Nematerijalni indikatori u razvoju tehničkih sustava

Škec, Stanko

Doctoral thesis / Disertacija

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:235:964786

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb







Sveučilište u Zagrebu

Fakultet strojarstva i brodogradnje

Stanko Škec

NEMATERIJALNI INDIKATORI U RAZVOJU TEHNIČKIH SUSTAVA

DOKTORSKI RAD

Zagreb, 2015.



Sveučilište u Zagrebu

Fakultet strojarstva i brodogradnje

Stanko Škec

NEMATERIJALNI INDIKATORI U RAZVOJU TEHNIČKIH SUSTAVA

DOKTORSKI RAD

Mentor: prof. dr. sc. Dorian Marjanović

Zagreb, 2015.



University of Zagreb

Faculty of Mechanical Engineering and Naval Architecture

Stanko Škec

THE INTANGIBLE INDICATORS IN DEVELOPMENT OF TECHNICAL SYSTEMS

DOCTORAL THESIS

Supervisor: Dorian Marjanović, PhD Full professor

Zagreb, 2015.

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK: 658.5:65.012.2

Ključne riječi: indikatori izvedbe, upravljanje projektima, intelektualni kapital, razvoj tehničkih sustava, uzorkovanje rada, organizacijski rizici, dinamička analiza kompleksnih mreža, metoda potencijala

Znanstveno područje: TEHNIČKE ZNANOSTI

Znanstveno polje: strojarstvo

Institucija na kojoj je rad izrađen: Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu

Mentor rada: dr. sc. Dorian Marjanović, red. prof.

Broj stranica: 164

Broj slika: 44

Broj tablica: 29

Broj korištenih bibliografskih jedinica: 239

Datum obrane: 24.06.2015.

Povjerenstvo:

dr. sc. Mario Štorga, izvanredni profesor – predsjednik Povjerenstva
(Fakultet strojarstva i brodogradnje, Zagreb)

dr. sc. Dorian Marjanović, redoviti profesor – mentor
(Fakultet strojarstva i brodogradnje, Zagreb)

dr. sc. Nedeljko Štefanić, redoviti profesor – član Povjerenstva
(Fakultet strojarstva i brodogradnje, Zagreb)

dr. sc. Marina Dabić, redovita profesorica – članica Povjerenstva
(Ekonomski fakultet, Zagreb)

dr. sc. Tomaž Savšek, docent – član Povjerenstva
(TPV d.d., Novo Mesto)

Institucija u kojoj je rad pohranjen: Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu

ZAHVALE

Zahvaljujem mentoru prof. dr. sc. Dorianu Marjanoviću na pruženoj prilici, strpljenju, savjetima i pomoći tijekom istraživanja i izrade doktorskog rada.

Zahvaljujem prof. dr. sc. Mariu Štorgi na čestim raspravama i savjetima koji su pomogli pri usmjeravanju i provođenju istraživanja.

Zahvaljujem prof. dr. sc. Lavoslavu Čakloviću na pomoći pri izradi matematičkog modela i prof. dr. sc. Mariji Janković na korisnim savjetima tijekom istraživačkog posjeta u Francuskoj.

Posebno zahvaljujem dr. sc. Zlatki Tečec Ribarić i dr. sc. Tomažu Savšeku na pomoći pri provođenju studije slučaja i vrednovanju provedenog istraživanja.

Zahvaljujem članovima Povjerenstva za ocjenu i obranu disertacije koji su svojim komentarima i primjedbama unaprijedili ovu doktorsku disertaciju.

Zahvaljujem svim bivšim i sadašnjim članovima Katedre za konstruiranje i razvoj proizvoda na tehničkoj i moralnoj podršci.

Zahvaljujem svojoj obitelji i prijateljima na strpljivosti, razumijevanju i moralnoj podršci koju su mi pružali svih ovih godina.

Posebno želim zahvaliti svojoj supruzi Tamari na stalnoj podršci i razumijevanju te kćeri Sofiji koja me uvijek oraspoloži i razveseli.

SAŽETAK

Ključne riječi: indikatori izvedbe, upravljanje projektima, intelektualni kapital, razvoj tehničkih sustava, uzorkovanje rada, organizacijski rizici, dinamička analiza kompleksnih mreža, metoda potencijala

Kontinuirano mjerenje i praćenje izvedbe projekata razvoja tehničkih sustava nužno je za objektivnu i jasnu procjenu dinamike ostvarivanja ciljeva, ranu detekciju i ispravljanje pogrešaka, te davanje pravodobne povratne informacije potrebne za uspješno upravljanje projektima. Tradicionalni pristupi upravljanja projektima razvoja tehničkih sustava uobičajeno koriste materijalne indikatore za mjerenje izvedbe projekta. Da bi informacija o izvedbi projekta bila potpuna, potrebno je uključiti i socio-tehničku perspektivu – značajke sudionika, procesa i radnoga okruženja. Socio-tehnička se perspektiva može opisati pomoću operativnih nematerijalnih indikatora s naglaskom na ponašanje pojedinaca i timova, razmjenu znanja te rješavanje tehničkih problema i stvaranje novih ideja. Analiza individualnog i timskog rada u hijerarhijskim organizacijskim strukturama osnova je za bolje razumijevanje, praćenje i mjerenje dinamike izvedbe projekata. Modeliranjem dinamike nematerijalnih operativnih indikatora omogućuje se proaktivno upravljanje projektima razvoja tehničkih sustava i prepoznavanje operativnih rizika vezanih uz te indikatore.

U okviru disertacije predloženi su nematerijalni indikatori svrstani u četiri cjeline intelektualnog kapitala na individualnoj i timskoj razini: *kompetencije i znanje, komunikacija i razmjena informacija, inovativnost i ideacija* te *motivacija i zadovoljstvo*. Predloženi je popis nematerijalnih indikatora poslužio kao polazište za izradu ankete, razvoj aplikacije za uzorkovanje rada i osmišljavanje integracije s IT sustavima, čime se omogućuje praćenje izvedbe pojedinaca i timova u stvarnom vremenu. Uzorkovanje rada do sada nije korišteno u ovom kontekstu, te omogućuje kvantitativno i objektivnije prikupljanje podataka o aktivnostima u razvoju tehničkih sustava na individualnoj i timskoj razini. U okviru doktorskog rada, definiran je i model agregacije koji omogućuje izračun agregiranih vrijednosti indikatora za cjeline intelektualnog kapitala. Koristeći težinske faktore dobivene pomoću Metode potencijala, agregirana vrijednost indikatora izračunava se upotrebom diferencijalno ponderirane linearne agregacije.

Studija slučaja provedena je u tvrtki čije su istraživačke i razvojne djelatnosti orijentirane na sustave za proizvodnju, distribuciju i transformaciju električne energije. Nakon provedene

studije slučaja analiza indikatora omogućila je detaljan uvid u izvođenje aktivnosti tijekom razvoja ugradbenih upravljačkih sustava i vrednovanje predložene metode. Postupak vrednovanja podijeljen je na dva dijela: 1. vrednovanje izvedivosti i korisnosti metode i 2. vrednovanje rezultata. Vrednovanje izvedivosti i korisnosti metode obuhvaćalo je usporedbu s pristupima u literaturi, upotrebu studije slučaja i razmatranje primjene metode u širem kontekstu. Prvi dio vrednovanja potvrdio je da su pojedinačni indikatori pravilno definirani i da predložena metoda ispunjava namijenjenu svrhu u smislu unutarnje konzistentnosti i vanjske relevantnosti. Za vrednovanje rezultata nematerijalnih indikatora poslužila je usporedba s rezultatima analize organizacijskih rizika dobivenih primjenom organizacijske metamatrice (društvena mreža, mreža znanja, mreža resursa, mreža zadataka). Drugi dio vrednovanja potvrdio je trendove indikatora te komplementarnost predložene metode s metodama za analizu organizacijskih rizika.

SUMMARY

Keywords: performance indicators, project management, intellectual capital, development of technical systems, work sampling, organizational risks, dynamic analysis of complex networks, Potential method

Continuous measurement and monitoring of project performance is essential for objective goal assessment, early detection of errors and providing timely feedback relevant for successful project management. Traditional project management approaches that are used in the development of technical systems are based on tangible indicators for project performance measurement. However, for the effective project management there is a necessity to embrace the socio-technical perspective – working processes and organizational environment. Sociotechnical perspective can be measured by using operational indicators with an emphasis on behavior, knowledge exchange and ideation aspects. Analysis of interactions between individuals in hierarchical organization structures is a prerequisite for better understanding, monitoring and measuring project performance dynamics. Modeling of dynamics of operational indicators for competencies, innovativeness, communication and motivation on individual and team level, enables proactive management of technical systems development projects and identification of operational risks related to those indicators.

Based on literature review and initial empirical studies, the list and network of intangible indicators were proposed. Indicators were grouped into four elements of intellectual capital on individual and team level: Competences and knowledge, Communication and information exchange, Innovativeness and ideation, and Motivation and satisfaction. The proposed list of indicators was used as a starting point for creating a survey, development of work sampling application and integration with IT systems for data gathering that allows monitoring of the performance of individuals and teams in real time. Work sampling has not been used in this context before and allows the quantitative and more objective data collection on activities within the technical systems development at the individual and team level. In addition, aggregation model was defined which allows calculation of aggregated values for each element of intellectual capital. Values for each intellectual capital element were calculated by using the weighting factors obtained with the Potential method and by applying the differential linear weighted aggregation.

A case study was carried out in the R&D company whose research and development activities are focused on the development of systems for production, distribution and transformation of

electrical energy. After case study had been conducted, analysis of the indicators enabled detailed insight into the performance of activities during the development of embedded control systems and validation of the proposed method.

The validation process of the proposed method was divided into two parts: 1. Validation of the feasibility and usefulness of the method, and 2. Validation of results. Validation of the feasibility and usefulness of the method included a comparison with existing literature, the use of case study and discussion about the method usage in a broader context. The first part of the validation confirmed that the individual indicators were set correctly and that the proposed method fulfills its intended purpose in terms of internal consistency and external relevance. For the purposes of validating the results of intangible indicators, comparison was used with the results of the organizational risk analysis method. The second part of the validation confirmed the results of the indicators trends and complementary nature of the proposed method to methods for organisational risk assessment.

PREDGOVOR

Ova disertacija izrađena je u okviru istraživanja o upravljanju projektima razvoja tehničkih sustava. Rad je jedan od ishoda istraživanja znanstvenog projekta br. 120-1201829-1828 „Modeli i metode upravljanja znanjem u razvoju proizvoda“ koji je financiralo Ministarstvo znanosti, obrazovanja i sporta Republike Hrvatske. Dio istraživanja proveden je u sklopu Eurekina projekta „E!8723 Visually Augmented Analysis of the Information Structures Evolving in Socio-technical Systems – VISINEV“. Studija slučaja i vrednovanje predložene metode provedeni su u suradnji s tvrtkama KONČAR Institut za elektrotehniku d.d. Zagreb i TPV d.d. Novo mesto. Očekuje se da bi predloženi nematerijalni indikatori mogli poslužiti za praćenje projekata u stvarnom vremenu te dati bolji uvid voditeljima projekata u trenutačno provođenje projekata.

SADRŽAJ

1. Uvodna razmatranja ... 1
   1.1. Cilj i svrha istraživanja ... 3
   1.2. Hipoteza i istraživačka pitanja ... 4
   1.3. Metodologija istraživanja ... 5
   1.4. Očekivani znanstveni doprinos ... 7
   1.5. Struktura disertacije ... 7
2. Pregled područja istraživanja ... 9
   2.1. Upravljanje razvojnim projektima ... 9
   2.2. Upravljanje intelektualnim kapitalom ... 12
   2.3. Timski rad u razvoju tehničkih sustava ... 16
3. Teorijske osnove istraživanja ... 21
   3.1. Mjerenje elemenata intelektualnoga kapitala ... 21
   3.2. Mjerenje izvedbe pojedinaca, timova i organizacija u razvojnim projektima ... 24
   3.3. Određivanje težinskih faktora i agregacija vrijednosti indikatora ... 27
   3.4. Organizacijski rizici koji proizlaze iz nematerijalnih aspekata ... 29
4. Razvoj nematerijalnih indikatora za praćenje razvoja tehničkih sustava ... 35
   4.1. Koraci razvoja nematerijalnih indikatora ... 35
   4.2. Prijedlog i validacija popisa nematerijalnih indikatora ... 36
   4.3. Prijedlog i validacija mreže nematerijalnih indikatora ... 43
   4.4. Određivanje važnosti nematerijalnih indikatora ... 48
      4.4.1. Primjena Metode potencijala na mrežu indikatora ... 49
   4.5. Model agregacije indikatora ... 52
5. Prikupljanje podataka za praćenje nematerijalnih indikatora ... 55
   5.1. Metode prikupljanja podataka ... 55
   5.2. Uzorkovanje rada ... 55
      5.2.1. Mobilna aplikacija za uzorkovanje rada ... 58
   5.3. Ankete za prikupljanje podataka ... 62
      5.3.1. Anketa 360-stupanjske procjene izvedbe kompetencija sudionika ... 64
      5.3.2. Anketa za prikupljanje podataka o kontekstu i okruženju razvojnog tima ... 67
   5.4. Integracija s postojećim korporativnim IT sustavima ... 68

5.5. Preslikavanje prikupljenih podatka u vrijednosti indikatora 70
6. Studija slučaja 73
6.1. Analiza uzorkovanja rada 73
6.1.1. Analiza prikupljenih podataka za cijelo razdoblje uzorkovanja 74
6.1.2. Analiza prikupljenih podataka za cijelo razdoblje uzorkovanja za svakog sudionika zasebno 81
6.1.3. Zaključci na temelju analize prikupljenih podataka za cijelo razdoblje uzorkovanja rada 85
6.2. Analiza dinamike vrijednosti indikatora u promatranom razdoblju 91
6.2.1. Indikatori izvedbe za element *kompetencije i znanje* 91
6.2.1.1. Individualna razina 91
6.2.1.2. Timska razina 95
6.2.1.3. Rasprava o rezultatima za element *kompetencije i znanje* 97
6.2.2. Indikatori izvedbe za element *komunikacija i razmjena informacija* 100
6.2.2.1. Individualna razina 100
6.2.2.2. Timska razina 106
6.2.2.3. Rasprava o rezultatima za element *komunikacija i razmjena informacija* 107
6.2.3. Indikatori izvedbe za element *inovativnost i ideacija* 110
6.2.3.1. Individualna razina 110
6.2.3.2. Timska razina 111
6.2.3.3. Rasprava o rezultatima za element *inovativnost i ideacija* 113
6.2.4. Indikatori izvedbe za element *motivacija i zadovoljstvo* 115
6.2.4.1. Individualna razina 115
6.2.4.2. Timska razina 116
6.2.4.3. Rasprava o rezultatima za element *motivacija i zadovoljstvo* 118
6.3. Određivanje agregirane vrijednosti nematerijalnih indikatora za elemente intelektualnoga kapitala 120
7. Vrednovanje predložene metode 123
7.1. Metodologija vrednovanja 123
7.2. Vrednovanje izvedivosti na temelju validacijskoga kvadrata 124
7.3. Vrednovanje dobivenih rezultata usporedbom s metodom za analizu organizacijskih rizika 130
7.3.1. Priprema metamatrice 130

7.4. Rezultati analize organizacijskih rizika 132
7.4.1. Analiza rezultata za domenu *agenti* 133
7.4.2. Analiza rezultata za domenu *znanje* 135
7.4.3. Analiza rezultata za domenu *resursi* 136
7.4.4. Analiza rezultata za domenu *aktivnosti* 137
7.5. Usporedba rezultata predložene metode s rezultatima dobivenim ORA-om 139
8. Zaključak 143
8.1. Rasprava 145
8.2. Smjerovi budućeg istraživanja 147
9. Literatura 149
Životopis 161
Biography 162
Popis objavljenih radova 163

POPIS SLIKA

Slika 2-1. Prikaz broja radova indeksiranih u bazi Scopus sa sintagmom „intellectual capital“ u naslovu, sažetku ili među ključnim riječima od 1983. do danas [59] 12

Slika 2-2. Prikaz broja radova indeksiranih u bazi Scopus sa sintagmom „intellectual capital“ i riječi „dynamic“ u naslovu, sažetku ili među ključnim riječima od 1996. do danas [59]..... 14

Slika 2-3. Pregled tema u tri etape istraživanja IK-a (prema [80]) 15

Slika 2-4. Porast udjela članaka (u relevantnim časopisima) koji sadrže empirijska istraživanja u području IK-a [85], [86] 16

Slika 2-5. Prikaz rasta broja radova indeksiranih u bazi Scopus s riječi „teamwork“ u naslovu, sažetku ili među ključnim riječima u području inženjerstva od 1970. do danas [59] 17

Slika 4-1. Metodologija razvoja popisa i mreže indikatora 36

Slika 4-2. Rezultati validacije indikatora izvedbe u a) tvrtki A i u b) tvrtki B 41

Slika 4-3. Mreža indikatora izvedbe 46

Slika 4-4. Prikaz distribucije stupnja za mrežu nematerijalnih indikatora..... 47

Slika 4-5. Najbolji nematerijalni indikatori prema mjerama proizišlim iz analiza mreže 47

Slika 6-1. Pregled broja upitnika na koje je odgovoreno po članu tima tijekom razdoblja uzorkovanja 74

Slika 6-2. Pregled udjela upitnika na koje je odgovoreno u specifičnom intervalu nakon trenutka emitiranja (vrijeme potrebno za odgovaranje na upitnike) 75

Slika 6-3. Pregled udjela upitnika na koje je odgovoreno sa specifičnim tipom rada (s dodatnom podjelom timskih aktivnosti)..... 76

Slika 6-4. Pregled udjela upitnika na koje je odgovoreno, a vezanih za specifični kontekst... 76

Slika 6-5. Pregled načina provođenja aktivnosti tijekom uzorkovanja s podjelom na individualni tehnički rad i timski rad 78

Slika 6-6. Priroda obrade informacija u okviru individualnoga i timskoga rada 78

Slika 6-7. Pregled ocjena relevantnosti informacija s obzirom na prirodu obrade informacije 79

Slika 6-8. Pregled udjela vremena provedenog na pojedinom tipu rada (za svakog sudionika)..... 82

Slika 6-9. Pregled udjela vremena provedenog za pojedini kontekst (za svakog sudionika) pri individualnom tehničkom i timskom radu 83

Slika 6-10. Pregled udjela različitih načina provođenja aktivnosti (za svakog sudionika) pri individualnom tehničkom i administrativnom radu te timskom radu 83

Slika 6-11. Pregled udjela razvojnih aktivnosti u okviru: a) individualnoga tehničkog rada b) timskog rada (za svakog sudionika)..... 85

Slika 6-12. Pregled prosječnih vrijednosti indikatora za pojedinu kompetenciju na razini cijelog tima 92
Slika 6-13. Prosječne ocjena svih kompetencija za pojedinog sudionika 93
Slika 6-14. Primjer prikaza vrijednosti indikatora za određenu kompetenciju 94
Slika 6-15. Promjena vrijednosti indikatora CI_IN3, CI_IN4 i CI_IN5 102
Slika 6-16. Promjena vrijednosti indikatora CI_IN6, CI_IN9 i CI_IN12 103
Slika 6-17. Promjena vrijednosti indikatora CI_IN7, CI_IN10 i CI_IN13 104
Slika 6-18. Promjena vrijednosti indikatora CI_IN8 i CI_IN11 105
Slika 6-19. Promjene vrijednosti indikatora II_IN1 (*broj individualnih ideacijskih aktivnosti vezanih za proizvod*) i II_IN3 (*broj individualnih ideacijskih aktivnosti vezanih za ost. aspekte*) 110
Slika 6-20. Promjena vrijednosti indikatora II_IN2 (*udio individualnih ideacijskih aktivnosti vezanih za proizvod s visokom relevantnošću informacije*) i II_IN4 (*udio individualnih ideacijskih aktivnosti vezanih za ost. aspekte s visokom relevantnošću informacije*) 111
Slika 6-21. Promjena vrijednosti indikatora II_TM5 (*broj timskih ideacijskih aktivnosti vezanih za proizvod*) i II_TM7 (*broj timskih ideacijskih aktivnosti vezanih za ost. aspekte*) 112
Slika 6-22. Promjena vrijednosti indikatora II_TM6 (*udio timskih ideacijskih aktivnosti vezanih za domenu proizvoda s visokom relevantnošću informacije*) i II_TM8 (*udio timskih ideacijskih aktivnosti vezanih za ost. domene s visokom relevantnošću informacije*) 113
Slika 6-23. Promjena vrijednosti indikatora *motivacija tijekom individualnih aktivnosti* (MS_IN1) 116
Slika 6-24. Prikaz vrijednosti indikatora *osobno zadovoljstvo* (MS_IN2) 116
Slika 6-25. Promjena vrijednosti indikatora *motivacija tijekom timskih aktivnosti* (MS_TM1) 117
Slika 6-26. Promjena vrijednosti indikatora *udio aktivnosti s višom razinom motivacije* (MS_TM3) 117
Slika 6-27. Promjena vrijednosti indikatora *udio aktivnosti s višom razinom relevantnosti informacije* (MS_TM4) 118
Slika 6-28. Agregirane vrijednosti za CI_IN po danima 121
Slika 6-29. Agregirane vrijednosti za IN_IN i IN_TM po danima 122
Slika 6-30. Agregirane vrijednosti za MS_IN i MS_TM po danima 122
Slika 7-1. Postupak vrednovanja 123
Slika 7-2. Kompetencije poredane po utjecaju prema mjerama iz org. metamatrice 135
Slika 7-3. Resursi poredani po utjecaju prema mjerama iz org. metamatrice 137
Slika 7-4. Aktivnosti poredane po utjecaju prema mjerama iz org. metamatrice 138

