističkom sektoru, dok je **Milanović** (**2010.**) obuhvatila velika, srednja i mala poduzeća no s isključivim naglaskom na korištenje IKT alata za dijeljenje znanja.
3. Provedena je detaljna analiza razvijenosti procesa dijeljenja znanja u malim, srednjim i velikim poduzećima, što je prvi rad takve vrste na uzorku hrvatskih poduzeća, te je izvršena usporedba rezultata s prethodnim istraživanjima (**Vidović, 2008**.; **Milanović, 2010.**). **Vidović (2008.)** je mjerila sljedeće varijable: 1. infrastruktura upravljanja znanjem; 2. nositelji upravljanja znanjem; 3. organizacijska kultura upravljanja znanjem; 4. IKT za upravljanje znanjem te 5. mjerenje korisnosti upravljanja znanjem. Autorica je ocijenila svaku dimenziju upravljanja znanjem zasebno, te se pokazalo da velika hrvatska poduzeća najviše napora ulažu u razvoj IKT-a za upravljanje znanjem, odnosno da spadaju u prvu generaciju upravljanja znanjem. **Milanović (2010.)** je mjerila zrelost upravljanja znanjem u velikim, srednjim i malim poduzećima korištenjem triju dimenzija: 1. organizacijska kultura, 2. ljudska dimenzija te IKT. Autorica navodi usporedbu s **Vidović (2008.),** te je zaključila kako je zamjetan napredak u korištenju praksi upravljanja znanjem u hrvatskim poduzećima. Autorica također

spominje tri faze razvijenosti procesa upravljanja znanjem: 1. faza: fokus poduzeća dominantno na IKT, organizacijska kultura nije pogodna za upravljanje znanjem (KM), ne nagrađuju se zaposlenici za svoj doprinos KM-u, menadžment poduzeća ne podupire KM; 2. faza/generacija KM-a: usredotočenost poduzeća na ljudsku i kulturološku dimenziju, menadžment podupire KM, razvijaju se organizacijska kultura i infrastruktura koje podupiru KM, mjeri se korisnost KM-a; 3. faza/generacija: poduzeća optimalno vode brigu o svim čimbenicima koji utječu na KM, te se posvećuje posebna briga kodiranju i pohrani informacija i znanja radi jednostavnosti u pristupanju istima. S obzirom na visoke ocjene ljudske i kulturološke dimenzije, **Milanović** (**2010.**) je zaključila da hrvatska poduzeća pripadaju drugoj generaciji KM-a. Primjenjujući klaster analizu u ovom radu došlo se do zaključka da poduzeća iz uzorka pripadaju dvama klasterima, pri čemu razmjerno veći broj poduzeća, čak 2/3 ima dobro razvijenu organizacijsku kulturu i podršku vrhovnog menadžmenta, a što su uz razvijenost IKT sustava čimbenici koji označavaju poduzeća druge generacije upravljanja znanjem. S obzirom na to da je konceptualnim modelom dokazan i značaj IKT sustava (uz adekvatnu podršku vrhovnog menadžmenta), može se pretpostaviti da poduzeća razvijaju temelje za prelazak iz druge u treću generaciju upravljanja znanjem.

Osim navedenih teorijskih doprinosa istraživanja, moguće je također definirati i praktične doprinose:

1. Doktorska disertacija eksplicite navodi kontekstualne čimbenike koji pridonose učinkovitoj implementaciji procesa dijeljenja znanja, odnosno pojašnjava principe ustroja organizacijske kulture, IKT sustava i podrške vrhovnog menadžmenta koji su bitni s aspekta mogućeg doprinosa dijeljenja znanja uspješnom poslovanju poduzeća.
2. U radu se detaljno obrazlažu procesi dijeljenja, odnosno davanja i primanja eksplicitnog i implicitnog znanja, a što se na ovaj način ne može pronaći u radovima koji se bave problematikom upravljanja znanjem u širem, odnosno dijeljenjem znanja u užem smislu.
3. U doktorskoj disertaciji razvijen je anketni upitnik kojim se mjere procesi dijeljenja znanja, no i razvijenosti kontekstualnih čimbenika bitnih za učinkovitu implementaciju procesa dijeljenja znanja. Povratnom informacijom nekolicine ispitanika u provedenom poštanskom istraživanju ustanovilo se da ispitanici smatraju dostavljeni upitnik vrstom samoevaluacije procesa koji se u poduzeću koriste s aspekta dijeljenja znanja. S obzirom na to da su neki ispitanici čak izrazili želju za dostavom rezultata istraživanja, smatra se

da je anketni upitnik vrijedan alat samoprocjene faze razvoja procesa dijeljenja znanja u velikim, srednjim i malim hrvatskim poduzećima.

4. U radu su detaljno analizirane i predložene smjernice razvoja pojedinih kontekstualnih čimbenika s aspekta dijeljenja znanja, a vrednovani su i sami procesi davanja i primanja eksplicitnog i implicitnog znanja koje poduzeća mogu prilagoditi vlastitim specifičnostima poslovanja i u tom smislu implementirati mjere koje će u specifičnim uvjetima poslovanja polučiti najbolje rezultate.
5. Rad se usporedilo sa sličnim radovima autorica **Vidović** (**2008**.) i **Milanović** (**2010**.) s obzirom na to da su autorice vrednovale čimbenike uspješne implementacije procesa upravljanja znanjem te su u svojim istraživanjima svrstala hrvatska poduzeća u prvu, odnosno drugu generaciju upravljanja znanjem. S obzirom na to da je veći dio ispitanika svrstan u klaster koji ima razvijene čimbenike organizacijske kulture i podrške vrhovnog menadžmenta, a što su odlike druge generacije upravljanja znanjem, smatra se korisnim da poduzeća iz manjinskog klastera prouče i primijene prakse poduzeća koja su s aspekta procesa dijeljenja znanja učinkovitija.
6. Rezultati istraživanja dalje će se diseminirati objavom kroz znanstvene i stručne konferencije i skupove kako bi zaključci postali dostupni čim širem krugu korisnika što u poslovnoj zajednici, a što u akademskoj.

5.3. OGRANIČENJA ISTRAŽIVANJA I PRIJEDLOZI DALJNJEG ISTRAŽIVANJA MOGUĆIH UNAPREĐENJA PROCESA DIJELJENJA ZNANJA U HRVATSKIM PODUZEĆIMA

Tijekom provedbe samog istraživanja, odnosno naknadno, tijekom analize prikupljenih rezultata došlo se do zaključka da postoji nekoliko ograničenja koja bi svakako trebalo uzeti u obzir. Prvo ograničenje je aplikativnog karaktera, te se vezuje za instrument istraživanja koji je uslijed kompleksnosti konceptualnog modela razmjerno opsežan. Vidljivo je to prije svega iz rezultata *online* istraživanja, kojim je prikupljeno ukupno 126 kompletno ispunjenih upitnika, dok ih je 156 ispunjeno djelomično, a čime je značajno umanjen konačni uzorak za obradu rezultata. Taj je nedostatak kompenziran slanjem poštanskih upitnika s plaćenim povratom, pri čemu je zabilježena znatno bolja stopa povrata (15 % u odnosu na 8 % kod *online* upitnika). Premda je instrument istraživanja opsežan, ipak je nužno naglasiti da sva obuhvaćena pitanja realno prikazuju stvarno poslovanje, te bi ispuštanje istih moglo naškoditi kvaliteti provedenog istraživanja. Ovakav zaključak dodatno potvrđuje konfirmatorna faktorska analiza koja je za

sve razvijene skale iznimno visoka. Ostala su ograničenja pretežno teorijske prirode te se ukratko opisuju u nastavku.

Pri definiranju kriterijske varijable Uspješnost poslovanja poduzeća korišteni su perceptivni financijski i nefinancijski pokazatelji uspješnosti poslovanja poduzeća prije i nakon, odnosno tijekom pandemije Covid-19. Osim ovih pokazatelja, također su se koristili i arhivski financijski pokazatelji ROA (povrat na imovinu) i ROE (povrat na kapital). Pokazatelj ROA prikazan je za svako poduzeće u digitalnom repozitoriju HGK-a, dok se pokazatelj ROE izračunao za svako poduzeće korištenjem dostupnih podataka iz iste baze, odnosno računanjem odnosa neto dobiti/gubitka i ukupnog kapitala. Međutim, potrebno je naglasiti da dostupni, recentni i proučeni članci iz područja dijeljenja znanja u modeliranju koriste perceptivne financijske i nefinancijske pokazatelje uspješnosti poslovanja (**Denison, Mishra, 1995.**; **Chen, Mohamed, 2008.**; **Zheng, Yang** i **McLean 2010.**; **Suppiah, Sandhu, 2011.**; **Andreeva, Kianto, 2012.**; **Podrug, Filipović** i **Kovač, 2017.**; **Oh, Han, 2018.**; **Oyemomi** i **dr., 2019.; Singh** i **dr., 2019.**). S druge strane u relevantnim znanstvenim časopisima nije se uspjelo pronaći niti jedno istraživanje iz područja dijeljenja znanja, i šire upravljanja znanjem, u kojem se arhivskim pokazateljima operacionalizirala uspješnost poslovanja. Argumentacija iznesena u **Buble** i **dr.** (**2003**.) prezentira glavna ograničenja korištenja arhivskih financijskih pokazatelja. Primjenom odgovarajućih statističkih metoda izvršila se analiza povezanosti perceptivnih i arhivskih pokazatelja, te su rezultati potvrdili tezu da među ovim skupinama pokazatelja ne postoji povezanost, ili ako postoji, ona je nedovoljno značajna. Slijedom toga, bolje je koristiti perceptivne financijske i nefinancijske pokazatelje kako se i učinilo u instrumentu ovog istraživanja.

Recentna znanstvena istraživanja iz područja dijeljenja znanja nerijetko propituju značaj IKT sustava za efikasno upravljanje znanjem, te ga ocjenjuju negativnim. Unatoč tome, IKT se analizirao u konceptualnom modelu dijeljenja znanja u funkciji prediktora zajedno s organizacijskom kulturom, te u tom smislu nije dan isključivi naglasak na IKT kao preduvjet uspješnosti poslovanja poduzeća. Upravo suprotno, u cijelom se radu proteže teza kako je s aspekta upravljanja poslovanjem opasno davati suviše velik naglasak na IKT, jer IKT sam po sebi ne garantira uspješno dijeljenje znanja. Ulaganja u IKT sustave pak podrazumijevaju preusmjeravanje značajnih sredstava u nerijetko skupe i nefleksibilne sustave, pa se u fazi planiranja treba posebna pozornost posvetiti usklađenosti IKT alata sa zahtjevima poduzeća i zaposlenika. Stav zaposlenika prema IKT-u mjeri se kroz česticu Poboljšana komunikacija u

kojoj zaposlenici iskazuju svoje zadovoljstvo primjenom IKT-a u dijeljenju znanja, što im omogućuje iznošenje kako pozitivnih, tako i negativnih stavova prema IKT-u. Ispuštanje ove varijable iz modela također bi imalo negativnih aspekata, jer su recentna istraživanja (**Edwards**, **2022**.) ukazala na potrebu dodatnog dokazivanja povezanosti IKT-a s dijeljenjem znanja.

Istraživanje u sklopu doktorske disertacije zamišljeno je da se provede na nacionalnoj razini kako bi se utvrdila pripadnost hrvatskih velikih, srednjih i malih poduzeća odgovarajućoj generaciji upravljanja znanjem. Ranija istraživanja iz istog područja (**Vidović, 2008**., **Milanović, 2010.**) došla su do oprečnih zaključaka, pa se smatra korisnim učiniti usporedbu nakon proteka cijelog desetljeća. To se pak smatra vrijednim parametrom daljnjeg istraživanja, jer bi se eventualna usporedba Republike Hrvatske mogla učiniti s pojedinim zemljama iz regije koje se po pitanju dijeljenja znanja nalaze u sličnom položaju kao i Hrvatska. Primjerice, istraživanje koje su proveli **Turulja**, **Cinjarević** i **Veselinović** (**2020.**) unutar zdravstvenog sustava Bosne i Hercegovine provedeno je s naglaskom da se BiH nalazi na začelju zemalja koje provode digitalizaciju. Nakon provedenog istraživanja koje je potvrdilo početnu hipotezu, smatra se korisnijim učiniti usporedbu sa zemljama koje su u sličnom položaju, nego sa zemljama koje su predvodnice po pitanju digitalizacije. Osim toga, postoji i praktična prepreka u provedbi istraživanja izvan nacionalnog okvira, a to je moguće uvođenje novih varijabli u model koji je ionako prilično kompleksan s obzirom na velik broj definiranih i potvrđenih varijabli.

U svojstvu kontekstualnih varijabli izdvojio se utjecaj perceptivnih financijskih i nefinancijskih varijabli za period prije i tijekom pandemije Covid-19. U tom smislu bilo bi poželjno ponoviti istraživanje s vremenskim odmakom kada bi posljedice pandemije Covid-19 na uspješnost poslovanja bile još evidentnije, pa bi u tom smislu bilo korisno izvršiti usporedbu velikih, srednjih i malih poduzeća koja su pomake u uspješnosti poslovanja ostvarila upravo zahvaljujući procesima dijeljenja znanja, odnosno ulaganja u razvoj kontekstualnih čimbenika koji pridonose učinkovitom dijeljenju znanja.
Prema tome, zaključno se može ustvrditi da bi bilo poželjno istraživanje provesti s vremenskim odmakom od, primjerice, 5 do 10 godina, radi realne evaluacije učinaka pandemije Covid-19 na uspješnost poslovanja poduzeća; radi eventualno novog pomaka hrvatskih poduzeća prema trećoj generaciji upravljanja znanjem te radi usporedbe hrvatskih poduzeća sa sličnim poduzećima iz regije u smislu razvijenosti infrastrukture (kontekstualnih čimbenika) za dijeljenje znanja.

6. ZAKLJUČAK

Iznenadna pojava pandemije Covid-19 preko noći je iz temelja promijenila uvjete poslovanja za poduzeća diljem svijeta. Iznova su se morali razmatrati poslovni procesi, preispitati poslovne misije, provesti SWOT analiza, kako unutar poduzeća, tako i u njegovom neposrednom okruženju, a sve s ciljem opstanka i razvijanja snažnih temelja za buduće poslovanje. Neupitna je pritom uloga znanja kojim poduzeće raspolaže, odnosno načina na koji se tim istim znanjem upravlja. Upravljanje znanjem kao koncept javlja se 1990-ih godina prošlog stoljeća i otada mu se pridaje sve veća pozornost. Premda među znanstvenicima ne postoji konsenzus glede definicije upravljanja znanjem, ipak su složni u pogledu činjenice da dijeljenje znanja čini njegovu središnju i najvrjedniju kariku. Ako se tome nadoda i kompleksnost znanja, posebice u odnosu na njegovu eksplicitnu i implicitnu dimenziju, tada se smatra višestruko korisnim detaljno ispitati načine učinkovite operacionalizacije dijeljenja znanja. Naime, dok je eksplicitno znanje - znanje koje se lako prikuplja, dokumentira, pohranjuje i koristi, za pretpostaviti je da poduzeća neće naići na veće prepreke prilikom dijeljenja ove vrste znanja. Suprotno tome, znanje koje je pohranjeno u umovima zaposlenika, te je rezultat dugogodišnjeg iskustva i prikupljanja kontekstualnog znanja, teško je izrecivo te u tom smislu pretpostavlja više troškove dijeljenja. Posebice je to bitno s aspekta učinka dijeljenja znanja na uspješnost poslovanja poduzeća, no i na njegov učinak na opći probitak na nacionalnoj razini, a o čemu u korist govori i činjenica da su mnoga nadnacionalna tijela prepoznala važnost znanja, uvrštavajući ga pritom u agende razvoja u nadolazećim periodima.

Podjednaku važnost upravljanju, odnosno dijeljenju znanja, istraživači su pridali i izučavanju kontekstualnih čimbenika koji dodatno pridonose razvoju ovoga procesa. Naime, da bi organizacije uopće mogle osigurati preduvjete za učinkovito dijeljenje znanja, nužno je da obrate pozornost planiranju, implementaciji i unapređivanju određenih kontekstualnih čimbenika koji se u podjednakoj mjeri razvrstavaju u strukturalne, tehnološke, kulturološke dimenzije i sferu ljudskih potencijala. Među velikim brojem postojećih infrastrukturalnih čimbenika nužnih za učinkovito dijeljenje znanja, u ovom su radu posebice izučavana tri čimbenika: organizacijska kultura u sklopu koje su definirane bitne odrednice – poslovna misija, opunomoćivanje i kontinuirano učenje; informacijsko komunikacijske tehnologije (IKT) čije su bitne odrednice – ulaganje u IKT sustave, njihova sposobnost prepoznavanja poslovnih prilika, te unaprijeđena komunikacija te podrška vrhovnog menadžmenta koja je za potrebe ovoga rada odvojena od organizacijske kulture, te prikazana kao zasebna moderacijska

varijabla koja može pozitivno utjecati na odnos organizacijske kulture i dijeljenja znanja, te IKT-a i dijeljenja znanja. Podrška vrhovnog menadžmenta s aspekta dijeljenja znanja može polučiti pozitivne rezultate posebice ako se razmatraju njezine sljedeće odrednice – otvorenost idejama zaposlenika, razvijanje visoke razine povjerenja između menadžera i zaposlenika, te redovito mentoriranje zaposlenika.

Organizacijska kultura predstavlja uhodane obrasce ponašanja koje dijele zaposlenici unutar istoga poduzeća, čak i kada nisu izričito zabilježeni u službenim dokumentima poput poslovne misije ili politike. Često se ovaj koncept opisuje i kao nevidljivom silom koja drži zaposlenike na okupu, potiče među njima stvaranje kolektivizma i osjećaja pripadnosti i odanosti poduzeću. Premda nije eksplicite navedena u poslovnoj misiji, kvalitetna poslovna misija odraz je organizacijske kulture. Primjerice, kvalitetna poslovna misija može odražavati uvriježene vrijednosti zaposlenika poduzeća, poput iskrenosti, sposobnosti, konkurentnosti, pripadnosti, poduzetnosti, vrijednosti znanja i njegovog učinka za uspješnost poslovanja, te u tom smislu poticanja kontinuiranog učenja i osposobljavanja. Zaposlenici mogu razviti osjećaj pripadnosti poduzeću na nekoliko načina, a jedan od svakako najbitnijih je posredstvom opunomoćivanja. Opunomoćivanjem se kod zaposlenika razvija osjećaj samoučinkovitosti i kontrole, usmjerenosti, potiče se razvoj samopouzdanja pa shodno tome i preuzimanje zahtjevnijih zadataka koji nalažu veći angažman. Kako bi opunomoćivanje polučilo čim bolje rezultate, bitno je da se pri njegovoj realizaciji uzmu u obzir i karakteristike zaposlenika, poput dobi i radnog staža jer će opunomoćivanje imati veći odjek među mlađim zaposlenicima nego među osobljem sa duljim radnim stažem. Motiviranje potonjih podrazumijeva razvijanje izazovnijih radnih zadataka, a nerijetko i rotaciju radnih mjesta. Organizacijska kultura nije statičan koncept, već koncept koji se razvija i raste kako raste i poduzeće. Da bi se to omogućilo, neophodno je u poduzeću osigurati preduvjete kontinuiranog učenja. Učenje se u poduzeću može provoditi na tri razine: individualnoj, grupnoj i razini poduzeća. Neovisno o tome na kojoj se razini učenje odvija, bitno je da omogući mijenjanje ustaljenih obrazaca ponašanja svim sudionicima učenja. Jedino na taj način moguće je proširiti iskustvene spoznaje koje će zaposlenicima osigurati prikladnije reagiranje na buduće okolnosti s kojima se još nisu susreli. Grupno učenje može se realizirati na nekoliko načina, poput rotacije radnih mjesta, samoinicirajućih timova, angažmana u privremenim projektnim timovima, mentoriranja i slično. U okolnostima u kojima učenje na proceduralnoj razini dovodi do pomaka u organizacijskim politikama, vrijednostima i pretpostavkama, može se konstatirati da je došlo

do učenja dvostrukom petljom odnosno do učenja na razini poduzeća, a to je ono čemu poduzeća trebaju težiti.

Informacijsko-komunikacijske tehnologije (IKT) često su kritizirane s aspekta njihova utjecaja na upravljanje znanjem u širem smislu, odnosno dijeljenje znanja u užem. Naime, pretpostavka da poduzeća koja implementiraju suvremene IKT alate za dijeljenje znanja ujedno ostvaruju i najbolje učinke i pomake u poslovanju, pogrešna je i dugoročno štetna za poslovanje. S druge strane, izostanak odgovarajućih IKT alata koji podržavaju sustavno i analitičko prikupljanje, dijeljenje, pohranjivanje i ažuriranje organizacijskog znanja neupitno pridonosi zaostajanju poduzeća u sferi učinkovitog upravljanja znanjem. Pomno analiziranje investicija u IKT sustave podrazumijeva prepoznavanje onih IKT alata koji najbolje odražavaju potrebe poslovanja i zaposlenika, odnosno služe specifičnoj svrsi: pri dijeljenu implicitnog znanja poželjno je ulagati u baze podataka koje obuhvaćaju kompetencije zaposlenika, opise najboljih praksi i ekspertne mreže, dok dijeljenje eksplicitnog znanja podrazumijeva odgovarajuće investicije u *online* sustave pretraživanja, intranet i alate za grupnu komunikaciju. Kvalitetno implementirani IKT sustavi omogućuju poduzećima pravovremeno prepoznavanje poslovnih prilika i prijetnji, te shodno tome poduzimanje odgovarajućih reaktivnih mjera. Posebice se ovo odnosi na poduzeća koja u startu raspolažu manjkavim tehnološkim znanjem, pa im IKT alati omogućuju učenje unutar istog poduzeća ili pak između poduzeća. Naime, IKT sustavi pripomažu razradi prototipova i modela koji pojednostavnjuju implicitna znanja, odnosno njihovu reprodukciju u novom okruženju. Slično tome, aditivna proizvodnja koja omogućuje višestruke prednosti, poput slobode dizajna, učinkovite uporabe resursa ili fleksibilnu proizvodnju, omogućuje poduzećima da se u kratkom periodu prilagode novonastalim uvjetima na tržištu te maksimiziraju potencijalne koristi. Poboljšana komunikacija moguća je uporabom brojnih IKT alata koje poduzeća imaju na raspolaganju, poput sustava za podršku grupnom odlučivanju (GDSS); elektroničke telekonferencije; poslovne inteligencije (BI); umjetne neuronske mreže (ANN), odnosno umjetne inteligencije (AI) itd.