POPIS TABLICA

Tablica 2-1. Usporedba uobičajene i nove paradigme intelektualnoga kapitala (prema [76]). 15

Tablica 3-1. Organizacijska metamatrica [24] 31

Tablica 4-1. Pregled elemenata ljudskoga kapitala na osnovi kojeg su definirani indikatori (temeljeno na elementima koje su identificirali Gonzalez-Loureiro i Figueroa Dorrego [7]) . 37

Tablica 4-2. Pregled elemenata strukturnoga kapitala na osnovi kojeg su definirani indikatori (temeljeno na elementima koje su identificirali Gonzalez-Loureiro i Figueroa Dorrego [7]) . 38

Tablica 4-3. Validacija indikatora izvedbe u tvrtki A i u tvrtki B..... 40

Tablica 4-4. Indikatori izvedbe intelektualnoga kapitala na individualnoj razini..... 42

Tablica 4-5. Indikatori izvedbe intelektualnoga kapitala na timskoj razini 43

Tablica 4-6. Rangiranje važnosti indikatora izvedbe IK (20 najbolje rangiranih indikatora).. 51

Tablica 4-7. Promjena vrijednosti skale prema Dawesu [183] 53

Tablica 5-1. Nematerijalni indikatori za koje će se podaci prikupljati uzorkovanjem rada..... 60

Tablica 5-2. Struktura opcija za unos koje su dostupne na izbornicima aplikacije za uzorkovanje rada 61

Tablica 5-3. Nematerijalni indikatori za koje će se podaci prikupljati anketom..... 65

Tablica 5-4. Nematerijalni indikatori za koje će se podaci prikupljati integracijom s postojećim korporativnim IT sustavima..... 70

Tablica 6-1. Udio tipa razvojnih aktivnosti u individualnom tehničkom i timskom radu 77

Tablica 6-2. Kontekst razvoja proizvoda prema tipu radne aktivnosti i razini motivacije za pojedinu aktivnost/kontekst..... 80

Tablica 6-3. Tip razvojnih aktivnosti prema prirodi transformacije informacija i relevantnosti informacije u pojedinoj aktivnosti..... 81

Tablica 6-4. Vrijednosti indikatora CK_IN4, CK_IN5 i CK_IN6 95

Tablica 6-5. Vrijednosti indikatora CK_TM1, CK_TM2 i CK_TM3..... 96

Tablica 6-6. Prikaz normaliziranih vrijednosti potrebnih za određivanje indikatora *udio društveno izoliranih članova tima* (CK_TM4)..... 96

Tablica 6-7. Prikaz normaliziranih vrijednosti potrebnih za određivanje indikatora *udio resursa koji nisu upotrijebljeni u zadovoljavajućoj mjeri* (CK_TM5) 97

Tablica 6-8.Vrijednosti indikatora CK_TM4 i CK_TM5 97

Tablica 6-9. Vrijednosti indikatora iz kategorije *komunikacija i razmjena informacija* na timskoj razini..... 106

Tablica 6-10. Prikaz vrijednosti indikatora CI_TM11 i CI_TM12 107

Tablica 6-11. Vrijednosti timskih indikatora za *inovativnost i ideaciju* koje su prikupljene anketom (II_TM1, II_TM2, II_TM3, II_TM4) 112
Tablica 6-12. Agregirane vrijednosti za CK_IN, CK_TM i CI_TM 120
Tablica 7-1. Vrijednosti ukupnih mjera izvedbe organizacije 133
Tablica 7-2. Pregled mjera za domenu *znanje* (prvi dio) 136
Tablica 7-3. Pregled mjera za domenu *znanje* (drugi dio) 136
Tablica 7-4. Pregled mjera za domenu *resursi* 137
Tablica 7-5. Pregled mjera za domenu *aktivnosti* 139

POPIS OZNAKA

$\mathcal{F}$	tok preferencije
V	skup indikatora
$\mathbb{R}$	skup realnih brojeva
X_i	potencijal indikatora *i*
α	luk koji spaja dva indikatora
n	broj čvorova (indikatora)
F	matrica toka
$\mathcal{A}$	skup lukova
w	vektor težine
Φ	funkcija vektora težine
ξ	jedinstvena fiksna točka funkcije Φ
I	vrijednost indikatora
ICK_j	agregirana vrijednost indikatora za kategoriju *j*
PVI	prilagođena vrijednost indikatora
S	broj uporišnih točaka skale
IVI	inicijalna vrijednost indikatora
N	broj točaka uzorkovanja
p	udio vremena koje sudionik provodi obavljajući referentnu aktivnost
R	razina preciznosti
$Z_{\lambda/2}$	broj standardnih devijacija
λ	razina značajnosti

POPIS KRATICA

AHP	*Analytic Hierarchy Process* (analitički hijerarhijski proces)
ANP	*Analytic Network Process* (analitički mrežni proces)
BO	broj odgovora
CAD	*Computer Aided Design* (konstruiranje pomoću računala)
DIC	*Direct Intellectual Capital* (metode direktnog izračuna intelektualnoga kapitala)
FMEA	*Failure mode and effects analysis* (analiza potencijalnih kvarova i njihovih posljedica)
HR	*Human resources* (ljudski potencijali)
I&R	istraživanje i razvoj
IAR	individualni administrativni rad
IK	intelektualni kapital
IM	razina individualne motivacije
IT	*Information technology* (informacijska tehnologija)
ITR	individualni tehnički rad
IVI	inicijalna vrijednost indikatora
M	matrica
MCM	*Market Capitalization Methods* (metode tržišne kapitalizacije)

ORA	*Organization Risk Analyzer* (analizator organizacijskih rizika)
PDA	*Personal digital assistants* (osobni digitalni pomoćnik)
PT	postotak ukupnog vremena
ROA	*Return on Assets methods* (metode određivanja povrata od imovine)
SC	*Scorecard Methods* (metode bodovanja)
TR	timski rad
UP	upravljanje projektima

1. Uvodna razmatranja

U prvom su poglavlju definirane osnovne značajke istraživanja. Na početku je objašnjena motivacija te cilj i svrha istraživanja. Poslije prikaza hipoteze i istraživačkih pitanja opisana je metodologija istraživanja s prikazom potrebnih koraka za provođenje istraživanja prikazanog u ovoj disertaciji. Poglavlje završava kratkim opisom teorijskih i praktičnih znanstvenih doprinosa.

Razvoj novih proizvoda i usluga preduvjet je kompetitivnosti i dugoročna uspjeha razvojnih tvrtki na tržištu s mogućnostima tvrtke u ostalim područjima kao što su npr.: planiranje razvojnih projekata, industrijski dizajn, simulacije i logistički kapaciteti. Prepreke uspješnosti razvojnih projekata proizlaze iz složenosti proizvoda i procesa razvoja, neodređenosti utjecajnih čimbenika i njihovih odnosa. Globalizacija dodatno utječe na složenost razvojnih procesa i proizvoda, ne samo porastom konkurencije već i raznolikošću zahtjeva koje proizvod treba ispuniti u različitim područjima tržišta koja proizlaze iz kulturnog i društvenog naslijeđa.

Kontinuirano mjerenje i praćenje izvedbe projekta nužno je za objektivnu i jasnu procjenu dinamike ostvarivanja ciljeva, ranu detekciju i ispravljanje pogrešaka te davanje pravodobne povratne informacije potrebne za uspješno upravljanje razvojnim projektima. Tradicionalni pristupi upravljanju projektima razvoja često ističu tehnički aspekt zanemarujući socio-tehničke elemente upravljanja (ponašanje, kultura, povjerenje). S napretkom informacijskih tehnologija tehnički je aspekt upravljanja projektima postao učinkovitiji te, relativno jednostavno, omogućuje analitički pristup upravljanju i procjeni rizika u projektima. Nedostatak postojećih pristupa opisao je Thamhain [1], koji tvrdi da je za učinkovito upravljanje razvojnim projektom potrebno obuhvatiti i socio-tehničku perspektivu – radne procese i značajke radnog okruženja.

Obilježja su razvojnih projekata brojne povratne veze te nelinearni i zakašnjeli učinci na ciljeve projekta [2], [3], [4], [5]. Radi boljeg razumijevanja uzroka nastanka povratnih veza te nelinearnosti projekata potrebno je mjeriti izvedbu projekta u stvarnom vremenu. Mjerenjem izvedbe projekta može se procijeniti uspješnost projekta prema različitim kriterijima. Takav je pristup osobito važan pri upravljanju inovativnim projektima u kojima ima dodatne neizvjesnosti. Pregledom stručne i znanstvene literature iz upravljanja projektima razvoja

tehničkih sustava (npr.[1], [6]), u kojoj se analizira mjerenje projektne izvedbe i upravljanje rizicima u kompleksnim razvojnim procesima, prepoznati su ključni nedostaci postojećih modela za analizu, praćenje i predviđanje izvedbe razvojnih projekata u stvarnom vremenu na individualnoj, timskoj i organizacijskoj razini. Shenhar i Dvir [6] ističu da metode upravljanja projektima temeljene na praćenju vremena, troškova i kvalitete zanemaruju brojne druge čimbenike uspješnosti ishoda projekta kao što su stečeno znanje, proces učenja, rast tvrtke na tržištu, inovativnost i intelektualno vlasništvo te razvojni kapacitet tvrtke.

Prema dostupnoj literaturi iz upravljanja i mjerenja izvedbe razvojnih projekata, jednom od glavnih tema istraživanja nameće se potreba za kvantifikacijom indikatora koji su nematerijalni i nefinancijski. U posljednjih nekoliko godina istraživači su uvelike zainteresirani za mjerenje elemenata intelektualnoga kapitala (IK) radi predviđanja uspješnosti razvojnih projekata. Istodobno, suvremena je paradigma istraživanja IK-a uglavnom eksplorativna te se svodi na epistemiološke rasprave o teorijskim modelima [7]. Iako je neupitna važnost eksplorativnih pristupa, temeljnu je razinu istraživanja potrebno nadograditi promatranjem elemenata IK-a u razvojnim tvrtkama.

Istraživači (npr. [8]) smatraju da su voditeljima projekata potrebne nove metode i indikatori za mjerenje evolucije IK-a na razini pojedinaca, timova i organizacije koji bi unaprijedili donošenje odluka u razvojnim projektima. Nove metode zahtijevaju proširenje indikatora koji omogućuju praćenje ponašanje pojedinaca i timova, razmjenu znanja, rješavanje tehničkih problema i stvaranje novih ideja. Prema Lohmanu i dr. [9], indikator izvedbe varijabla je koja pokazuje učinkovitost ili uspješnost sustava ili procesa iz određene perspektive ili prema zadanom planu. Veleva i Ellenbecker [10] indikatore nazivaju i parametrima, čije vrijednosti proizlaze iz mjerenja i analize prikupljenih podataka interpretiranih u kontekstu. Takav je pristup praktičan i lako razumljiv te se često primjenjuje za mjerenje IK-a. Osim uvođenja novih nematerijalnih indikatora, potrebno je utvrditi međusobnu povezanost indikatora unutar pojedinih elemenata IK-a, čime bi se znatno proširila perspektiva projektnim voditeljima razvoja tehničkih sustava u skladu s prijedlogom Verbano i Creme [8] te im se olakšalo donošenje odluka povezanih s izvedbom projekta.

Mjerenje izvedbe projekta često je implicitno vezano uz identifikaciju i upravljanje projektnim rizicima [11], [12]. Budući da je prema ISO-u [13] rizik definiran kao „efekt nesigurnosti u odnosu prema postavljenom cilju”, proces upravljanja rizicima omogućuje prilagodbu percepcije i razumijevanja rizika ciljevima projekta i mjerenju uspješnosti.

Pregledom literature iz upravljanja rizicima uočljiv je velik raskorak između teorije i praktične primjene metoda i tehnika upravljanja rizicima u razvoju kompleksnih tehničkih sustava što je izazov za brojne istraživače, ali i eksperte iz industrije [14]. Iako su u literaturi objavljene brojne metode, tehnike i alati upravljanja rizicima u razvoju kompleksnih tehničkih sustava, u praksi se primjenjuje relativno reduciran skup metoda, tehnika i alata. Prema Tarounu [15], većina metoda za upravljanje rizicima subjektivne su i promatraju rizik kao dvodimenzionalni fenomen vjerojatnosti i utjecaja. Koristeći se dvodimenzionalnim modelom vjerojatnosti i utjecaja kao temeljem analize, brojne aktualne metode (npr. AHP, FMEA, metode *Fuzzy* itd.) pritom ne uzimaju u obzir međuovisnosti između pojedinačnih rizika.

Neke studije upravljanja kompleksnim projektima prikazale su efekte nelinearnog ponašanja unutar organizacija [16] kao što je nastajanje cikličnih rizika i obrazaca rizika koji se ponavljaju [17], ali bez potrebne teorijske osnove i objašnjenja. Za bolje razumijevanje fenomena rizika u razvojnim projektima te za unapređenje upravljanja rizicima općenito potrebno je proširiti postojeće modele rizika uzimajući u obzir izvedbu projekta u realnom vremenu i promjene nematerijalnih indikatora. Trenutačno dostupne metode promatraju rizik kao pojedinačni događaj, koji je odijeljen od prijašnjih i budućih događaja, s vrijednostima vjerojatnosti i utjecaja određenim na temelju iskustva, ali bez formalne evaluacije. Mnogim se pojedinačnim rizicima tako može upravljati, ali ne i posljedicama njihove interakcije te njihovih kumulativnih učinaka koji mogu znatno negativno utjecati na izvedbu projekta. Prema Thamhainovim [1] tvrdnjama, organizacije prilično uspješno identificiraju i analiziraju poznate rizike, ali neuspješno rješavaju problematiku rizika koja proizlazi iz njihove interakcije.

1.1. Cilj i svrha istraživanja

Cilj je istraživanja razvoj modela i metode za praćenje i mjerenje izvedbe projekata razvoja tehničkih sustava nematerijalnim indikatorima na individualnoj i timskoj razini te identifikacija organizacijskih rizika vezanih uz te indikatore. Takav cilj zahtijeva da se u okviru istraživanja provede:

1) analiza interakcija između pojedinaca i timova u razvoju tehničkih sustava radi stvaranja osnova za praćenje i mjerenje dinamike razvoja elemenata intelektualnoga kapitala

2) modeliranje dinamike razvoja elemenata intelektualnoga kapitala i njihove interakcije tijekom razvoja tehničkih sustava kako bi se nadogradili postojeći pristupi upravljanju projektima.

Analizom interakcija navedenih pod točkom 1 omogućit će se bolje razumijevanje i interpretacija razvoja tehničkih sustava te stvoriti preduvjeti za modeliranje dinamike razvoja elemenata intelektualnoga kapitala. Tako definirane osnove za praćenje i mjerenje dinamike elemenata intelektualnoga kapitala u okviru razvoja tehničkog sustava omogućit će teorijsku i praktičnu podlogu nužnu za kreiranje sustava vrednovanja elemenata intelektualnoga kapitala. Saznanja i spoznaje dobivene analizom interakcija i modeliranjem dinamike intelektualnoga kapitala mogu nadograditi postojeće metode za upravljanje razvojnim projektima. Primijenjeni aspekti istraživanja podrazumijevaju razvoj alata koji može pomoći organizacijama u provođenju aktivnosti razvoja tehničkih sustava i ponuditi voditeljima projekata drukčiji pogled na praćenje razvojnih aktivnosti.

1.2. Hipoteza i istraživačka pitanja

Predloženim istraživanjem verificirat će se hipoteza da sustav vrednovanja elemenata intelektualnoga kapitala omogućuje praćenje dinamike projekata razvoja tehničkih sustava i evaluaciju razvojnih projekata u realnom vremenu te se time unapređuju postojeći pristupi tradicionalnom upravljanju projektima razvoja tehničkih sustava.

Na temelju predložene hipoteze, odnosno osnovne pretpostavke istraživanja, osmišljena su sljedeća istraživačka pitanja:

1. Koje se metode za mjerenje elemenata intelektualnoga kapitala na individualnoj i timskoj razini mogu primijeniti u projektima razvoja tehničkih sustava?
2. Kako se može modelirati međusoban utjecaj pojedinih nematerijalnih indikatora na individualnoj i timskoj razini?
3. Kako prikupiti podatke o nematerijalnom aspektu aktivnosti tijekom razvoja tehničkih sustava?
4. Kako odrediti doprinos pojedinih mjerenih nematerijalnih indikatora razvoju elemenata intelektualnoga kapitala za pojedince i timove?
5. Kako identificirati rizike organizacijske strukture vezane za nematerijalnu perspektivu?

U disertaciji će se prikazati postupak definiranja nematerijalnih indikatora te modela agregacije indikatora na individualnoj i timskoj razini. Predloženi model temeljit će se na teorijskim i praktičnim istraživanjima provedenim u stvarnom, industrijskom okruženju.

1.3. Metodologija istraživanja

Istraživanje na području upravljanja projektima razvoja tehničkih sustava obuhvaća formulaciju modela i teorija o fenomenima unutar tog okruženja, kao i stvaranje te validaciju znanja, metoda i alata temeljenih na tim modelima i teorijama radi unapređenja procesa i ishoda razvoja tehničkih sustava [18]. Postojeći trend prema istraživanjima potvrđenima u praktičnom okruženju [19] podrazumijeva kombiniran pristup istraživanju s brojnim kvalitativnim i kvantitativnim metodama istraživanja.

Pragmatizam kao suvremena istraživačka paradigma omogućuje povezivanje i objedinjavanje različitih pristupa, što je nužno s obzirom na prirodu područja istraživanja [20]. U upravljanju projektima razvoja tehničkih sustava brojni se istraživači [21] zauzimaju za odbacivanje pozitivizma te podržavaju pragmatizam kao temeljnu istraživačku paradigmu.

Socio-tehničko okruženje u kojem se danas odvijaju procesi razvoja tehničkih sustava zahtijeva metodološki pluralizam obuhvaćajući brojne deduktivne i induktivne pristupe istraživanju. Općenito, metodologija istraživanja treba podržavati planirani proces istraživanja te pridonijeti vjerodostojnosti i ispravnosti rezultata, iako je potrebno uzeti u obzir to da je priroda metodologija koje služe za istraživanje socio-tehničkih pojava heuristička.

Metodologija istraživanja obuhvaća preliminarno istraživanje, modeliranje, prikupljanje podataka, analizu te validaciju rezultata istraživanja. Uvođenjem elemenata iz opće metodologije istraživanja u znanosti o konstruiranju [18] utvrđena je metodologija istraživanja koja se sastoji od ovih koraka:

1) Preliminarno istraživanje – početak istraživanja zahtijeva pregled postojeće stručne i znanstvene literature unutar područja istraživanja. Na temelju pregleda literature utvrđuje se postojeće stanje u području istraživanja i definiraju njegove osnovne pretpostavke. Radi detaljna opisivanja postojeće situacije i smjernica daljnjeg istraživanja provodi se empirijsko istraživanje u obliku opservacija i analize postojećih procesa razvoja tehničkih sustava.

Kao rezultat ovog koraka, postavljaju se ciljevi istraživanja (poglavlje 1.1) i definiraju glavni istraživački problemi, pitanja i hipoteza (poglavlje 1.2). Također, definiraju se relevantne

discipline i područja koja je potrebno obuhvatiti daljnjim pregledom literature i postojećih pristupa.

2) Modeliranje – u ovom se koraku teži predlaganju novih metoda i modela za podršku procesu upravljanja razvojem tehničkih sustava. Razvoj modela i metoda podrazumijeva uključivanje glavnih teorijskih principa socio-tehničkih sustava, upravljanja razvojem tehničkih sustava, upravljanja intelektualnim kapitalom i dostupnih empirijskih podataka.

Tijekom ovoga koraka identificiraju se elementi intelektualnoga kapitala i njihovi pojedinačni operativni indikatori na individualnoj i timskoj razini za projekte razvoja tehničkih sustava. Cjelovitost i konzistentnost popisa nematerijalnih indikatora i mreže njihove interakcije provjerit će se u praksi sudjelovanjem tvrtki na primjerima stvarnih projekata razvoja tehničkih sustava. Analiza dobivenih rezultata obuhvatit će identifikaciju utjecaja između pojedinih indikatora. Na temelju identificiranih veza između indikatora izradit će se kvalitativni i matematički model njihove interakcije Metodom potencijala [22]. Metoda potencijala omogućuje postupak samorangiranja korištenjem hijerarhijskom strukturom indikatora s povratnim vezama. Na temelju izrađenih grafova s intenzitetima preferencija izračunat će se težinski faktori kao preduvjet za kreiranje matematičkog modela agregacije individualnih indikatora u indikatore kategorija intelektualnoga kapitala. Također se provodi analiza kreiranoga mrežnog modela izračunom statističkih svojstava mreže i pojedinačnih indikatora. Provjera konzistentnosti i funkcionalnosti modela preduvjet je sljedećeg koraka u istraživanju. Predloženi mrežni model nematerijalnih indikatora izvedbe omogućit će i praćenje rizika vezanih uz razvoj elemenata intelektualnoga kapitala tijekom procesa razvoja proizvoda.

3) Prikupljanje podataka – na početku se detaljno analizira tvrtka u kojoj će se metode i modeli provoditi jer je za pravilno prikupljanje podataka potrebno uzeti u obzir specifičnosti njenih razvojnih procesa. Ovaj se korak izvodi metodama poput anketa (npr. za ocjenu kompetencija primijenit će se 360-stupanjska procjena izvedbe) i uzorkovanja rada (engl. *work sampling*).

4) Analiza podataka – poslije prikupljanja podataka, analiziraju se kumulativne vrijednosti mjera za cijelo razdoblje uzorkovanja te vrijednosti indikatora dobivene preslikavanjem iz podataka uzorkovanja i provedenih anketa. Zatim se analiziraju promjene pojedinačnih vrijednosti indikatora radi praćenja trendova tijekom razvoja tehničkog sustava, ali i njihov utjecaj na agregirane vrijednosti elemenata intelektualnoga kapitala.

5) Vrednovanje – vrednovanje unutarnje konzistentnosti i vanjske relevantnosti predložene metode temelji se na „validacijskom kvadratu“ [23] te usporedbi dobivenih rezultata s metodom analize organizacijskih rizika [24]. U zadnjem se koraku rezultati istraživanja potvrđuju teorijski i praktično te se vrednuju ciljani teorijski i praktični znanstveni doprinosi. Uspoređivanjem postignutih rezultata s postavljenim ciljevima istraživanja definiraju se prednosti i nedostaci modela i metode proizišle iz istraživanja. Ishod ove faze podrazumijeva i predlaganje potrebnih unapređenja te smjernica za primjenu u svakodnevnim procesima razvoja tehničkih sustava. Na temelju zaključaka i saznanja iz završne faze istraživanja mogu se postaviti smjerovi budućih istraživanja.

Iako je opisana metodologija izložena sekvencijalno, brojne su iteracije između pojedinačnih koraka istraživanja. Time se omogućuje primjena različitih metoda i pristupa pri izvršavanju pojedinih faza na temelju novostečenog znanja i iskustva, ali i naknadna reformulacija ciljeva te ishoda pojedinih koraka istraživanja.

1.4. Očekivani znanstveni doprinos

Očekivani doprinos predloženog istraživanja, u sklopu izrade doktorskog rada, očituje se u:

1) teorijskom doprinosu u obliku modela i metoda za upravljanje socio-tehničkim aspektom projekata razvoja tehničkih sustava modeliranjem dinamike nematerijalnih indikatora i rizika u stvarnom vremenu

2) praktičnom doprinosu procesu upravljanja projektima razvoja tehničkih sustava razvojem alata za mjerenje i praćenje socio-tehničkog aspekta projekata tijekom razvoja tehničkih sustava.

1.5. Struktura disertacije

Ova je disertacija podijeljena na osam poglavlja. U prvom je poglavlju objašnjena motivacija, cilj i svrha istraživanja, a potom su navedeni hipoteza i istraživačka pitanja. Također je opisana metodologija istraživanja s prikazom potrebnih koraka za provođenje istraživanja prikazanog u radu.

U drugom je poglavlju područje istraživanja objašnjeno trima tematskim cjelinama: Upravljanje razvojnim projektima, Upravljanje intelektualnim kapitalom i Timski rad u razvoju tehničkih sustava. Za svaku od triju tematskih cjelina dan je pregled literature radi boljeg pozicioniranja istraživanja te definiranja postojećeg stanja u navedenim područjima.

Preostale su teorijske osnove u trećem poglavlju. Nakon preliminarnog uvoda u opća područja istraživanja u drugom poglavlju, u trećem je opis postojećih metoda i pristupa za mjerenje elemenata intelektualnoga kapitala i izvedbe pojedinaca, timova i organizacija u razvojnim projektima. Dan je pregled literature metoda vrednovanja i agregacije koji je nužan za uvođenje matematičkih osnova potrebnih za izradu matematičkog modela agregacije indikatora. U ovom su poglavlju također objašnjeni organizacijski rizici koji proizlaze iz nematerijalnih indikatora te metode za njihovu identifikaciju i analizu.

U četvrtom je poglavlju prikazan postupak razvoja nematerijalnih indikatora za praćenje razvoja tehničkih sustava. Opisan je postupak kreiranja i validacije popisa i mreže indikatora, ali i način na koji je definiran model agregacije nematerijalnih indikatora.

Opis postupka prikupljanja podataka za predložene indikatore nalazi se u petom poglavlju, a u šestom je poglavlju prikazana analiza rezultata provedene studije slučaja. Analiza je podijeljena u tri dijela: 1. analiza prikupljenih podataka uzorkovanjem rada, 2. analiza vrijednosti indikatora, 3. analiza agregiranih vrijednosti za pojedine kategorije intelektualnoga kapitala. Rezultati dobiveni provedenom studijom slučaja uspoređeni su s rezultatima drugih istraživanja.

Nakon prikaza provedene studije slučaja, u sedmom poglavlju prikazan je postupak vrednovanja predložene metode koja se sastoji od upotrebe metode „validacijskoga kvadrata“ i usporedbe s metodom za analizu organizacijskih rizika.

U završnom su poglavlju sažetak istraživanja, rasprava i smjerovi budućeg istraživanja. Odgovarajući na istraživačka pitanja postavljena u uvodnom poglavlju, objašnjeni su ishodi i doprinos provedenog istraživanja

.

2. Pregled područja istraživanja

U drugom je poglavlju objašnjeno područje istraživanja koje se sastoji od triju tematskih cjelina: Upravljanje kompleksnim razvojnim projektima, Upravljanje intelektualnim kapitalom i Timski rad u razvoju tehničkih sustava. Uza svaku je od triju tematskih cjelina pregled literature radi boljeg pozicioniranja istraživanja te objašnjenja postojećeg stanja u navedenim područjima. U potpoglavlju Upravljanje kompleksnim razvojnim projektima uvedeni su i definirani pojmovi razvojnih projekata i upravljanja projektima te opisana postojeća promjena paradigme u području upravljanja projektima. U potpoglavlju Upravljanje intelektualnim kapitalom objašnjen je koncept intelektualnoga kapitala i njegovih sastavnica. Također su prikazani trenutačni smjerovi istraživanja u području intelektualnoga kapitala te objašnjena promjena fokusa na empirijska istraživanja. Kao logičan nastavak, u posljednjem potpoglavlju prikazan je pregled dosadašnjih istraživanja timskog rada u razvoju tehničkih sustava.

2.1. Upravljanje razvojnim projektima

Upravljanje projektom (UP) neprestano se razvija kao profesija, ali i kao područje istraživanja. S obzirom na njegovu važnu primjenu u različitim razvojnim kontekstima i granama industrije, nužno je stalno praćenje zahtjeva u tom području. Promjene utječu na način na koji se shvaća i percipira upravljanje projektom, ali i provodi u praktičnom okruženju [25].

U prevladavajućoj paradigmi upravljanja projektom smatra se da je projekt vremenski ograničen i jednokratan zadatak za čije je vođenje odgovoran voditelj projekta [26]. Prema Pintu i Slevinu [27], značajke su projekta: 1. definirani početak i kraj, 2. specifični predodređeni cilj, 3. niz kompleksnih ili međupovezanih aktivnosti, 4. ograničeni proračun. S druge strane, već su i prije pojedini istraživači isticali važnost ljudske perspektive pri definiranju projekta. Na primjer, Reiss [28] ističe da je projekt ljudska aktivnost kojom se postiže jasan cilj u određenom vremenskom razmaku.

Upravljanje projektom može se definirati kao primjena znanja, vještina, alata i tehnika u projektnim aktivnostima radi ispunjavanja projektnih zahtjeva [29]. Lock [30] definira svrhu upravljanja projektom kao planiranje, organizaciju i kontrolu aktivnosti radi uspješna provođenja projekta unatoč rizicima i nesigurnostima.

Uz navedene, i druge definicije projekta i UP-a u literaturi su općenite. U praksi upravljanje projektom najčešće obuhvaća specifičan skup metoda i alata koje se strogo temelje na tehničkoj perspektivi UP-a [31]. Tehnička perspektiva upravljanja projektom proizlazi iz pozitivističkog pristupa rješavanju problema i provođenju projekta. S obzirom na prepoznatu važnost tehničke perspektive UP-a, razvijen je velik broj metoda i alata za UP [1]. Ipak, brojni autori navode da postojeće metode i alati za upravljanje projektom nisu prikladni za kompleksne razvojne projekte, iako se često primjenjuju za tu svrhu [1], [32], [33], [34]. Primjerice, Rodrigues i Williams [35] navode nedostatke u primjeni PERT-a i WBS-a u kompleksnim projektima. Turner [36] tvrdi da je nužno mijenjati postojeću paradigmu UP-a temeljenu na kvantitativnim pristupima jer potpomaže lažni osjećaj sigurnosti [37].

U takvu se okruženju uspješnost projekta razmatra pomoću kriterija vremena, troškova i kvalitete, što se naziva i „željeznim trokutom“ [38]. Današnja praksa još podrazumijeva korištenje mjerama projektne izvedbe koje se uglavnom temelje na opipljivim i materijalnim aspektima [1]. U tom smislu, Snider i dr. [39] proširuju shvaćanje materijalnih aspekata projekata te predlažu praćenje inženjerskih informacijskih objekata radi boljeg razumijevanja i predviđanja izvedbe projekta.

Posljedica je prevladavajuće tehničke paradigme UP-a raskorak između teorije i prakse upravljanja kompleksnim razvojnim inženjerskim projektima (u smislu organizacijske, tehnološke i informacijske kompleksnosti) što je velik problem za istraživače i za industriju. Suvremeni pristupi UP-u često zanemaruju nematerijalne aspekte (ponašanje, kultura, povjerenje itd.), iako brojni istraživači ističu njihovu važnost. Atkinson [38] tvrdi da aktivnosti UP-a koje počivaju isključivo na mjerama vremena, troškova i kvalitete pokazuju određene nedostatke pri upravljanju kompleksnim razvojnim projektima. On smatra da takav pristup nije pogrešan, ali je nepotpun jer ne uključuje mjere vezane za informacijske sustave, dobrobit organizacije i dobrobit drugih zainteresiranih strana. Pollack [40] sugerira da čimbenici uspješnosti projekta ovise o međuljudskim odnosima i da su povezani s organizacijskom kulturom. Analizom uzroka problema u projektima, Posner [41] zaključuje da primarna problematika voditelja projekta nije tehnička, već ljudska. Yeo [42] smatra da upravo zbog pretjerana isticanja tehničke perspektive UP-a dolazi do neuspjeha projekta. Cooke-Davis [43] također navodi važnost „ljudskih faktora“ koji su povezani sa svim ostalima faktorima uspješnosti jer ljudi provode projekte. Na istom je tragu i Chapman [44] koji tvrdi da zanemarivanje društvene perspektive projekata može donijeti pogrešnu i nepotpunu procjenu mogućih rizika jer analiza projektnih rizika često zahtijeva analizu

ljudskoga kapitala, koji je teže mjerljiv i razumljiv [31]. Dakle, korištenje isključivo „željeznim trokutom“ kao skupom faktora uspješnosti nije dovoljno u praćenju izvedbe socio-tehničke perspektive projekata. Brojni su različiti aspekti UP-a međusobno usko vezani i nije uputno opisivati projekte isključivo koristeći se materijalnom perspektivom, već je potrebno obuhvatiti socio-tehničku perspektivu projekta i organizacije.

Uspostava ravnoteže između nematerijalnog aspekta UP-a (npr. osobnih karakteristika zaposlenika) te materijalnog aspekta UP-a (npr. ograničenja vremena i troškova) ključna je za uspješno provođenje projekta. Ako je voditelj projekta uspješan u identificiranju i vrednovanju nematerijalnog aspekta UP-a te u uravnoteživanju nematerijalnog i materijalnog UP-a, vjerojatnost za krajnji uspjeh projekta raste [45], [46].

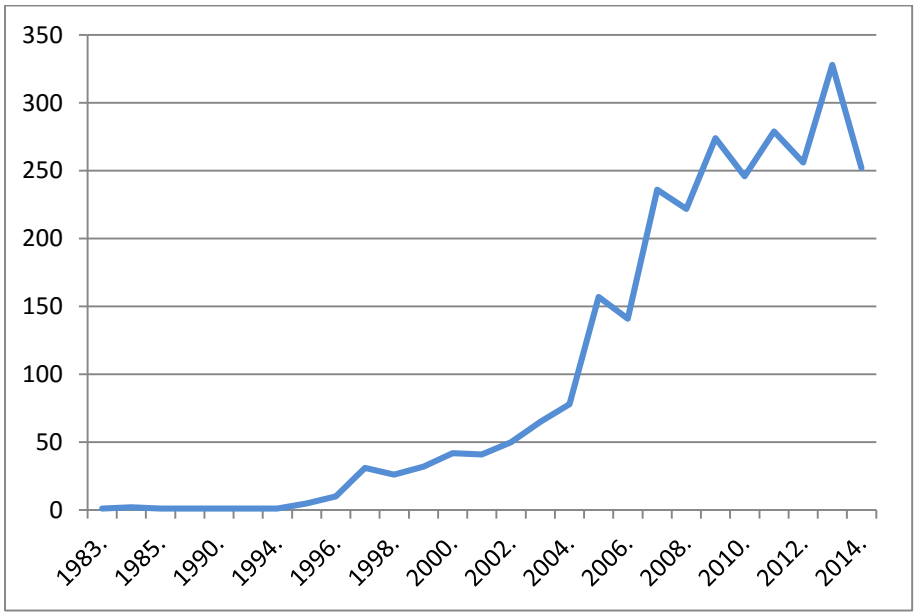
Prijenos znanja s jednog projekta na drugi projekt navodi se kao dodatna značajka UP-a i jedan od ključnih čimbenika dugoročna uspjeha [47], [48]. Uspješan prijenos znanja s jednog projekta na drugi skraćuje vrijeme i troškove potrebne za drugi projekt. Shenar i dr. [48] ističu razlike između kratkoročne i dugoročne evaluacije izvedbe projekta. Kratkoročna je evaluacija usko vezana uza završavanje projekta u smislu tradicionalnih kriterija njegove uspješnosti. Dugoročna je evaluacija vezana uz potencijal koji je stvoren za nove projekte. Takvim pristupom evaluaciji ističe se važnost zadržavanja identificiranih ključnih članova razvojnog tima iz prijašnjih uspješnih projekata kako bi mogli pridonositi i na budućim projektima (npr. [49]). Kao osnova za praćenje dugoročne uspješnosti projekta i organizacije opet se navodi važnost „ljudske“ perspektive upravljanja projektima.

Iako bi se provođenje kompleksnih projekata moglo shvatiti kao proces za koji je iznimno važna društvena komponenta te je određen poviješću, kontekstom, individualnim vrijednostima i okruženjem – aktualnošću projekta [50], u literaturi je praćenje nematerijalnih i neopipljivih aspekata još uvijek nedovoljno istraženo. Sadašnje su metode za praćenje nematerijalnog aspekta projekta na individualnim i timskim razinama rijetke i raspršene po različitim područjima istraživanja. Za unapređenje UP-a općenito potrebno je proširiti postojeće modele, metode i alate UP-a kako bi se obuhvatili nematerijalni aspekti projektne izvedbe [51], [52], [53], [54]. Proširenjem kriterija uspješnosti uzimajući u obzir nematerijalne aspekte razvojnih projekata [52], [53], [55], [56] i postavljanjem temelja za mjerenje intelektualnoga kapitala u inženjerskom kontekstu otvaraju se mogućnosti prikupljanja novih spoznaja te se daje širi pogled na praćenje i mjerenje izvedbe projekta.

2.2. Upravljanje intelektualnim kapitalom

Brojne i različite definicije intelektualnoga kapitala (IK) objašnjavaju taj fenomen na različite načine, no uglavnom se intelektualnim kapitalom smatra nematerijalna i neopipljiva imovina na temelju koje se može stvoriti nova vrijednost u organizaciji. Intelektualni se kapital može definirati i kao kombinacija aktivnosti i nematerijalnih resursa organizacije (ljudski, strukturni i relacijski) [57]. Prema Edvinssonu i Sullivanu [58], IK podrazumijeva *znanje koje se može pretvoriti u vrijednost*.

Zbog isticanja važnosti organizacijskoga učenja i ljudskoga kapitala kao glavnih razloga uspješnosti mnogih organizacija, u posljednja dva desetljeća naglo je poraslo zanimanje za istraživanja u području IK-a (Slika 2-1).



Slika 2-1. Prikaz broja radova indeksiranih u bazi Scopus sa sintagmom „intellectual capital“ u naslovu, sažetku ili među ključnim riječima od 1983. do danas [59]

U prvoj etapi istraživanja IK-a definirani su brojni „okviri intelektualnoga kapitala“ radi isticanja njegove važnosti *za postizanje i održavanje kompetitivne prednosti na tržištu* [60], a u drugoj se fazi istraživanja IK-a proučavao njegov utjecaj na organizacijsku izvedbu iz perspektive financija i stvaranja vrijednosti [61], [62], [63], [64]. Za proučavanje utjecaja IK-a na različite aspekte organizacijske izvedbe upotrebljavaju se različite klasifikacije IK-a, no uvriježen model IK-a sastoji se od triju komponenata – ljudskoga kapitala, strukturnoga kapitala i relacijskoga kapitala [57], [65], [66].

Ljudski je kapital skup vrijednosti, stavova, iskustva, vještina, motivacije, kompetencija i znanja koje posjeduju zaposlenici. On je nematerijalna imovina svakog pojedinca i

organizacija ga ne može posjedovati, osim njegovom preobrazbom u materijalni oblik kao što je novi proizvod [67], [68].

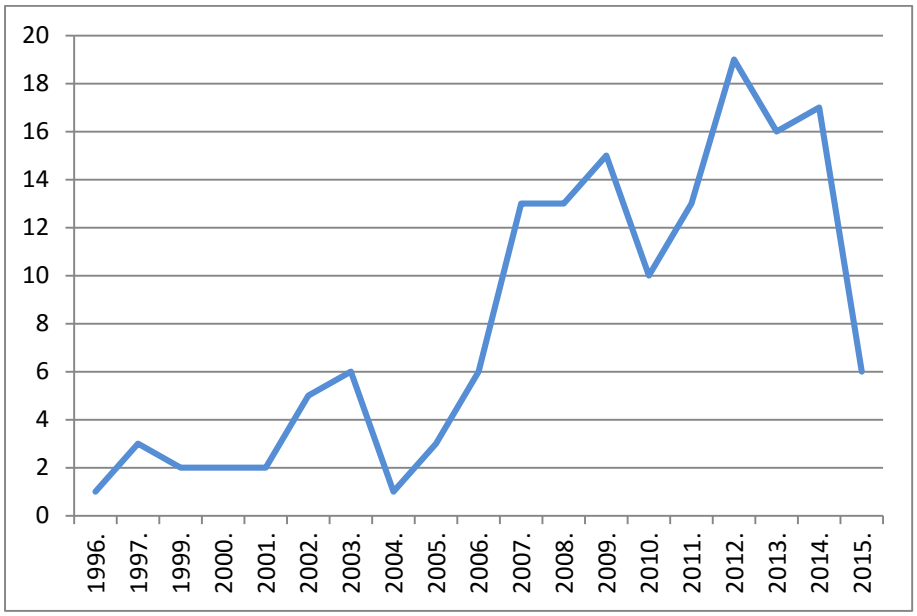
Strukturni (ili organizacijski) kapital uključuje svu nefizičku infrastrukturu, tehnologije, patente, procese i baze podataka organizacije koji su nužni za rad zaposlenika te omogućuju funkcioniranje organizacije. Strukturni je kapital institucionalizirano znanje i iskustvo koje se nalazi u informacijskim sustavima, organizacijskoj strukturi i organizacijskoj kulturi [69], [70], [71].

Kao posljednja komponenta intelektualnoga kapitala u literaturi se navodi relacijski kapital koji je definiran kao vrijednost koju organizacija stvara odnosima s kupcima, dobavljačima, tržišnim konkurentima itd. Relacijski kapital proizlazi iz sposobnosti organizacije da u interakciji s ostalim organizacijama unaprijedi stvaranje vrijednosti. Organizacije s velikim relacijskim kapitalom uspješno prate promjenu zahtjeva i potreba korisnika i kupaca [72], [73].

Iako postoje brojne modifikacije i varijacije koje se neznatno razlikuju od gore prikazana modela, mogu se svesti na tri navedene komponente IK-a. Na primjer, osobne kompetencije, vještine i iskustva pripadaju ljudskom kapitalu jer su svojstveni pojedincu.