Podrška vrhovnog menadžmenta vidljiva je prije svega u intenzitetu poticanja zaposlenika na samostalno izlaganje ideja i davanje prijedloga, pri čemu je krucijalno povjerenje koje menadžeri razvijaju prema zaposlenicima. Uobičajeno se u kontekstu rukovoditelja koji potiču i podržavaju procese dijeljenja znanja spominje da oni trebaju imati karakteristike transformacijskih menadžera, odnosno da trebaju imati jaku karizmu, sposobnost inspiriranja zaposlenika, sposobnost stimuliranja njihova intelekta te prakticiranje brige o svim

zaposlenicima. Između ostaloga, podrška vrhovnog menadžmenta izravno ovisi i o razini povjerenja između rukovoditelja i zaposlenika, a ako je ona prisutna, tada posljedično raste i predanost zaposlenika organizaciji, odnosno poistovjećivanje s poduzećem i njegovim uspjehom, a to nerijetko znači i ulaganje dodatnih napora u izvršavanje radnih zadataka. Mentoriranje zaposlenika još je jedan od indikatora iskazivanja podrške vrhovnog menadžmenta, a može osigurati niz pozitivnih učinaka, poput unapređenja vještina zaposlenika, poticanja intrinzične motivacije i razvijanje boljeg odnosa s nadređenima te općenito bolju apsorpciju znanja i vještina na razini poduzeća.

Primjenom odgovarajućih statističkih metoda analize podataka prikupljenih istraživanjem dokazan je pozitivan utjecaj prediktorskih varijabli, odnosno organizacijske kulture i IKT sustava, kao i moderacijske varijable – podrške vrhovnog menadžmenta na odnos prediktorskih varijabli i procesa dijeljenja znanja, odnosno posljedično na uspješnost poslovanja poduzeća. Temeljem provedenog istraživanja potvrđena je teza da se kod ispitivanja učinka dijeljenja znanja na uspješnost poslovanja poduzeća prvenstveno trebaju koristiti perceptivni financijski i nefinancijski pokazatelji, dok arhivski pokazatelji nedovoljno objektivno prikazuju uspješnost poslovanja s aspekta učinkovitog dijeljenja znanja. U odnosu na dijeljenje znanja kao središnju varijablu konceptualnog modela, zaključak je da je za uspješnost poslovanja podjednako značajno ulagati napore u davanje i primanje eksplicitnog i implicitnog znanja, jer zanemarivanje jednog od njih ili davanje prevelikog značaja drugome može imati negativne posljedice za uspješnost poslovanja. Sljedeći bitan zaključak istraživanja jest da ne postoje razlike u poduzećima s aspekta dijeljenja znanja u odnosu na veličinu poduzeća ili pripadnost pojedinoj grani, a što posljedično podrazumijeva implementaciju smjernica za uspješnu provedbu procesa dijeljenja znanja koje je moguće prilagoditi kontekstu poslovanja individualnih poduzeća.

Integrativni model mjerenja razvijenosti procesa dijeljenja znanja koji istovremeno mjeri kontekstualne čimbenika koji utječu na dijeljenje znanja, ali i učinak procesa dijeljenja znanja na poslovni rezultat pokazao se u ovom istraživanju kao kvalitetan instrument mjerenja razvijenosti preduvjeta za učinkovito dijeljenje znanja. Značaj razvijenog instrumenta jest svakako i u činjenici da nudi detaljnu analitiku razvijenosti praksi i metoda davanja i primanja eksplicitnog i implicitnog znanja, čime poduzeća mogu dodatno procijeniti razvijenost procesa dijeljenja znanja uzimajući u obzir ove kriterije. Moguće da će takvom usporedbom razvijenosti preduvjeta učinkovitog dijeljenja znanja pojedina poduzeća odlučiti razviti i implementirati

određene prakse koje još nisu primijenila, a koja moguće dovedu do pozitivnih pomaka k dijeljenju znanja među zaposlenicima. Modelom se također ukazalo na značaj podrške vrhovnog menadžmenta, ne samo u sklopu organizacijske kulture, što se može iščitati u mnogim recentnim znanstvenim istraživanjima, već kao zasebne varijable koju je posebno značajno izučavati u odnosu na njezin utjecaj na IKT sustave koji se primjenjuju u poduzeću. Implementacije skupih i nefleksibilnih IKT sustava za dijeljenje znanja neće ostvariti dugoročno pozitivne rezultate ako vrhovni menadžment dodatno ne podrži zaposlenike da učinkovito primijene odgovarajuće IKT alate. Pritom se misli na pravovremenu edukaciju zaposlenika prije uvođenja IKT alata, uvažavanje potreba zaposlenika pri odabiru IKT alata koji će im olakšati procese dijeljenja znanja, no isto tako i podršku zaposlenicima tijekom korištenja novih sustava i alata ako se ovi pokažu nedovoljno prilagođeni njihovim potrebama. Ovim je radom također dodatno skrenuta pozornost na nužnost vrednovanja perceptivnih pokazatelja uspješnosti poslovanja poduzeća, koji su u odnosu na arhivske pokazatelje dokazani kao relevantnije mjere uspješnosti poslovanja poduzeća u odnosu na procese dijeljenja znanja. Jasnom sistematizacijom ovih pokazatelja dodatno se omogućilo i drugim istraživačima da obrate pozornost na mjerenje perceptivnih pokazatelja uspješnosti poslovanja pri analizi razvijenosti procesa dijeljenja znanja u poduzećima. Doprinos istraživanja očituje se i u činjenici da se unaprijedila relevantna hrvatska literatura koja se bavi izučavanjem dijeljenja, odnosno upravljanja znanjem s obzirom na to da se istraživanje provelo na velikim, srednjim i malim hrvatskim poduzećima, te da su zaključci istraživanja moguće primjenjivi u svim promatranim jedinicama.

Konačno, jedan od najznačajnijih doprinosa istraživanja jest, uz dubinsku analizu principa dijeljenja eksplicitnog i implicitnog znanja, i činjenica da se potvrdila teza o ostvarenom značajnom napretku hrvatskih poduzeća koja sada prema rezultatima ovog i sličnih istraživanja većinom pripadaju drugoj generaciji upravljanja znanjem, koju karakterizira usredotočenost poduzeća na ljudsku i kulturološku dimenziju, menadžment koji podupire upravljanje znanjem, razvoj organizacijske kulture i infrastrukture koje podupiru upravljanje znanjem te mjerenje korisnosti upravljanja znanjem, što se može učiniti primjenom perceptivnih pokazatelja uspješnosti poslovanja. Sistematičnom primjenom zaključaka istraživanja i sustavnim ulaganjem napora u daljnje razvijanje kontekstualnih čimbenika dijeljenja znanja moguće je prognozirati napredak i prema trećoj generaciji upravljanja znanjem kroz sljedeće desetljeće s obilježjima optimalne brige poduzeća o svim čimbenicima koji utječu na upravljanje znanjem, uz poseban naglasak na kodiranje i pohranu informacija i znanja radi njihove lakše dostupnosti.

LITERATURA

A) KNJIGE

1. Ackerman, M., Pipek, V., Wulf, V. (2003.): *Sharing Expertise – Beyond Knowledge Management*, The MIT Press, Cambridge, London.

2. Aldrich, H. E. (1979.): Organizations & environments. Englewood Cliffs: Prentice-Hall.

3. Argote, L. (2013.): *Organisatonal learning: Creating, retaining and transferring knowledge*, Springer Science & Business Media.

4. Bass, B. M., Riggio, R.E. (2006.): *Transformational Leadership*, Second Edition, Lawrence Erlbaum Associates Publishers, Mahwah, New Jersey, 2006.

5. Baets, W. R. (Ed.). (2006.): *Knowledge Management and Management Learning:: Extending the Horizons of Knowledge-Based Management* (Vol. 9), Springer Science & Business Media.

6. Bahtijarević-Šiber, F. (1999.); Management ljudskih potencijala. Golden marketing, Zagreb.

7. Barney, J. (2014.): *Gaining and Sustaining Competitive Advantage*, Fourth Edition, Pearson Education Limited, UK.

8. Becker, F. D., Steele, F. (1995.): *Workplace by design: Mapping the high-performance workscape*. Jossey-Bass.

9. Buble, M., Cingula, M, Dujanić, M., Dulčić, Ž., Ljubić, F., Mencer, I. i dr. (1997.): Strategijski management. Ekonomski fakultet Split, Split.

10. Bukowitz, W., Williams, R. (2000.): *The Knowledge Management field book*, Financial Times/Prentice Hall, London.

11. Caldeira, C. P. (2007.): *Introduction to Information Systems: Supporting and Transforming Business*, Ed. R. Rainer, E. Turban, R. Potter, John Wiley & Sons Inc.

12. Dalkir, K. (**2011.**): *Knowledge Management in Theory and Practice*. Elsevier Inc., Burlington, MA.

13. Davenport, T. H., Prusak, L. (1998.): *Working knowledge: How organizations manage what they know*, Harvard Business Press.

14. Diamantopoulos, A., Siguaw, J. A. (**2007.**): *Introducing LISREL: A Guide for the Uninitiated*, SAGE Publications, London.

15. Fieldfa, A. (2009.): *Discovering Statistics Using SPSS*, 3rd Edition, Sage Publications Ltd., London.

16. Fulgosi, A. (1988.): *Faktorska analiza, 3. dopunjeno izdanje*, Školska knjiga, Zagreb.

17. Hair, J. F., Black, W. C., Babin, B. J., Anderson, R. E. (**2010.**): *Multivariate Data Analysis: A Global Perspective*, 7th Edition, Pearson Education Inc., Upper Saddle River, New Jersey.

18. Howell, D. C. (2010.): *Statistical Methods for Psychology*, 7th Edition, Cengage Wadsworth Belmont, California, USA.

19. Kaplan, R. S., Norton, D. P. (1996.): *The Balanced Scorecard: Translating Strategy into Action*, HBS Press, Boston.

20. Kline, T. (2005.): *Psychological testing: A practical approach to design and evaluation*, Sage.

21. Koontz, H., & Weihrich, H. (2010.): *Essentials of management: An international perspective*. McGraw Hill.

22. Liessmann, K. P. (2008.): *Teorija neobrazovanosti – Zablude društva znanja*, Naklada Jesenski i Turk, Zagreb.

23. Lučin, P. (2007.): *Kvaliteta u visokom obrazovanju*, Nacionalna zaklada za znanost, visoko školstvo i tehnologijski razvoj Republike Hrvatske, Zagreb.

24. Marsick, V. J., Watkins, K. E. (1997.): Informal and Incidental Learning in the Workplace, Rotledge Revivals.
25. Myers, C. G. (2021.): Performance Benefits of Reciprocal Vicarious Learning in Teams, Acadamey of Management Journal, Vol. 64, No. 3, str. 926-947.
26. Nonaka, I., Takeuchi, H. (**1995.**): *The Knowledge Creating Company*. New York: Oxford University Press.
27. Polanyi, M. (1966.): *The Tacit Dimension*. Doubleday & Company, New York.
28. Rainer, R. K., Turban, E. (2008.): *Introduction to Information Systems*, Wiley.
Schein, E.H. (2010.) *Organisational Culture and Leadership* (4th Ed.). San Francisco: Jossey-Bass.
29. Quinn, R. E. (1988.): *Beyond rational management: Mastering the paradoxes and competing demands of high performance*, Jossey-Bass, San Francisco.
30. Sundać, D., Škalamera-Alilović, D., Babić, M. (**2016.**) *Poslovno okruženje i intelektualni kapital*. Ekonomski fakultet Rijeka, Rijeka.
31. Švarc, J. (2009.) *Hrvatska u društvu znanja – Prijepori i perspektive inovacijske politike,* Školska knjiga, Zagreb.

B) ČLANCI
32. Ahearne, M., Mathieu, J., Rapp, A. (2005.): To empower or not to empower your sales force? An empirical examination of the influence of leadership empowerment behavior on customer satisfaction and performance, *Journal of Applied psychology*, Vol. 90, No. 5, str. 945-955.
33. Ajzen, I., Fishbein, M. (1977.): Attitude-behavior relations: A theoretical analysis and review of empirical research, *Psychological bulletin*, Vol. 84, No. 5, str. 888-918.
34. Akbari, N., Ghaffari, A. (2017.): Verifying relationship of knowledge management initiatives and the empowerment of human resources. *Journal of Knowledge Management*, Vol. 21, No. 5, str. 1-22.
35. Akinola, M., Martin, A. E., Phillips, K. W. (2018.): To delegate or not to delegate: Gender differences in affective associations and behavioral responses to delegation, *Academy of management journal*, Vol. 61, *No.* 4, str. 1467-1491.
36. Al-Busaidi, K. A. (2014.): Knowledge workers' perceptions of potential benefits and challenges of inter-organizational knowledge sharing systems: a Delphi study in the health sector, *Knowledge Management Research & Practice*, Vol. 12, No. 4, str. 398-408.
37. Al-Kurdi, O. F., El-Haddadeh, R., Eldabi, T. (**2019**.): The role of organisational climate in managing knowledge sharing among academics in higher education, *International Journal of Information Management*, Vol. 50, str. 217-227.
38. Ambos, T. C., Nell, P. C., Pedersen, T. (2013.): Combining stocks and flows of knowledge: The effects of intra-functional and cross-functional complementarity, *Global Strategy Journal*, Vol. 3, No. 4, str. 283-299.
39. Andreeva, T., Kianto, A. (2012.): Does knowledge management really matter? Linking knowledge management practices, competitiveness and economic performance**,** *Journal of Knowledge Management*, Vol. 16, No. 4, str. 617-636.
40. Argyres, N. S., Silverman, B. S. (2004.): R&D, organization structure, and the development of corporate technological knowledge, *Strategic Management Journal*, Vol. 25, No. 8-9, str. 929-958.
41. Ashford, S. J., Rothbard, N. P., Piderit, S. K., Dutton, J. E. (1998.): Out on a Limb: The Role of Context and Impression Management in Selling Gender-Equity Issues, *Administrative Science Quarterly*, Vol. 43, No. 1, str. 23-57.

42. Aslam, M. S., Ali, I., Qammar, A., Kiwan, L., Dhir, A. (2022.): How knowledge acquisition creates a competitive edge? A qualitative inquiry from international consultancy alliance. *International Marketing Review*, Vol. 39, No. 3, str. 653-681.
43. Babič, K., Černe, M., Connelly, C. E., Dysvik, A., Škerlavaj, M. (2019.): Are we in this together? Knowledge hiding in teams, collective prosocial motivation and leader-member exchange. *Journal of Knowledge Management*, Vol. 23, No. 8, str. 1502-1522.
44. Barić, V., Jeleč Raguž, M. (2010.): Hrvatska na putu prema društvu znanja, *Poslovna izvrsnost*, Vol. 4, No. 2, str. 57-76.
45. Bartkus, B., Glassman, M., McAfee, R. B. (2000.): Mission statements: are they smoke and mirrors?, *Business Horizons*, Vol. 43, No. 6, str. 23-8.
46. Becerra, M., Lunnan, R., Huemer, L. (2008.): Trustworthiness, risk, and the transfer of tacit and explicit knowledge between alliance partners, *Journal of Management Studies*, Vol. 45, No. 4, str. 691-713.
47. Belak, S., Ušljebrka, I. (2014.): Organizacijska kultura kao čimbenik uspješne provedbe organizacijske promjene, *Oeconomica Jadertina*, Vol. 4, No. 2, str. 80-98.
48. Bick, G., Jacobson, M. Abratt, R. (2003.): The corporate identity management process revisited, *Journal of Marketing Management*, Vol. 19, No. 5, str. 835-855
49. Biloslavo, R., Lynn, M. (2007.): Mission statements in Slovene enterprises, *Management decision*, Vol 45, No 4, str. 773-788.
50. Bingham, C. B., Heimeriks, K. H., Schijven, M., Gates, S. (2015.): Concurrent learning: How firms develop multiple dynamic capabilities in parallel, *Strategic Management Journal*, Vol. 36, No. 12, str. 1802-1825.
51. Birkett, M. A., Day, S. J. (1994.): Internal pilot studies for estimating sample size, *Statistics in medicine*, Vol. 13, Nos. 23-24, str. 2455-2463.
52. Bock, G., Kim, Y. (2002.): Breaking the Myths of Rewards: An Exploratory Study of Attitudes about Knowledge Sharing, *Information Resources Management Journal*, Vol. 15, str. 14-21.
53. Bolisani, E., Scarso, E. (1999.): Information technology management: a knowledge-based perspective, *Technovation*, Vol. 19, No. 4, str. 209-217.
54. Bryant, S. E. (2003.): The role of transformational and transactional leadership in creating, sharing and exploiting organizational knowledge, *Journal of Leadership & Organizational Studies*, Vol. 9, No. 4, str. 32-44.
55. Buble, M., Pučko, D., Pavić, I., Dulčić, Ž., Lahovnik, M., Alfirević, N., Rejc, A., Čater, T. (2003.): Successful competitive strategies of large Croatian and Slovenian enterprises, *Managemen*t, Vol. 8, No. 1, str. 1-112.
56. Carless, S. A. (2004.): Does psychological empowerment mediate the relationship between psychological climate and job satisfaction?, *Journal of Business and Psychology*, Vol. 18, str. 405-425.
57. Carmeli, A., Atwater, L., Levi, A. (**2011.**): How leadership enhances employees' knowledge sharing: the intervening roles of relational and organizational identification, *The Journal of Technology Transfer*, Vol. 36, No. 3, str. 257-274.
58. Cavaliere, V., Lombardi, S., Giustiniano, L. (2015.): Knowledge sharing in knowledge-intensive manufacturing firms. An empirical study of its enablers. *Journal of Knowledge Management*, Vol. 19, No. 6, str. 1124-1145.
59. Chen, C.-J., Hung, S.-W. (**2010.**): To give or to receive? Factors influencing members' knowledge sharing and community promotion in professional virtual communities, *Information and Management*, Vol. 47, str. 226-236.
60. Chen, L., Mohamed, S. (2008.): Contribution of knowledge management activities to organisational business performance. *Journal of Engineering, Design and Technology*, Vol. 6, No. 3, str. 269-285.

61. Chong, S. C. (2006.): KM critical success factors: a comparison of perceived importance versus implementation in Malaysian ICT companies, *The learning organization*, Vol. 13, No. 3, str. 230-256.
62. Coun, M. M., Peters, P. C., Blomme, R. R. (2019.): Let's share!'The mediating role of employees' self-determination in the relationship between transformational and shared leadership and perceived knowledge sharing among peers, *European Management Journal*, Vol. 37, No. 4, str. 481-491.
63. Cropanzano, R., Mitchell, M. S. (2005.): Social exchange theory: An interdisciplinary review. *Journal of management*, Vol. 31, No. 6, str. 874-900.
64. Crossan, M. M., Lane, H. W., White, R. E. (1999.): An organizational learning framework: From intuition to institution, *Academy of management review*, Vol. 24, No. 3, str. 522-537.
65. Daft, R. L., Sormunen, J., Parks, D. (1988.): Chief executive scanning, environmental characteristics and company performance: An empirical study, *Strategic Management Journal Vol.* 9, No. 2, str. 123-139.
66. Denison, D. R., Mishra, A. K. (**1995.**): Toward a theory of organisational culture and effectiveness, *Organisation Science*, Vol. 6, No. 2, str. 204-223.
67. DeSarbo, W. S., Di Benedetto, C. A., Song, M., Sinha, I. (2004.): Revisiting the Miles and Snow strategic framework: uncovering interrelationships between strategic types, capabilities, environmental uncertainty, and firm performance, *Strategic Management Journal*, Vol. 26, No. 1, str. 47-74.
68. de Vries, R. E., van den Hoof, B., de Ridder, J. A. (2006.): Explaining knowledge sharing: the role of team communication styles, job satisfaction and performance beliefs, *Communication Research*, Vol. 33, No. 2, str. 115-135.
69. Diakoulakis, I. E., Georgopoulos, N. B., Koulouriotis, D. E., Emiris, D. M. (2004.): Towards a holistic knowledge management model, *Journal of Knowledge Management*, Vol. 8, No. 1, str. 32-46.
70. Distel, A. P. (2019.): Unveiling the microfoundations of absorptive capacity: A study of Coleman's bathtub model, *Journal of Management*, Vol. 45, No. 5, str. 2014-2044.
71. Donate, M. J., Guadamillas, F. (**2011.**): Organizational factors to support knowledge management and innovation, *Journal of Knowledge Management*, Vol. 15, No. 6, str. 890-914.
72. Drucker, P. F. (1999.): Knowledge-Worker Productivity: The Biggest Challenge, *California Management Review*, Vol. 41, No. 2, str. 79-94.
73. Duncan, R. B. (1972.): Characteristics of organizational environments and perceivedenvironmental uncertainty, *Administrative Science Quarterly*, Vol. 17, No. 3, str. 313–327.
74. Dysvik, A., Buch, R., Kuvaas, B. (**2015.**): Knowledge donating and knowledge collecting, *Leadership & Organisation Development Journal*, Vol. 36, No. 1, str. 35-53.
75. Edmondson, A. C. (2002.): The local and variegated nature of learning in organizations: A group-level perspective, *Organization science*, Vol. 13, No. 2, str. 128-146.
76. Edwards, J. S. (2022.): Where knowledge management and information management meet: Research directions, *International Journal of Information Management*, Vol. 63, str. 102458-02468.
77. Ermisch, J., Gambetta, D., Laurie, H., Siedler, T., Noah Uhrig, S. C. (2009.): Measuring people's trust, *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, Vol. 172, No. 4, str. 749-769
78. Fabrigar, L. R., Wegener, D. T., MacCallum, R. C., Strahan, E. J. (1999.): Evaluating the use of exploratory factor analysis in psychological research, *Psychological Methods*, Vol. 4, No. 3, str. 272-299.