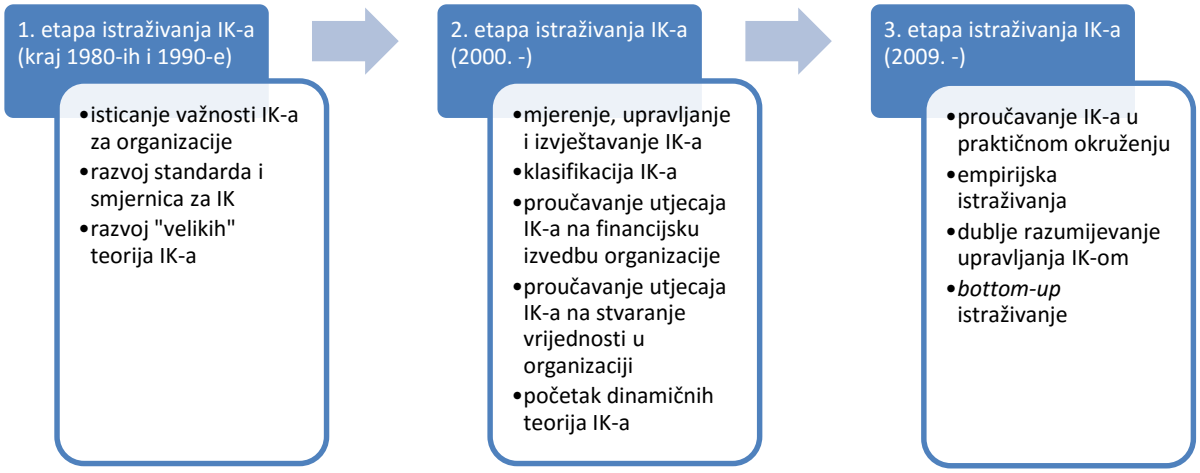
Ovaj prevladavajući model uvelike utječe na način praćenja i mjerenja IK-a tijekom druge etape njegova istraživanja. Poslije odgovora na pitanje što je IK i od čega se sastoji, u drugoj se etapi postavilo pitanje mjerenja njegovih elemenata [74]. Upravljanje IK-om prepoznato je kao ključan čimbenik u stvaranju financijskoga kapitala (bogatstva) organizacije te su razvijene brojne metode i alati za praćenje elemenata IK-a radi provjere sposobnosti organizacije da ispuni tražene zahtjeve i postigne uspjeh [75] (odabrani pristupi prikazani su u poglavlju 3.2). U ovoj su etapi počele i glasne polemike o potrebi za dinamičnom teorijom intelektualnoga kapitala. Viedma Marti [76] tvrdi da postojećoj paradigmi istraživanja IK-a *nedostaje dinamičnosti i fleksibilnosti koja je potrebna u modernom okruženju. Fokusirajući se na postojeću nematerijalnu imovinu (ljudski, strukturni i relacijski kapital), takvi modeli IK-a podložni su opasnom redukcionizmu.* Kianto [77], pak, tvrdi da se u pozadini takvog modela IK predstavlja kao zaliha ili dobra kojima se može upravljati kao i s materijalnim i opipljivim aspektima organizacije. Bratianu [78] to potvrđuje i kritizira linearnost i materijalistički pristup takvoga modela IK-a. Viedma Marti [76] u svom je radu identificirao i analizirao osnovne principe u postojećem i uvriježenu modelu te predložio postulate nove paradigme teorije IK-a (Tablica 2-1).

U okviru nove paradigme uočljive su promjene prema dinamičkom pogledu na intelektualni kapital i promjene razine proučavanja i analize IK-a unutar organizacije. O'Donnel [79] u svojem kritičkom osvrtu ističe potrebu za istraživanjima čiji je cilj proučavanje dinamike nematerijalnog aspekta te nastanak i evolucija IK-a unutar organizacijskog okruženja. U posljednjih deset godina sve je više radova o dinamici u okviru IK-a (Slika 2-2).



Slika 2-2. Prikaz broja radova indeksiranih u bazi Scopus sa sintagmom „intellectual capital“ i riječi „dynamic“ u naslovu, sažetku ili među ključnim riječima od 1996. do danas [59]

Kao sastavni dio druge etape istraživanja IK-a, mnogi su istraživači (npr. [7]) analizirali povezanost komponenti IK-a i određene dimenzije organizacijske izvedbe (Slika 2-3). U takvu se istraživanju za svaku komponentu IK-a identificira određeni broj pripadajućih faktora te se traže veze između faktora komponenti IK-a i određene dimenzije organizacijske izvedbe prema provedenoj statističkoj analizi. Dumay i Garanina [80], u svojem kritičkom osvrtu, tvrde da takva istraživanja vode različitim zaključcima te da se ne može postići znanstveni konsenzus. Riahi-Belkaoui [81] i Chen i dr. [82] u svojem su istraživanju otkrili pozitivnu vezu između IK-a i financijske izvedbe organizacije, a Firer i Williams [83], ispitujući vezu IK-a i financijske izvedbe organizacije, nisu uspjeli pronaći nikakvu povezanost. Uočljivo je također da predmet istraživanja nisu relacije između mjerljivih indikatora, već između identificiranih faktora triju komponenata IK-a. Tako su brojni modeli veza kreirani na temelju anketa u kojima su sudjelovali predstavnici različitih organizacija, a ne na temelju stvarnih mjerljivih podataka u organizacijama. Uočava se da povezanost između različitih komponenata IK-a nije svedena na razinu projekata, iako brojni faktori označavaju elemente ljudskoga i strukturnoga kapitala.

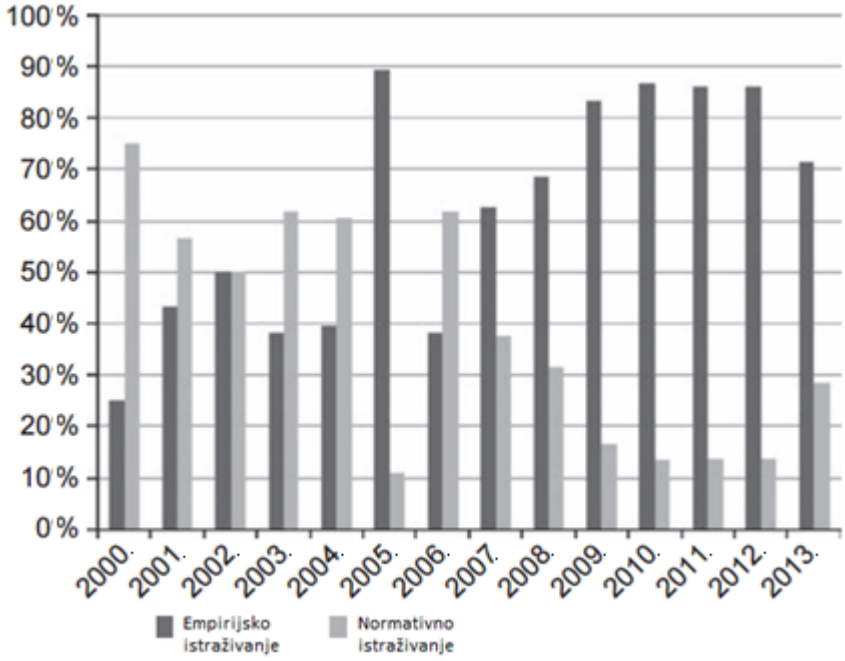


Slika 2-3. Pregled tema u tri etape istraživanja IK-a (prema [80])

Tablica 2-1. Usporedba uobičajene i nove paradigme intelektualnoga kapitala (prema [76])

Uobičajena paradigma	Nova paradigma
1. Pogled iz perspektive računovodstva - praktična mogućnost za mjerenje nematerijalne imovine.	1. Isticanje važnosti formulacije strategije.
2. Isticanje važnosti provedbe strategije, bez prethodno pravilno provedene formulacije strategije iz perspektive IK-a.	2. Intelektualni se kapital ne može podijeliti na sastavne dijelove – proizvod ili usluga koji proizlaze iz određene organizacije nisu vezani za bilo koju određenu vrstu kapitala, već su nastali iz njihove sprege.
3. Podjela intelektualnoga kapitala – svaka vrsta kapitala neovisna je o drugoj iako je to odvajanje umjetno.	3. Temeljne kompetencije kao jedina nematerijalna imovina kojom je potrebno upravljati – uspostaviti vezu između proizvoda i usluga i temeljnih kompetencija.
4. Uzročno-posljedične veze – ispitivanje odnosa između vrste kapitala i ciljeva.	4. Stvarnost i dinamičnost u vrijednosti stvaranja procesa – kako organizacije raspoređuju i razvijaju resurse.
5. Relativno statičan pristup stvaranju vrijednosti – nedostatak pogleda iz perspektive aktivnosti.	5. Identifikacija, vrednovanje i procjena ključnih kompetencija za stvaranje novih vrijednosti.
6. Ograničeni koncept intelektualnoga kapitala – naglasak je na intelektualnoj imovini.	6. Isticanje uloge individualnih karakteristika i sposobnosti [84].
7. Upotreba istih modela i metodologija za upravljanje i izradu izvješća.	7. Intelektualni kapital kao dinamičan koncept.
8. Pristup nematerijalnoj imovini kao materijalnoj – primjena sličnih pristupa.	8. Razlika između intelektualne „aktive" i „pasive".

Sukladno tome, Guthrie i dr. [85] te Dumay i Garanina [80] upućuju na potrebu za novom (trećom) etapom istraživanja IK-a u kojoj je cilj dublje razumijevanje upravljanja njime. Proučavanjem nastanka i razvoja IK-a unutar organizacija pristupom „odozdo prema gore" omogućit će se bolji uvid na stvarni utjecaj IK-a na izvedbu organizacije. Stoga su za praćenje razvoja IK-a na nižim organizacijskim razinama (Slika 2-3, Slika 2-4) važna empirijska istraživanja intelektualnoga kapitala.



Slika 2-4. Porast udjela članaka (u relevantnim časopisima) koji sadrže empirijska istraživanja u području IK-a [85], [86]

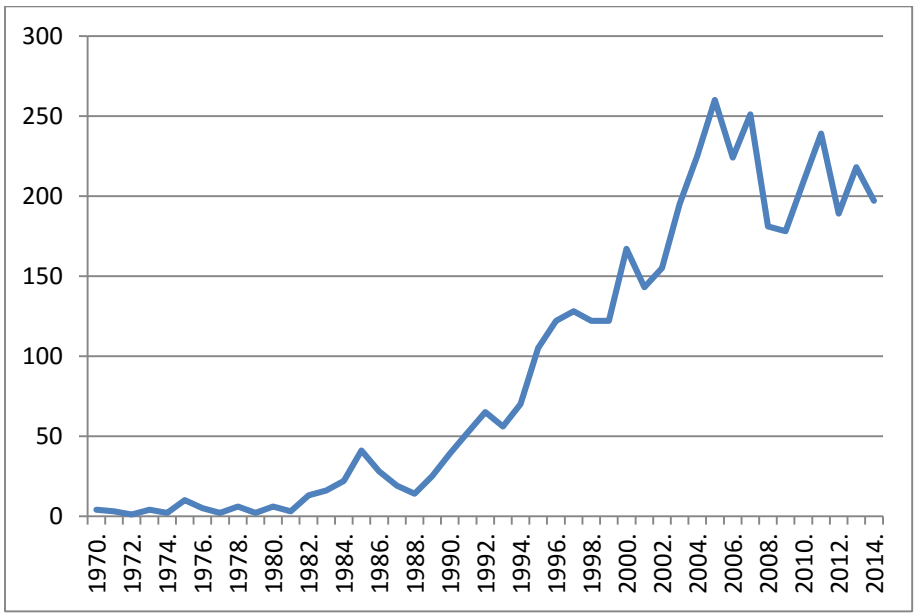
Sukladno aktualnim smjerovima istraživanja [80], [86], tijekom provedenog istraživanja promatrani su događaji i promjene na razini pojedinaca i timova koji ostvaruju projekt. Promatranje elemenata ljudskoga i strukturnoga kapitala okosnica je istraživanja jer su oni individualna i timska razina. Tako koncipirano istraživanje omogućit će bolje razumijevanje i interpretaciju promjena IK-a u stvarnom okruženju te veza između njegovih različitih elemenata. Provođenje empirijskih istraživanja omogućit će kritički pogled na predložene mjere i time veće unapređenje postojećih modela i metoda.

2.3. Timski rad u razvoju tehničkih sustava

Kako će u žarištu istraživanja biti individualna i timska razina razvoja tehničkih sustava, u okviru pregleda područja nužan je pregled dosadašnjih istraživanja u tom kontekstu. Brojni istraživači ističu važnost proučavanja i integracije raznolika područja inženjerskog znanja i disciplina za razvoj novih i inovativnih rješenja. Za integraciju je ključna razmjena informacija, koordinacija između sudionika i suradnja članova tima [53]. U provođenju integracije nameće se važnost timskog rada tijekom razvojnih aktivnosti [87] radi rješavanja problema koje pojedinci samostalno ne bi mogli riješiti [88]. Dakle, svrha je timskog rada razmjena ideja, znanja i resursa [89].

Prijašnja istraživanja u razvoju tehničkih sustava tijekom 1960-ih bavila su se radom pojedinačnoga konstruktora, a u 1980-ima povećao se broj istraživanja kojima je cilj bio

proučiti rad tima koji sudjeluje u razvoju tehničkih sustava [90]. Takav se trend može prikazati i rastom broja radova vezanih uz timski rad (Slika 2-5).



Slika 2-5. Prikaz rasta broja radova indeksiranih u bazi Scopus s riječi „teamwork“ u naslovu, sažetku ili među ključnim riječima u području inženjerstva od 1970. do danas [59]

Valkenburg [91] je podijelila istraživanja vezana za timski rad u kontekstu razvoja tehničkih sustava u tri različite kategorije: 1. timski rad iz perspektive procesuiranja informacija, 2. usporedba grupnih i individualnih protokola i 3. aspekti timskog rada kojih nema pri individualnom radu. Ova je posljednja kategorija pobudila najviše zanimanja istraživača te sadržava istraživanja vezana uza strukturu komunikacije [88], suradnju [92] i interakciju između članova tima [93].

Prema Hoeglu i Gemuendenu [94], tim se može definirati kao društveni sustav od tri ili više osoba, koji je sastavni dio organizacije te čiji članovi percipiraju sebe i preostale članove tima kao njezine sastavne dijelove koji rade na zajedničkom zadatku. U kontekstu razvoja tehničkih sustava timski se rad odnosi na stupanj suradnje između različitih članova tima koji sudjeluju u razvojnom procesu. Timski rad u usporedbi s radom pojedinca nosi brojne probleme, ali i nudi nove mogućnosti za članove tima. Svaki član tima ima svoj način provođenja aktivnosti u smislu komunikacije, interakcije i donošenja odluka, koji se temelji na njegovim kompetencijama, osobnim karakteristikama i vještinama. Članovi timova imaju i vlastite obrasce ponašanja tijekom radnih aktivnosti, različita očekivanja i shvaćanja kvalitete procesa i proizvoda. Analiza i razumijevanje razvoja tehničkih sustava ključan je dio razvojnog procesa i stoga je presudno da tim postigne zajedničko razumijevanje problema,

unatoč pojedinačnim mentalnim modelima. Članovi tima također dijele zajednički cilj koji se može podijeliti na dvije razine. Prva je razina vezana za ciljeve upravljačke strukture organizacije, a druga proizlazi iz tehničkih zahtjeva, sigurnosnih ograničenja, stajališta kolega te potreba dobavljača i kupaca.

Upravo iz ovog dijela timskog rada proizlaze njegovi nedostaci – različita interpretacija i konflikti u načinu razmišljanja. Kritičko razmišljanje koje podupire razvoj novih ideja i pravilno donošenje odluka također donosi konflikte koji uzrokuju gubitak vremena i narušavaju odnose u timu [95]. Konflikti mogu prouzročiti frustracije i pogrešno donošenje odluka [96].

Tijekom razvoja tehničkih sustava timovi imaju relativno stabilnu strukturu i članovi tima rade zajedno na više projekata. Uobičajeno je da je svaki član tima odgovoran za izvršavanje pojedinog zadatka, ovisno o njegovim kompetencijama. Badke-Schaub [97] tvrdi da se pri razvoju tehničkih sustava rijetko provodi „stvarni“ timski rad i da konstruktori najveći dio vremena rade individualno, iako je potreba za komunikacijom i interakcijom velika. Ipak, potrebno je istaknuti da druga istraživanja upućuju na drukčije zaključke. Bucciarelli [98] navodi da je razvoj tehničkih sustava društveno intenzivan proces, što je potvrđeno Robinsonovim [99], [100] empirijskim istraživanjem.

U literaturi se mogu pronaći brojne studije koje potvrđuju vezu između timskog rada i organizacijske izvedbe [101], [102], iako bez detaljna uvida u to kako je timski rad povezan s pojedinim aspektima organizacijske izvedbe. U istraživanjima vezanim za uspješnost timskog rada najčešće se rabe prilično grube i nejasne mjere timskog rada, pritom onemogućujući istodobno analizu različitih aspekata timskog rada [94]. Kad je riječ o praćenju timskog rada, na njegovu uspješnost upućuju učinkovito rješavanje konflikata, uspješno donošenje odluka, kreativno rješavanje problema, učinkovita komunikacija i dobra koordinacija aktivnosti [103]. Uloge i odnosi između članova tima također utječu na izvedbu timskog rada. Treba istaknuti da za procjenu uspješnosti timskog rada nije dovoljno obuhvatiti samo kontekstualne čimbenike na razini tima kao što su predanost timskom radu i zajedničko razumijevanje, već je potrebno uzeti i faktore koji su vezani za svakoga pojedinog člana tima.

Stvaranje novih ideja ključno je tijekom svih faza razvoja kompleksnih tehničkih sustava: u razumijevanju problema, razvoju prikladnih rješenja i konačnoj primjeni tih rješenja u stvarnoj okolini. Svaki inovativni iskorak rezultat je spoja kompetencija, inovativnosti, komunikacije radi razmjene znanja te motiviranosti na individualnoj i timskoj razini. Pri

evoluciji tih elemenata tijekom razvoja tehničkih sustava pojavljuju se brojni rizici koje je teško prepoznati i kojima je teško upravljati korištenjem postojećim metodama projektnog upravljanja. Nematerijalni pokazatelji s naglaskom na ponašanje pojedinaca i timova te stvaranje ideja omogućili bi dodatnu perspektivu praćenja izvedbe tima tijekom razvojnih projekata u stvarnom vremenu.

3. Teorijske osnove istraživanja

Poslije preliminarnog uvoda u opća područja istraživanja u drugom poglavlju, u trećem je opis teorijskih osnova istraživanja nužnih za izradu ove disertacije. U prva dva potpoglavlja prikazan je opis postojećih metoda i pristupa za mjerenje elemenata intelektualnoga kapitala te izvedbe pojedinaca, timova i organizacija u razvojnim projektima. Dan je pregled literature za potrebe određivanja težinskih faktora i agregacije vrijednosti indikatora nužnih za izradu matematičkog modela agregacije indikatora. U zadnjem potpoglavlju objašnjeni su organizacijski rizici koji proizlaze iz nematerijalnih aspekata te metode za njihovu identifikaciju i analizu.

3.1. Mjerenje elemenata intelektualnoga kapitala

Intenzivno istraživanje mjerenja elemenata IK-a započelo je u 90-im godinama XX. stoljeća, kad su se počeli pojavljivati nove metode i modeli mjerenja kao što su Intangible Assets Monitor, Skandia Navigator™ i Balanced Scorecard. Na temelju tih modela, ali i upotrebom studija iz drugih područja istraživanja, razvoj metoda za mjerenje elemenata IK-a ubrzao se i znatno napredovao [104]. Takav ubrzan razvoj rezultirao je brojnim novim metodama i modelima za mjerenje IK-a te potpomogao razumijevanje IK-a. Prema principima koje primjenjuju, metode za mjerenje elemenata IK-a mogu se podijeliti u četiri kategorije [105], [106]:

1) **metode direktnog izračuna intelektualnoga kapitala** (engl. *Direct Intellectual Capital – DIC*) temelje se na procjeni ekonomske vrijednosti neopipljive imovine. Nakon identifikacije komponenata IK-a slijedi izravna evaluacija individualnih komponenata ili agregirane vrijednosti (npr. Technology Broker, TVC™, The Value Explorer™ itd.)
2) **metode tržišne kapitalizacije** (engl. *Market Capitalization Methods – MCM*) temelje se na procjeni razlike između knjigovodstvene vrijednosti i tržišne vrijednosti organizacije (npr. Tobin's Q, IAMV™ itd.).
3) **metode određivanja povrata od imovine** (engl. *Return on Assets methods –ROA*) temelje se na izračunu povrata od neopipljive imovine. Prihodi organizacije podijeljeni su s vrijednošću organizacijske opipljive imovine te je dobiveni rezultat zatim

usporeden s prosjekom određene grane industrije. (npr. VAIC™, Calculated Intangible Value, EVA™ itd.).

4) **metode bodovanja** (engl. *Scorecard Methods – SC*) temelje se na uporabi različitih indikatora i indeksa, koji se mogu prikazati pomoću tablica bodovanja (IC-index™, Skandia Navigator™ itd.).

Metode, koje su svrstane u skupine ROA i MCM, sadržavaju financijske kriterije i mjere [106]. Te su holističke metode orijentirane na najvišu organizacijsku razinu bez mogućnosti primjene na nižim organizacijskim razinama kao što su projekti, timovi i pojedinci. Prednost je metoda iz skupine ROA i MCM što ih često dobro prihvaćaju organizacije i upravljačke strukture jer su financijski kriteriji ustaljen način prikaza rezultata mjerenja IK-a.

Metode, koje su svrstane u skupine DIC i SC, nude širu sliku organizacijske izvedbe te se mogu primijeniti na različitim razinama u organizaciji. Mjerenje pomoću ovih metoda uže je vezano uz razinu izvršavanja aktivnosti te stoga daju rezultate brže i preciznije, uz ograničenje da indikatori ovise o kontekstu i zahtijevaju modifikaciju za različite primjene. Metode koje pripadaju skupini DIC temelje se na financijskim mjerama, a metode iz skupine SC na nefinancijskim mjerama [106].