79. Frank, D. J., Meyer, J. W. (2007.): University expansion and the knowledge society. *Theory and society*, Vol. 36, No. 4, str. 287-311.
80. Gatarik, E. (**2019.**) The value of knowledge sharing in decision-making and organisational development: a model-theoretic systemic analysis of an intervention in Austria S.M.E., *Economic Research*, Vol. 32, No. 1, str. 148-167.
81. Gold, A. H., Malhotra, A., Segars, A. H. (2001.): Knowledge management: An organizational capabilities perspective, *Journal of management information systems*, Vol. 18, No. 1, str. 185-214.
82. Grigoriou, K., Rothaermel, F. T. (2017.): Organizing for knowledge generation: Internal knowledge networks and the contingent effect of external knowledge sourcing. *Strategic Management Journal*, Vol. 38, No. 2, str. 395-414.
83. Gururajan, V., Fink, D. (2010.): Attitudes towards knowledge transfer in an environment to perform, *Journal of Knowledge Management*, Vol. 14, No. 6, str. 828 – 840.
84. Haneberg, D. H. (2021.): Interorganizational learning between knowledge-based entrepreneurial ventures responding to COVID-19, *The Learning Organization*, Vol. 28, No. 2, str. 137-152.
85. Haldin-Herrgard, T. (2000.): Difficulties in diffusion of tacit knowledge in organizations, *Journal of Intellectual capital*, Vol. 1, No. 4, str. 357-365.
86. Handžić, M. (2010.): Integrated socio-technical knowledge management model: an empirical evaluation, *Journal of Knowledge Management*, Vol. 15, No. 2, str. 198-211.
87. Hansen, M. T., Mors, M. L., Løvås, B. (2005.): Knowledge sharing in organizations: Multiple networks, multiple phases, *Academy of Management Journal*, Vol. 48, No. 5, str. 776-793.
88. Hirota, S., Kubo, K., Miyajima, H., Hong, P., Park, Y. W. (2010.): Corporate mission, corporate policies and business outcomes: evidence from Japan, *Management decision*, Vol 45, No. 4, str. 773-788.
89. Hu, L. T., Bentler, P. M. (1999.): Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives, *Structural equation modeling: a multidisciplinary journal*, Vol. 6, No. 1, str. 1-55.
90. Huber, G. P. (1991.): Organizational learning: The contributing processes and the literatures. *Organization science*, Vol. 2, No. 1, str. 88-115.
91. Jain, A. (2016.): Learning by hiring and change to organizational knowledge: Countering obsolescence as organizations age, *Strategic Management Journal*, Vol. 37, No. 8, str. 1667-1687.
92. Jeong, I., Shin, S. J. (2019.): High-performance work practices and organizational creativity during organizational change: a collective learning perspective, *Journal of Management*, Vol. 45, No. 3, str. 909-925.
93. Jiang, Y., Chen, C. C. (2018.): Integrating knowledge activities for team innovation: Effects of transformational leadership, *Journal of Management*, Vol. 44, No. 5, str. 1819-1847.
94. Johannessen, J. A., Olaisen, J., Olsen, B. (2001.): Mismanagement of tacit knowledge: the importance of tacit knowledge, the danger of information technology, and what to do about it, *International journal of information management*, Vol. 21, No. 1, str. 3-20.
95. Joia, L. A., Lemos, B. (2010.): Relevant factors for tacit knowledge transfer within organisations, *Journal of knowledge management*, Vol. 14, No 3, str. 410-427.
96. Kaplan, A., Aronoff, S. (1996.): Productivity paradox: work settings for knowledge work, *Facilities*, Vol. 14, Nos 3/4, str. 6-14.
97. Kaplan, R. S., Norton, D. P. (1992.): The Balanced Scorecard: Measures that Drive Performance, *Harvard Business Review*, (January-February), str. 71-79.
98. Kark, R., Shamir, B., Chen, G. (2003.): The two faces of transformational leadership: Empowerment and dependency, *Journal of applied psychology*, Vol. 88, No. 2, str. 246-255.

99. Kesner-Škreb, M. (2007.): Lisabonska strategija, *Financijska teorija i praksa*, Vol. 31, No. 4, str. 441-443.
100. Khamseh, H. M., Jolly, D. R. (2008.): Knowledge transfer in alliances: determinant factors', *Journal of Knowledge Management*, Vol. 12, No. 1, str. 37-50.
101. Kim, S. L., Kim, M., Yun, S. (2015.): Knowledge Sharing, Abusive Supervision, and Support: A Social Exchange Perspective, *Group & Organization Management*, Vol. 40, No. 5, str. 599-624.
102. Kline, R. B. (2010.): Promise and pitfalls of structural equation modeling in gifted research, In Thompson, B., Subotnik, R. F., (Eds.), *Methodologies for conducting research on giftedness*, American Psychological Association, str. 147-169.
103. Kreiser, P. M., Marino, L. D., Weaver, K. M. (2002.): Assessing the Psychometric Properties of the Entrepreneurial Orientation Scale: A Multi-Country Analysis, *Entrepreneurship Theory & Practice*, Vol. 26, str. 71-71.
104. Kunovjanek, M., Wankmüller, C. (2021.): An analysis of the global additive manufacturing response to the COVID-19 pandemic, *Journal of Manufacturing Technology Management*, Vol. 32 No. 9, str. 75-100.
105. Kuvaas, B., Buch, R., Weibel, A., Dysvik, A., Nerstad, C. G. (2017.): Do intrinsic and extrinsic motivation relate differently to employee outcomes?, *Journal of Economic Psychology*, Vol. 61, str. 244-258.
106. Lai, I. K. W., Wong, J. W. C. (2020.): Comparing crisis management practices in the hotel industry between initial and pandemic stages of COVID-19. *International Journal of Contemporary Hospitality Management*, Vol. 32, No. 10, str. 3135-3156.
107. Lancaster, G. A., Dodd, S., Williamson, P. R. (2004.): Design and analysis of pilot studies: recommendations for good practice, *Journal of evaluation in clinical practice*, Vol. 10, No. 2, str. 307-312.
108. Leach, D. J., Wall, T. D., Jackson, P. R. (2003.): The effect of empowerment on job knowledge: An empirical test involving operators of complex technology, *Journal of Occupational and Organizational Psychology*, Vol. 76, No. 1, str. 27-52.
109. Lecuona, J. R., Reitzig, M. (2014.): Knowledge worth having in 'excess': The value of tacit and firm-specific human resource slack, *Strategic Management Journal*, Vol. 35, No. 7,
110. Lee, J.-H., Kim, Y.-G. (**2001.**): Effects of managerial drivers and climate maturity on knowledge management performance: empirical validation, *PACIS 2001 Proceedings*, Vol. 77, str. 1097-1111.
111. Lee, S., Kim, B. G., Kim, H. (2012.): An integrated view of knowledge management for performance, *Journal of Knowledge management*, Vol. 16, No. 2, str. 183-203.
112. Lee, Y., Tao, W., Li, J. Y. Q., Sun, R. (2020.): Enhancing employees' knowledge sharing through diversity-oriented leadership and strategic internal communication during the COVID-19 outbreak, *Journal of Knowledge Management*, Vol. 25, No. 6, str. 1526-1549.
113. Leonardi, P. M., Bailey, D. E. (2008.): Transformational technologies and the creation of new work practices: Making implicit knowledge explicit in task-based offshoring, *MIS quarterly*, str. 411-436.
114. Liang, T. P., Liu, C. C., Wu, C. H. (2008.): Can social exchange theory explain individual knowledge-sharing behavior? A meta-analysis, *Proceedings of the International Conference on Information Systems*, ICIS, str. 1-37.
115. Liden, R. C., Arad, S. (1996.): A power perspective of empowerment and work groups: implications for human resources management research, *Research in Personnel and Human Resources Management*, Vol. 14, str. 205-251.
116. Liden, R. C., Tewksbury, T. W. (1995.): Empowerment and work teams, objavljeno u: Ferris, G., Rosen, S. D., Barnum, D. T., *Handbook of Human Resource Management*, Blackwell Publishers, Cambridge, Mass., str. 386±403.

117. Lin, H.-F. (**2007.**): Knowledge sharing and firm innovation capability: an empirical study, *International Journal of Manpower*, Vol. 28, No. 3/4, str. 315-332.
118. Lu, L., Leung, K., Koch, P. T. (2006.): Managerial knowledge sharing: The role of individual, interpersonal, and organizational factors, *Management and Organization Review*, Vol. 2, No. 1, str. 15-41.
119. Malhotra, Y. (**1998.**): Tooks@ work: Deciphering the knowledge management hype. *The journal for quality and participation*, Vol. 21, No. 4, str. 58-60.
120. March J. G. (1991.): Exploration and exploitation in organizational learning. *Organization Science*, Special Issue: Organizational Learning: Papers in Honor of (and by) James G. March) Vol. 1, No. 2, str. 71–87.
121. McElroy, M. (1999.): The knowledge life cycle, *ICM Conference on KM*, str. 1-13.
122. Metcalf, L., Askay, D. A., Rosenberg, L. B. (2019.): Keeping humans in the loop: pooling knowledge through artificial swarm intelligence to improve business decision making, *California Management Review*, Vol. 61, No. 4, str. 84-109.
123. Meyer, M. H., Zack, M. H. (1996.): The design and development of information products, *MIT Sloan Management Review*, Vol. 37, No., 3, str. 43.
124. McCann III, J.E., Buckner, M. (2004.): Strategically integrating knowledge management initiatives, *Journal of Knowledge Management*, Vol. 8, No. 1, str. 47-63.
125. Menon, T., Pfeffer, J. (2003.): Valuing internal vs. external knowledge: Explaining the preference for outsiders, *Management science*, Vol. 49, No. 4, str. 497-513.
126. Migdadi, M. (2009.): Knowledge management enablers and outcomes in the small-and-medium sized enterprises, *Industrial Management & Data Systems*, Vol. 109, No. 6, str. 840-858.
127. Milanović, Lj. (2010.): Korištenje informacijske tehnologije za upravljanje znanjem u hrvatskim poduzećima, *Zbornik Ekonomskog fakulteta u Zagrebu*, Vol. 8, No. 2, str. 195-211.
128. Mirzaee, S., Ghaffari, A. (2018.): Investigating the impact of information systems on knowledge sharing, *Journal of Knowledge Management*, Vol. 22, No. 3, str. 501-520.
129. Moffet, S., McAdam, R., Parkinson, S. (**2002.**): Developing a Model for Technology and Cultural Factors in Knowledge Management: A Factor Analysis, *Knowledge and Process Management*, Vol. 9, No. 4, str. 237-255.
130. Nickerson, J. A., Zenger, T. R. (2004.): A knowledge-based theory of the firm—The problem-solving perspective, *Organization science*, Vol. 15, No. 6, str. 617-632.
131. Oh, S.-y., Han. H.-s. (**2020.**): Facilitating organisational learning activities: Types of organisatioanl culture and their influence on organisational learning and performance, *Knowledge Management Research & Practice*, Vol. 18, No. 1, str. 1-15.
132. Oldroyd, J. B., Morris, S. S., Dotson, J. P. (2019.): Principles or templates? The antecedents and performance effects of cross-border knowledge transfer, *Strategic Management Journal*, Vol. 40, No. 13, str. 2191-2213.
133. Oyemomi, O., Liu, S., Neaga, I., Chen, H., Nakpodia, F. (2019.): How cultural impact on knowledge sharing contributes to organizational performance: Using the fsQCA approach, *Journal of Business Research*, Vol. 94, str. 313-319.
134. Oztekin, A., Delen, D., Zaim, H., Turkyilmaz, A., Zaim, S. (2015.): The influence of knowledge management on financial and non-financial performance, *Journal of Information & Knowledge Management*, Vol. 14, No. 2, str. 1550013-1550027.
135. Palvalin, M., Lönnqvist, A., Vuolle, M. (2013.): Analysing the impacts of ICT on knowledge work productivity", *Journal of Knowledge Management*, Vol. 17, No. 4, str. 545-557,
136. Panahi, S., Watson, J., Partridge, H. (2013.): Towards tacit knowledge sharing over social web tools, *Journal of knowledge management*, Vol. 17, No. 3, str. 1-23.

137. Panian, Ž. (2010.): Some Practical Experiences in Data Governance , *World Academy of Science, Engineering and Technology (WASET),* Vol. 62, str. 468-475
138. Parker, L. D. (2020.): The COVID-19 office in transition: cost, efficiency and the social responsibility business case. *Accounting, Auditing & Accountability Journal*, Vol. 33, No. 8. str. 1943-1967.
139. Podrug, N., Filipović, D., Kovač, M. (2017.): Knowledge sharing and firm innovation capability in Croatian ICT companies, *International journal of manpower,* Vol. 38, No. 4, str. 632-644
140. Prieto, I. M., Revilla, E. (2006.): Learning Capability and Business Performance: A Non-Financial and Financial Assessment, *The Learning Organization*, Vol. 13, str. 166-185.
141. Phang, M. M. S., Foong, S.-Y. (**2010.**): Information communication technologies (ICTs) and knowledge sharing: The case of professional accountants in Malaysia, *World Journal of Science,* Technology and Sustainable Development, Vol. 7, No. 1, pp. 21-35.
142. Purvanova, R. K., Bono, J. E. (2009.): Transformational leadership in context: Face-to-face and virtual teams, *The leadership quarterly,* Vol. 20, No. 3, str. 343-357.
143. Rouyre, A., Fernandez, A. S. (2019.): Managing knowledge sharing-protecting tensions in coupled innovation projects among several competitors. *California Management Review*, Vol. 62, No. 1, str. 95-120.
144. Rusjan, B. (2005.): Usefulness of the EFQM excellence model: Theoretical explanation of some conceptual and methodological issues, *Total Quality Management & Business Excellence,* Vol. 16, No. 3, str. 363-380.
145. Samuelsson, P., Nilsson, L. E. (2002.): Self-assessment practices in large organisations: Experiences from using the EFQM excellence model, *International Journal of Quality & Reliability Management*, Vol. 19, No. 1, str. 10-23.
146. Schiuma, G., Schettini, E., Santarsiero, F. Carlucci, D. (2022.): The transformative leadership compass: six competencies for digital transformation entrepreneurship, International Journal of Entrepreneurial Behavior & Research, Vol. 28, No. 5, pp. 1273-1291.
147. Schoenherr, T., Griffith, D. A., Chandra, A. (2014.): Intangible capital, knowledge and new product development competence in supply chains: process, interaction and contingency effects among SMEs, *International journal of production research*, Vol. 52, No. 16, str. 4916-4929.
148. Schreurs, J., Moreau, R. (**2006**): The EFQM self assessment model in performance management. *Proceedings ECEL 2006 conference Athene*, str. 1-6.
149. Sher, P. J., Lee, V. C. (2004.) Information technology as a facilitator for enhancing dynamic capabilities through knowledge management, *Information & management*, Vol. 41, No. 8, str. 933-945.
150. Singh, S. K., Gupta, S., Busso, D., Kamboj, S. (2021.): Top management knowledge value, knowledge sharing practices, open innovation and organizational performance, *Journal of Business Research*, Vol. 128, str. 788-798.
151. Sorakraikitikul, M., Siengthai, S. (**2014.**): Organisational learning culture and workplace spirituality: Is knowledge sharing behavior a missing link?, *The Learning Organisation,* Vol. 21, No. 3, str. 175-192.
152. Stewart, G. L., Astrove, S. L., Reeves, C. J., Crawford, E. R., Solimeo, S. L. (2017.): Those with the most find it hardest to share: Exploring leader resistance to the implementation of team-based empowerment, *Academy of Management Journal,* Vol. 60, No. 6, str. 2266-2293.
153. Steyn, C., Kahn, M. (**2008.**): Towards the development of a knowledge management practices survey for application in knowledge intensive programs, *South African Journal of Business Management,* Vol. 39, No. 1, str. 45-53.

154. Suppiah, V. N., Sandhu, M. S. (2011.): Organisational Culture's Influence on Tacit Knowledge Sharing Behaviour, *Journal of Knowledge Management,* Vol. 15, No. 3, str. 462-477.
155. Škalamera-Alilović, D. (2007.): Utjecaj tehnološkog sektora poslovnog okruženja na uspješnost nacionalne ekonomije. U: Bušelić, M. (ur.) Znanje i konkurentnost. Pula, Sveučilište Jurja Dobrile u Puli, Odjel za ekonomiju i turizam "Dr. Mijo Mirković", str. 349-375.
156. Švarc, J., Dabić, M. (2017.): Evolution of the Knowledge Economy: a Historical Perspective with an Application to the Case of Europe, *Journal of the Knowledge Economy*, Vol. 8, No. 1, str. 159-176.
157. Tan, H. H., Zhao, B. (2010.): Individual- and Perceived Contextual-Level Antecedents of Individual Technical Information Inquiry in Organizations, *The Journal of Psychology*, Vol. 137, No. 6, str. 597-621.
158. Tortoriello, M., Reagans, R., McEvily, B. (2012.): Bridging the knowledge gap: The influence of strong ties, network cohesion, and network range on the transfer of knowledge between organizational units, *Organization science*, Vol. 23, No. 4, str. 1024-1039.
159. Turulja, L., Cinjarevic, M., Veselinovic, L. (2020.): Information technology and knowledge sharing for better health care: an emerging economy context. Journal of Knowledge Management, Vol. 25, No. 3, str. 559-572.
160. Tzabbar D. (2009.): When does scientist recruitment affect technological repositioning?, *Academy of Management Journal,* Vol. 52, No. 5, str. 873–896.
161. Van den Hooff, B., Huysman, M. (2009.): Managing knowledge sharing: Emergent and engineering approaches, *Information & management*, Vol. 46, No. 1, str. 1-8.
162. Van Teijlingen, E., Hundley, V. (2002.): The importance of pilot studies, *Nursing Standard (through 2013)*, Vol. 16, No. 40, str. 33-36.
163. Van Wijk, R., Jansen, J. J., Lyles, M. A. (2008.): Inter-and intra-organizational knowledge transfer: a meta-analytic review and assessment of its antecedents and consequences, *Journal of management studies*, Vol. 45, No. 4, str. 830-853.
164. Vidović, M. (2008.): Razvijenost prakse upravljanja znanjem u Hrvatskoj, *Zbornik Ekonomskog fakulteta u Zagrebu*, Vol. 6, No. 1, str. 275-288.
165. Weick, K. E. (1991.): The Nontraditional Quality of Organizational Learning, *Organization Science*, Vol. 2, No. 1, str. 116–124.
166. Whitehead, A. L., Sully, B. G. O., Campbell, M. J. (2014.): Pilot and feasibility studies: Is there a difference from each other and from a randomised controlled trial?, Contemporary Clinical Trials, Vol. 38, No. 1, str. 130-133.
167. Wiig, K. M. (1997.): Knowledge management: Where did it come from and where will it go?, *Expert systems with applications*, Vol. 13, No. 1, str. 1-14.
168. Wong, S. I., Giessner, S. R. (2018.): The thin line between empowering and laissez-faire leadership: An expectancy-match perspective, *Journal of Management*, Vol. 44, No. 2, str. 757-783.
169. Xu, J., Quaddus, M. (2007.): Exploring the factors influencing end users' acceptance of knowledge management systems: Development of a research model of adoption and continued use, *Journal of Organizational and End User Computing (JOEUC)*, Vol. 19, No. 4, str. 57-79.
170. Yao, F. K., Chang, S. (2017.): Do individual employees' learning goal orientation and civic virtue matter? A micro-foundations perspective on firm absorptive capacity, *Strategic Management Journal*, Vol. 38, No. 10, str, 2041-2060.
171. Zack, M. (1999.): Developing a Knowledge Strategy, California Management Review, Vol. 41, No. 3, str. 125–145.
172. Zahra, S. A., Garvis, D. M. (2000.): International corporate entrepreneurship and firm performance. The moderating effect of international environmental hostility, Journal of business venturing, Vol. 15, No. 5-6, str. 469-492.

173. Zhang, J., Baden-Fuller, C. (2010.): The Influence of Technological Knowledge Base and Organizational Structure on Technology Collaboration, *Journal Of Management Studies*, Vol. 47, No. 4, str. 679-704.
174. Zhang, X., Jiang, J. Y. (2015.): With whom shall I share my knowledge? A recipient perspective of knowledge sharing, *Journal of Knowledge Management*, Vol. 19, No. 2, str. 277-295.
175. Zollo M, Singh H. (2004.): Deliberate learning in corporate acquisitions: post-acquisition strategies and integration capability in U.S. bank mergers, *Strategic Management Journal*, Vol. 25, No. 13, str. 1233–1256.
176. Zulhamri, A., Yuhanis, S. N., Aziz, A. (2013.): Building a unique online corporate identity, *Marketing Intelligence & Planning*, Vol. 31, No. 5, str. 451 - 471
177. Žugaj, M., Bojanić-Glavica, B., Brčić, R. (2004.): Organizacijska kultura u funkciji uspješnosti poslovanja organizacije. *Ekonomski vjesnik,* Vol. XVII, No. 1-2, str. 17-29.

C) OSTALI IZVORI
178. Statističke informacije 2020., Državni zavod za statistiku Republike Hrvatske, Zagreb

POPIS TABLICA

R. br.	Naziv tablice	Stranica
1.	Faze procesa upravljanja znanjem	17
2.	Kategorizacija znanja u odnosu na izvore generiranja	21
3.	Vrste mehanizama davanja eksplicitnog i implicitnog/tacitnog znanja	32
4.	Vrste mehanizama primanja eksplicitnog i implicitnog/tacitnog znanja	38
5.	Obilježja organizacijske kulture prema Denisonu i Mishri (1995.)	44
6.	Sistematizacija vrsta učenja na individualnoj, grupnoj i organizacijskoj razini	55
7.	IKT alati za dijeljenje znanja i opis njihovih temeljnih značajki	69
8.	Stupanj utjecaja kriterija na procjenu poslovne izvrsnosti prema EFQM modelu i mjere za ocjenu postignuća	84
9.	Analitički prikaz mjernih varijabli korištenih u anketnom upitniku i izvora njihovog kreiranja	100
10.	Testiranje preduvjeta za provođenje eksploratorne faktorske analize za skale *Organizacijska kultura*, *Informacijsko--komunikacijske tehnologije*, *Podrška vrhovnog menadžmenta*, *Dijeljenje znanja* i skale *Uspješnost poslovanja poduzeća* Kaiser-Mayer-Olkin testom te Bartlettovim testom sfericiteta	100
11.	Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Organizacijska kultura u objedinjenom istraživanju	100
12.	Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Informacijsko-komunikacijske tehnologije u objedinjenom istraživanju	100
13.	Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Podrška vrhovnog menadžmenta u objedinjenom istraživanju	100
14.	Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Dijeljenje znanja u objedinjenom istraživanju	101

15.	Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Uspješnost poslovanja poduzeća u objedinjenom istraživanju	102
16.	Faktorska zasićenja na skali Organizacijska kultura (objedinjeno istraživanje)	104
17.	Faktorska zasićenja na skali Informacijsko-komunikacijske tehnologije (objedinjeno istraživanje)	105
18.	Faktorska zasićenja na skali Podrška vrhovnog menadžmenta (objedinjeno istraživanje)	106
19.	Faktorska zasićenja na skali Dijeljenje znanja u prvoj iteraciji (objedinjeno istraživanje)	107
20.	Faktorska zasićenja na skali Uspješnost poslovanja poduzeća (objedinjeno istraživanje)	109
21.	Prikaz koeficijenata unutarnje konzistencije (Cronbach alpha)	109
22.	Usporedba arhivskog pokazatelja ROA i perceptivnih financijskih pokazatelja prije pandemije Covida-19	110
23.	Usporedba arhivskog pokazatelja ROA i perceptivnih financijskih pokazatelja nakon pandemije Covida-19	111
24.	Usporedba arhivskog pokazatelja ROA i perceptivnih nefinancijskih pokazatelja prije pandemije Covida-19	111
25.	Usporedba arhivskog pokazatelja ROA i perceptivnih nefinancijskih pokazatelja nakon pandemije Covida-19	111
26.	Usporedba arhivskog pokazatelja ROE i perceptivnih financijskih pokazatelja prije pandemije Covida-19	112
27.	Usporedba arhivskog pokazatelja ROE i perceptivnih financijskih pokazatelja nakon pandemije Covida-19	112
28.	Usporedba arhivskog pokazatelja ROE i perceptivnih nefinancijskih pokazatelja prije pandemije Covida-19	112
29.	Usporedba arhivskog pokazatelja ROE i perceptivnih nefinancijskih pokazatelja nakon pandemije Covid-19	113
30.	Usporedba perceptivnih financijskih pokazatelja prije i nakon, odnosno tijekom pandemije Covida-19	113
31.	Usporedba perceptivnih nefinancijskih pokazatelja prije i nakon, odnosno tijekom pandemije Covida-19	114
32.	Normalnost distribucije u *online* istraživanju	115
33.	Deskriptivni pokazatelji uzorka iz *online* istraživanja	116
34.	Slaganje modela iz *online* istraživanja s podacima	117
35.	Zasićenost čestica pripadajućim faktorima u *online* istraživanju	118
36.	Interpretacija medijacijskog modela za *online* istraživanje	118
37.	Slaganje moderacijskog modela s podacima za *online* istraživanje	120
38.	Normalnost distribucije u poštanskom istraživanju	121
39.	Deskriptivni pokazatelji uzorka iz poštanskog istraživanja	122
40.	Slaganje modela s podacima za poštansko istraživanje	123
41.	Faktorska zasićenja indikatora (parcela) s pripadajućom latentnom varijablom u poštanskom istraživanju	123
42.	Slaganje medijacijskog modela s podacima za poštansko istraživanje	123
43.	Slaganje moderacijskog modela s podacima za poštansko istraživanje	125

44.	Normalnost distribucije za objedinjeno istraživanje	126
45.	Deskriptivni pokazatelji uzorka iz objedinjenog istraživanja	127
46.	Slaganje modela s podacima za objedinjeno istraživanje	128
47.	Faktorska zasićenja indikatora (parcela) s pripadajućom latentnom varijablom za sve podatke	128
48.	Prosječne vrijednosti latentnih varijabli za tri grupe poduzeća koje se razlikuju po djelatnosti	129
49.	Hi-kvadrat test za CFA model za tri grupe poduzeća koje se razlikuju po djelatnosti	129
50.	Prosječne vrijednosti latentnih varijabli za tri grupe poduzeća koje se razlikuju po veličini	130
51.	Hi-kvadrat test za CFA model za tri grupe poduzeća koje se razlikuju po veličini	130
52.	Slaganje medijacijskog modela s podacima za objedinjeno istraživanje	131
53.	Slaganje moderacijskog modela s podacima za objedinjeno istraživanje	132
54.	Utjecaj prediktorskih varijabli na Davanje eksplicitnog znanja	135
55.	Utjecaj prediktorskih varijabli na Davanje implicitnog znanja	136
56.	Utjecaj prediktorskih varijabli na Primanje eksplicitnog znanja	137
57.	Utjecaj prediktorskih varijabli na Primanje implicitnog znanja	138
58.	Utjecaj prediktorskih varijabli na Dijeljenje eksplicitnog znanja (davanje i primanje)	139
59.	Utjecaj prediktorskih varijabli na Dijeljenje implicitnog znanja (davanje i primanje)	140
60.	Utjecaj prediktorskih varijabli na Davanje znanja (eksplicitnog i implicitnog)	141
61.	Utjecaj prediktorskih varijabli na Primanje znanja (eksplicitnog i implicitnog)	142
62.	Analitika interakcija prediktori – podčestice Dijeljenje znanja (postotak objašnjene varijance)	142
63.	Deskriptivna statistika za dva klastera	144
64.	T-test za nezavisne uzorke (dva klastera) na varijabli Organizacijska kultura	147
65.	T-test za nezavisne uzorke (dva klastera) na varijabli IKT	147
66.	T-test za nezavisne uzorke (dva klastera) na varijabli Podrška vrhovnog menadžmenta	147

POPIS SLIKA

R.br.	Naziv slike	Str.
1.	Integrirani ciklus upravljanja znanjem	17
2.	Prikaz konceptualnog modela dijeljenja znanja	83
3.	*Scree plot* indikatora Organizacijska kultura (objedinjeno istraživanje)	103
4.	*Scree plot* indikatora Informacijsko-komunikacijske tehnologije (objedinjeno istraživanje)	105

5.	*Scree plot* indikatora Podrška vrhovnog menadžmenta (objedinjeno istraživanje)	106
6.	*Scree plot* indikatora Dijeljenje znanja (objedinjeno istraživanje)	107
7.	*Scree plot* indikatora Uspješnost poslovanja poduzeća (objedinjeno istraživanje)	108
8.	Jačina veza u medijacijskom modelu	119
9.	Jačina veza u moderacijskom modelu za *online* istraživanje	120
10.	Jačina veza u medijacijskom modelu za poštansko istraživanje	124
11.	Moderacijski model i jačina veza za poštansko istraživanje	125
12.	Medijacija i jačina veza u objedinjenom istraživanju	132
13.	Moderacija i jačina veza u objedinjenom istraživanju	133
14.	Interakcija između Podrške vrhovnog menadžmenta i Organizacijske kulture na Dijeljenje znanja	133
15.	Interakcija između Podrške vrhovnog menadžmenta i IKT-a na Dijeljenje znanja	134
16.	Definiranje broja klastera	144
17.	Određivane optimalnog broja klastera	145
18.	Distribucija IKT varijable izražene na z-skali za dva klastera	145
19.	Distribucija ORK varijable izražene na z-skali za dva klastera	145
20.	Distribucija PVM varijable izražene na z-skali za dva klastera	146
21.	Boxplot za varijablu IKT izraženu na z-skali za dva klastera	146
22.	Boxplot za varijablu ORK izraženu na z-skali za dva klastera	146
23.	Boxplot za varijablu PVM izraženu na z-skali za dva klastera	147

POPIS PRILOGA

R.br.	Naziv priloga	Str.
1.	Anketni upitnik	183
2.	Korelacijske matrice skala u *online* istraživanju	189
3.	Korelacijske matrice skala u poštanskom istraživanju	191
4.	Eksploratorna faktorska analiza za skalu Organizacijska kultura u *online* istraživanju	193
5.	Eksploratorna faktorska analiza za skalu IKT u *online* istraživanju	194
6.	Eksploratorna faktorska analiza za skalu Podrška vrhovnog menadžmenta u *online* istraživanju	195
7.	Eksploratorna faktorska analiza za skalu Dijeljenje znanja u *online* istraživanju	196
8.	Eksploratorna faktorska analiza za skalu Uspješnost poslovanja poduzeća u *online* istraživanju	198
9.	Eksploratorna faktorska analiza za skalu Organizacijska kultura u poštanskom istraživanju	200
10.	Eksploratorna faktorska analiza za skalu IKT u poštanskom istraživanju	201
11.	Eksploratorna faktorska analiza za skalu Podrška vrhovnog menadžmenta u poštanskom istraživanju	202
12.	Eksploratorna faktorska analiza za skalu Dijeljenje znanja u poštanskom istraživanju	203

13.	Eksploratorna faktorska analiza za skalu Uspješnost poslovanja poduzeća u poštanskom istraživanju	204
14.	Moderirana medijacija - ROA i ROE kao kriteriji	205

PRILOG 1. ANKETNI UPITNIK

DIJELJENJE ZNANJA U FUNKCIJI UNAPREĐENJA USPJEŠNOSTI POSLOVANJA PODUZEĆA

1. ORGANIZACIJSKA KULTURA

(Sustav vrijednosti specifičan za zaposlenike pojedinog poduzeća, odnosno njihove karakteristike koje ih potiču na zajedništvo i ulaganje kolektivnih napora u uspješnu realizaciju radnih zadataka.)

Ocijenite sljedeće tvrdnje koje opisuju sastavnice organizacijske kulture:

a) POSLOVNA MISIJA (Način postizanja vizije poslovanja, odnosno smjera u kojem se poduzeće želi razvijati; djelokrug poslovanja; temelj definiranja ciljeva poslovanja.)

Tvrdnje vezane uz POSLOVNU MISIJU	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
1. Naše poduzeće na transparentan način promiče poslovnu misiju.	1	2	3	4	5
2. Jasno definirana misija potpomaže razvijanje zajedništva.	1	2	3	4	5
3. Zaposlenici razumiju smisao poslovanja te su odani misiji poslovanja.	1	2	3	4	5
4. U našem je poduzeću dijeljenje znanja značajan segment poslovne misije.	1	2	3	4	5

b) OPUNOMOĆIVANJE ZAPOSLENIKA (Davanje veće slobode zaposlenicima u ispunjavanju radnih zadataka, mogućnost samostalnog odlučivanja i djelovanja.)

Tvrdnje vezane uz OPUNOMOĆIVANJE ZAPOSLENIKA	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
5. Naše poduzeće potiče preuzimanje inicijativa od strane zaposlenika.	1	2	3	4	5
6. Zaposlenici se aktivno potiču da sudjeluju u donošenju odluka.	1	2	3	4	5
7. Od zaposlenika se očekuje visok osobni angažman u dijeljenju znanja.	1	2	3	4	5
8. Zaposlenici visoko vrednuju mogućnost obavljanja izazovnih zadataka.	1	2	3	4	5

c) KONTINUIRANO UČENJE

Tvrdnje vezane uz KONTINUIRANO UČENJE	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
9. Poduzeće izdvaja značajna sredstva za edukativne i razvojne programe kako bi unaprijedilo specifična znanja i vještine zaposlenika.	1	2	3	4	5
10. Fleksibilnost i želja za promjenama temeljni su motivi kontinuiranog učenja u poduzeću.	1	2	3	4	5
11. Naše poduzeće potiče poduzetničko ponašanje, zbog čega se zaposlenicima toleriraju povremene pogreške i eksperimenti.	1	2	3	4	5
12. Učenje iz pogrešaka omogućava se kroz timski rad i konsenzus.	1	2	3	4	5

2. INFORMACIJSKO-KOMUNIKACIJSKE TEHNOLOGIJE (IKT)

Ocijenite sljedeće tvrdnje koje opisuju sastavnice informacijsko-komunikacijskih tehnologija (IKT):

a) INVESTICIJE U IKT SUSTAVE

Tvrdnje vezane uz INVESTICIJE U IKT	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
13. Sustav poslovne inteligencije* u našem poduzeću efikasno podržava svakodnevno poslovanje.	1	2	3	4	5
14. Računalni programi koji omogućuju učenje na daljinu unapređuju svakodnevno poslovanje.	1	2	3	4	5
15. IKT sustavi u našem poduzeću prilagođeni su potrebama zaposlenika.	1	2	3	4	5
16. IKT sustavi u našem poduzeću redovito se ažuriraju.	1	2	3	4	5

* *Poslovna inteligencija je skup metodologija za prikupljanje, analizu i distribuciju poslovnih informacija uz pomoć različitih računalnih programa.*

b) PREPOZNAVANJE POSLOVNIH PRILIKA

Tvrdnje vezane uz PREPOZNAVANJE POSLOVNIH PRILIKA	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
17. IKT se u našem poduzeću koristi za otkrivanje poslovnih prilika.	1	2	3	4	5
18. Naše poduzeće koristi IKT-om koje omogućuje praćenje konkurencije.	1	2	3	4	5
19. Naše poduzeće koristi IKT koje omogućuje praćenje aktivnosti poslovnih partnera.	1	2	3	4	5
20. IKT sustavi u našem poduzeću olakšavaju zaposlenicima korištenje društvenih kontakata u svrhu prikupljanja relevantnih informacija o novim prilikama na tržištu.	1	2	3	4	5

c) POBOLJŠANA KOMUNIKACIJA

Tvrdnje vezane uz POBOLJŠANU KOMUNIKACIJU	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
21. U našem poduzeću zaposlenici redovito komuniciraju *e-mailom* i sličnim alatima radi zajedničkog obavljanja radnih zadataka.	1	2	3	4	5
22. IKT sustavi u našem poduzeću omogućuju zaposlenicima na različitim radnim mjestima i/ili lokacijama da zajednički uče na daljinu.	1	2	3	4	5
23. IKT sustavi u našem poduzeću omogućuju zaposlenicima da u kratkom roku lociraju nužan izvor znanja, poput specifične baze podataka.	1	2	3	4	5

24. IKT sustavi u našem poduzeću osiguravaju pristup točnim i pravodobnim podatcima.	1	2	3	4	5

3. PODRŠKA VRHOVNOG MENADŽMENTA

Ocijenite sljedeće tvrdnje koje opisuju podršku vrhovnog menadžmenta:

a) OTVORENOST MENADŽERA IDEJAMA I PRIJEDLOZIMA ZAPOSLENIKA

Tvrdnje vezane uz OTVORENOST MENADŽERA IDEJAMA I PRIJEDLOZIMA ZAPOSLENIKA	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
25. Menadžeri promiču sustav vrijednosti u kojem se cijeni mišljenje svakog zaposlenika.	1	2	3	4	5
26. Menadžeri potiču zaposlenike na otvoreno iznošenje ideja/prijedloga na sastancima s nadležnima.	1	2	3	4	5
27. Menadžeri potiču zaposlenike na formalnu i neformalnu komunikaciju unutar poduzeća.	1	2	3	4	5
28. Menadžeri potiču povezivanje zaposlenika u grupe radi učenja i generiranja novih ideja.	1	2	3	4	5

b) RAZVIJANJE POVJERENJA IZMEĐU ZAPOSLENIKA I MENADŽERA

Tvrdnje vezane uz RAZVIJANJE POVJERENJA IZMEĐU ZAPOSLENIKA I MENADŽERA	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
29. Zaposlenici doživljavaju uspjeh poduzeća kao vlastiti uspjeh.	1	2	3	4	5
30. Zaposlenicima je važna reputacija koju njihovo poduzeće ima među vanjskim subjektima.	1	2	3	4	5
31. Menadžeri se ponašaju kao savjetnici, te prakticiraju kontrolu isključivo za procjenu dostignuća zaposlenika.	1	2	3	4	5
32. Menadžeri potiču zaposlenike na bavljenje zahtjevnijim zadacima, čak i kada postoji mogućnost neuspjeha.	1	2	3	4	5

c) MENTORIRANJE (POUČAVANJE) ZAPOSLENIKA

Tvrdnje vezane uz MENTORIRANJE (POUČAVANJE) ZAPOSLENIKA	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
33. Redovitim mentoriranjem zaposlenika menadžeri dodatno ističu važnost znanja za uspješnost poslovanja poduzeća.	1	2	3	4	5
34. Novim zaposlenicima omogućen je period orijentacije radi upoznavanja organizacijske strukture i sistematizacije poslova.	1	2	3	4	5
35. Zaposlenicima koji preuzimaju nove dužnosti omogućeno je mentoriranje, neovisno o tome koliko dugo rade u poduzeću.	1	2	3	4	5

36. Primjenjuju se programi rotiranja zaposlenika pomoću kojih menadžeri različitih odjela pomažu zaposlenicima unaprijediti svoja znanja i vještine.	1	2	3	4	5

4. DIJELJENJE EKSPLICITNOG I IMPLICITNOG ZNANJA*

a) Ocijenite sljedeće tvrdnje koje opisuju DAVANJE EKSPLICITNOG ZNANJA:

Tvrdnje vezane uz DAVANJE EKSPLICITNOG ZNANJA	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
37. Zaposlenici redovito kroz organizirane edukacije prenose znanja, vještine i iskustva drugim zaposlenicima.	1	2	3	4	5
38. Zaposlenici koriste virtualna spremišta za pohranjivanje znanja i iskustava koja time postaju dostupna drugim zaposlenicima.**	1	2	3	4	5
39. Zaposlenici redovito pišu izvješća nadređenima o vlastitim postignućima (stečena znanja, vještine i iskustva).	1	2	3	4	5

** Eksplicitno znanje je znanje koje se može jednostavno prikupiti, pohraniti i dijeliti, dok je implicitno znanje svojstveno zaposlenicima, teško se artikulira te se pretežno prenosi osobnim kontaktom.*

*** Virtualna spremišta su* online *alati za komunikaciju poput MS Teamsa ili ZOOM-a koji omogućuju pohranjivanje, dijeljenje i ponovno korištenje dokumenata.*

b) Ocijenite sljedeće tvrdnje koje opisuju DAVANJE IMPLICITNOG ZNANJA:

Tvrdnje vezane uz DAVANJE IMPLICITNOG ZNANJA	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
40. Zaposlenici slobodno iznose ideje i stavove na poslovnim sastancima s nadređenima.	1	2	3	4	5
41. Zaposlenici se trude osobnim kontaktom pomoći manje iskusnim kolegama.	1	2	3	4	5
42. Zaposlenici u timovima i u neformalnim kontaktima rado daju savjete kolegama/prijateljima.	1	2	3	4	5

c) Ocijenite sljedeće tvrdnje koje opisuju PRIMANJE EKSPLICITNOG ZNANJA:

Tvrdnje vezane uz PRIMANJE EKSPLICITNOG ZNANJA	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
43. Zaposlenici se redovito educiraju o načinima prenošenja znanja, vještina i iskustava drugim zaposlenicima.	1	2	3	4	5
44. Zaposlenici organizirano primaju i analiziraju periodična izvješća o tržišnim trendovima i potrebama.	1	2	3	4	5
45. Zaposlenici organizirano primaju i analiziraju periodična izvješća o rezultatima poslovanja, te organizacijskim politikama i procedurama.	1	2	3	4	5

d) Ocijenite sljedeće tvrdnje koje opisuju PRIMANJE IMPLICITNOG ZNANJA:

Tvrdnje vezane uz PRIMANJE IMPLICITNOG ZNANJA	Uopće se ne slažem	Ne slažem se	Niti se slažem niti ne slažem	Djelomično se slažem	U potpunosti se slažem
46. Tijekom poslovnih sastanaka zaposlenici slobodno postavljaju pitanja kolegama i nadređenima.	1	2	3	4	5
47. Zaposlenici koji žele usvojiti nove vještine otvoreno upitaju iskusnije kolege da im ih prenesu.	1	2	3	4	5
48. Zaposlenici u timovima i u neformalnim kontaktima rado primaju savjete vlastitih kolega i prijatelja.	1	2	3	4	5

5. USPJEŠNOST POSLOVANJA PODUZEĆA

a) Ocijenite sljedeće tvrdnje koje opisuju financijske pokazatelje uspješnosti poslovanja u razdoblju PRIJE izbijanja pandemije COVID-19 (PRIJE 2020. godine)

Tvrdnje vezane uz FINANCIJSKE POKAZATELJE USPJEŠNOSTI POSLOVANJA PRIJE COVIDA-19	Uopće se ne slažem	Ne slažem se	Niti se slažem niti ne slažem	Djelomično se slažem	U potpunosti se slažem
49. U odnosu na konkurenciju, naše poduzeće je zabilježilo veći rast prodaje.	1	2	3	4	5
50. U odnosu na konkurenciju, naše poduzeće je bolje optimiziralo troškove.	1	2	3	4	5
51. Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina.	1	2	3	4	5
52. U odnosu na konkurenciju, naše poduzeće ostvarilo je bolju profitabilnost.	1	2	3	4	5

b) Ocijenite sljedeće tvrdnje koje opisuju financijske pokazatelje uspješnosti poslovanja u razdoblju NAKON izbijanja pandemije COVIDOM-19 (NAKON 2020. godine)

Tvrdnje vezane uz FINANCIJSKE POKAZATELJE USPJEŠNOSTI POSLOVANJA NAKON COVIDA-19	Uopće se ne slažem	Ne slažem se	Niti se slažem niti ne slažem	Djelomično se slažem	U potpunosti se slažem
53. U odnosu na konkurenciju, naše poduzeće je zabilježilo veći rast prodaje.	1	2	3	4	5
54. U odnosu na konkurenciju, naše poduzeće je bolje optimiziralo troškove.	1	2	3	4	5
55. Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina.	1	2	3	4	5
56. U odnosu na konkurenciju, naše poduzeće ostvarilo je bolju profitabilnost.	1	2	3	4	5

c) Ocijenite sljedeće tvrdnje koje opisuju nefinancijske pokazatelje uspješnosti poslovanja u razdoblju PRIJE izbijanja pandemije COVIDOM-19 (PRIJE 2020. godine)

Tvrdnje vezane uz NEFINANCIJSKE POKAZATELJE USPJEŠNOSTI POSLOVANJA PRIJE COVIDA-19	Uopće se ne slažem	Ne slažem se	Niti se slažem niti ne slažem	Djelomično se slažem	U potpunosti se slažem
57. U odnosu na konkurenciju kvaliteta naših proizvoda/usluga je bolja.	1	2	3	4	5

58. U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju.	1	2	3	4	5
59. U odnosu na konkurenciju, naše poduzeće brže raste.	1	2	3	4	5
60. U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike.	1	2	3	4	5

d) Ocijenite sljedeće tvrdnje koje opisuju nefinancijske pokazatelje uspješnosti poslovanja u razdoblju NAKON izbijanja pandemije COVID-19 (NAKON 2020. godine)

Tvrdnje vezane uz NEFINANCIJSKE POKAZATELJE USPJEŠNOSTI POSLOVANJA NAKON COVIDA-19	**Uopće se ne slažem**	**Ne slažem se**	**Niti se slažem niti ne slažem**	**Djelomično se slažem**	**U potpunosti se slažem**
61. U odnosu na konkurenciju kvaliteta naših proizvoda/usluga je bolja.	1	2	3	4	5
62. U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju.	1	2	3	4	5
63. U odnosu na konkurenciju, naše poduzeće brže raste.	1	2	3	4	5
64. U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike.	1	2	3	4	5

65. Spol:
1. Muški 2. Ženski

66. Dobna skupina:
1. 20 - 29 2. 30 - 39 3. 40 - 49
4. 50 - 59 5. 60 - 64 6. 65 i više

67. Radni staž u trenutnom poduzeću:
1. < 10 godina
2. 10 – 20 godina
3. > 20 godina

68. Najviši završeni stupanj obrazovanja:
1. osnovna škola
2. srednja škola
3. viša stručna sprema / prvostupnik
4. visoka stručna sprema / stručni magisterij
5. znanstveni magisterij / doktorat

69. Položaj u poduzeću:
1. vrhovni menadžment
2. srednji menadžment
3. niži menadžment
4. nemenadžerska razina

70. Godine radnog iskustva na trenutnoj poziciji:
1. < 10 godina
2. 10 – 20 godina
3. > 20 godina

71. Vlasnička struktura
1. privatno vlasništvo
2. državno vlasništvo
3. mješovito vlasništvo

72. Veličina poduzeća mjerena brojem zaposlenih:
1. veliko poduzeće (> 250 zaposlenika)
2. srednje poduzeće (50 – 250 zaposlenika)
3. malo poduzeće (< 50 zaposlenika)

73. Djelatnost poslovanja:
1. pretežno proizvodnja
2. pretežno usluge
3. kombinacija proizvodnje i usluga

74. Djelokrug poslovanja poduzeća:
1. pretežno domaće tržište
2. pretežno inozemno tržište
3. kombinacija domaćeg i inozemnog tržišta

ZAHVALJUJEMO NA VAŠEM VREMENU I TRUDU!