Predlaganjem niza metoda za mjerenje IK-a istraživači su istaknuli važnost vrednovanja IK-a, ali istaknuli i brojne probleme pri traženju cjelovita i pravilna pristupa. Zbog kompleksnosti vrednovanja i mjerenja različitih elemenata IK-a, uobičajene metode ne mogu ispuniti zahtjeve koji su nametnuti u smislu davanja odgovarajuće svakodnevne informacije donositeljima odluka i voditeljima projekata. Brojni razlozi mogu biti uzrok ne ispunjavanja svih potrebnih zahtjeva. Organizacije su razvijale vlastite sustave mjerenja i vrednovanja IK-a za potrebe svojeg poslovanja koji nikad nisu bili namijenjeni upotrebi u širem kontekstu [106], [107]. Mnoge od predloženih metoda u literaturi su teorijski prijedlozi upitne primjenjivosti [107], [108].

Metode koje se trenutačno služe isključivo kvantitativnim financijskim mjerama (kao što su metode koje pripadaju skupinama MCM i ROA) teško se mogu iskoristiti za potrebe upravljanja projektima. Sadašnji pristupi mjerenju IK-a uglavnom se temelje na povremenu mjerenju u odabranim situacijama [109]. Posljedica su takvog pristupa zakašnjeli rezultati koji ne oslikavaju realno stanje projekta ili organizacije tijekom izvedbe. Iz takva mjerenja i praćenja proizlazi statičnost indikatora, koji se mjere godišnje ili polugodišnje. Također, indikatori se prate na organizacijskoj razini što onemogućuje praćenje rada pojedinaca i timova.

Analizirajući literaturu iz mjerenja IK-a, indikatori IK-a općenito se mogu podijeliti u dvije skupine: financijski i nefinancijski. U pogledu praktičnosti i jednostavnosti prikupljanja podataka, financijski indikatori (trošak razvojnog odjela / trošak nove tehnologije, prosječni prihodi od patentiranih proizvoda i procesa, prihodi od novih proizvoda / ukupni prihodi) imaju prednosti. Oni jednostavno omogućuju usporedbu organizacijskih cjelina (odjela, timova) unutar tvrtke te međusobnu usporedbu tvrtki. Ipak, priroda IK-a nije monetarna [106], [110] te se IK ne može mjeriti isključivo upotrebom tradicionalnih financijskih indikatora. S druge strane, nefinancijski indikatori koji su navedeni u literaturi često nemaju zadovoljavajući opis ili mjeru potrebnu za potpunu definiciju određenog indikatora. Provođenjem studije slučaja, Vuolle i dr. [52] ustanovili su da su mnogi postojeći indikatori IK-a preopćeniti što otežava njihovu primjenjivost u stvarnim organizacijama.

Bontis i Fitz-Enz [111] u svojem su istraživanju potvrdili povezanost između obaju tipova indikatora ističući njihovu konzistentnost, neovisno o tom što su nefinancijski (često kvalitativni) indikatori percipirani kao manje objektivni.

Ipak, iako postoje brojne metode za praćenje i mjerenje IK-a u literaturi, pojedini istraživači (npr. [8], [112]) smatraju da su i dalje potrebne nove metode i indikatori izvedbe za voditelje razvojnih projekata koji su zainteresirani za mjerenje organizacijske nematerijalne imovine. Novi su nematerijalni indikatori nužni kako bi se unaprijedilo rješavanje problema i donošenje odluka te omogućilo razumijevanje učinka organizacije na tržišnoj razini (kompetitivnost, inovacija, rast).

Za mjerenje elemenata IK-a tijekom projekata razvoja tehničkih sustava, u okviru izrade ove disertacije početno će se definirati nematerijalni indikatori. Pri stvaranju popisa nematerijalnih indikatora koji bi omogućili praćenje projekata u realnom vremenu nameće se potreba za drukčijim metodama prikupljanja podataka. Osmišljavanje valjane i robusne metodologije prikupljanja podataka te njihovo preslikavanje u vrijednosti indikatora dva su ključna aspekta kreiranja indikatora izvedbe o kojima uvelike ovisi njihova upotrebljivost i učinkovitost [113].

Na temelju dobivenih spoznaja iz pregleda literature te uočenih nedostataka postojećih pristupa, u sklopu disertacije predložit će se popis nematerijalnih indikatora za individualnu i timsku razinu unutar konteksta razvoja tehničkih sustava.

3.2. Mjerenje izvedbe pojedinaca, timova i organizacija u razvojnim projektima

Budući da se razvoj tehničkih sustava provodi kao projekt [114], metode i alati za upravljanje projektima neprestano se primjenjuju za praćenje i usmjeravanje razvojnih projekta. Jednom od glavnih komponenata upravljanja projektima nameće se mjerenje izvedbe pojedinca, tima i organizacije koje je potrebno za osiguravanje željena smjera projekta te njegove vrijednosti za cijelu organizaciju. Općenito gledano, mjerenje izvedbe pojedinca, tima i organizacije omogućuje prikupljanje informacija o učinkovitosti procesa i organizacije te povećava vjerojatnost uspjeha projekta i organizacije [115], [116].

Početna istraživanja indikatora u području razvoja tehničkih sustava vezana su za procjenu potrebnog napora i vremena tijekom projekta [117]. Tradicionalni su pristupi upravljanju projektima primijenjeni i u kontekstu razvoja tehničkih sustava tijekom dugog razdoblja iako su pojedini istraživači upozoravali na nedostatak informacija za realnu procjenu stanja u kompleksnim projektima. Stoga su predložili indikatore koji će omogućiti objektivniju procjenu trajanja i troškova. Indikatori i predloženi parametarski izrazi za procjenu izvedbe projekata temeljeni su na analizi prethodno provedenih razvojnih projekata. Primjeri takvih pristupa opisani su u istraživanjima Nordena [118], Griffina [119], Bahilla i Chapmana [120] te Jacome i Lapinskii [121] čiji je cilj bio razvoj modela koji će se usredotočiti na tradicionalne čimbenike uspješnosti projekta u kontekstu razvoja tehničkih sustava. Norden [118] je kreirao model ovisnosti *uloženog truda* i *trajanja projekta* na temelju analize 65 različitih projekata razvoja tehničkih sustava. Griffin [119] je upotrebom indikatora vezanih za *karakteristike i ishode projekta* te *razvojnog procesa* razvio model za određivanje vremena potrebnog za razvoj i isporuku proizvoda. Bahill i Chapman [120] upotrebom su dvaju kompozitnih indikatora – *zahtjevnost konstrukcije* i *resursi*, omogućili brzu i jednostavnu procjenu izvedivosti projekta. Uzimajući u obzir *veličinu*, *kompleksnost* i *produktivnost* proizvoda, Jacome i Lapinskii [121] definirali su model za određivanje ukupnog troška razvoja tehničkog sustava.

Analizom postojećih modela Bashir i Thomson [117] zaključili su da su ključni čimbenici potrebni za opis razvoja tehničkih sustava kompleksnost proizvoda (funkcijska kompleksnost, tehnička zahtjevnost), sposobnost razvojnog tima (iskustvo pojedinca i tima) i kompleksnost upravljanja timom (veličina tima, komunikacijski tokovi).

Paralelno s ovim istraživanjima, pojedini su se istraživači (npr. [122], [123]) usredotočili na indikatore uspješnosti razvojnih organizacija. Griffin i Page [122] izradili su opširan pregled postojećih indikatora izvedbe korištenih na razini projekata i portfelja unutar konteksta razvojnih organizacija, a Cooper [123] je u svojem istraživanju proučavao što razvojne organizacije čini uspješnima te identificirao ključne faktore uspješnosti. Među novijim istraživanjima potrebno je istaknuti rad Griesa i Restrepoa [124] u kojem se studijom slučaja potvrđuje važnost indikatora za upravljanje razvojnim projektima uzimajući u obzir specifičnosti organizacije, projekta i timova. Taylor i Ahmed-Kristensen [125] identificirali su skup ključnih čimbenika uspješnosti i indikatora izvedbe za proces globalnog razvoja proizvoda. Iz perspektive vitkog (*engl. lean*) razvoja proizvoda Dombrowski i dr. [126] predložili su skup specifičnih grupa indikatora organizacijske izvedbe, ali bez pojedinačnih mjera za svaki indikator.

Ipak, ni u jednom od ovih istraživanja nije se proučavala nematerijalna perspektiva individualnog i timskog rada unutar projekata razvoja tehničkih sustava ostavljajući ovo područje istraživanja nepokrivenim.

Pri osmišljavanju nematerijalnih indikatora za kontekst razvoja tehničkih sustava potrebno je uzeti u obzir dosadašnje spoznaje iz literature o razvoju indikatora u navedenom kontekstu. Poslije analize indikatora izvedbe koji su implementirani u različite javne i privatne organizacije, Parmenter [127] je također iznio nekoliko važnih činjenica o njihovoj prirodi i obilježjima:

- monetarni su indikatori zakašnjeli (engl. *lagging*) pokazatelji, pa bi nefinancijski indikatori mogli biti učinkovitiji za praćenje realne[1] izvedbe promatranog fenomena
- učestalo mjerenje može dati pravodobnu informaciju u realnom vremenu
- prikladno oblikovani indikatori izvedbe mogu uputiti na tip akcije koji je potreban za bolju izvedbu
- mjerenja se ne smiju provoditi samo na organizacijskoj razini, nego moraju biti povezane s nižim organizacijskim razinama (pojedinci i timovi) radi unapređenja procesa upravljanja na operativnim razinama.

[1] Realno vrijeme (trenutnost) je vrijeme koje je povezano s događajem koji se promatra direktno i u trenutku, a ne kao naknadno prikupljanje (promatrano više puta), ili kao nagađanje (predikcija).

Gries i Restrepo [124] naveli su i ključne probleme u korištenju indikatorima izvedbe u razvojnim projektima u praksi:

1. zbog heterogenosti aplikacije i različitih izvora podataka česti su problemi sinkronizacije i analize prikupljenih podataka
2. praćenje i mjerenje prevelikog broja indikatora koji nisu u skladu sa strategijom kompanije može pridonijeti „inflaciji" indikatora izvedbe
3. prva dva problema mogu uzrokovati neprecizne i neuvjerljive rezultate tzv. pseudopreciznost.

Upravo je to motiviralo autora ove disertacije da poveže spoznaje iz srodnih područja istraživanja (upravljanje ljudskim resursima, organizacijska psihologija) i razvoja tehničkih sustava radi definiranja popisa nematerijalnih indikatora unutar razvojnih projekata koji bi bili u skladu s prijedlozima Parmentera [127] i Griesa i Restrepoa [124].

U posljednjih nekoliko godina sve je više istraživanja koja povezuju intelektualni kapital i razvoj tehničkih sustava (npr. [71], [128]), a cilj im je analiza utjecaja faktora IK-a na razvoj proizvoda. Kako bi se omogućilo praćenje i mjerenje nematerijalnih aspekata aktivnosti u razvoju tehničkih sustava, potrebno je osmisliti indikatore koji će se usredotočiti na individualnu i timsku razinu i, u konačnici, obuhvatiti socio-tehničku perspektivu [129]. Pri tome bi se korištenjem pristupom *bottom up* omogućilo brže i preciznije dobivanje podataka te fleksibilnost vezana za različite razine primjene (pojedinci, timovi, projekti, organizacije). Također, korištenjem nematerijalnim indikatorima za individualnu i timsku razinu te prikupljanjem kvantitativnih podataka o aktualnim vrijednostima mjera za indikatore u razvojnim aktivnostima dobila bi se objektivnija slika o stanju elemenata IK-a na operativnoj razini (engl. *in action*). U usporedbi s trenutačnim indikatorima, upotrebom novokreiranih vodećih (engl. *leading*) indikatora dobio bi se točniji prikaz trenutačne situacije te omogućilo praćenje i upravljanje projektima u realnom vremenu.

Opsežnost nematerijalne perspektive razvojnih projekata može rezultirati većim brojem nematerijalnih indikatora. Za sažimanje većeg broja indikatora[2] i kreiranje sustava vrednovanja predlaže se upotreba metoda vrednovanja i agregacije. Korištenjem metodama vrednovanja omogućuje se rangiranje i vrednovanje pojedinih indikatora, a određene metode omogućuju i uključivanje veza između indikatora u matematički model.

[2] U skladu s prije navedenim postavkama Greisa and Restrepoa [2011].

3.3. Određivanje težinskih faktora i agregacija vrijednosti indikatora

Budući da pristupi za mjerenje izvedbe IK-a pomoću indikatora često uključuju velik broj indikatora, pri njihovoj primjeni nastaje velika količina informacija koju donositelj odluke mora procesuirati i analizirati. Prema Hwangu i Linu [130], novostvorena količina informacija može negativno utjecati na donošenje odluka i upravljanje procesima. Stoga se u praksi teži smanjenju količine informacija koju donositelji odluke i voditelji projekta moraju obraditi. Agregacija je jedan od načina smanjenja količine informacija za donositelje odluka i voditelje projekata. Kako bi se stvorili preduvjeti za izvođenje agregacije indikatora, nužno je prethodno odrediti težinske faktore pojedinih indikatora.

Težinski se faktori mogu odrediti na razini cijelog tima ili svaki član individualno može odrediti pripadajuće vrijednosti za svaki indikator.

Prema Čakloviću [131], težinski faktori mogu se odrediti:

- izravnom procjenom težinskih faktora
- procjenom važnosti pojedinog kriterija
- upotrebom metode Swing
- uspoređivanjem u parovima.

Prva su dva pristupa uvriježena i ne zahtijevaju posebno objašnjenje. Metoda Swing unaprijeđen je pristup koji ujedinjuje prva dva navedena pristupa. Na početku je potrebno odabrati alternativu s najnižom prihvatljivosti za sve indikatore, a zatim i indikator na koji je potrebno najviše utjecati. Potom treba odabrati drugorangirani indikator čiji se raspon uspoređuje s prvorangiranim indikatorom. Kao posljednji pristup za određivanje težinskih faktora navodi se uspoređivanje u parovima upotrebom AHP-a (engl. *Analytic Hierarchy Process* [132]) ili Metode potencijala. Metoda AHP uključuje početno osmišljavanje hijerarhije vrednovanja, a zatim eksperti uspoređuju i rangiraju alternative ovisno o kriterijima. Uzimajući u obzir jednostavnost, dostupnost računalnih alata za njezinu upotrebu te mogućnost primjene u različitim industrijskim granama, lako je zaključiti zašto je AHP jedna od najčešće primjenjivanih metoda za višekriterijsko odlučivanje. Ipak, zbog nemogućnosti da obuhvati relacije između indikatora, za potrebe disertacije odabrana je Metoda potencijala [131]. Ona uključuje sve pozitivne strane AHP-a, ali omogućuje i uporabu nepotpunih podataka i proceduru samorangiranja (poglavlje 4.4). Samorangirajuća hijerarhija omogućuje različite vrste veza između indikatora, što nije moguće pri korištenju ANP-om (eng. *Analytic Network Process*), općenitijom verzijom AHP-a.

Nakon određivanja težinskih faktora, potrebno je definirati način na koji će se provesti agregacija pojedinačnih indikatora. Agregacija se može definirati kao sjedinjavanje pojedinačnih rezultata vrednovanja u zajedničko ili grupno vrednovanje [131]. U kontekstu indikatora za praćenje IK-a, agregacija podrazumijeva određivanje vrijednosti indikatora na razini elemenata IK-a koje čine vrijednosti podindikatora. Matematička kombinacija (naziva se i agregacija) pojedinačnih indikatora često se naziva indeksom, integriranim ili kompozitnim indikatorom. Kompozitni indikator agregat je svih dimenzija, ciljeva pojedinačnih indikatora i varijabli koje su poslužile pri njegovoj definiciji i izračunu [134].

Iako se agregacija može provesti na brojne načine [135], prema Podgorskom [136] najčešće se to čini izračunom prosječnih vrijednosti: aritmetičke, geometrijske ili harmonijske. Aritmetička ili linearna agregacija najčešći je pristup u području upravljanja. Ipak, za korištenje linearnom agregacijom sve vrijednosti moraju imati istu mjernu jedinicu. S druge strane, geometrijska se agregacija primjenjuje ako pojedinačni indikatori nisu usporedivi prema tipu ljestvice te su njihove vrijednosti isključivo pozitivne [136].

Kao najčešća podvrsta linearne agregacije, u literaturi se navodi diferencijalno ponderirana linearna agregacija [134]. Upotreba ponderirane linearne agregacije podrazumijeva množenje svake vrijednosti indikatora s odgovarajućim ponderom (težinskim faktorom utjecaja). Pri takvom je pristupu potrebno uzeti u obzir uvjet preferencijalne nezavisnosti koji je ključan za provođenje linearne agregacije.

Indikator A preferencijalno je nezavisan od indikatora B ako za svake dvije njegove vrijednosti $a, a' \in A$ vrijedi:

$$\begin{gathered}(a, b) \succcurlyeq (a', b)\ za\ neki\ b \in B \\ \Longrightarrow (a, b_0) \succcurlyeq (a', b_0)\ za\ svaki\ b_0 \in B.\end{gathered} \tag{1}$$

Kako se indikatori često temelje na istom skupu prikupljenih podataka ili između njih postoje uzročno-posljedične veze, Rodriguez i dr. [137] ističu važnost međuovisnosti između indikatora. Pojedini istraživači (npr. [138]) smatraju da proučavanje indikatora izvedbe iz aspekta njihove povezanosti s drugim indikatorima omogućuje bolje razumijevanje i predodžbu o njihovoj izvedbi. Stoga su istaknuli potrebu za identificiranjem i analizom relacija između različitih indikatora izvedbe na različitim organizacijskim razinama. Kao posljedica, nameće se potreba za identifikacijom veza između nematerijalnih indikatora koji se mogu pratiti na razini projekta. Iako Podgorski [136] predlaže uklanjanje međuovisnih

indikatora radi manje potrošnje resursa za analizu izvedbe, takav pristup može navesti na pogrešne zaključke. Zanemarivanje međuovisnosti između pojedinačnih indikatora jedan je od nedostataka brojnih procedura agregacije kojima se koristi u postojećim pristupima. Ipak, primjenom Metode potencijala taj je problem riješen u prethodnom koraku jer su pri izračunu težinskih faktora međuovisnosti između indikatora uzete u obzir (poglavlje 4.4).

Postojeći pristupi agregaciji imaju i druge nedostatke. Naime, agregacijski modeli ne prikazuju transparentno vrijednosti pojedinačnih indikatora te slabiju izvedbu pojedinoga indikatora nadomještaju boljom izvedbom nekoga drugoga [139]. Donositelji odluka često pribjegavaju agregiranim vrijednostima pritom zanemarujući izvore podataka, način izračuna težinskih faktora te proceduru agregacije, a posljedica je iskrivljena slika proizišla iz agregiranih vrijednosti. Tada nedostatak detaljna uvida u pojedinačne vrijednosti može pridonijeti pogrešnu shvaćanju i interpretaciji rezultata [140]. Iako agregirana vrijednost definirana na višoj razini može pružiti dodatan pogled na promatrani fenomen, jedna vrijednost ne može omogućiti preciznost i transparentnost informacije o pojedinoj kategoriji IK-a. Stoga se unutar predloženog pristupa preporučuje upotreba i praćenje pojedinačnih indikatora i pripadajućih trendova, u odnosu prema isključivu fokusiranju na agregiranu vrijednost timske izvedbe u kontekstu IK-a.

Saisana i Tarantola [141] tvrde da se kompozitni indikatori često *temelje na podindikatorima koji nemaju jasnu mjernu jedinicu te ne postoji jasan i vidljiv način određivanja težinskih faktora za podindikatore.* Zbog toga će se u nastavku disertacije (poglavlje 4.1) osobito pozorno izložiti metodologija odabira indikatora koji će poslužiti za izračun agregiranih vrijednosti te način određivanja pripadajućih težinskih faktora korištenjem Metodom potencijala [131].

3.4. Organizacijski rizici koji proizlaze iz nematerijalnih aspekata

Radi razumijevanja organizacijskih rizika, potrebno je identificirati njihove uzroke te razloge njihova nastajanja. U tom kontekstu, brojna organizacijska istraživanja ističu važnost nekoliko različitih perspektiva ljudskoga kapitala – kompleksnost [142], liderstvo [111], znanje i učenje [143] te veza s drugim elementima intelektualnoga kapitala [144], [145]. Iako su navedeni aspekti međusobno povezani, Ashworth [146] navodi da nije jasno koji elementi ljudskoga kapitala najviše utječu na izvedbu pojedinca unutar tima.

Literatura organizacijskog učenja jasno upućuje na vezu između znanja i produktivnosti organizacije [147]. Organizacija uči preko pojedinaca od kojih se sastoji te je tako izravno ili neizravno vezana za učenje pojedinca. Stoga pojedini istraživači (npr. [148]) tvrde da su razlike u produktivnosti između organizacija vezane uz kumulativno iskustvo i početne kompetencije pojedinaca te time žele potvrditi da je znanje ključan čimbenik u određivanju izvedbe tima.

S druge strane, teorija društvenih mreža sugerira da je, osim kompetencija i vještina, pri procjeni izvedbe tima potrebno voditi računa o strukturama moći i utjecaja unutar društvene mreže skupine [149]. Gledajući iz ove perspektive, izvedba pojedinca ovisi o njegovim odnosima s drugim sudionicima, a ne o znanju ili resursima pojedinca [150]. Kiesler i dr. [151] ističu važnost koordinacije, strukture i komunikacije pri određivanju pojedinačnih doprinosa izvedbi tima. Iz navedenog se može zaključiti da pogled iz perspektive društvenih mreža ističe važnost komunikacijskih mreža, ali pritom ne obuhvaća druge ključne aspekte timske izvedbe kao što su znanje i kompetencije. Ipak, razmjena informacija između zaposlenika organizacije ključna je za individualnu i timsku izvedbu iz društvene i praktične perspektive te podržava koncepte kao što je organizacijsko učenje [147].