PRILOG 2. KORELACIJSKE MATRICE SKALA U *ONLINE* ISTRAŽIVANJU

Tablica 2.1: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Organizacijska kultura u *online* istraživanju

	PM1	PM2	PM3	PM4	OZ1	OZ2	OZ3	OZ4	KU1	KU2	KU3	KU4
PM1	–											
PM2	0.617	–										
PM3	0.745	0.605	–									
PM4	0.738	0.525	0.631	–								
OZ1	0.587	0.451	0.556	0.590	–							
OZ2	0.564	0.451	0.533	0.544	0.723	–						
OZ3	0.576	0.534	0.524	0.700	0.694	0.668	–					
OZ4	0.642	0.596	0.694	0.702	0.668	0.594	0.720	–				
KU1	0.608	0.408	0.477	0.653	0.523	0.477	0.560	0.560	–			
KU2	0.669	0.556	0.586	0.603	0.554	0.571	0.572	0.621	0.627	–		
KU3	0.389	0.283	0.431	0.459	0.532	0.659	0.518	0.481	0.410	0.454	–	
KU4	0.498	0.381	0.474	0.563	0.509	0.599	0.631	0.605	0.485	0.687	0.686	–

Tablica 2.2: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Informacijsko-komunikacijske tehnologije u *online* istraživanju

	IS1	IS2	IS3	IS4	PPP1	PPP2	PPP3	PPP4	PK1	PK2	PK3	PK4
IS1	–											
IS2	0.438	–										
IS3	0.613	0.613	–									
IS4	0.581	0.553	0.862	–								
PPP1	0.644	0.444	0.640	0.593	–							
PPP2	0.481	0.241	0.433	0.415	0.639	–						
PPP3	0.467	0.304	0.420	0.424	0.649	0.760	–					
PPP4	0.487	0.372	0.591	0.524	0.630	0.702	0.680	–				
PK1	0.416	0.374	0.446	0.409	0.345	0.181	0.254	0.316	–			
PK2	0.519	0.510	0.598	0.586	0.550	0.484	0.523	0.610	0.438	–		
PK3	0.579	0.475	0.699	0.686	0.709	0.543	0.554	0.650	0.458	0.751	–	
PK4	0.558	0.556	0.768	0.787	0.619	0.409	0.454	0.532	0.416	0.625	0.734	–

Tablica 2.3: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Podrška vrhovnog menadžmenta u *online* istraživanju

	OMI1	OMI2	OMI3	OMI4	RP1	RP2	RP3	RP4	MZ1	MZ2	MZ3	MZ4
OMI1	–											
OMI2	0.857	–										
OMI3	0.800	0.831	–									
OMI4	0.683	0.661	0.728	–								
RP1	0.583	0.561	0.582	0.491	–							
RP2	0.524	0.481	0.518	0.476	0.814	–						
RP3	0.778	0.681	0.652	0.641	0.625	0.549	–					
RP4	0.594	0.606	0.490	0.487	0.492	0.454	0.718	–				
MZ1	0.634	0.580	0.583	0.591	0.496	0.456	0.733	0.638	–			
MZ2	0.586	0.490	0.505	0.539	0.487	0.490	0.660	0.508	0.632	–		
MZ3	0.679	0.597	0.615	0.670	0.528	0.431	0.804	0.592	0.737	0.755	–	
MZ4	0.344	0.308	0.391	0.362	0.419	0.418	0.516	0.413	0.552	0.420	0.484	–

Tablica 2.4: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Dijeljenje znanja u *online* istraživanju

	DEZ1	DEZ2	DEZ3	DII1	DII2	DII3	PEZ1	PEZ2	PEZ3	PIZ1	PIZ2	PIZ3
DEZ1	—											
DEZ2	0.704	—										
DEZ3	0.632	0.672	—									
DII1	0.476	0.361	0.284	—								
DII2	0.532	0.469	0.348	0.627	—							
DII3	0.534	0.447	0.383	0.610	0.812	—						
PEZ1	0.715	0.618	0.661	0.396	0.469	0.497	—					
PEZ2	0.577	0.621	0.658	0.259	0.338	0.338	0.730	—				
PEZ3	0.522	0.538	0.555	0.403	0.350	0.359	0.554	0.784	—			
PIZ1	0.452	0.349	0.292	0.805	0.597	0.571	0.394	0.302	0.432	—		
PIZ2	0.460	0.411	0.397	0.468	0.547	0.465	0.339	0.342	0.418	0.635	—	
PIZ3	0.563	0.483	0.417	0.447	0.611	0.623	0.453	0.412	0.493	0.524	0.695	—

Tablica 2.5: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Uspješnost poslovanja poduzeća u *online* istraživanju

	FP1	FP2	FP3	FP4	FP5	FP6	FP7	FP8	NFP1	NFP2	NFP3	NFP4	NFP5	NFP6	NFP7	NFP
FP1	—															
FP2	0.786	—														
FP3	0.667	0.604	—													
FP4	0.824	0.783	0.677	—												
FP5	0.618	0.514	0.528	0.505	—											
FP6	0.661	0.805	0.582	0.692	0.599	—										
FP7	0.458	0.446	0.606	0.414	0.783	0.578	—									
FP8	0.635	0.606	0.554	0.665	0.817	0.715	0.748	—								
NFP1	0.608	0.678	0.501	0.592	0.395	0.536	0.352	0.393	—							
NFP2	0.438	0.578	0.353	0.506	0.234	0.406	0.134	0.272	0.733	—						
NFP3	0.706	0.716	0.560	0.679	0.489	0.648	0.407	0.528	0.641	0.592	—					
NFP4	0.552	0.672	0.423	0.564	0.361	0.481	0.312	0.376	0.727	0.683	0.697	—				
NFP5	0.542	0.628	0.397	0.552	0.384	0.507	0.305	0.402	0.839	0.735	0.566	0.652	—			
NFP6	0.459	0.587	0.380	0.494	0.303	0.472	0.203	0.321	0.734	0.885	0.584	0.688	0.800	—		
NFP7	0.692	0.698	0.595	0.656	0.637	0.619	0.556	0.649	0.574	0.501	0.820	0.585	0.564	0.565	—	
NFP8	0.487	0.625	0.432	0.512	0.441	0.504	0.355	0.450	0.592	0.607	0.587	0.770	0.694	0.673	0.669	—

PRILOG 3. KORELACIJSKE MATRICE SKALA U POŠTANSKOM ISTRAŽIVANJU

Tablica 3.1: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Organizacijska kultura u poštanskom istraživanju

	PM1	PM2	PM3	PM4	OZ1	OZ2	OZ3	OZ4	KU1	KU2	KU3	KU4
PM1	-											
PM2	,432	-										
PM3	,450	,287	-									
PM4	,418	,321	,522	-								
OZ1	,279	,155	,286	,462	-							
OZ2	,302	,131	,319	,467	,627	-						
OZ3	,205	,167	,256	,530	,487	,581	-					
OZ4	,069	,047	,165	,141	,225	,279	,257	-				
KU1	,369	,128	,271	,437	,320	,291	,298	,153	-			
KU2	,308	,230	,290	,454	,397	,364	,338	,171	,605	-		
KU3	,199	,211	,230	,356	,496	,437	,420	,121	,371	,471	-	
KU4	,253	,278	,203	,359	,477	,448	,379	,143	,366	,447	,685	-

Tablica 3.2: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Informacijsko--komunikacijske tehnologije u poštanskom istraživanju

	IS1	IS2	IS3	IS4	PPP1	PPP2	PPP3	PPP4	PK1	PK2	PK3	PK4
IS1	-											
IS2	,474	-										
IS3	,595	,490	-									
IS4	,499	,500	,670	-								
PPP1	,367	,328	,420	,366	-							
PPP2	,397	,311	,390	,296	,745	-						
PPP3	,401	,399	,450	,416	,641	,789	-					
PPP4	,357	,386	,458	,401	,605	,645	,613	-				
PK1	,219	,312	,312	,398	,196	,134	,171	,228	-			
PK2	,359	,498	,413	,414	,368	,336	,360	,368	,575	-		
PK3	,442	,427	,487	,432	,486	,490	,500	,513	,365	,618	-	
PK4	,462	,330	,572	,515	,427	,434	,444	,468	,361	,456	,711	-

Tablica 3.3: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Podrška vrhovnog menadžmenta u poštanskom istraživanju

	OMI1	OMI2	OMI3	OMI4	RP1	RP2	RP3	RP4	MZ1	MZ2	MZ3	MZ4
OMI1	-											
OMI2	,694	-										
OMI3	,644	,758	-									
OMI4	,498	,541	,652	-								
RP1	,442	,391	,371	,413	-							
RP2	,313	,274	,284	,331	,658	-						
RP3	,423	,466	,472	,450	,401	,419	-					
RP4	,358	,476	,473	,502	,381	,315	,601	-				
MZ1	,546	,610	,558	,496	,440	,403	,569	,491	-			
MZ2	,503	,535	,548	,405	,335	,380	,432	,334	,499	-		
MZ3	,484	,470	,542	,479	,355	,321	,489	,382	,582	,665	-	
MZ4	,306	,298	,330	,472	,317	,207	,374	,452	,389	,408	,518	-

Tablica 3.4: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Dijeljenje znanja u poštanskom istraživanju

	DEZ1	DEZ2	DEZ3	DII1	DII2	DII3	PEZ1	PEZ2	PEZ3	PIZ1	PIZ2	PIZ3
DEZ1	-											
DEZ2	,529	-										
DEZ3	,473	,563	-									
DII1	,392	,315	,285	-								
DII2	,395	,248	,223	,515	-							
DII3	,407	,286	,252	,458	,734	-						
PEZ1	,628	,425	,463	,425	,410	,333	-					
PEZ2	,590	,454	,516	,328	,332	,328	,716	-				
PEZ3	,537	,360	,414	,279	,359	,420	,565	,804	-			
PIZ1	,365	,200	,157	,532	,392	,371	,282	,226	,298	-		
PIZ2	,404	,363	,227	,521	,510	,574	,320	,224	,229	,555	-	
PIZ3	,435	,328	,266	,487	,590	,598	,364	,297	,279	,432	,713	-

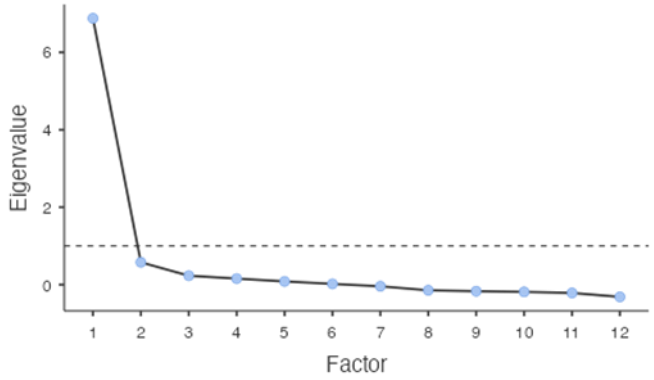
Tablica 3.5: Korelacijska matrica (Pearsonov koeficijent korelacije) za skalu Uspješnost poslovanja poduzeća u poštanskom istraživanju

	FP1	FP2	FP3	FP4	FP5	FP6	FP7	FP8	NFP1	NFP2	NFP3	NFP4	NFP5	NFP6	NFP7	NFP8
FP1	-															
FP2	,626	-														
FP3	,731	,551	-													
FP4	,706	,697	,654	-												
FP5	,649	,480	,565	,576	-											
FP6	,483	,694	,513	,605	,633	-										
FP7	,490	,427	,518	,444	,770	,586	-									
FP8	,523	,503	,542	,628	,802	,723	,792	-								
NFP1	,307	,347	,297	,330	,246	,314	,159	,273	-							
NFP2	,352	,413	,295	,402	,367	,392	,249	,343	,737	-						
NFP3	,573	,505	,528	,643	,548	,536	,454	,596	,455	,502	-					
NFP4	,344	,463	,391	,436	,295	,406	,284	,331	,539	,518	,514	-				
NFP5	,378	,422	,388	,423	,355	,429	,290	,377	,706	,611	,492	,500	-			
NFP6	,374	,412	,364	,427	,454	,466	,349	,449	,615	,766	,558	,541	,777	-		
NFP7	,535	,444	,476	,530	,672	,587	,597	,684	,375	,428	,778	,462	,506	,624	-	
NFP8	,305	,431	,370	,408	,352	,432	,335	,412	,486	,461	,511	,822	,553	,608	,608	-

PRILOG 4. EKSPLORATORNA FAKTORSKA ANALIZA ZA SKALU ORGANIZACIJSKA KULTURA U *ONLINE* ISTRAŽIVANJU

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 57,3 % varijance rezultata skale Organizacijska kultura. Karakteristični korijen faktora iznosi 6,87. Sve čestice imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50). *Scree plot* je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Slika 4.1: *Scree plot* indikatora Organizacijska kultura (*online* istraživanje)



Izvor: pripremila doktorandica.

Tablica 4.1: Faktorska zasićenja na skali Organizacijska kultura (*online* istraživanje)

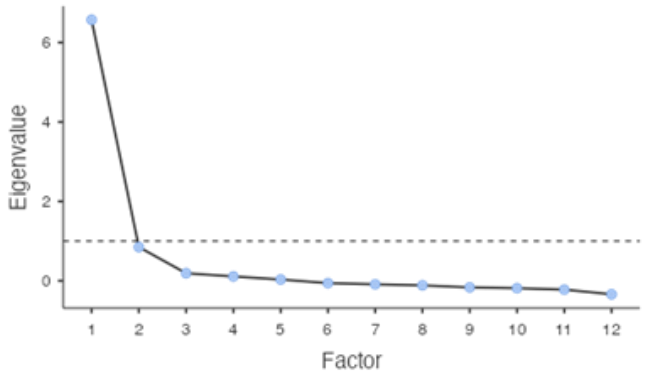
	Faktor / 1	**Unikvitet**
Naše poduzeće na transparentan način promiče poslovnu misiju.	0,805	0,352
Jasno definirana misija potpomaže razvijanje zajedništva.	0,659	0,566
Zaposlenici razumiju smisao poslovanja, te su odani misiji poslovanja.	0,760	0,422
U našem poduzeću dijeljenje znanja značajni je segment poslovne misije.	0,821	0,326
Naše poduzeće potiče preuzimanje inicijativa od strane zaposlenika.	0,773	0,403
Zaposlenici se aktivno potiču da sudjeluju u donošenju odluka.	0,757	0,427
Od zaposlenika se očekuje visok osobni angažman u dijeljenju znanja.	0,813	0,339
Zaposlenici visoko vrednuju mogućnost obavljanja izazovnih zadataka.	0,840	0,294
Poduzeće izdvaja značajna sredstva za edukativne i razvojne programe kako bi unaprijedilo specifična znanja i vještine zaposlenika.	0,701	0,509
Fleksibilnost i želja za promjenama temeljni su motivi kontinuiranog učenja u poduzeću.	0,775	0,399
Naše poduzeće potiče poduzetničko ponašanje, zbog čega se zaposlenicima toleriraju povremene pogreške i eksperimenti.	0,622	0,613
Učenje iz pogrešaka omogućava se kroz timski rad i konsenzus.	0,725	0,475

Izvor: pripremila doktorandica.

PRILOG 5. EKSPLORATORNA FAKTORSKA ANALIZA ZA SKALU IKT U *ONLINE* ISTRAŽIVANJU

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 54,8 % varijance rezultata skale Informacijsko-komunikacijske tehnologije. Karakteristični korijen faktora iznosi 6,57. Sve čestice imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50). *Scree plot* je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Slika 5.1: *Scree plot* indikatora Informacijsko-komunikacijske tehnologije (*online* istraživanje)



Izvor: pripremila doktorandica.

Tablica 5.1: Faktorska zasićenja na skali Informacijsko-komunikacijske tehnologije (*online* istraživanje)

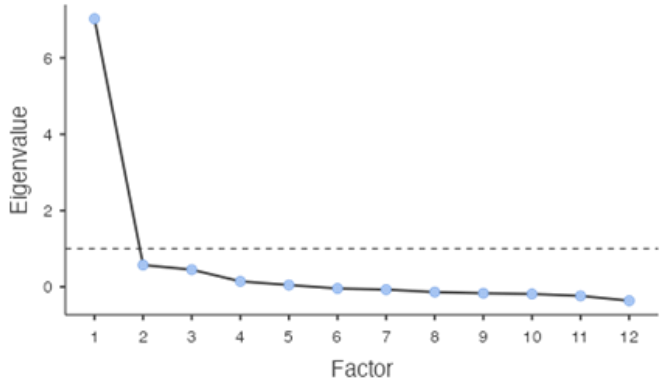
	Faktor / 1	**Unikvitet**
Sustav poslovne inteligencije* u našem poduzeću efikasno podržava svakodnevno poslovanje.	0,706	0,501
Računalni programi koji omogućuju učenje na daljinu unapređuju poslovanje.	0,615	0,622
IKT sustavi u našem poduzeću prilagođeni su potrebama zaposlenika.	0,860	0,260
IKT sustavi u našem poduzeću redovito se ažuriraju.	0,837	0,299
IKT se u našem poduzeću koriste za otkrivanje poslovnih prilika.	0,790	0,376
Naše poduzeće koristi IKT koje omogućuju praćenje konkurencije.	0,623	0,612
Naše poduzeće koristi IKT koje omogućuju praćenje aktivnosti poslovnih partnera.	0,639	0,591
IKT u našem poduzeću olakšavaju zaposlenicima korištenje društvenih kontakata u svrhu prikupljanja relevantnih informacija o novim prilikama na tržištu.	0,732	0,465
U našem poduzeću zaposlenici redovito komuniciraju *e-mailom* i sličnim alatima radi zajedničkog obavljanja radnih zadataka.	0,499	0,751
IKT u našem poduzeću omogućuju zaposlenicima na različitim radnim mjestima i/ili lokacijama da zajednički uče na daljinu.	0,763	0,417
IKT u našem poduzeću omogućuju zaposlenicima da u kratkom roku lociraju nužan izvor znanja, poput specifične baze podataka.	0,861	0,258
IKT sustavi u našem poduzeću osiguravaju pristup točnim i pravodobnim podacima.	0,837	0,300

Izvor: pripremila doktorandica

PRILOG 6. EKSPLORATORNA FAKTORSKA ANALIZA ZA SKALU PODRŠKA VRHOVNOG MENADŽMENTA U *ONLINE* ISTRAŽIVANJU

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 58,6 % varijance rezultata skale Informacijsko-komunikacijske tehnologije. Karakteristični korijen faktora iznosi 7,03. Sve čestice imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50). *Scree plot* je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Slika 6.1: *Scree plot* indikatora Podrška vrhovnog menadžmenta (*online* istraživanje)



Izvor: pripremila doktorandica

Tablica 6.1: Faktorska zasićenja na skali Podrška vrhovnog menadžmenta (*online* istraživanje)

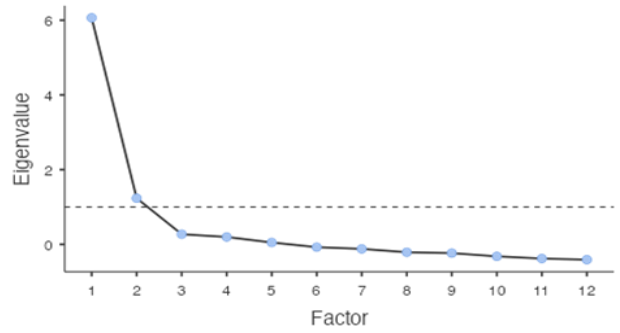
	Faktor / 1	**Unikvitet**
Menadžeri promiču sustav vrijednosti u kojem se cijeni mišljenje svakog zaposlenika	0,884	0,219
Menadžeri potiču zaposlenike na otvoreno iznošenje ideja/prijedloga na sastancima s nadležnima.	0,835	0,303
Menadžeri potiču zaposlenike na formalnu i neformalnu komunikaciju unutar poduzeća.	0,821	0,327
Menadžeri potiču povezivanje zaposlenika u grupe radi učenja i generiranja novih ideja.	0,769	0,409
Zaposlenici doživljavaju uspjeh poduzeća kao vlastiti uspjeh.	0,694	0,518
Zaposlenicima je važna reputacija koju njihovo poduzeće ima među vanjskim subjektima.	0,630	0,603
Menadžeri se ponašaju kao savjetnici, te prakticiraju kontrolu isključivo za procjenu dostignuća zaposlenika.	0,887	0,213
Menadžeri potiču zaposlenike na bavljenje zahtjevnijim zadacima, čak i kada postoji mogućnost neuspjeha.	0,717	0,486
Redovitim mentoriranjem zaposlenika menadžeri dodatno ističu važnost znanja za uspješnost poslovanja poduzeća.	0,783	0,386
Novim zaposlenicima omogućen je period orijentacije radi upoznavanja organizacijske strukture i sistematizacije poslova.	0,717	0,487
Zaposlenicima koji preuzimaju nove dužnosti omogućeno je mentoriranje, neovisno o tome koliko dugo rade u poduzeću.	0,829	0,313
Primjenjuju se programi rotiranja zaposlenika pomoću kojih menadžeri različitih odjela pomažu zaposlenicima unaprijediti svoja znanja i vještine	0,520	0,730

Izvor: pripremila doktorandica.

PRILOG 7. EKSPLORATORNA FAKTORSKA ANALIZA ZA SKALU DIJELJENJE ZNANJA U *ONLINE* ISTRAŽIVANJU

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje dvaju faktora s karakterističnim korijenom većim od jedan. Zajedno objašnjavaju 63,3 % varijance rezultata skale Dijeljenje znanja. Karakteristični korijen prvog faktora iznosi 6,19, a drugog 1,41, dok je postotak objašnjene varijance uz prvi faktor 51,5 %, a uz drugi 11,7 %. *Scree plot* je u skladu s dobivenim podacima te također upućuje na postojanje dvaju faktora. Uvidom u faktorsku matricu zasićenja, vidljivo je kako drugi faktor sadrži samo jednu česticu koja ima zasićenje veće od ,50, što predstavlja graničnu vrijednost ispod koje se zasićenje smatra zanemarivim (**Truong, McColl**, **2011**). S obzirom na to da ta čestica ima veće zasićenje na prvom faktoru te da svaki faktor treba sadržavati barem tri čestice (**Yong, Pierce, 2013**), ponovljena je faktorska analiza metodom maksimalne vjerojatnosti, ali uz unaprijed fiksiran broj faktora na jedan. Faktorska matrica pokazala je kako sve čestice na dobivenom faktoru imaju zadovoljavajuće visoko zasićenje (veće od ,50) te je prihvaćeno jednofaktorsko rješenje.

Slika 7.1: *Scree plot* indikatora Podrška vrhovnog menadžmenta (*online* istraživanje)



Izvor: pripremila doktorandica.

Tablica 7.1: Faktorska zasićenja na skali Dijeljenje znanja u prvoj iteraciji (*online* istraživanje)

	Faktor 1	2	Unikvitet
Zaposlenici redovito kroz organizirane edukacije prenose znanja, vještine i iskustva drugim zaposlenicima.	0,793		0,363
Zaposlenici koriste virtualna spremišta* za pohranjivanje znanja i iskustava koja time postaju dostupna drugim zaposlenicima.	0,741		0,407
Zaposlenici redovito pišu izvješća nadređenima o vlastitim postignućima (stečena znanja, vještine i iskustva).	0,703	-0,338	0,391
Zaposlenici slobodno iznose ideje i stavove na poslovnim sastancima s nadređenima.	0,643	0,439	0,394
Zaposlenici se trude osobnim kontaktom pomoći manje iskusnim kolegama.	0,732	0,443	0,267
Zaposlenici u timovima i u neformalnim kontaktima rado daju savjete kolegama/prijateljima.	0,727	0,409	0,304

Zaposlenici se redovito educiraju o načinima prenošenja znanja, vještina i iskustava drugim zaposlenicima.	0,783		0,318
Zaposlenici organizirano primaju i analiziraju periodična izvješća o tržišnim trendovima i potrebama	0,746	-0,496	0,197
Zaposlenici organizirano primaju i analiziraju periodična izvješća o rezultatima poslovanja, te organizacijskim politikama i procedurama.	0,717		0,397
Tijekom poslovnih sastanaka zaposlenici slobodno postavljaju pitanja kolegama i nadređenima.	0,658	0,417	0,393
Zaposlenici koji žele usvojiti nove vještine otvoreno upitaju iskusnije kolege da im ih prenesu.	0,630		0,539
Zaposlenici u timovima i u neformalnim kontaktima rado primaju savjete vlastitih kolega i prijatelja.	0,720		0,451
Note. 'Maximum likelihood' extraction method was used in combiation with a 'none' rotation			

Izvor: pripremila doktorandica**.**

Tablica 7.2: Faktorska zasićenja na skali Dijeljenje znanja u drugoj iteraciji (*online* istraživanje)

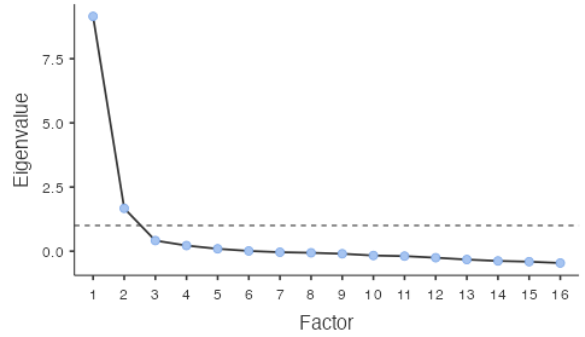
	Faktor / 1	**Unikvitet**
Zaposlenici redovito kroz organizirane edukacije prenose znanja, vještine i iskustva drugim zaposlenicima.	0,814	0,337
Zaposlenici koriste virtualna spremišta* za pohranjivanje znanja i iskustava koja time postaju dostupna drugim zaposlenicima.	0,751	0,436
Zaposlenici redovito pišu izvješća nadređenima o vlastitim postignućima (stečena znanja, vještine i iskustva).	0,704	0,504
Zaposlenici slobodno iznose ideje i stavove na poslovnim sastancima s nadređenima.	0,630	0,603
Zaposlenici se trude osobnim kontaktom pomoći manje iskusnim kolegama.	0,712	0,493
Zaposlenici u timovima i u neformalnim kontaktima rado daju savjete kolegama/prijateljima.	0,709	0,498
Zaposlenici se redovito educiraju o načinima prenošenja znanja, vještina i iskustava drugim zaposlenicima.	0,773	0,403
Zaposlenici organizirano primaju i analiziraju periodična izvješća o tržišnim trendovima i potrebama	0,709	0,497
Zaposlenici organizirano primaju i analiziraju periodična izvješća o rezultatima poslovanja te organizacijskim politikama i procedurama.	0,692	0,521
Tijekom poslovnih sastanaka zaposlenici slobodno postavljaju pitanja kolegama i nadređenima.	0,647	0,581
Zaposlenici koji žele usvojiti nove vještine otvoreno upitaju iskusnije kolege da im ih prenesu.	0,638	0,593
Zaposlenici u timovima i u neformalnim kontaktima rado primaju savjete vlastitih kolega i prijatelja.	0,719	0,483
Note. 'Maximum likelihood' extraction method was used in combination with a 'none' rotation		

Izvor: pripremila doktorandica.

PRILOG 8. EKSPLORATORNA FAKTORSKA ANALIZA ZA SKALU USPJEŠNOST POSLOVANJA PODUZEĆA U *ONLINE* ISTRAŽIVANJU

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje dvaju faktora s karakterističnim korijenom većim od jedan. Zajedno objašnjavaju 69,7 % varijance rezultata skale Uspješnost poslovanja poduzeća. Karakteristični korijen prvog faktora iznosi 9,26, a drugog 1,90, dok je postotak objašnjene varijance uz prvi faktor 57,9 %, a uz drugi 11,9 %. *Scree plot* je u skladu s dobivenim podacima te također upućuje na postojanje dva faktora. Uvidom u faktorsku matricu zasićenja pokazuje kako drugi faktor sadrži tri čestice koje imaju zasićenje veće od ,50, što predstavlja graničnu vrijednost ispod koje se zasićenje smatra zanemarivim (**Truong, McColl, 2011**). S obzirom na to da ta čestice imaju više zasićenje na prvom faktoru, ponovljena je faktorska analiza metodom zajedničkih faktora, ali uz unaprijed fiksiran broj faktora na jedan. Faktorska matrica pokazala je kako sve čestice na dobivenom faktoru imaju zadovoljavajuće visoko zasićenje (veće od ,50) te je prihvaćeno jednofaktorsko rješenje skale.

Slika 8.1: *Scree plot* indikatora Podrška vrhovnog menadžmenta (*online* istraživanje)



Izvor: pripremila doktorandica

Tablica 8.1: Faktorska zasićenja na skali Uspješnost poslovanja poduzeća u prvoj iteraciji (*online* istraživanje)

	Faktor 1	Faktor 2	Unikvitet
U odnosu na konkurenciju, naše poduzeće zabilježilo je veći rast prodaje. (PRIJE PANDEMIJE)	0,785		0,302
U odnosu na konkurenciju, naše poduzeće bolje je optimiziralo troškove. (PRIJE PANDEMIJE)	0,854		0,253
Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina. (PRIJE PANDEMIJE)	0,659	0,315	0,466
U odnosu na konkurenciju, naše poduzeće ostvarilo je veću profitabilnost. (PRIJE PANDEMIJE)	0,793		0,321
U odnosu na konkurenciju, naše poduzeće zabilježilo je rast prodaje. (NAKON PANDEMIJE)	0,627	0,529	0,327
U odnosu na konkurenciju, naše poduzeće bolje je optimiziralo troškove. (NAKON PANDEMIJE)	0,757	0,326	0,321
Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina. (NAKON PANDEMIJE)	0,535	0,562	0,398

U odnosu na konkurenciju, naše poduzeće ostvarilo je veću profitabilnost. (NAKON PANDEMIJE)	0,676	0,553	0,237
U odnosu na konkurenciju, kvaliteta naših proizvoda/usluga je bolja. (PRIJE PANDEMIJE)	0,822		0,269
U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju. (PRIJE PANDEMIJE)	0,766	-0,498	0,166
U odnosu na konkurenciju, naše poduzeće brže raste. (PRIJE PANDEMIJE)	0,813		0,335
U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike. (PRIJE PANDEMIJE)	0,782		0,344
U odnosu na konkurenciju, kvaliteta naših proizvoda/usluga je bolja. (NAKON PANDEMIJE)	0,807		0,638
U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju. (NAKON PANDEMIJE)	0,800	-0,455	0,153
U odnosu na konkurenciju, naše poduzeće brže raste. (NAKON PANDEMIJE)	0,809		0,303
U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike. (NAKON PANDEMIJE)	0,758		0,409

Izvor: pripremila doktorandica

Tablica 8.2: Faktorska zasićenja na skali Uspješnost poslovanja poduzeća u drugoj iteraciji (*online* istraživanje)

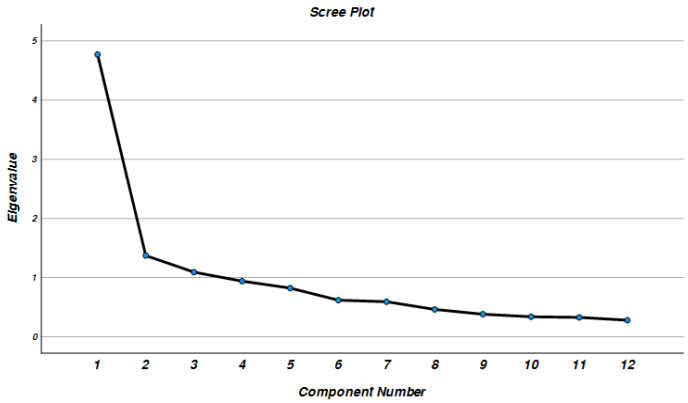
	Faktor / 1	**Unikvitet**
U odnosu na konkurenciju, naše poduzeće zabilježilo je veći rast prodaje. (PRIJE PANDEMIJE)	0,830	0,312
U odnosu na konkurenciju, naše poduzeće bolje je optimiziralo troškove. (PRIJE PANDEMIJE)	0,883	0,220
Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina. (PRIJE PANDEMIJE)	0,693	0,520
U odnosu na konkurenciju, naše poduzeće ostvarilo je veću profitabilnost. (PRIJE PANDEMIJE)	0,828	0,314
U odnosu na konkurenciju, naše poduzeće zabilježilo je rast prodaje. (NAKON PANDEMIJE)	0,646	0,582
U odnosu na konkurenciju, naše poduzeće bolje je optimiziralo troškove. (NAKON PANDEMIJE)	0,788	0,380
Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina. (NAKON PANDEMIJE)	0,560	0,686
U odnosu na konkurenciju, naše poduzeće ostvarilo je veću profitabilnost. (NAKON PANDEMIJE)	0,702	0,507
U odnosu na konkurenciju, kvaliteta naših proizvoda/usluga je bolja. (PRIJE PANDEMIJE)	0,784	0,386
U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju. (PRIJE PANDEMIJE)	0,681	0,536
U odnosu na konkurenciju, naše poduzeće brže raste. (PRIJE PANDEMIJE)	0,834	0,305
U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike. (PRIJE PANDEMIJE)	0,760	0,422
U odnosu na konkurenciju, kvaliteta naših proizvoda/usluga je bolja. (NAKON PANDEMIJE)	0,750	0,438
U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju. (NAKON PANDEMIJE)	0,714	0,490
U odnosu na konkurenciju, naše poduzeće brže raste. (NAKON PANDEMIJE)	0,830	0,311
U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike. (NAKON PANDEMIJE)	0,734	0,461

Izvor: pripremila doktorandica.

PRILOG 9. EKSPLORATORNA FAKTORSKA ANALIZA ZA SKALU ORGANIZACIJSKA KULTURA U POŠTANSKOM ISTRAŽIVANJU

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 39,7 % varijance rezultata skale Organizacijska kultura. Karakteristični korijen faktora iznosi 4,876. Većina čestica imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50). *Scree plot* je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Slika 9.1: *Scree plot* indikatora Organizacijska kultura (poštansko istraživanje)



Izvor: pripremila doktorandica.

Tablica 9.1: Faktorska zasićenja na skali Organizacijska kultura (poštansko istraživanje)

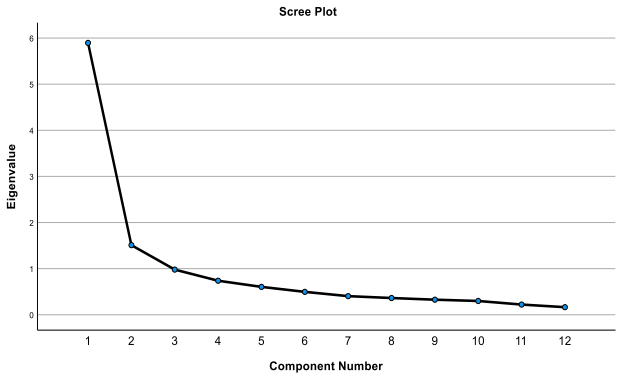
	Faktor / 1	**Unikvitet**
Naše poduzeće na transparentan način promiče poslovnu misiju.	0,551	0,303
Jasno definirana misija potpomaže razvijanje zajedništva.	0,411	0,169
Zaposlenici razumiju smisao poslovanja, te su odani misiji poslovanja.	0,554	0,307
U našem je poduzeću dijeljenje znanja značajan segment poslovne misije.	0,745	0,555
Naše poduzeće potiče preuzimanje inicijativa od strane zaposlenika.	0,723	0,522
Zaposlenici se aktivno potiču da sudjeluju u donošenju odluka.	0,724	0,523
Od zaposlenika se očekuje visok osobni angažman u dijeljenju znanja.	0,676	0,456
Zaposlenici visoko vrednuju mogućnost obavljanja izazovnih zadataka.	0,315	0,100
Poduzeće izdvaja značajna sredstva za edukativne i razvojne programe kako bi unaprijedilo specifična znanja i vještine zaposlenika.	0,624	0,390
Fleksibilnost i želja za promjenama temeljni su motivi kontinuiranog učenja u poduzeću.	0,692	0,479
Naše poduzeće potiče poduzetničko ponašanje, zbog čega se zaposlenicima toleriraju povremene pogreške i eksperimenti.	0,695	0,482
Učenje iz pogrešaka omogućava se kroz timski rad i konsenzus.	0,694	0,482

Izvor: pripremila doktorandica.

PRILOG 10. EKSPLORATORNA FAKTORSKA ANALIZA ZA SKALU IKT U POŠTANSKOM ISTRAŽIVANJU

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 49,1 % varijance rezultata skale Informacijsko-komunikacijske tehnologije. Karakteristični korijen faktora iznosi 5,89. Većina čestica ima zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50). *Scree plot* je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Slika 10.1: *Scree plot* indikatora Informacijsko-komunikacijske tehnologije (poštansko istraživanje)



Izvor: pripremila doktorandica.

Tablica 10.1: Faktorska zasićenja na skali Informacijsko-komunikacijske tehnologije (poštansko istraživanje)

	Faktor / 1	**Unikvitet**
Sustav poslovne inteligencije* u našem poduzeću efikasno podržava svakodnevno poslovanje.	0,664	0,441
Računalni programi koji omogućuju učenje na daljinu unapređuju poslovanje.	0,641	0,411
IKT sustavi u našem poduzeću prilagođeni su potrebama zaposlenika.	0,750	0,562
IKT sustavi u našem poduzeću redovito se ažuriraju.	0,700	0,490
IKT sustavi se u našem poduzeću koriste za otkrivanje poslovnih prilika.	0,721	0,519
Naše poduzeće koristi IKT sustave koji omogućuju praćenje konkurencije.	0,727	0,529
Naše poduzeće koristi IKT sustave koje omogućuju praćenje aktivnosti poslovnih partnera.	0,752	0,565
IKT u našem poduzeću olakšavaju zaposlenicima korištenje društvenih kontakata u svrhu prikupljanja relevantnih informacija o novim prilikama na tržištu.	0,731	0,535
U našem poduzeću zaposlenici redovito komuniciraju *e-mailom* i sličnim alatima radi zajedničkog obavljanja radnih zadataka.	0,477	0,227
IKT sustavi u našem poduzeću omogućuju zaposlenicima na različitim radnim mjestima i/ili lokacijama da zajednički uče na daljinu.	0,674	0,455

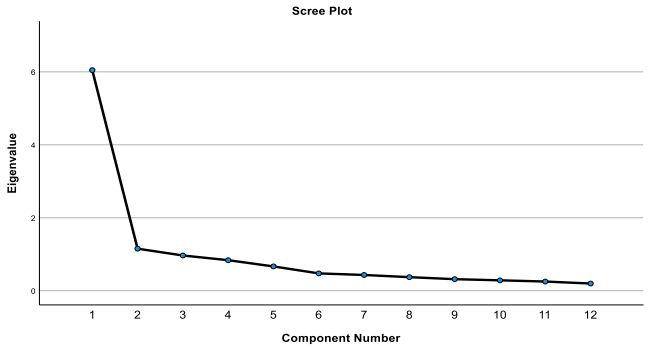
IKT sustavi u našem poduzeću omogućuju zaposlenicima da u kratkom roku lociraju nužan izvor znanja, poput specifične baze podataka.	0,779	0,606
IKT sustavi u našem poduzeću osiguravaju pristup točnim i pravodobnim podacima.	0,744	0,554

Izvor: pripremila doktorandica

PRILOG 11. EKSPLORATORNA FAKTORSKA ANALIZA ZA SKALU PODRŠKA VRHOVNOG MENADŽMENTA U POŠTANSKOM ISTRAŽIVANJU

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 50,4 % varijance rezultata skale Informacijsko-komunikacijske tehnologije. Karakteristični korijen faktora iznosi 6,05. Sve čestice imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50). *Scree plot* je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Slika 11.1: *Scree plot* indikatora Podrška vrhovnog menadžmenta (poštansko istraživanje)



Izvor: pripremila doktorandica

Tablica 11.1: Faktorska zasićenja na skali Podrška vrhovnog menadžmenta (poštansko istraživanje)

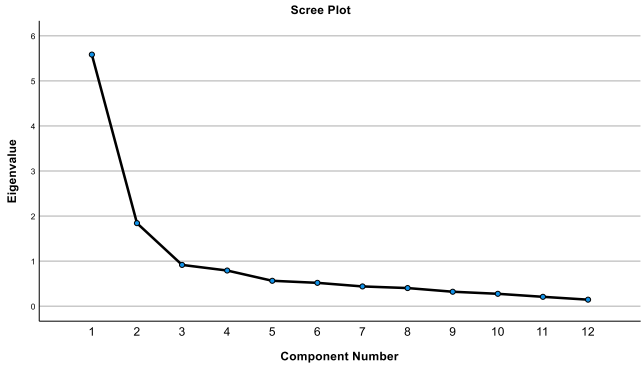
	Faktor / 1	**Unikvitet**
Menadžeri promiču sustav vrijednosti u kojem se cijeni mišljenje svakog zaposlenika.	0,743	0,552
Menadžeri potiču zaposlenike na otvoreno iznošenje ideja/prijedloga na sastancima s nadležnima.	0,785	0,616
Menadžeri potiču zaposlenike na formalnu i neformalnu komunikaciju unutar poduzeća.	0,798	0,637
Menadžeri potiču povezivanje zaposlenika u grupe radi učenja i generiranja novih ideja	0,739	0,547
Zaposlenici doživljavaju uspjeh poduzeća kao vlastiti uspjeh.	0,630	0,397
Zaposlenicima je važna reputacija koju njihovo poduzeće ima među vanjskim subjektima.	0,554	0,307
Menadžeri se ponašaju kao savjetnici te prakticiraju kontrolu isključivo za procjenu dostignuća zaposlenika.	0,717	0,514
Menadžeri potiču zaposlenike na bavljenje zahtjevnijim zadacima, čak i kada postoji mogućnost neuspjeha.	0,675	0,455
Redovitim mentoriranjem zaposlenika menadžeri dodatno ističu važnost znanja za uspješnost poslovanja poduzeća.	0,783	0,614
Novim zaposlenicima omogućen je period orijentacije radi upoznavanja organizacijske strukture i sistematizacije poslova.	0,716	0,512
Zaposlenicima koji preuzimaju nove dužnosti omogućeno je mentoriranje, neovisno o tome koliko dugo rade u poduzeću.	0,745	0,555
Primjenjuju se programi rotiranja zaposlenika pomoću kojih menadžeri različitih odjela pomažu zaposlenicima unaprijediti svoja znanja i vještine	0,583	0,340

Izvor: pripremila doktorandica.

PRILOG 12. EKSPLORATORNA FAKTORSKA ANALIZA ZA SKALU DIJELJENJE ZNANJA U POŠTANSKOM ISTRAŽIVANJU

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 46,5 % varijance rezultata skale Informacijsko-komunikacijske tehnologije. Karakteristični korijen faktora iznosi 5,58. Sve čestice imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50). *Scree plot* je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Slika 12.1: *Scree plot* indikatora Podrška vrhovnog menadžmenta (poštansko istraživanje)



Izvor: pripremila doktorandica

Tablica 12.1: Faktorska zasićenja na skali Podrška vrhovnog menadžmenta (poštansko istraživanje)

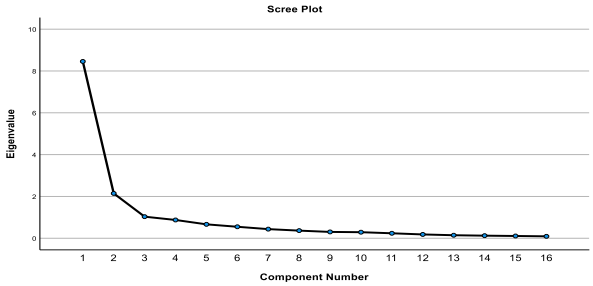
	Faktor / 1	**Unikvitet**
Zaposlenici redovito kroz organizirane edukacije prenose znanja, vještine i iskustva drugim zaposlenicima.	0,760	0,577
Zaposlenici koriste virtualna spremišta* za pohranjivanje znanja i iskustava koja time postaju dostupna drugim zaposlenicima.	0,612	0,374
Zaposlenici redovito pišu izvješća nadređenima o vlastitim postignućima (stečena znanja, vještine i iskustva).	0,580	0,337
Zaposlenici slobodno iznose ideje i stavove na poslovnim sastancima s nadređenima.	0,675	0,456
Zaposlenici se trude osobnim kontaktom pomoći manje iskusnim kolegama.	0,706	0,498
Zaposlenici u timovima i u neformalnim kontaktima rado daju savjete kolegama/prijateljima.	0,711	0,506
Zaposlenici se redovito educiraju o načinima prenošenja znanja, vještina i iskustava drugim zaposlenicima.	0,733	0,538
Zaposlenici organizirano primaju i analiziraju periodična izvješća o tržišnim trendovima i potrebama.	0,717	0,514
Zaposlenici organizirano primaju i analiziraju periodična izvješća o rezultatima poslovanja te organizacijskim politikama i procedurama.	0,683	0,466
Tijekom poslovnih sastanaka zaposlenici slobodno postavljaju pitanja kolegama i nadređenima.	0,579	0,335
Zaposlenici koji žele usvojiti nove vještine otvoreno upitaju iskusnije kolege da im ih prenesu.	0,690	0,476
Zaposlenici u timovima i u neformalnim kontaktima rado primaju savjete vlastitih kolega i prijatelja.	0,713	0,508
Note. 'Maximum likelihood' extraction method was used in combination with a 'none' rotation		

Izvor: pripremila doktorandica.

PRILOG 13. EKSPLORATORNA FAKTORSKA ANALIZA ZA SKALU USPJEŠNOST POSLOVANJA PODUZEĆA U POŠTANSKOM ISTRAŽIVANJU

Prema Kaiser-Guttmanovu kriteriju utvrđeno je postojanje jednog faktora s karakterističnim korijenom većim od jedan. Ovaj faktor objašnjava 52,8 % varijance rezultata skale Informacijsko-komunikacijske tehnologije. Karakteristični korijen faktora iznosi 8,46. Sve čestice imaju zadovoljavajuće visoka zasićenja ekstrahiranim faktorom (> ,50). *Scree plot* je u skladu s dobivenim podacima te također upućuje na postojanje jednog faktora.