Nadalje, prijašnja istraživanja ističu važnost kritičnosti pojedinog zadatka i pomoću tog kriterija objašnjavaju vezu između izvedbe pojedinca te učinkovitosti organizacije. Wiig [152] navodi da opća izvedba organizacije ovisi o učinkovitosti pojedinaca u provođenju pojedinačnih aktivnosti i zadataka. Pojedini istraživači (npr. [153], [154]) tvrde da se kritičnost zadatka može procijeniti na temelju nezamjenjivosti sudionika dodijeljenog tom zadatku.

Ujedinjavanjem različitih perspektiva pojedinačnog i timskog rada u organizaciji omogućuje se odgovarajuća identifikacija rizika u različitim elementima organizacijske strukture. Već spomenuti elementi kao što su zaposlenici, znanja, resursi i aktivnosti sa svojim međusobnim vezama čine organizacijsku strukturu [24]. Određivanjem ključnih zaposlenika, znanja, resursa i aktivnosti u nekoj organizaciji omogućuje se otkrivanje rizika intelektualnoga kapitala [154].

Prema Brezillonu [155], različiti elementi organizacijske strukture mogu se modelirati kompleksnim mrežama, grafovima. Analiza takvih grafova omogućuje određivanje neizravnih veza između različitih elementa organizacijske strukture, identifikaciju obrazaca, praćenje komunikacijskih i informacijskih tokova te otkrivanje rizika pojedinih elemenata i cijele

organizacije. Elementi organizacijske strukture i veze među njima mogu se prikazati skupom mreža koji se naziva organizacijska metamatrica (Tablica 3-1) [24].

Tablica 3-1. Organizacijska metamatrica [24]

	AGENTI	**ZNANJE**	**RESURSI**	**ZADACI**
AGENTI	**M1. Mreža komunikacije** – tko komunicira s kim	**M2. Mreža znanja** – tko zna što ili tko ima koje kompetencije	**M3. Mreža pristupa resursima** – tko se koristi kojim (fizičkim) resursom	**M4. Mreža zaduženja** – tko se bavi kojom aktivnosti
ZNANJE		**M5. Mreža informacija** – koje je znanje/kompetencija povezano s drugim znanjem/ kompetencijom	**M6. Mreža adekvatnosti resursa** - koje znanje/kompetencija zahtijeva koji resurs	**M7. Mreža potreba za znanjem** – koje je znanje/kompetencija potrebno za koju aktivnost
RESURSI			**M8. Mreža zamjene resursa** – koji se resurs može zamijeniti kojim	**M9. Mreža potrebe za resursom** – koji je resurs potreban za koju aktivnost
ZADACI				**M10. Mreža aktivnosti** – koja aktivnost slijedi koju aktivnost

Metamatrica modelira organizaciju povezujući različite matrice u povezanu cjelinu. Organizacijska metamatrica razvijena je kao nastavak PCANS organizacijskog modela [156] koji je uključivao mreže suradnje, zadataka i znanja. U prijašnjim se pristupima koristilo mrežom samo za prikaz pojedinih domena, pri tom ne uzimajući u obzir međuovisnosti između različitih domena.

Organizacijska metamatrica [24] ima nekoliko značajki:

- omogućuje prikaz skupa elemenata organizacijske strukture i veza između njih
- omogućuje preslikavanje prikupljenih podataka u elemente organizacijske strukture i relacije između njih
- omogućuje definiranje domena organizacijske strukture za koje se provodi analiza i procjena rizika
- definira rječnik za prikaz i analizu organizacijske strukture.

Na temelju rezultata dobivenih iz analize organizacijske metamatrice mogu se razmatrati već spomenuti rizici podijeljeni u sedam kategorija [24]:

- **Rizici kritičnosti članova tima** – temelje se na mjerama kojima se određuje tko od članova tima ima ekskluzivno znanje, radi s ekskluzivnim resursima ili ekskluzivno sudjeluje u aktivnostima. Korištenjem mjerama u ovoj kategoriji može se analizirati kako će uklanjanje pojedinog člana tima iz organizacije utjecati na njezinu sposobnost da izvrši određenu aktivnost ili zadatak.
- **Rizici raspodjele resursa** – temelje se na mjerama koje određuju kako korištenje resursima utječe na sposobnost obavljanja zadataka. Mjerama u ovoj kategoriji razmatra se koliko je raspodjela aktivnosti po članovima tima ujednačena i imaju li članovi tima pristup resursima koji su im potrebni za obavljanje aktivnosti.
- **Komunikacijski rizici** – temelje se na mjerama razine komunikacije i strukture autoriteta unutar organizacije. Mjerama u ovoj kategoriji razmatra se koliko članovi tima komuniciraju radi izvršavanja aktivnosti. Mjere u ovoj kategoriji otkrivaju koliko je komunikacija centralizirana ili decentralizirana u promatranom timu te koliko članovi tima komuniciraju s voditeljima pri rješavanju problema.
- **Rizici redundancije** – temelje se na redundanciji u izvođenju aktivnosti, pristupu resursima i znanju. Organizacija s malom redundantnošću bit će „ranjivija“ kad pojedini član tima ili resurs nisu više dostupni. S druge strane, zbog previše redundancije organizacija je neefikasna.
- **Rizici aktivnosti (zadataka)** – temelje se na redoslijedu izvođenja aktivnosti i podjeli aktivnosti među članovima tima. Mjerama u ovoj kategoriji razmatra se koliko član tima ima na raspolaganju sve potrebne resurse za obavljanje aktivnosti. Za potrebe ove kategorije rizika također se koristi mjerama za određivanje vremenske sljedivosti i izvedivosti pojedine aktivnosti.
- **Rizici osobne interakcije** – temelje se na komunikaciji među pojedinim članovima tima. Mjerama u ovoj kategoriji razmatraju se interakcije članova tima iz perspektive znanja (surađuju li članovi tima s istim ili komplementarnim kompetencijama?), ali su jednako tako vezane za identifikaciju članova tima čiji bi odlazak rascjepkao organizaciju te uzrokovao manju povezanost između članova tima.
- **Rizici izvedbe** – temelje se na sposobnosti za uspješno obavljanje aktivnosti. Mjerama u ovoj kategoriji razmatra se je li organizacija (članovi tima) sposobna obaviti sve potrebne aktivnosti te koliko obavljanje pojedine aktivnosti ovisi o određenim pojedincima.

Analiza organizacijskih rizika, u nastavku disertacije, poslužit će za validaciju dobivenih rezultata predloženim nematerijalnim indikatorima. Iako prvotna namjena analize organizacijskih rizika nije praćenje elemenata IK-a, očito je da analiza ovog tipa omogućuje dobar uvid u razinu IK-a unutar tima.

4. Razvoj nematerijalnih indikatora za praćenje razvoja tehničkih sustava

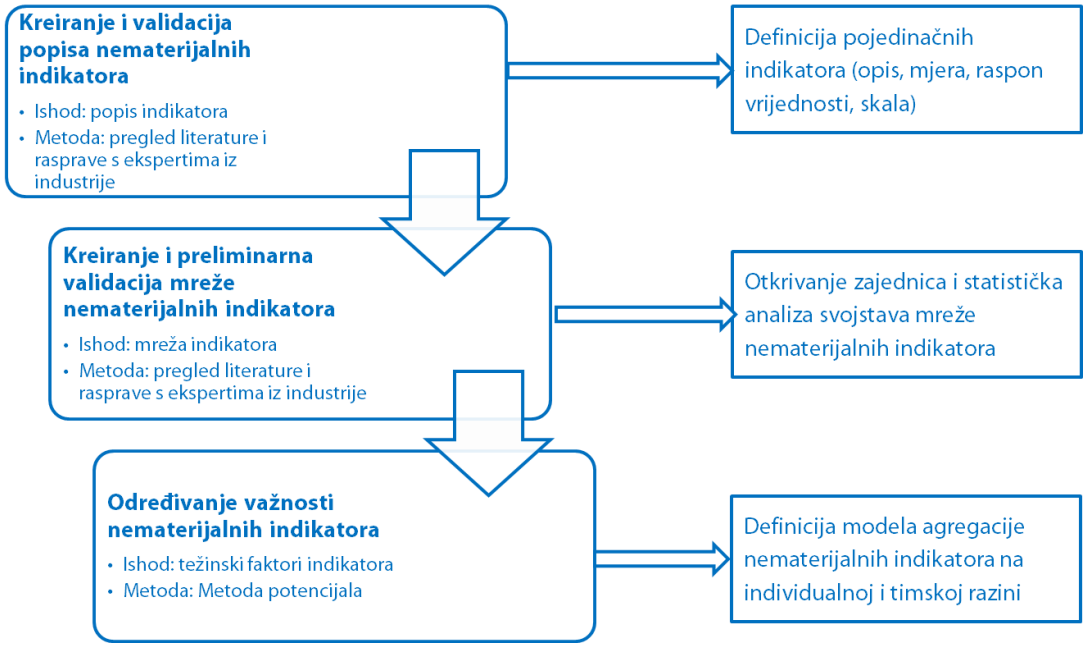
U četvrtom poglavlju prikazan je postupak razvoja nematerijalnih indikatora za praćenje razvoja tehničkih sustava. Dan je opis postupka kreiranja i validacije popisa nematerijalnih indikatora. U nastavku poglavlja prikazan je način identifikacije i validacije relacija između pojedinih indikatora radi određivanja utjecaja između njih, ali i između elemenata intelektualnoga kapitala u cjelini. Nakon izrade mreže nematerijalnih indikatora stvoreni su preduvjeti za određivanje težinskih faktora i stvaranje modela agregacije nematerijalnih indikatora.

4.1. Koraci razvoja nematerijalnih indikatora

Istraživanje prikazano u ovoj disertaciji temelji se na suvremenim principima mjerenja izvedbe intelektualnoga kapitala za potrebe praćenja kompleksnih razvojnih projekata u različitim sektorima (energetski, prijevozni, zdravstveni itd). Pristup primijenjen u ovoj disertaciji dan je na slici (Slika 4-1) sa sljedećim koracima:

1. Kreiranje popisa nematerijalnih indikatora:
    a. istraživanje postojećih pristupa i perspektiva mjerenja intelektualnoga kapitala u literaturi te kreiranje popisa indikatora
    b. validacija preliminarnog popisa nematerijalnih indikatora u realnom industrijskom okruženju radi provjere redundancije, važnosti i razumijevanja indikatora
    c. prilagodba i modifikacija popisa indikatora za individualnu i timsku razinu na temelju rezultata validacije.
2. Kreiranje mreže nematerijalnih indikatora:
    a. istraživanje i definiranje veza između nematerijalnih indikatora te stvaranje mreže nematerijalnih indikatora
    b. validacija mreže radi provjere nedostataka pojedinih veza i određivanja važnosti identificiranih veza, što provode industrijski partneri
    c. analiza statističkih svojstava mreže i pojedinačnih nematerijalnih indikatora
3. Razvoj modela agregacije nematerijalnih indikatora
    a. primjena Metode potencijala [131] za određivanje težinskih faktora

b. evaluacija rezultata usporedbom s rezultatima statističke analize mreže
c. definiranje modela agregacije za nematerijalne indikatore na individualnoj i timskoj razini



Slika 4-1. Metodologija razvoja popisa i mreže indikatora

4.2. Prijedlog i validacija popisa nematerijalnih indikatora

Popis nematerijalnih indikatora izrađen je na temelju detaljna pregleda literature o upravljanju intelektualnim kapitalom, projektom i znanjem. Analizom literature pronađeno je više od 400 indikatora koji su relevantni za mjerenje i praćenje različitih aspekata intelektualnoga kapitala u organizacijama. Detaljnijim uvidom u opis indikatora i primjenu lako je uočiti da su mnogi od postojećih indikatora namijenjeni isključivo za upotrebu na razini cjelokupne organizacije te da se prate svake godine. Primjeri indikatora na organizacijskoj razini za različite elemente intelektualnoga kapitala jesu *broj patenata, godišnje ulaganje u razvojni odjel organizacije, broj zaposlenika s doktoratom, broj zaposlenika koji su sudjelovali na usavršavanju / ukupan broj zaposlenika* itd. S obzirom na znatan broj takvih indikatora izvedbe u literaturi, u ovoj disertaciji odabran je drukčiji pristup koji se temelji na principu „odozdo prema gore". Takvim su pristupom u središtu istraživanja nematerijalni indikatori za praćenje individualne i timske razine, koji pripadaju komponentama ljudskoga i strukturnoga kapitala. Temeljem detaljnog pregleda kriterija vezanih uz elemente ljudskog (Tablica 4-1) i strukturnoga kapitala (Tablica 4-2), postavljena je osnova za daljnju identifikaciju mogućih indikatora.

Tablica 4-1. Pregled elemenata ljudskoga kapitala na osnovi kojeg su definirani indikatori (temeljeno na elementima koje su identificirali Gonzalez-Loureiro i Figueroa Dorrego [7])

Elementi ljudskoga kapitala	Referencije
edukacija i razvoj osobnih kompetencija	Johanson i dr., 1999. [157]; Bontis i Fitz-enz, 2002. [111]; Bueno Campos i dr., 2003. [159]; Alwert i dr. 2004. [160]; Bozbura i dr., 2004. [61]; Chen i dr., 2004. [82]; Hayton, 2005. [67]; Wang i Chang, 2005. [161]; Bozbura i dr., 2007. [162]; Sharabati i dr., 2010. [163]; Suraj i Bontis, 2012. [164]; Wang i dr., 2014. [165]
kreativnost	Cardinal i dr., 2001. [166]; Bueno Campos i dr., 2003. [159]; Bozbura i dr., 2004. [61]; Chen i dr., 2004. [82]; Han i dr., 2008. [167]; Sharabati i dr., 2010. [163]; Wang i dr., 2014. [165]
motivacija/zadovoljstvo	Bontis i Fitz-enz, 2002. [111]; Bueno Campos i dr., 2003. [159]; Alwert i dr., 2004. [160]; Bozbura i dr., 2004. [61]; Chen i dr., 2004.[82]; Bozbura i dr., 2007. [162]; Han i dr., 2008. [167]; Halim, 2010. [158]; Suraj i Bontis, 2012. [164]
prilagodljivost	Bueno Campos i dr., 2003. [159]; Marr i dr. 2004.;
sposobnost komunikacije i razmjene znanja	Bontis i Fitz-enz, 2002. [111]; Bueno Campos i dr., 2003. [159]; Alwert i dr., 2004. [160]; Bozbura i dr., 2004. [61]; Bozbura i dr., 2007. [162]; Han i dr., 2008. [167]; Halim, 2010. [158]; Suraj i Bontis, 2012. [164]; Wang i dr., 2014. [165]
sposobnost rada u timu	Cardinal i dr., 2001. [166]; Bueno Campos i dr., 2003. [159]; Bozbura i dr., 2007. [162]; Han i dr., 2008. [167]; Suraj i Bontis, 2012. [164]
sposobnost učenja	Cardinal i dr., 2001. [166]; Bueno Campos i dr., 2003. [159]; Chen i dr., 2004. [82]; Wang i Chang, 2005. [161]
stručnost	Bontis i Fitz-enz, 2002. [111]; Bueno Campos i dr., 2003. [159]; Bozbura i dr., 2004. [61]; Chen i dr., 2004. [82]; Marr i dr., 2004. [168]; Leiponen, 2005 [169]; Hayton, 2005. [67]; Bozbura i dr., 2007 [162]; Han i dr., 2008. [167]; Halim, 2010. [158]; Sharabati i dr., 2010. [163]; Suraj i Bontis, 2012 [164]; Wang i dr., 2014. [165]

Nekoliko je primjera faktora i indikatora koji služe za mjerenje elemenata ljudskoga kapitala u nastavku. Johanson i dr. [157] za mjerenje ljudskoga kapitala navode indikatore *udio izostanaka*, *indeks ljudskoga kapitala* te *broj dana koje su zaposlenici proveli na edukaciji*. Bontis i Fitz-enz [111] predlažu dimenzije *zadovoljstvo zaposlenika*, *privrženost tvrtki*, *motivacija zaposlenika*, *usklađenost vrijednosti*, *zadržavanje ključnih ljudi*, *liderstvo* te indikatore *stvaranja*, *razmjene* i *integracije znanja*. Halim [158] je za mjerenje ljudskoga kapitala upotrijebila indikatore *profesionalna kompetencija*, *socijalna kompetencija*,

motivacija zaposlenika i *sposobnost vođenja*. Chen i dr. [82] navode tri kategorije indikatora (indeksa) za ljudski kapital: *kompetencije zaposlenika (npr. kvaliteta zaposlenika, učinkovitost edukacije, strateško vodstvo)*, *stav zaposlenika (npr. stupanj zadovoljstva, radni vijek zaposlenika)* i *kreativnost zaposlenika (sposobnost kreativnog razmišljanja, prihodi od originalnih ideja zaposlenika).*

Nakon identifikacije indikatora potrebnih za mjerenje i praćenje ljudskoga kapitala odnosno individualne razine, isti je postupak proveden i za indikatore strukturnoga kapitala (Tablica 4-2). Kao primjer faktora i kriterija strukturnoga kapitala, Suraj i Bontis [164] navode njih 25, među kojima se mogu izdvojiti *procedure koje potiču inovativnost*, *podrška okoline*, *nedostatak vještina potrebnih za nove zahtjeve* itd. Potrebno je napomenuti da su kriteriji i indikatori koji su vezani za materijalni aspekt strukturnoga kapitala isključeni iz procedure identifikacije indikatora (npr. tehnološka oprema).

Tablica 4-2. Pregled elemenata strukturnoga kapitala na osnovi kojeg su definirani indikatori (temeljeno na elementima koje su identificirali Gonzalez-Loureiro i Figueroa Dorrego [7])

Elementi strukturnoga kapitala	Referencije
istraživačke i ideacijske aktivnosti	Cardinal i dr., 2001. [166]; Bueno Campos i dr., 2003. [159]; Alwert i dr. 2004. [160]; Bozbura i dr., 2004. [61]; Chen i dr., 2004. [82]; Hayton, 2005. [67]; Halim, 2010. [158]; Sharabati i dr., 2010. [163]; Suraj i Bontis, 2012. [164]; Wang i dr., 2014. [165]
organizacijska kultura	Brooking, 1996. [170]; Roos i dr., 1998. [171]; Johanson i dr., 1999. [157]; Bontis i Fitz-enz, 2002. [111]; Bueno Campos i dr., 2003. [159]; Alwert i dr., 2004. [160]; Bozbura i dr., 2004. [61]; Chen i dr., 2004. [82]; Carmeli i Tishler, 2004. [172]; Wang i Chang, 2005. [161]; Halim, 2010. [158]; Sharabati i dr., 2010. [163]; Suraj i Bontis, 2012. [164]; Wang i dr., 2014. [165]
organizacijska struktura	Cardinal i dr., 2001. [166]; Bueno Campos i dr., 2003. [159]; Chen i dr., 2004. [82]; Marr i dr., 2004. [168]; Hayton, 2005. [67]
organizacijsko učenje	Nonaka, 1994. [173]; Cardinal i dr., 2001. [166]; Bueno Campos i dr., 2003. [159]; Alwert i dr., 2004. [160]; Chen i dr., 2004. [82]; Gallego i Rodríguez, 2005. [174]; Halim, 2010. [158]; Hsu i dr., 2012. [175]; Suraj i Bontis, 2012. [164]; Wang i dr., 2014. [165]

Indikatori pronađeni u literaturi provjereni su i analizirani radi odabira relevantnih za kontekst razvoja tehničkih sustava. Poslije prvoga koraka odabira preostalo je 140 kvalitativnih i

kvantitativnih indikatora intelektualnoga kapitala. Indikatori su namjerno ostavljeni u općenitu obliku kako bi se omogućila njihova uporaba u različitim sektorima i projektima unutar inženjerskoga konteksta. Identificirani su indikatori podijeljeni u četiri kategorije, odnosno četiri elementa intelektualnoga kapitala [176]:

- kompetencije i znanje
- komunikacija i razmjena informacija
- inovativnost i ideacija
- motivacija i zadovoljstvo.

Indikatori su zatim klasificirani prema organizacijskoj razini (individualna, timska), pretpostavljenoj učestalosti njihove promjene (dnevna, tjedna, kvartalna ili godišnja razina) i razini granularnosti razvojnog procesa na kojoj se primjenjuju (portfelj, projekt, faza, zadatak), kako bi se obuhvatile njihove različite perspektive. Popis indikatora zatim je bio dodatno „pročišćen" i prerađen kako bi se istaknuli vodeći (engl. *leading*) i operativni indikatori (vezane na aktivnosti) koji su, po svojoj definiciji, orijentirani na trenutačno i buduće stanje.

Za pojedine aspekte izvedbe IK-a u literaturi nisu pronađeni odgovarajući indikatori te su osmišljeni novi. Stoga su indikatori vezani uz *kompetencije i znanje* zahtijevali daljnju razradu (na kompetencije relevantne za kontekst razvoja tehničkih sustava). U okviru razrade bilo je nužno definirati i način prikupljanja podataka za predložene kompetencije jer su u literaturi kompetencije često navedene samo kao faktori ljudskoga kapitala. Indikatori vezani uz *komunikaciju i razmjenu informacija* inspirirani su literaturom iz upravljanja znanjem i informacijama [177], [178]. U literaturi iz područja intelektualnoga kapitala pronađeni su faktori ljudskoga i strukturnoga kapitala (npr. *stvaranje*, *razmjena* i *integracija znanja*), ali bez jasno definiranih metrika i načina prikupljanja.