Slika 13.1: *Scree plot* indikatora Uspješnost poslovanja poduzeća (poštansko istraživanje)



Izvor: pripremila doktorandica

Tablica 13.1: Faktorska zasićenja na skali Uspješnost poslovanja poduzeća (poštansko istraživanje)

	Faktor / 1	**Unikv.**
U odnosu na konkurenciju, naše poduzeće zabilježilo je veći rast prodaje. (PRIJE PANDEMIJE)	0,726	0,527
U odnosu na konkurenciju, naše poduzeće bolje je optimiziralo troškove. (PRIJE PANDEMIJE)	0,726	0,528
Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina. (PRIJE PANDEMIJE)	0,708	0,501
U odnosu na konkurenciju, naše poduzeće ostvarilo je veću profitabilnost. (PRIJE PANDEMIJE)	0,774	0,599
U odnosu na konkurenciju, naše poduzeće zabilježilo je rast prodaje. (NAKON PANDEMIJE)	0,764	0,584
U odnosu na konkurenciju, naše je poduzeće bolje optimiziralo troškove. (NAKON PANDEMIJE)	0,765	0,585
Financijsko poslovanje našeg poduzeća može se ocijeniti kao bolje nego prethodnih godina. (NAKON PANDEMIJE)	0,674	0,454
U odnosu na konkurenciju, naše poduzeće ostvarilo je veću profitabilnost. (NAKON PANDEMIJE)	0,783	0,614
U odnosu na konkurenciju, kvaliteta naših proizvoda/usluga je bolja. (PRIJE PANDEMIJE)	0,603	0,363
U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju. (PRIJE PANDEMIJE)	0,664	0,440
U odnosu na konkurenciju, naše poduzeće brže raste. (PRIJE PANDEMIJE)	0,798	0,637
U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike. (PRIJE PANDEMIJE)	0,665	0,442
U odnosu na konkurenciju, kvaliteta naših proizvoda/usluga je bolja. (NAKON PANDEMIJE)	0,698	0,487
U odnosu na konkurenciju, naše poduzeće ima bolju reputaciju. (NAKON PANDEMIJE)	0,751	0,564
U odnosu na konkurenciju, naše poduzeće brže raste. (NAKON PANDEMIJE)	0,810	0,656
U odnosu na konkurenciju, naše poduzeće ima zadovoljnije zaposlenike. (NAKON PANDEMIJE)	0,690	0,477

Izvor: pripremila doktorandica.

PRILOG 14. MODERIRANA MEDIJACIJA - ROA I ROE KAO KRITERIJI

***Online* istraživanje**

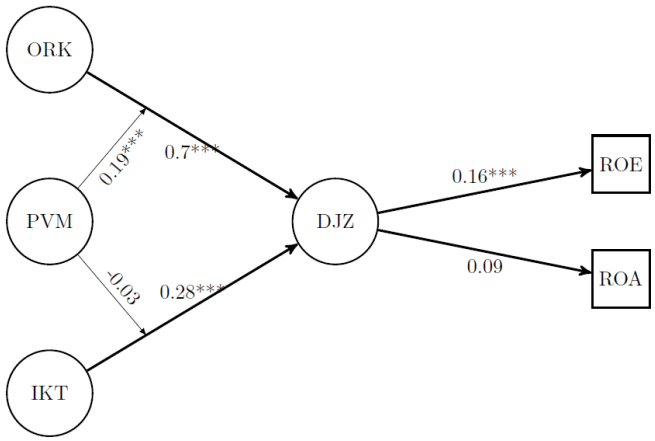
Provjerena je moderirana moderacija za model u kojem su kao pokazatelji uspješnosti poslovanja poduzeća korišteni kriteriji ROA i ROE. Moderacijski model na podacima iz predistraživanja ne pristaje dobro podacima χ^2 = 378,93, df = 175, p < 0,01; χ^2/df = 2,16; CFI = 0,89 i TLI = 0,88; RMSEA = 0,09 (0,08-0,10) i SRMR = 0,2. Pritom je veličina indeksa AIC = 5089.91, BIC = 5240.65.

Poštansko istraživanje

Provjerena je moderirana moderacija za model u kojem su kao pokazatelji uspješnosti poslovanja poduzeća korišteni kriteriji ROA i ROE. Moderacijski model na podacima iz glavnog istraživanja djelomično zadovoljavajuće pristaje podacima χ^2 = 331,35, df = 175, p < 0,01; χ^2/df = 1,85; CFI = 0,92 i TLI = 0,90; RMSEA = 0,06 (0,05-0,07) i SRMR = 0,09. Pritom je veličina indeksa AIC = 6413,55, BIC = 6589,67.

U modelu je utvrđena povezanost između organizacijske klime i dijeljenja znanja (p < 0,001), ali nije utvrđena interakcija između podrške vrhovnog menadžmenta i organizacijske klime te podrške vrhovnog menadžmenta i informacijsko-komunikacijske tehnologije na dijeljenje znanja. Također, nije utvrđen moderacijski efekt podrške vrhovnog menadžmenta na odnos između prediktora i kriterija posredovan dijeljenjem znanja.

Slika 14.1 Jačina veza između pondera u poštanskom istraživanju (Maximum Likelihood Method sa standardiziranim koeficijentima)



Izvor: pripremila doktorandica.

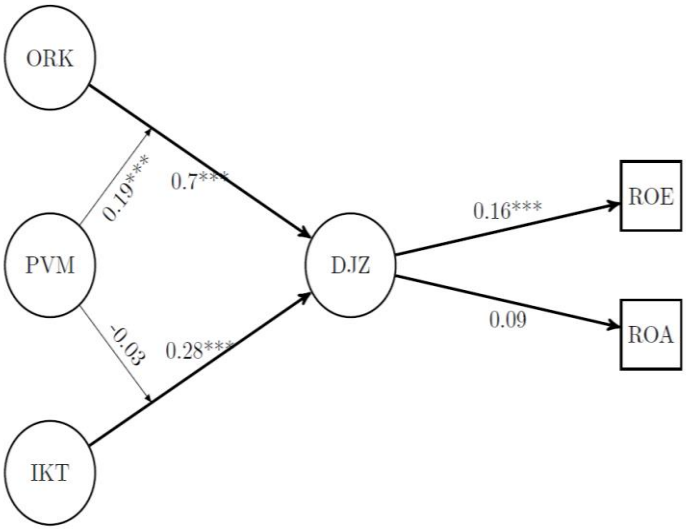
Objedinjeno istraživanje

Provjerena je moderirana moderacija za model u kojem su kao pokazatelji uspješnosti poslovanja poduzeća korišteni kriteriji ROA i ROE. Moderacijski model na podacima iz predistraživanja i glavnog istraživanja djelomično dobro pristaje podacima χ^2 = 544,04, df =

175, $p < 0,01$; χ^2/df = 3,10; CFI = 0,91 i TLI = 0,89; RMSEA = 0,08 (0,07-0,08) i SRMR = 0,15. Pritom je veličina indeksa AIC = 12626,71, BIC = 12828,38.

Utvrđen je medijacijski efekt između organizacijske kulture i ROE preko dijeljenja znanja (β = 0,12, p = 0,004), medijacijski efekt između informacijsko-komunikacijske tehnologije i ROE preko dijeljenja znanja (β = 0,04, p = 0,01) te je utvrđena zanemariva moderirana medijacija između organizacijske kulture i podrške vrhovnog menadžmenta koja preko dijeljenja znanja djeluje na ROE (β = 0,03, p = 0,03).

Slika 14.2 Jačina veza između pondera u objedinjenom istraživanju



Izvor: pripremila doktorandica.

EXTENDED ABSTRACT

At the beginning of 1990s, **Drucker** (**1999**) expressed the importance of acknowledging transition into the knowledge society where primate was given to intangible resources in the production process, especially human knowledge. Knowledge is the only resource whose value does not decrease through its usage, but rather increases. Therefore, it is important that the management recognizes the existence of organisational knowledge at the right time, namely the business segments in which knowledge should be improved. Considering knowledge complexity, or its explicit and implicit dimension, alongside employees' attitudes as basic knowledge carriers to actively participate in knowledge sharing, it is scientifically reasonable to explore modalities in which enterprises operationalise their knowledge sharing.

A scientific hypothesis has been defined according to the complexity of problem and subject of scientific research. The basic scientific hypothesis is:
There is a positive interaction between organisational culture and ICT on one side and knowledge sharing on the other, thus being manifested in business performance, while top management support strengthens interaction between organisational culture and ICT from one side and knowledge sharing process on the other.

Such a hypothesis implies also three **auxiliary hypotheses**:
PH1. Organisational culture which supports knowledge sharing is characterized by: clear mission, continuous learning and employees' empowerment.
PH2. Possible characteristics of ICT supportive of knowledge sharing are: continuous investments in ICT, recognition of business opportunities and improved communication.
PH3. Top management support to knowledge sharing can be identified as: openness to subordinates' ideas, development of high level of trust and regular mentoring of associates.

According to the problem and the subject of research and the described scientific hypothesis, **purpose of research** has also been defined:
According to theoretical cognitions on the concepts of knowledge management and knowledge sharing consolidated within economic science, it is important to explore efficiency of knowledge sharing process within enterprises with special emphasis given to contextual factors in order to develop explanatory model for improving knowledge sharing process in enterprises.

Goal of research *is to explore the impact of knowledge sharing on enterprises' business performance, namely explore if the suggested contextual factors of knowledge sharing improve the influence of knowledge sharing on business performance.*

Knowledge sharing is a dual process consisting of two basic activities: knowledge giving and knowledge receiving. From this aspect, it should be explored from the standpoint of people who offer their knowledge (giving), namely from the standpoint of people who receive knowledge and use it within a specific context (receiving). This definition implies knowledge sharing is a social phenomenon largely depending on psychological characteristics of knowledge givers and receivers. Social Exchange Theory offers a theoretical basis for exploring the process itself while it explains human behaviour in social exchanges that differ from economic ones while participants' obligations are not clearly defined (**Chen**, **Hung**, **2010**).

One of the most popular knowledge categorizations was developed by **Polanyi** (**1966**) who made a difference between explicit and implicit or tacit knowledge. Since explicit knowledge can be easily collected, documented, saved and used, one can assume that costs of sharing this knowledge will be lower (**Oztekin** *et al***, 2015**). On the contrary, significant part of organisational knowledge is within employees' minds so its sharing basically depends on personal contacts made between employees. The following table offers an overview of the most important procedures and operations for giving explicit and implicit or tacit knowledge.

Table 1: Categorisation of processes for giving explicit and implicit/tacit knowledge

Process	Activities
GIVING EXPLICIT KNOWLEDGE	1. Educating employees about procedures for giving knowledge
	2. Providing information on market trends and needs to employees
	3. ICT technologies (e-mails, webinars, online meetings through platforms such as MS Teams, Zoom and alike)
	4. Implementation of periodic reports, regulations, operative standards, procedures and similar
	5. Systems for rewarding employees
	6. Creating databases which contain knowledge and experience of employees portrayed as "best practices"
GIVING IMPLICIT KNOWLEDGE	1. Establishing clusters (networks) of employees who have different expertise which they transfer to other employees
	2. Rescheduling surplus of employees with specific knowledge so they can transfer it to other employees
	3. Brainstorm
	4. Communication by ICT: discussion lists, forums, graphic designs such as CAD, tele- and video-conferences

Source: prepared by a PhD student

Receiving explicit and implicit knowledge are fundamentally different, so one should differ processes which can and should be implemented in the process of receiving explicit and implicit knowledge, as can be seen in the following table.

Table 4: Categorisation of processes for receiving explicit and implicit/tacit knowledge

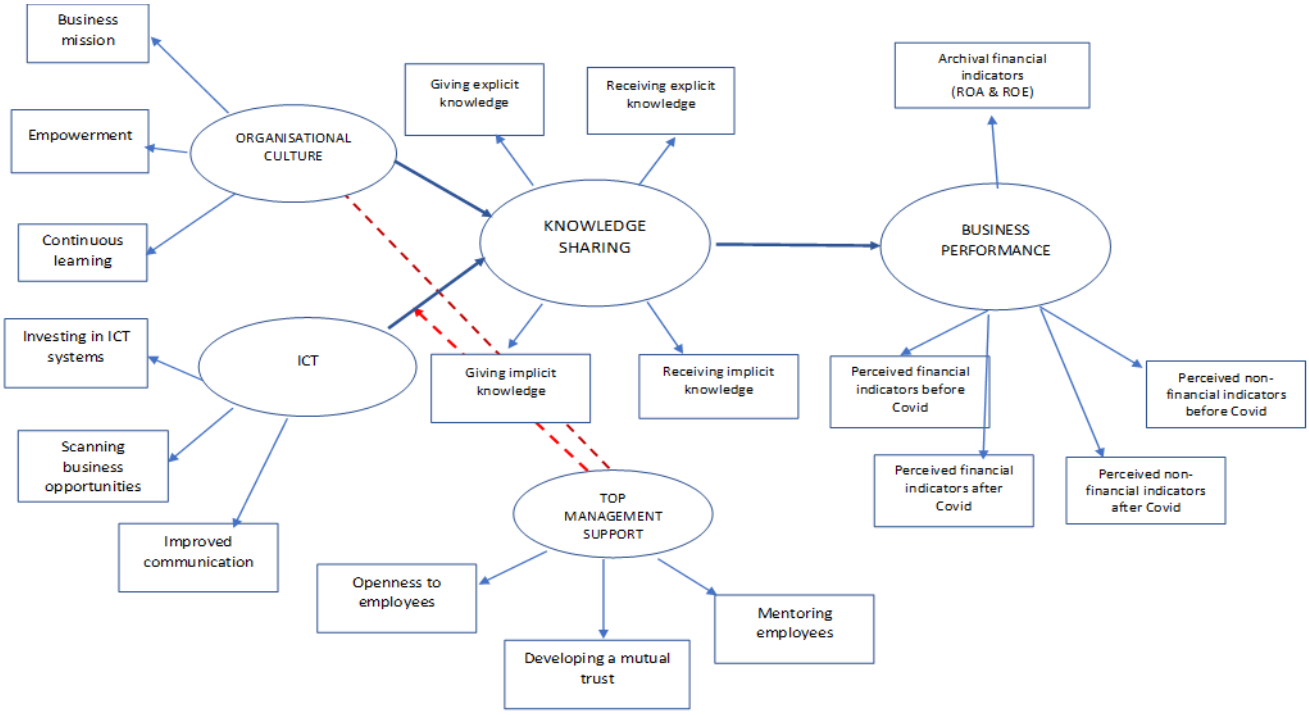
Process	Activities
RECEIVING EXPLICIT KNOWLEDGE	1. Reading and analysing reports on organisational politics and procedures
	2. Reading and analysing reports on business results
	3. Using the system for systematization of supplies (internal databases) and flows of knowledge (externally collected data) to provide employees with easy access
	4. Using the system of ICT (online meetings, discussion rooms, interspaces for collecting data)
	5. Periodic meetings of employees
	6. Receiving knowledge from lectures organised to provide more qualitative knowledge receiving, such as development of cognitive capabilities and creativity
	7. Using prototypes and product designs
RECEIVING IMPLICIT KNOWLEDGE	1. Learning on other employees' mistakes
	2. Direct reception of knowledge from individual experiences of mentors
	3. Encouraging employees' socialization due to accepting common language and identity
	4. Employees' rotation

Source: prepared by a PhD student

Knowledge sharing process can be implemented efficiently if certain pre-requisites are met. A large body of recent scientific research categorizes the following pre-requisite as important for qualitative knowledge sharing: perceived top management support, norms supportive of knowledge sharing, quality of relationships between employees (**Ahsford** *et al***, 1998**), access to information (**Tan** and **Zhao, 2003**), system of rewards and ICT usage (**Lin, 2007**) and organisational climate and trust (**Al-Kurdi** *et al***, 2019**). By analyzing scientific papers which in detail explore factors for enabling knowledge management in general, or knowledge sharing as a central phase of knowledge management it has been concluded that influential factors for efficient knowledge sharing might represent an integration of the following factors: organisational culture, information and communication technologies (ICT) and top management support.

This doctoral thesis includes conceptual and empirical part of research with a purpose of testing the conceptual model of knowledge sharing. A model has been displayed in Picture 1 and it includes the following variables: organisational culture, ICT, top management support, knowledge sharing and business performance. Organisational culture and ICT are latent predicting variables, top management support is suggested as a latent moderating variable, knowledge sharing represents a latent variable of a higher level that also represents a mediator between organisational culture and ICT on one side and business performance on the other.

Picture 1. Conceptual model of knowledge sharing



Source: prepared by a PhD student

An empirical part of the doctoral thesis is based on gathering primary data by using a questionnaire. For that purpose, a measurement instrument was developed (questionnaire) consisting of six parts. The questionnaire was designed to measure the concepts within the suggested conceptual model, and it is based on relevant literature. The first five parts include parcels which measure individual constructs so that each variable belonging to a construct is described using four parcels, except for the central variable of knowledge sharing which is a higher-level variable. The first part measured organisational culture with three manifest variables: business mission, employees' empowerment and continuous learning. All variables are measured by parcels partially taken from the existing literature (**Sorakraikitikul** and **Siengthai, 2014**, **Oh** and **Han**, **2019**), or newly developed if there are no appropriate measurement indicators. A business mission was described by parcels/claims including: a transparent promotion of the business mission, development of collectiveness, dedication of employees to the business mission and emphasis to knowledge sharing as an important segment of the business mission. Empowerment of employees was described by parcels/claims referring to: employees taking over initiatives, active participation of employees in making decisions, high engagement of employees in knowledge sharing within the same department, but also within other departments and possibility of performing demanding assignments. Continuous

learning was described by parcels/claims referring to: investments in educational and development programs, motivating employees for continuous learning, accepting trials and errors by employees and implementation of teamwork and consensus.

The next variable refers to ICT which was measured by three manifest variables: investments in ICT systems, recognition of business opportunities and possible improvement of communication with parcels partly taken from other sources (**Gold, Malhotra, Segars**, **2001**, **Phang** and **Foong, 2010**, **Andreeva** and **Kianto, 2012**.) or partly developed by the author according to the analysed literature (**Handžić, 2010, Oztekin** ***et al*****, 2015, Mirzaee** and **Ghaffari, 2018)**. Investments in ICT systems were measured by the following parcels: implementation of business intelligence systems, using computers for distance learning, adjusting ICT systems to employees' needs and their regular maintenance. Recognition of business opportunities was measured by following parcels/claims: usage of ICT tools for recognizing business opportunities/browsing relevant sources, using ICT for tracking the competition, using ICT for tracking the activities of business partners and using ICT between employees to spread business contacts. A possible improvement of communication was measured by parcels/claims: usage of ICT tools for mutual completion of assignments, distance learning through ICT, locating required data sources by ICT and access to accurate and relevant information due to ICT usage.

The third part of the questionnaire measured top management support by three manifest variables: managers' openness to the ideas and suggestions of employees, developing mutual trust and mentoring of employees (**Lee** and **Kim, 2001**, **Carmeli, Atwater** and **Levi**, **2011**). Managers' openness to the ideas and suggestions of employees was measured by the following claims: promoting the system of values which appreciates all employees' opinions, encouraging employees to freely expose their ideas and suggestions, encouraging formal and informal communication by managers and including employees in learning groups. Developing mutual trust was defined according to the following claims: identifying employees with enterprise's success, importance which employees give to the enterprise's reputation compared to external stakeholders, advisory role of managers and encouraging employees to cope with complex assignments, even if they do not succeed. Mentoring of employees was measured by the following claims: practicing regular mentoring to emphasize importance of knowledge, organising orientation period for new employees, mentoring employees who are given new assignments and rotating employees to collect new knowledge and skills.

The fourth part included the central variable of knowledge sharing that also represents a variable of higher order, which includes giving and receiving explicit and implicit knowledge. Giving and receiving knowledge were measured independently by six parcels (**de Vries, Van den Hooff** and **de Ridder, 2006, Lin, 2007, Dysvik, Buch** and **Kuvaas, 2015**). Giving explicit knowledge was measured by the claims: transferring knowledge, skills and experiences through organised workshops, storing knowledge and experiences virtually and preparing employees' reports about their own accomplishments. Giving implicit knowledge included the following parcels: presenting employees' ideas and attitudes in meetings with superiors, helping less experienced employees through personal contact and consulting employees in teams. The parcels used to describe receiving of explicit knowledge included the following claims: educating employees about modalities of transferring knowledge, skills and experiences, analysing reports on market trends and needs by employees and analysing periodic reports about business results, organisational politics and procedures. Receiving implicit knowledge was described by the following claims: employees asking questions to superiors in meetings, asking more experienced employees for advice about adopting new skills and receiving advices from colleagues in informal teams.

The fifth part included variables which measured success of an enterprise. When defining criterion variable Business success of enterprise perceptive financial and non-financial indicators of business success were used before and after the pandemic. Perceptive financial indicators before/during the Covid-19 pandemic were measured by the parcels: increase of sales compared to competition, successful optimization of costs compared to competition, financial business compared to previous years and profitability compared to competition. Perceptive non-financial indicators before and after the Covid-19 pandemic were measured by: quality of products and/or services compared to competition, reputation of enterprise compared to competition, increase of business volume compared to competition and employees' satisfaction compared to competition. Besides perceptive financial and non-financial indicators, the model included also financial indicators from the archives: Return on Asset (ROA) and Return on Equity (ROE) (**Buble** *et al,* **2003**, **DeSarbo** *et al,* **2004, Oztekin** *et al,* **2015**). Indicator ROA was calculated for each enterprise in a digital repository of Croatian Chamber of Commerce, while ROE had to be calculated for each enterprise according to available data from the same base, namely by calculating the ratio of net gain/loss to total equity.

Data needed for perceptive indicators of business success (financial and non-financial) were provided by questionnaires (**Oh** and **Han, 2019**; **Singh** *et al***, 2019**). It should be emphasized that a vast body of research within knowledge sharing includes perceptive financial and non-financial indicators of business success, while archive indicators were not used for measuring the dependent variable (**Denison** and **Mishra**, **1995, Chen** and **Mohamed**, **2008**, **Zheng, Yang** and **McLean 2009**, **Andreeva** and **Kianto, 2012**, **Podrug, Filipović** and **Kovač, 2017**, **Oh** and **Han, 2018**, **Oyemomi** *et al***, 2019**, **Singh** *et al*, **2019**). Accordingly, and based on the conducted research, the conclusion was drawn that analysis of the given results could have been done solely by using perceptive financial and non-financial indicators. Still, a comparison was made with archive financial indicators due to additional analysis of interaction between archive and perceptive indicators. For the purpose of further data analysis, a paired sample T-test was made for perceptive and archive indicators which proved the lack of interaction so further analysis was based solely on perceptive indicators, following the above explained arguments.

The final part of the questionnaire included ten items in total, of which six referred to employee structure (gender, age, work experience, level of education, position in an enterprise and working experience at the current workplace), whereas four items measured demographic variables of enterprises (ownership structure, size of enterprise, categorisation of business activities and scope of business activities). Analysis of responses gathered in each phase of research also offered analysis of the participants. For example, the main sample includes mostly men aged between 40 and 49 years, who work in an enterprise for less than 10 years, have high professional qualifications and hold their positions for less than 10 years. The enterprises, which participated in research, are mostly small, privately owned and oriented toward domestic market.

Possible limitations in measurements were respondents' bias which tried to be optimised by giving the questionnaire to managers at all levels, but also to employees who, according to classification of their positions within enterprises do not belong to managerial cadre.

In order to decrease the number of questions in the questionnaire and, consequently, the number of analysed variables, the questionnaire was first tested on a target group comprising higher education employees: six professors holding courses similar to the topics of the dissertation, two statisticians, one mathematician and one psychologist. They mutually contributed to a more precise definition of individual questions, thus, according to their suggestions some items were

united: within organisational culture items continuous learning and learning from mistakes were combined in a unique item continuous learning, within ICT variable improved communication and faster decision-making were united into a unique item improved communication, while top management variable combined items developing trust and encouraging employees to accept challenging assignments were transformed in a unique item developing trust. Further reduction in the number of variables included in the conceptual model was achieved by calculating results for each indicator as average value of all items belonging to that indicator. Namely, when creating latent variables, indicators can be either items or parcels of items. In the proposed conceptual model, a model adequately corresponded to data when analysis included parcels of items. Research was conducted on a sample of big, middle and small-sized Croatian companies, while target group included top managers and their close associates who share their knowledge.

After test analysis further improved the questionnaire, research was conducted in two phases: online questionnaire which included 126 completely filled in questionnaires and sending the printed version of the questionnaire with paid return, thus collecting additional 224 questionnaires. Since the main hypothesis in dissertation was proved by using a technique of structural equation modelling, sample size was determined according to recommendation made by **Hair** *et al* (**2010**): sample between 100 and 400 respondents is considered sufficient for this sort of analysis. Analysis of collected data was made for a sample of 350 units. Namely, after testing the questionnaire on a smaller focus group of ten higher education employees, online pre-research was conducted for further testing of questionnaire. Here it is of utmost importance to emphasize that a concept of pre-research is used intentionally and not a pilot study given that research proved valid from the perspective of matching sample with data at this phase of research. Accordingly, since questionnaire proved to be valid, and no additional modifications were required, data gathered in pre-research could have been united with data from the main research to conduct the final analysis (**Birkett, Day, 1994**, **Lancaster, Dodd, Williamson, 2002**, **Van Teijlingen, Hundley, 2013**, **Whitehead, Sully, Campbell, 2014**).

Analysis and data of collected primary data were made by using statistical programs of SPSS, Lisrel and R. Methods of descriptive statistical analysis were used for the description of sample and the main concepts used in a suggested conceptual model. A comparison of knowledge sharing operationalisation in enterprises was made by using methods of bivariant statistical analysis (t-test, Anova), while methods of multivariant statistical analysis were used for analysing reliability of individual scales and measurement instrument (Cronbach alpha,

Structural Equation Modelling – SEM). SEM was also used for testing the main and auxiliary hypotheses, namely for testing the complete conceptual model.

For the purpose of developing a hypothetical conceptual model which had to explain the importance of individual variables for business performance, it was necessary to validate all ad-hoc developed scales that measure following latent variables: organisational culture, ICT, top management support, knowledge sharing and business performance.

Requirements for conducting exploratory factor analysis were firstly tested for all the developed scales: Organisational culture, ICT, Top management support, Knowledge sharing and Business performance. Since research used ad-hod developed scales, it was first necessary to conduct exploratory factor analysis of all scales used to determine factor structure and analyse measurement model. Since factor analysis is based on Pearson correlation coefficients (**Fulgosi, 1988**), normality of distribution of all scales used was primarily tested. Shapiro-Wilk test indicated that items used in all scales statistically significantly deviate from normal distribution. Therefore, parameters of skewness and kurtosis were also calculated. These parameters for all parcels are within tolerable range of -2 to +2 (**Kline, 2005**) implying that usage of factor analysis on this data will not influence the final results. Respectively, if deviation from normal distribution is near expected values, parametric statistical analyses such as factor analysis will not lead to significant consequences for the results (**Howell, 2010**).

After checking the normality of distribution, data were tested for conducting factor analysis. To be more precise, Kaiser-Mayer-Olkin and Bartlett test of sphericity were applied for all used scales. According to **Field** (**2009**) total value of KMO test between .50 and .70 is mediocre, between .70 and .80 good, between .80 and .90 high and above .90 excellent in extraction of factors. Bartlett sphericity test checks if parcels in scale are highly correlated, which is also one of main preconditions for conducting factor analysis. If parcels correlate too high ($r > .85$ or $r < -.85$), it becomes impossible to determine unique contribution of factors to variables that correlate too high. Therefore, after checking Bartlet test, correlation matrices of all scales were additionally controlled.

Table 1: Testing preconditions for conducting exploratory factor analysis for scales Organisational culture, ICT, Top management support, Knowledge sharing and Business performance by Kaiser-Mayer-Olkin test and Bartlet sphericity test

NAME OF SCALE	Kaiser-Mayer-Olkin test	Bartlett sphericity test
Organisational culture	0.91	$\chi 2=1107$; df=66; $p < .01$
Information and communication technologies	0.92	$\chi 2=1109$; df=66; $p < .01$
Top management support	0.90	$\chi 2=1285$; df=66; $p < .01$
Knowledge sharing	0.87	$\chi 2=1121$; df=66; $p < .01$
Business performance	0.87	$\chi 2=2102$; df=66; $p < .01$

Source: prepared by a PhD student

Since value of Kaier-Mayer-Olkin test for all scales was minimally 0.87 it can be concluded that first precondition for conducting exploratory factor analysis was fulfilled. Further on, it was statistically significant for all scales with risk level of wrong conclusion less then 1%.

For the purpose of testing factor structure of scales exploratory factor analysis was conducted by maximum likelihood method. This method was chosen while **Fabriger** *et al* (**1999**) concluded that within data with normal distribution, method of maximum likelihood is the best choice since it enables calculation of high range of model fit and it allows testing statistical significance of factor saturation and correlations between factors. The criteria for keeping the number of factors were set in values of characteristic square-root that should be at least 1 (Kaiser-Guttman criterium), percentage of explained variance for each factor, Catell *Scree plot* test and interpretability of factors. All factors in all tested scales were highly saturated with assumed parcels.

To check the reliability of all used scales, Cronbach alpha coefficient of internal consistency was calculated for each scale individually, as can be seen in Table 2.

Table 2. Overview of internal consistency coefficients (Cronbach alpha)

	Organisational culture	**ICT**	**Top management support**	**Knowledge sharing**	**Business performance**
Cronbach alpha	**0.94**	**0.93**	**0.94**	**0.92**	**0.95**

Source: prepared by a PhD student

Values of internal consistency coefficients were rather high, thus additionally confirming the quality of developing and applying parcels for measuring contribution of individual variables to successful application of knowledge sharing within enterprise.

Conjoint research included a total of 3.000 enterprises, of which 350 enterprises provided fully completed questionnaires of the following structure: 44 big enterprises (13%), 95 medium sized enterprises (27%) and 211 small enterprises (60%). Among the respondents 52% were male, 35% aged between 40 and 49 with less than 10 years of services (38%), with high professional qualifications (60%). Furthermore, 56% of respondents belong to top management with work experience at the same position for less than 10 years (42%), while enterprises analysed mostly operate in the private sector (90%), are small-sized (62%), mostly provide services (60%) on domestic market (46%).

Analysis of modification indices in confirmatory factor model made for data in online and postal research concluded that the model fit could be improved by additional evaluation of covariance indicators for Knowledge sharing and Business performance. Model fit is then satisfactory.

Table 3: Model fit for conjoint research

Index	Referential value	Calculated value	Interpretation (Data fit)
χ^2/df χ^2 = 260.09, df=106, p < 0,01	< 3	2.45	Satisfactory
CFI	> 0.9	0.96	Satisfactory
TLI	> 0.9	0.94	Satisfactory
RMSEA	< 0.10	0.06 (0.05-0.07)	Satisfactory
SRMR	< 0.10	0.04	Satisfactory

AIC= 10.241,38, BIC= 10.420,08

Source: prepared by doctorand.

All parcels in model were satisfactory highly saturated by assumed factors, as an be seen in Table 4.

Table 4: Factor saturation of indicators (parcels) with belonging latent variable for all data

Latent variable	Indicator	Saturation
Organisational culture	Business mission	0.74
Organisational culture	Empowerment of employees	0.74
Organisational culture	Continuous learning	0.83
ICT	Investments in ICT	0.82
ICT	Business opportunities	0.72
ICT	Improved communication	0.87
Top management support	Managers' openness to employees' ideas	0.82
Top management support	Developing trust	0.82
Top management support	Mentoring employees	0.82
Knowledge sharing	Giving explicit knowledge	0.71
Knowledge sharing	Giving implicit knowledge	0.66
Knowledge sharing	Receiving explicit knowledge	0.63
Knowledge sharing	Receiving implicit knowledge	0.70
Business performance	Finances before 2020	0.69
Business performance	Finances after 2020	0.58
Business performance	Non-finances before 2020	0.91
Business performance	Non-finances after 2020	0.53

Source: prepared by doctorand.

After this analysis mediation and moderation were analysed (for all research phases). Firstly, mediation model for data gathered in online and postal research was tested with Organisational culture and ICT being predictors, Knowledge sharing a mediator and Business performance a criterium. Mediation model was conducted for latent variables and it proved satisfactory fit with data.

Table 5: Mediation model fit in conjoint research

Index	Referential value	Calculated value	Interpretation (Data fit)
$\chi 2/df$ $\chi 2 = 263.55$, df=110, $p < 0,00$	< 3	2.39	Satisfactory
CFI	> 0.9	0.96	Satisfactory
TLI	> 0.9	0.95	Satisfactory
RMSEA	< 0.10	0.06 (0.05-0.07)	Satisfactory
SRMR	< 0.10	0.04	Satisfactory

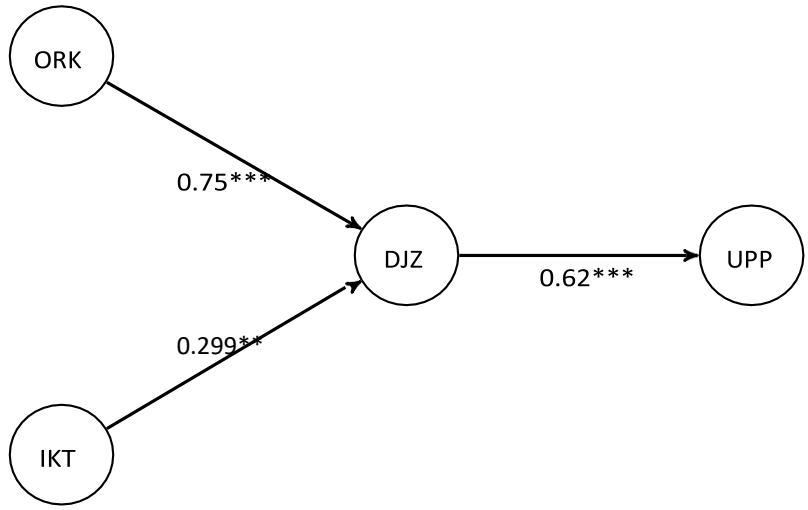
AIC= 10.236,84, BIC= 10.400,33

Source: prepared by doctorand.

Analysis proved interaction between Organisational culture and Knowledge sharing ($p < 0.001$), and between ICT and Knowledge sharing ($p < 0.001$). Also, an interaction was proved between Knowledge sharing and Business performance ($p < 0.001$). Mediation role of Knowledge sharing between Organisational culture and Business performance was proved ($\beta = 0.47$, $p < 0.001$), but also mediation role of Knowledge sharing between ICT and Business performance ($\beta = 0.18$, $p < 0.001$). With the increase of Organisational culture value, Knowledge sharing value will also increase thus positively effecting Business performance,

while increase of ICT value will positively effect value of Knowledge sharing thus increasing the value of Business performance as well. The next picture shows beta-ponders between predictors and mediators, and mediators and criterium.

Picture 1: Mediation and strength of interactions in conjoint research (using MLM Method)



Source: prepared by a PhD student

Moderation model in conjoint research partially satisfactory fitted data.

Table 6: Moderation model fit for conjoint research

Index	Referential value	Calculated value	Interpretation (Data fit)
$\chi 2/df$ $\chi 2 = 476.89$, df=141, $p < 0,01$	< 3	3.38	Good
CFI	> 0.9	0.92	Good
TLI	> 0.9	0.90	Good
RMSEA	< 0.10	0.08 (0.07-0.09)	Good
SRMR	< 0.10	0.16	Good

AIC= 10.236,84, BIC= 10.400,33

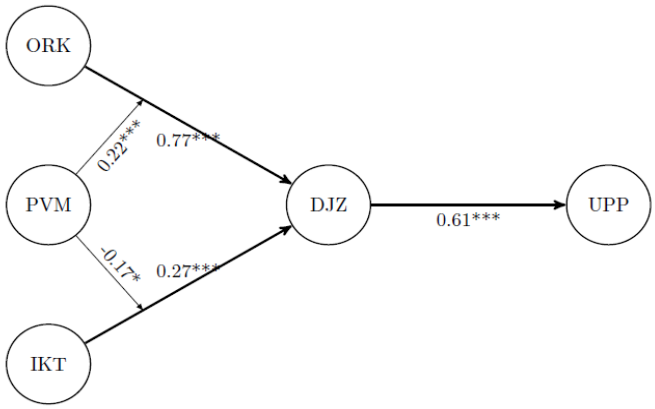
Source: prepared by doctorand.

Analysis of model indicated interaction between Organisational culture and Knowledge sharing ($p < 0.001$) and Knowledge sharing and Business performance ($p < 0.001$). It also proved a mediation effect of Knowledge sharing between Organisational culture and Business performance (β=0.48, $p < 0.001$). Model analysis also proved interaction between ICT and Knowledge sharing ($p < 0.001$) and a mediation effect for Knowledge sharing between ICT and Business performance (β=0.17, $p < 0.001$).

An interaction has been proved between Top management support and Organisational culture (β =0.16, $p < 0.001$) but also between ICT and Top management support (β =-0.12,$p < 0.05$)

for Knowledge sharing. Analysis indicated a moderated mediation (β =0.10, p < 0.001) implying Top management support determines interaction between Organisational culture and Knowledge sharing that intervenes between Organisational culture and Business performance.

Picture 2: Moderation and significance of interactions in conjoint research (using MLM Method)



Source: prepared by a PhD student

Finally, it can be concluded that moderation analysis proved a significant influence of Top management support for interactions between ICT, Knowledge sharing and Business performance, while Top management support is less influential on interaction between Organisational support, Knowledge sharing and Business performance. In other words, if Organisational culture is strong enough to motivate employees for knowledge sharing, employees will give special importance to Top management support in knowledge sharing. Strong organisational culture is a sufficiently influential factor to independently contribute to knowledge sharing among employees, thus, consequently affecting business performance as well.

Kmeans cluster analysis was conducted to determine a number of clusters in reference to indicators Organisational culture, Top management support and ICT thus determining whether enterprises belong to one of three knowledge management generations. To evaluate an optimal number of clusters *NbClust* was used combining a different number of distance measures, number of clusters and clustering methods. According to this method, two clusters showed the most parsimonious solutions.

Picture 3: Defining a number of clusters

```
## Among all indices:
## ==================
## * 2 proposed  0 as the best number of clusters
## * 1 proposed  1 as the best number of clusters
## * 9 proposed  2 as the best number of clusters
## * 2 proposed  3 as the best number of clusters
## * 2 proposed  4 as the best number of clusters
## * 4 proposed  5 as the best number of clusters
## * 1 proposed  8 as the best number of clusters
## * 5 proposed  9 as the best number of clusters
##
## Conclusion
## ==========================
## * According to the majority rule, the best number of clusters is  2 .
```

Source: Prepared by a PhD student

Elbow method was used for determining the number of clusters with *within sum of squares* option that generates clusters based on the least inter-group variability and the highest possible among-group variability. According to this method, two clusters provide the most parsimonious solution.

The following table shows that cluster 2 has N=234 units of analysis and above-average values much higher than cluster 1 that has N=111 units of analysis. In both clusters almost each analysed variable was negatively asymmetric with the only exception being Organisation culture, which was positively asymmetric in cluster 2.

Table 7: Descriptive statistics for two clusters

Cluster	Variable	Average	Stand. Dev.	Min	Max	Asymmetry	Kurtosis	No of valid units
2								
2	ICT	0.43	0.71	-2.35	1.57	-0.62	0.76	234
2	Org Cult	0.51	0.55	-0.85	3.80	0.58	4.28	234
2	Top MN Supp	0.51	0.52	-1.00	1.28	-0.56	-0.27	234
1								
1	ICT	-0.89	0.93	-3.51	1.25	-0.60	0.34	111
1	Org Cult	-1.06	0.89	-4.25	0.66	-1.38	2.31	111
1	Top MN Supp	-.,03	0.91	-4.00	0.44	-1.03	1.07	111

Source: Prepared by a PhD student

The results of cluster analysis indicate that out of totally 350 analysed enterprises 234 belong to a cluster with strongly developed Organisational culture and Top management support, which are also characteristics of the second knowledge management generation (**Milanović, 2010**). Compared to the first cluster, second includes 111 analysed enterprises or 39% of

analysed enterprises with strongly developed ICT that characterizes the first knowledge management generation. Accordingly, the comparison of the two calculated clusters imply that the majority of analysed enterprises belong to the second knowledge management generation having the following characteristics: enterprises are mostly privately owned and they offer a combination of production and services.

In conclusion, it can be said that this research made the following scientific contributions:

1. It proved an integrative model of knowledge sharing process measurement that simultaneously explores factors influencing knowledge sharing process and the effect of knowledge sharing on business performance in a completely new mode. Top management support has been excluded as a moderator, which is new compared to similar papers exploring the process of knowledge sharing. Variables Organisational culture and ICT have been evaluated compared to criteria which other researchers partly include, but rarely explicitly systemise (e.g. business mission, empowerment, investments in ICT and recognizing opportunities in business environment). The most important contribution of this research was given in analysing knowledge sharing from the aspects of giving and receiving explicit and implicit knowledge, while the influence of knowledge sharing in business performance was made upon comparison between perceptive and archival indicators of business performance.
2. Knowledge sharing model based on organisational capabilities developed by **Gold**, **Malhotra** and **Segars** (**2001**) was upgraded. These authors concluded that business efficiency depends on infrastructure that support knowledge management and includes technological structure, company management and cultural structure, together with infrastructure including knowledge management processes: knowledge collecting, knowledge reshaping, application and protection of knowledge. Similarly to these authors, the conceptual model also positions Organisational culture and ICT systems to predictive variables, but exclusively compared to knowledge sharing as a central process of knowledge sharing which is more precisely analysed compared to categories of knowledge: explicit and implicit, but also from the aspects of giving and receiving knowledge.

2.1. Top management support was repositioned compared to previous research that included Top management support in Organisational culture (**Lu, Leung, Koch, 2006**, **Lin, 2007**, **Sorakraikitikul** and **Siengthai, 2014**). In this research Top management support is a sufficiently significant factor to be analysed independently, but not completely

separated from Organisational culture and ICT since this specific variable can significantly contribute to more efficient usage of Organisational culture and ICT. These interactions were proved by analysing moderated mediation that implied a connection between Top management support and Organisational culture, but also between Top management support and ICT. Besides, exploratory factor analysis proved that Top management support conceptually can and should be separated from Organisational culture considering its importance for Knowledge sharing. Analysis of interactions between moderating variable and predicting variables proved that average Top management support and strong Organisational culture lead to the highest Knowledge sharing, while high Top management support and moderate ICT systems result in highest level of Knowledge sharing.

2.2. Measuring the influence of Knowledge management on Business performance was redefined by introducing multidimensional indicators of Business performance (**Andreeva** and **Kianto**, **2012**). Within this aspect, **Buble** *et al* (**2008**) concluded that relying solely on archival indicators of Business performance can lead to wrong conclusions while archival indicators reflect effects of decisions made in the past and are submissive to creative accounting. From these reasons a conceptual model included perceptive financial and non-financial indicators since analysis proved there is no statistically significant interaction between archival and perceptive indicators. Therefore, measuring Business performance from the aspect of Knowledge sharing should definitely be done by using perceptive indicators of performance. Within the model perceptive financial indicators of Business performance were explicitly defined: sales increase compared to competition, better optimisation of costs compared to competition, better financial business compared to previous years and increased profitability compared to previous years (indicators were measured before and after Covid-19 pandemics). Perceptive non-financial indicators have been defined as follows: higher level of service and products quality compared to competition, a better reputation compared to competition, faster growth compared to competition and more satisfied employees compared to competition (measured before and after Covid-19 pandemics).

3. Scientific literature on implementation modalities for Knowledge sharing was improved, especially considering the fact that this concept has not been explored in the Republic of Croatia. Namely, authors who conducted similar research (**Vidović, 2008**, **Milanović, 2010**) analysed modalities of Knowledge management, but not Knowledge sharing. Compared to their research, a concept of Knowledge sharing has been more

precisely analysed by its decomposition to giving and receiving explicit and implicit knowledge. Furthermore, **Vidović** (**2008**) conducted research solely on Croatian large enterprises in tourism, while **Milanović** (**2010**) analysed large, medium- and small-sized enterprises with exclusive emphasis given to ICT usage for Knowledge sharing.

4. A detailed analysis of development stage of Knowledge sharing process has been done in small, medium- and large-sized enterprises, being the first research of that kind conducted on a sample of Croatian companies. The final results have been compared to similar research made by **Vidović** (**2008**) and **Milanović** (**2010**). Vidović (2008) measured the following variables: 1. Infrastructure for Knowledge management (KM), 2. Carriers of KM, 3. Organisational culture for KM, 4. ICT for KM and 5. Measuring usefulness of KM. The author graded each dimension of Knowledge management independently and concluded that big Croatian enterprises invest highest effort into development of ICT for Knowledge management, thus belonging to the first generation of KM. **Milanović** (**2010**) measured the maturity of Knowledge management in big, medium and small-sized Croatian enterprises by using three dimensions: 1. Organisational culture, 2. Human dimension and 3. ICT. This author made a comparison with work of Vidović (2008) and she concluded that Croatian enterprises made a significant breakthrough in usage of Knowledge management practices in Croatian enterprises. The author also mentioned the three phases of Knowledge management development: 1. Phase: focus of enterprises dominantly on ICT, Organisational culture not adjusted to KM, employees are not praised for their contribution to KM and management is not supportive of KM, 2. Phase/KM generation: enterprises are focused on human and cultural dimension, management is supportive of KM, Organisational culture and infrastructure for KM are being developed, usefulness of KM is measured; 3. Phase/KM generation: enterprises optimally develop all factors influential to KM, with special concern given to coding and saving information and knowledge so they can be more easily approached. Considering high grades of human and cultural dimension, **Milanović** (**2010**) concluded that Croatian enterprises belong to second KM generation. Cluster analysis implied that enterprises analysed within the sample belong to two clusters, with a relatively larger number of enterprises (2/3) which are well-developed Organisational culture and Top management support. These factors, alongside developed ICT systems characterize enterprises belonging to the second KM generation. Since the conceptual model also proved significance of ICT systems (with adequate Top

management support), it can be assumed that Croatian enterprises develop basis for transfer from the second to the third generation of Knowledge management.