Faza „pročišćivanja" rezultirala je popisom od 70 indikatora koji su validirani u stvarnom okruženju, u dvjema tvrtkama koje razvijaju tehničke sustave u automobilskom i energetskom sektoru. Validacijom je procijenjena važnost i razumijevanje indikatora s praktičnoga gledišta te su odbačeni redundantni indikatori. Kako bi se ujednačili postupci i ishod validacije, održani su uvodni sastanci u objema tvrtkama tijekom kojih su razjašnjeni kontekst, ciljevi i procedura validacije. Zatim su održane dvije radionice (sa svakim partnerom) na kojima je sudjelovalo po pet predstavnika iz svake tvrtke i dva istraživača. Sudionici na radionicama bili su članovi odjela ljudskih resursa, osiguranja kvalitete, razvoja i upravljanja.

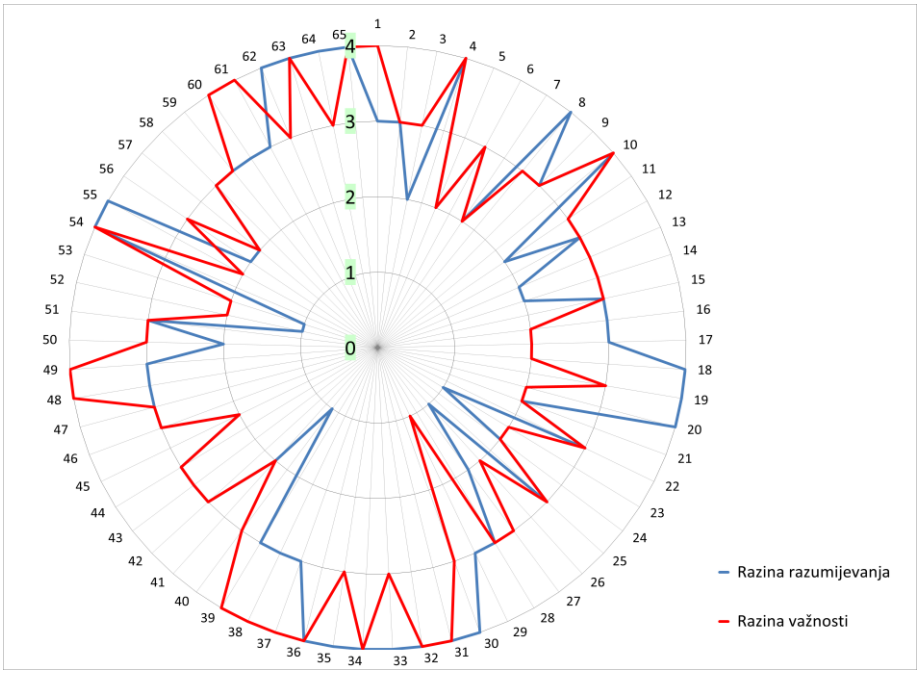
Razina važnosti indikatora procijenjena je da bi se ocijenila nužnost njihova praćenja i preliminarno odredila njihova važnost unutar strategije tvrtke prema stavovima članova tima zaduženog za validaciju. Procjena razine razumijevanja indikatora provedena je radi prepoznavanja indikatora koji nisu dovoljno intuitivni i logično objašnjeni. Sudionici radionica trebali su ocijeniti dvije navedene dimenzije upotrebom jednostavne skale od 0 do 4 (0 označava nevažnost / nerazumijevanje indikatora, 4 označava jako visoku razinu važnosti / razumijevanja indikatora). Agregirani rezultati validacije prikazani su u tablici (Tablica 4-3), a pregled ocjena po pojedinačnim indikatorima prikazan je na slici (Slika 4-2).

Tablica 4-3. Validacija indikatora izvedbe u tvrtki A i u tvrtki B

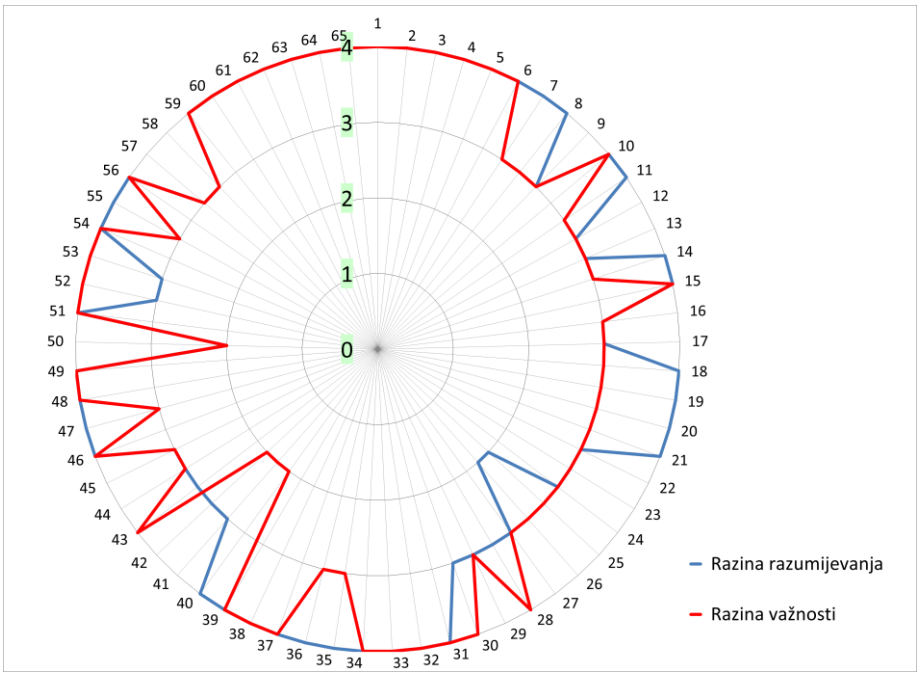
Ocjene indikatora	**Tvrtka A**		**Tvrtka B**	
	Broj indikatora	Postotak indikatora	Broj indikatora	Postotak indikatora
indikatori s „razinom razumijevanja“ = 1	6	9 %	0	0 %
indikatori s „razinom razumijevanja“ = 2	13	20 %	3	5 %
indikatori s „razinom razumijevanja“ = 3	27	42 %	20	31 %
indikatori s „razinom razumijevanja“ = 4	19	29 %	42	65 %
indikatori s „razinom važnosti" = 1	1	2 %	0	0 %
indikatori s „razinom važnosti“ = 2	16	25 %	5	8 %
indikatori s „razinom važnosti“ = 3	30	46 %	27	42 %
indikatori s "razinom važnosti“ = 4	18	28 %	33	51 %

Članovi tima zaduženog za validaciju iz tvrtke B (automobilski sektor) ocjenjivali su indikatore prilično visokim ocjenama, a među ocjenama članova tvrtke A (energetski sektor) ipak je znatno više nižih ocjena. Za razumijevanje i pravilnu interpretaciju takvih razlika provedeni su neformalni intervjui s timovima koji su bili zaduženi za validaciju indikatora. Otkriveno je da je u strategiji tvrtke B postavljen jasan naglasak na razvoj ljudskih resursa i unapređenje timskog rada te su, stoga, rezultati za nematerijalne indikatore prilično visoki s obzirom da je to tematika s kojom su sudionici bili upoznati. S druge strane, u tvrtki A, istaknuti su materijalni aspekti upravljanja projektima u pogledu vremena, troškova i kvalitete proizvoda, a samim time aspekti intelektualnog kapitala nisu prepoznati kao važan element u trenutačnoj strategiji. Kad je važnost bila ocijenjena niskim ocjenama u objema kompanijama, indikatori su bili zamijenjeni ili uklonjeni. Nadalje, za indikatore s niskom razinom razumijevanja izrađeni su detaljniji opisi pojedinog indikatora ili su opisi promijenjeni i

preformulirani. Prema rezultatima, šest je indikatora ocijenjeno jako niskom ocjenom razumijevanja. Primjer je takvog indikatora „udio primljenih informacija od ljudskih/neljudskih resursa“ čija je svrha praćenje udjela informacija dobivenih izravno od ostalih članova tima, odnosno korporativnim informacijskim sustavima. Nakon diskusije, indikator je prenamijenjen za praćenje udjela informacija dobivenih izravnom komunikacijom licem u lice (CI_IN8: Udio informacija primljenih licem u lice).



a)



b)

Slika 4-2. Rezultati validacije indikatora izvedbe u a) tvrtki A i u b) tvrtki B

Postupak je rezultirao popisom nematerijalnih indikatora za praćenje i mjerenje intelektualnoga kapitala na individualnoj i timskoj razini u kontekstu inženjerskih razvojnih projekata (Tablica 4-4 i Tablica 4-5). Za svaki je indikator određena metoda prikupljanja podataka kako bi se definirala procedura mjerenja i definirali zahtjevi za fazu provedbe.

Tablica 4-4. Indikatori izvedbe intelektualnoga kapitala na individualnoj razini

Individualna razina		
Kompetencije i znanje		Metoda prikupljanja podataka
CK_IN1	Rješavanje problema	Anketa (360-stupanjska metoda procjena)
CK_IN2	Donošenje odluka	Anketa (360-stupanjska metoda procjena)
CK_IN3	Pružanje brze i detaljne povratne informacije	Anketa (360-stupanjska metoda procjena)
CK_IN4	Sposobnost definiranja i razumijevanja uloga i odgovornosti	Anketa (360-stupanjska metoda procjena)
CK_IN5	Sposobnost praćenja/ocjenjivanja izvedbe tima	Anketa (360-stupanjska metoda procjena)
CK_IN6	Liderstvo	Anketa (360-stupanjska metoda procjena)
CK_IN7	Opća IT pismenost	Anketa (360-stupanjska metoda procjena)
CK_IN8	Specifična IT pismenost	Anketa (360-stupanjska metoda procjena)
CK_IN9	Relevantnost individualnih kompetencija za opis posla	Anketa (360-stupanjska metoda procjena)
CK_IN10	Tehničko znanje	Anketa (360-stupanjska metoda procjena)
CK_IN11	Kreativnost	Anketa (360-stupanjska metoda procjena)
CK_IN12	Socijalne vještine	Anketa (360-stupanjska metoda procjena)
CK_IN13	Odgovornost	Anketa (360-stupanjska metoda procjena)
CK_IN14	Sposobnost učenja	Anketa (360-stupanjska metoda procjena)
CK_IN15	Troškovi razvoja kompetencija i vještina po sudioniku	Korporativni informacijski sustavi
Komunikacija i razmjena informacija		Metoda prikupljanja podataka
CI_IN1	Broj "best practice"-a po sudioniku	Korporativni informacijski sustavi
CI_IN2	Broj rješenja po sudioniku	Korporativni informacijski sustavi
CI_IN3	Udio vremena utrošen na diskusije	Uzorkovanje rada
CI_IN4	Udio vremena utrošen na formalne sastanke	Uzorkovanje rada
CI_IN5	Udio vremena utrošen na sastanke tima	Uzorkovanje rada
CI_IN6	Udio vremena utrošen na primanje informacije	Uzorkovanje rada
CI_IN7	Udio relevantnih primljenih informacija	Uzorkovanje rada
CI_IN8	Udio informacija primljenih licem-u-lice	Uzorkovanje rada
CI_IN9	Udio vremena utrošen na slanje informacije	Uzorkovanje rada
CI_IN10	Udio relevantnih poslanih informacija	Uzorkovanje rada
CI_IN11	Udio informacija poslanih licem-u-lice	Uzorkovanje rada
CI_IN12	Udio vremena utrošen na izmjenu informacija	Uzorkovanje rada
CI_IN13	Udio relevantnih izmijenjenih informacija	Uzorkovanje rada
CI_IN14	Broj transferiranih MB po sudioniku	Korporativni informacijski sustavi
CI_IN15	Razmjene, učenje, osobni razvoj	Korporativni informacijski sustavi
Inovativnost i ideacija		Metoda prikupljanja podataka
II_IN1	Broj individualnih ideacijskih aktivnosti vezanih za domenu proizvoda	Uzorkovanje rada
II_IN2	Udio individualnih ideacijskih aktivnosti vezanih za domenu	Uzorkovanje rada
II_IN3	Broj individualnih ideacijskih aktivnosti vezanih za ostale domene	Uzorkovanje rada
II_IN4	Udio individualnih ideacijskih aktivnosti vezanih za ostale domene s visokom relevantnošću informacije	Uzorkovanje rada
Motivacija i zadovoljstvo		Metoda prikupljanja podataka
MS_IN1	Motivacija tijekom individualnih aktivnosti	Uzorkovanje rada
MS_IN2	Osobno zadovoljstvo	Anketa

Tablica 4-5. Indikatori izvedbe intelektualnoga kapitala na timskoj razini

Timska razina		
Kompetencije i znanje		Metoda prikupljanja podataka
CK_TM1	Udio sudionika s nedovoljnim kompetencijama	Anketa (360-stupanjska metoda procjena)
CK_TM2	Udio izvrsnih članova tima	Anketa (360-stupanjska metoda procjena)
CK_TM3	Udio nezadovoljavajućih kompetencija	Anketa (360-stupanjska metoda procjena)
CK_TM4	Broj društveno izoliranih članova tima	Uzorkovanje rada
CK_TM5	Udio resursa koji nisu korišteni u zadovoljavajućoj mjeri	Uzorkovanje rada
Komunikacija i razmjena informacija		Metoda prikupljanja podataka
CI_TM1	U kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od internih izvora	Anketa
CI_TM2	U kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od eksternih izvora	Anketa
CI_TM3	U kolikoj mjeri se znanje pohranjuje u internim bazama podataka	Anketa
CI_TM4	U kolikoj mjeri se članovi tima osjećaju ugodno dok koriste već postojeća rješenja	Anketa
CI_TM5	U kolikoj mjeri se članovi tima osjećaju motivirano da dijele znanje s drugim članovima tima	Anketa
CI_TM6	U kolikoj mjeri članovi tima smatraju da sudjelovanje u timskim aktivnostima stvara iskustvo te rezultira novim rješenjima	Anketa
CI_TM7	U kolikoj mjeri se članovi tima osjećaju ugodno dijeleći znanje s drugim članovima tima	Anketa
CI_TM8	U kolikoj mjeri članovi tima smatraju da je jednostavno naći kolege s potrebnim kompetencijama	Anketa
CI_TM9	U kolikoj mjeri članovi tima smatraju da su interne baze podataka jednostavne za korištenje	Anketa
CI_TM10	Učestalost obavještavanja o novim unosima i rješenjima u internim bazama podataka	Anketa
CI_TM11	Broj slabih komunikacijskih veza	Uzorkovanje rada
CI_TM12	Broj jakih komunikacijskih veza	Uzorkovanje rada
Inovativnost i ideacija		Metoda prikupljanja podataka
II_TM1	U kolikoj mjeri okruženje prihvaća način razmišljanja "izvan kutije"	Anketa
II_TM2	U kolikoj mjeri okruženje podržava stvaranje novih ideja i odbacivanje postojećih	Anketa
II_TM3	U kolikoj mjeri su inovacije cilj menadžmenta	Anketa
II_TM4	U kolikoj mjeri menadžment podržava inovativnost u projektima	Anketa
II_TM5	Broj timskih ideacijskih aktivnosti vezanih za domenu proizvoda	Uzorkovanje rada
II_TM6	Udio timskih ideacijskih aktivnosti vezanih za domenu proizvoda s visokom relevantnošću informacije	Uzorkovanje rada
II_TM7	Broj timskih ideacijskih aktivnosti vezanih za ostale domene	Uzorkovanje rada
II_TM8	Udio timskih ideacijskih aktivnosti vezanih za ostale domene s visokom relevantnošću informacije	Uzorkovanje rada
Motivacija i zadovoljstvo		Metoda prikupljanja podataka
MS_TM1	Motivacija tijekom timskih aktivnosti	Uzorkovanje rada
MS_TM2	Vrijeme provedeno na društvene aktivnosti koje nisu vezane uz rad	Korporativni informacijski sustavi
MS_TM3	Udio aktivnosti s višom razinom motivacije	Uzorkovanje rada
MS_TM4	Udio aktivnosti s višom razinom relevantnosti informacije	Uzorkovanje rada

4.3. Prijedlog i validacija mreže nematerijalnih indikatora

Kao što je već spomenuto (poglavlje 3.2), u novijim se istraživanjima indikatora izvedbe ispituju i analiziraju njihovi međuutjecaji. Takva istraživanja mogu pridonijeti razumijevanju i upotrebi indikatora na nekoliko različitih načina. Na temelju identificiranih relacija između indikatora može se smanjiti preliminarni broj indikatora. Smanjivanje broja indikatora

omogućit će jednostavnije praćenje. Posebno se to odnosi na indikatore koji su međusobno usko povezani te se mogu ujediniti u jedinstveni indikator. Identifikacija utjecaja između indikatora može poslužiti i kao osnova za kreiranje uzročno-posljedičnih dijagrama indikatora izvedbe koji mogu potpomoći razumijevanju njihove ukupne izvedbe [137].

Potrebno je uzeti u obzir da su predloženi nematerijalni indikatori dio ukupnog sustava za mjerenje i praćenje organizacijske izvedbe. Dakako, korektna analiza i razumijevanje ovog odvojenog i ograničenog dijela sustava koji se sastoji od nematerijalnih indikatora omogućuje lakše naknadno povezivanje materijalnih indikatora. Iz perspektive IK-a potvrđeno je mnogo puta da su njegovi elementi međusobno povezani (npr. [7]), ali često je takav tip analize proveden koristeći se generičkim varijablama ili parametrima, a ne upotrebom indikatora sa zadanim načinom mjerenja i jasnom metrikom.

Za određivanje utjecaja između indikatora mogu se primijeniti dva različita pristupa: ekspertno znanje ili statistička analiza prikupljenih podataka. Glavna je prednost tehnika temeljenih na ekspertnom znanju što nema potrebe za velikom količinom prikupljenih podataka. Dakako, identificirane veze stoga neće biti precizne kao primjenom statističkih tehnika čiji se rezultati ne temelje na iskustvu ili subjektivnim procjenama, već na neposrednoj analizi skupa podataka.

Na temelju ovih postavki, kao pristup za stvaranje mreže nematerijalnih indikatora izvedbe u ovom radu poslužilo je znanje eksperata radi definiranja utjecaja između različitih nematerijalnih indikatora izvedbe i određivanja najutjecajnijih indikatora u modelu. Opravdanje je za odabir takva pristupa u prirodi indikatora. Naime, s obzirom na različitu učestalost promjene i praćenja pojedinih indikatora (npr. indikatori kategorije *kompetencije i znanje* ne prate se jednako često kao indikatori kategorije *komunikacija i razmjena informacija*), ne može se prikupiti potrebna količina podataka za uspostavljanje statističkih veza između indikatora. Izrada mreže međuovisnosti između indikatora statističkom analizom rezultirala bi jako malim brojem identificiranih međuzavisnosti između indikatora, upravo zbog malog broja mjerenja pojedinih indikatora. Također, s obzirom na drukčiji pristup prikupljanju podataka u sklopu provedenog istraživanja, nije moguće korištenje prijašnjim podacima vezanim za izvedbu intelektualnoga kapitala.

Na temelju pregleda literature te razumijevanja problematike upravljanja projektima relevantne za mjerenje izvedbe IK-a definirane su veze između indikatora. Kao rezultat ovog koraka, kreirana je mreža međuovisnosti indikatora.

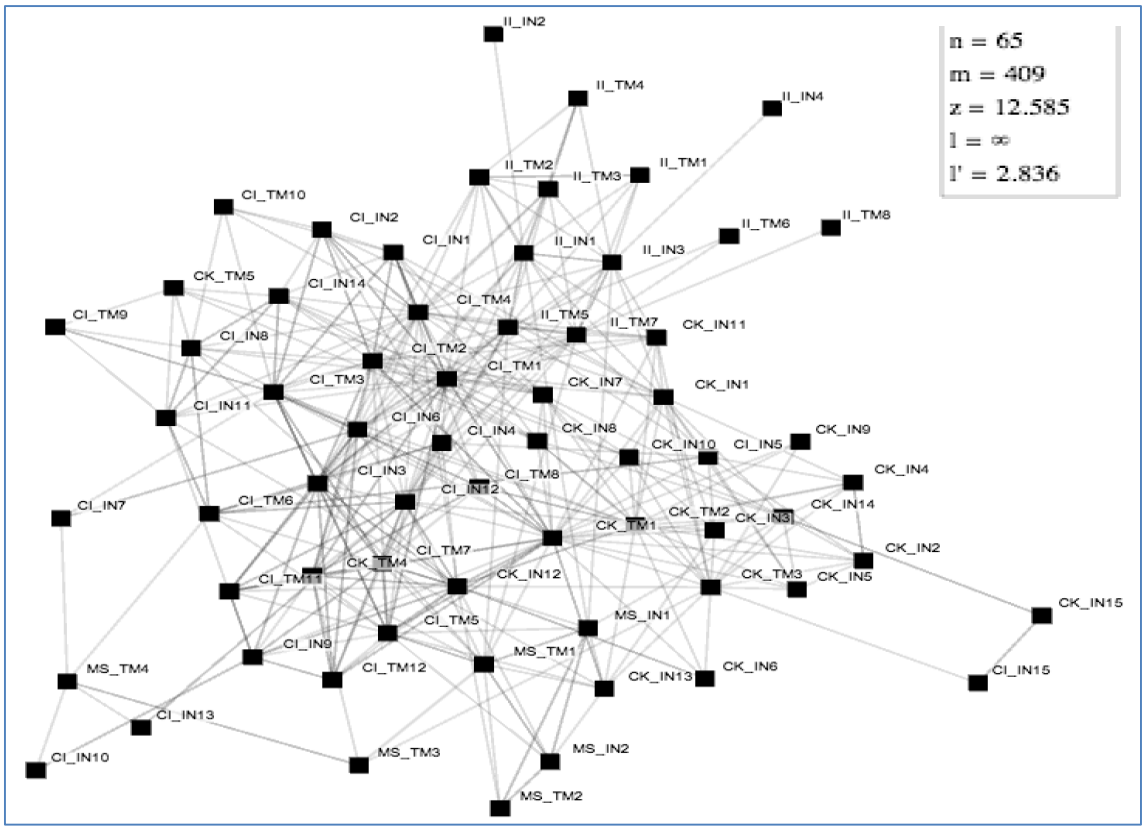
Predložena mreža validirana je u suradnji s ekspertima iz navedenih tvrtki. Zbog velikog broja indikatora i gustoće veza u svakoj je tvrtki odabran po jedan ekspert koji je imao funkciju voditelja i koordinatora validacije. Odabrani su eksperti konzultirali suradnike iz drugih odjela i s različitim kompetencijama. Osim verifikacije identificiranih veza između indikatora, eksperti su trebali procijeniti vrijednost jačine utjecaja koristeći se sličnom skalom kao i prije – od 0 do 4 (0 nema utjecaja između indikatora, 4 ima vrlo velik utjecaj između indikatora).

Na temelju podataka dobivenih iz prve faze validacije stvorena je mreža nematerijalnih indikatora. Otkrivanje zajednica provedeno je na kreiranoj mreži kako bi se istražile zajednice indikatora koje su gušće povezane unutar skupine nego s ostatkom mreže i kako bi se mogle analizirati veze između nematerijalnih indikatora koji pripadaju različitim elementima na individualnoj i timskoj razini (Slika 4-3b).

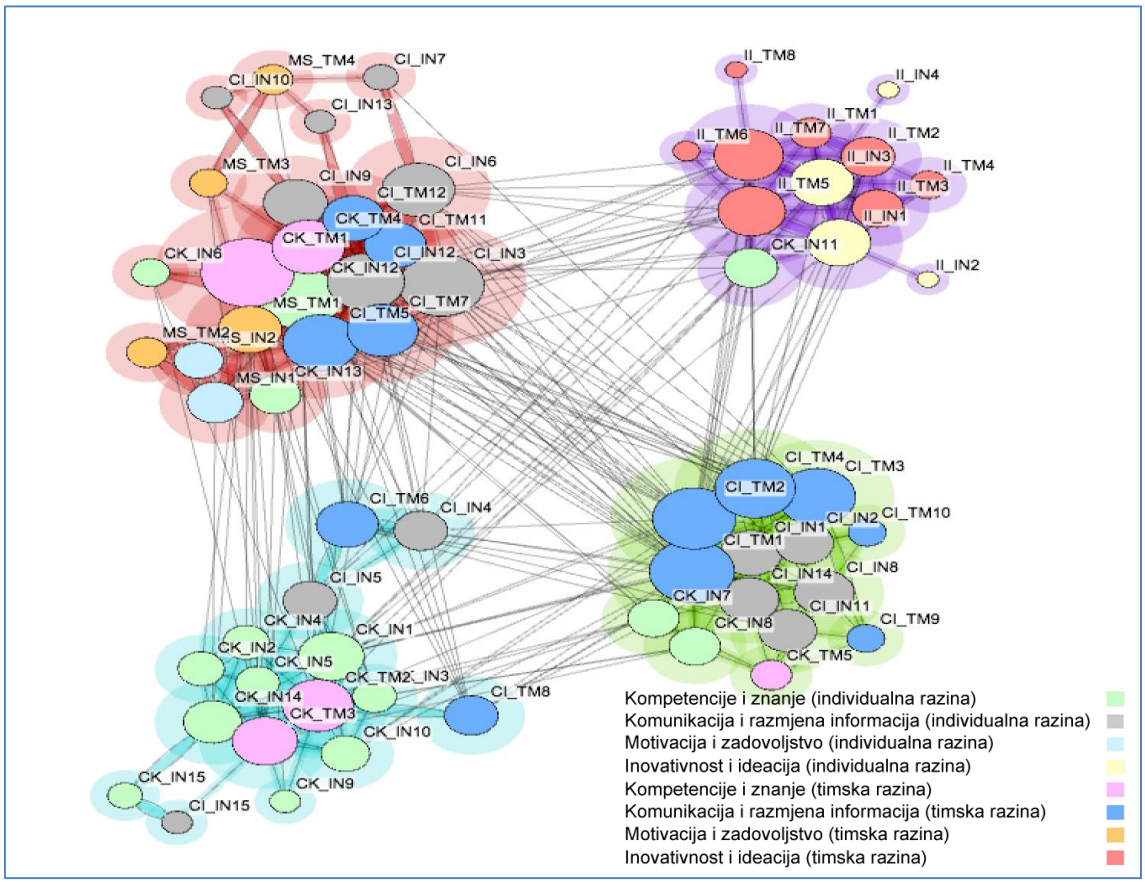
Otkrivanje zajednica potvrdilo je jak utjecaj indikatora izvedbe na individualnoj razini indikatorima na timskoj razini u istoj kategoriji IK-a, ali su također uputili na veze između elemenata IK-a na višoj razini. Posebno se dobro uočava povezanost indikatora iz kategorije *komunikacija i razmjena znanja* s indikatorima iz drugih kategorija (prisutni znatno u čak tri zajednice). Također, pojedini indikatori iz kategorije *kompetencije i znanje* u zajednicama su s indikatorima iz drugih kategorija. Na primjer, *kreativnost,* koja pripada kategoriji *kompetencije i znanje*, usko je vezana uz kategoriju *inovativnost i ideacija*, a *socijalne vještine* vezane su uz indikatore kategorije *komunikacija i razmjena informacija*.

Početna je analiza mreže provedena radi određivanja pojedinih njezinih karakteristika. Za provjeru postupka kreiranja mreže u literaturi se sugerira uporaba distribucije stupnja čvorova koja može uputiti na pristranost istraživača. Stupanj čvora u mreži definira se kao broj bridova s kojima je navedeni čvor incidentan. Prema Powellu i dr. [179], mogu se razlikovati različite distribucije stupnjeva čvorova u mreži koristeći se log-log prikazom – na x-osi logaritam je stupnja, a na y-osi logaritam broja čvorova s određenim stupnjem. Raspodjela stupnja čvorova prikazana je histogramom u kojem se raspon kategorija stupnja eksponencijalno povećava s rastom stupnja.

Kategorije su formirane tako da pokrivaju raspon stupnjeva 1, 2-3, 4-7, 8-15 itd. Broj uzoraka u svakoj kategoriji podijeljen je s rasponom kategorije kako bi se normalizirale vrijednosti za pojedinu od njih. Takvim je pristupom kreirana agregirana distribucija stupnja mrežne strukture na log-log skali.



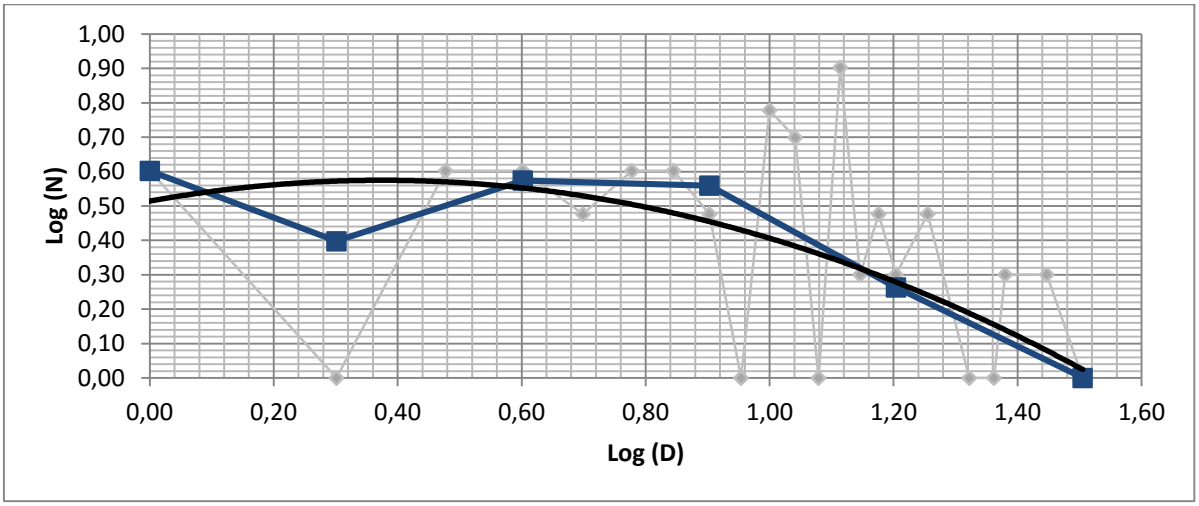
a) mreža indikatora izvedbe



b) otkrivanje zajednica

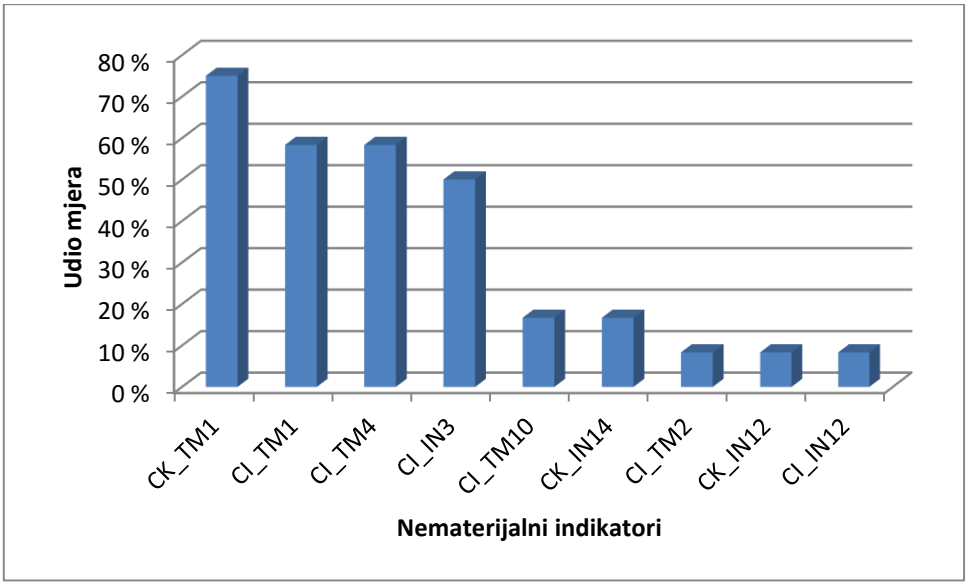
Slika 4-3. Mreža indikatora izvedbe

Iz analize distribucije stupnja čvorova uočljiv je konveksni oblik aproksimacije koji upućuje na to da je mreža kreirana bez pristranosti istraživača (Slika 4-4).



Slika 4-4. Prikaz distribucije stupnja za mrežu nematerijalnih indikatora

Radi dubljeg razumijevanja strukturnih svojstava mreže, statistička je analiza mreže i čvorova provedena pomoću ORA-NetScenesa [180]. Za analiziranu mrežu izračunate su sljedeće mjere: centralnost stupnja, centralnost blizine, centralnost svojstvenog vektora i centralnost međupoloženosti [181]. Vrijednost prikazana na slici (Slika 4-5) postotak je mjera u kojima je pojedini indikator izvedbe svrstan među prva tri indikatora.



Slika 4-5. Najbolji nematerijalni indikatori prema mjerama proizišlim iz analiza mreže

Na temelju toga zaključeno je da su najutjecajniji nematerijalni indikatori u mreži:

- CK_TM1: udio sudionika s nedovoljnim kompetencijama *[kompetencije i znanje (timska razina)]*

- CI_TM1: u kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od unutarnjih izvora *[komunikacija i razmjena informacija (timska razina)]*
- CI_TM4: u kolikoj mjeri se članovi tima osjećaju ugodno dok koriste već postojeća rješenja *[komunikacija i razmjena informacija (timska razina)]*
- CI_IN3: udio vremena utrošen na diskusije *[komunikacija i razmjena informacija (individualna razina)]*
- CI_TM10: učestalost obavještavanja o novim unosima i rješenjima u internim bazama podataka *[komunikacija i razmjena informacija (timska razina)]*
- CK_IN14: sposobnost učenja *[kompetencije i znanje (individualna razina)]*
- CI_TM2: u kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od vanjskih izvora *[komunikacija i razmjena informacija (timska razina)]*
- CK_IN12: socijalne vještine *[kompetencije i znanje (individualna razina)]*
- CI_IN12: udio vremena utrošen na izmjenu informacija *[komunikacija i razmjena informacija (individualna razina)]*

4.4. Određivanje važnosti nematerijalnih indikatora

Nakon početne analize mreža, korištenjem vrijednosti jačine utjecaja između indikatora stvoreni su preduvjeti za primjenu postojećih procedura rangiranja iz teorije vrednovanja i za izračun težinskih faktora za svaki pojedini indikator u mreži. Pridruživanje vrijednosti nematerijalnih indikatora težinskim faktorima omogućuje razvoj modela agregacije te izračun vrijednosti jedinstvenog indeksa za svaki od četiriju elemenata IK-a.

Jedna je od mogućnosti za određivanje važnosti indikatora uporaba rezultata iz izravnog ocjenjivanja njihove važnosti koje su industrijski partneri proveli pri validaciji popisa. Problem je u takvu pristupu što je većina indikatora ocijenjena ocjenama 3 i 4 (Slika 4-2) i zbog toga je rangiranje indikatora otežano. Stoga se za određivanje važnosti pojedinog indikatora uzima u obzir utjecaj između različitih indikatora u mreži.

Uzimajući u obzir jačinu utjecaja između indikatora, za proračun težinskih faktora i rangiranje indikatora može se primijeniti Metoda potencijala [131]. Uspoređujući tu metodu sa Saatyjevim AHP-om koji organizira podatke kao recipročnu matricu, Metoda potencijala koristi se direktnim težinskim grafovima s intenzitetom preferencija koje su definirali validatori u koraku ocjenjivanja važnosti utjecaja između indikatora.

4.4.1. Primjena Metode potencijala na mrežu indikatora

Na temelju vrijednosti preferencija za danu mrežu definiran je graf indikatora. Usmjeren graf prirodna je struktura za zapisivanje rezultata uspoređivanja u parovima pri određivanju vrijednosti utjecaja između indikatora. Skup čvorova u grafu predstavlja skup objekata koji se uspoređuju, a broj lukova u grafu jednak je broju uspoređenih parova vrhova. U primjeni Metode potencijala [131] na mrežu nematerijalnih indikatora vrhovi se međusobno ne uspoređuju, nego se uspoređuje utjecaj para vrhova na najviši entitet – intelektualni kapital. Dakle, intenzitet preferencija određuje se usporedbom utjecaja između parova indikatora. Intenzitet preferencije nenegativan je broj koji su validatori dodijelili u fazi validacije mreže korištenjem skalom intenziteta od 0 do 4, a temeljem kojih su izračunate vrijednosti potencijala.

Tokom preferencije naziva se nenegativna funkcija $\mathcal{F}$ koja svakom luku (preferenciji) pridružuje njezin intenzitet [131]. Dobiveni graf nazivamo grafom preferencije. Ako je intenzitet preferencije jednak 0, orijentacija je luka nevažna.

Ako s V označimo skup svih indikatora, glavni je cilj vrednovanja određivanje funkcije vrijednosti $X : V \to \mathbb{R}$ koja je u skladu s $\mathcal{F}$ na sljedeći način:

$$X_i - X_j = \mathcal{F}_\alpha \tag{2}$$

U gornjem izrazu $\alpha = (i, j)$ označava luk koji izlazi iz vrha j i ulazi u vrh i. Ako X postoji, onda se $\mathcal{F}$ naziva konzistentni tok.

Potencijal X_i za indikator i definiramo kao zbroj svih ulaza i izlaza podijeljen s brojem čvorova n, tj.

$$X_i = \frac{1}{n}\left(\sum_{(i,j)\in\mathcal{A}} \mathcal{F}_{(i,j)} - \sum_{(j,i)\in\mathcal{A}} \mathcal{F}_{(j,i)}\right) \tag{3}$$

gdje se u prvom zbroju zbraja po svim lukovima (i, j) koji ulaze u i -ti čvor, a u drugom se zbraja po svim lukovima (j, i) koji izlaze iz i-tog čvora.

Matrica toka F matrica je pridružena toku $\mathcal{F}$ na sljedeći način

$$\mathrm{F_{i,j}} = \begin{cases} \mathcal{F}_{(\mathrm{i,j})}, & \text{ako } (\mathrm{i,j}) \in \mathcal{A} \\ -\mathcal{F}_{(\mathrm{j,i})}, & \text{ako } (\mathrm{j,i}) \in \mathcal{A} \end{cases} \tag{4}$$

pri čemu je $\mathcal{A}$ skup svih lukova. Ako još stavimo da je prema definiciji $\mathrm{F}_{ii} = 0, i = 1, \dots, n$, onda je matrica F antisimetrična i gornja se formula za potencijal svodi na računanje srednje vrijednosti elemenata u retku matrice F. Dakle,

$$X_i = \frac{1}{n} \sum_{j=1}^{n} F_{ij} \tag{5}$$

Iz ovog izraza slijedi da je potencijal X za potpuni graf preferencija aritmetička sredina stupaca matrice toka F.

Kao što je već spomenuto, očita je sličnost sa Saatyjevom AHP metodom, iako se u ovom pristupu umjesto kvocijenta omjera vjerojatnosti ω_i/ω_j procjenjuje razlika $X_i - X_j$.

Korištenjem grafom indikatora, Metoda potencijala [131] omogućuje izračun nepoznatih težinskih faktora primjenom procedure samorangiranja. Procedura samorangiranja započinje s određivanjem preliminarnog vektora težina w i izračunom novog vektora $\Phi(w)$, koristeći se izrazom:

$$w = \frac{a^X}{\|a^X\|_1} \tag{6}$$

u kojem je $a > 1$ i a ima konstantnu vrijednost. Zbroj svih komponenata težinskog vektora jednak je 1 jer je zbroj vektora potencijala jednak 0. Dobiveni težinski vektor može se shvatiti kao novi početni težinski vektor koji omogućuje izračun $\Phi\big(\Phi(w)\big)$. Uzastopnim djelovanjem funkcije Φ može se izračunati niz vektora:

$$w \mapsto \Phi(w) \mapsto \Phi\big(\Phi(w)\big) \mapsto \cdots \mapsto \Phi^n(w) \mapsto \cdots \tag{7}$$

Navedeni niz konvergira te dobiveni limes ne ovisi o odabiru početnog vektora. Limes je jedinstvena fiksna točka funkcije Φ:

$$\xi = \Phi(\xi) \tag{8}$$

koja proizlazi iz Browerova teorema o fiksnoj točki [131]. Hijerarhijska struktura samorangiranja zahtijeva jednakost prve i zadnje razine strukture, neovisno o broju međurazina između njih. U ovom slučaju, izvršena je direktna usporedba veza između indikatora, zbog čega se samorangiranje provodi u jednom koraku. Nakon provedenog proračuna, rezultati dobiveni Metodom potencijala prikazani su u tablici (Tablica 4-6) (20 najutjecajnijih indikatora). Pozadina žute boje u tablici (Tablica 4-6) sugerira da su isti indikatori proizišli i kao najutjecajniji iz prethodno provedene analize statičkih svojstava mreže.

Tablica 4-6. Rangiranje važnosti indikatora izvedbe IK (20 najbolje rangiranih indikatora)

Redoslijed	Oznaka	Težinski faktor	Naziv indikatora
1	CI_TM4	0.0268	U kolikoj mjeri se članovi tima osjećaju ugodno dok koriste već postojeća rješenja
2	CI_TM1	0.0241	U kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od internih izvora
3	CI_TM2	0.0221	U kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od eksternih izvora
4	CI_IN3	0.0214	Udio vremena utrošen na diskusije
5	CK_IN12	0.0192	Socijalne vještine
6	CI_IN12	0.0188	Udio vremena utrošen na izmjenu informacija
7	CI_TM7	0.0185	U kolikoj mjeri se članovi tima osjećaju ugodno dijeleći znanje s drugim članovima tima
8	CI_TM5	0.0184	U kolikoj mjeri se članovi tima osjećaju motivirano da dijele znanje s drugim članovima tima
9	CI_IN6	0.0182	Udio vremena utrošen na primanje informacije
10	CK_IN1	0.0181	Rješavanje problema
11	MS_TM1	0.0176	Motivacija tijekom timskih aktivnosti
12	CK_IN14	0.0174	Sposobnost učenja
13	CI_TM3	0.0173	U kolikoj mjeri se znanje pohranjuje u internim bazama podataka
14	MS_IN1	0.0173	Motivacija tijekom individualnih aktivnosti
15	CK_IN11	0.0172	Kreativnost
16	CK_TM1	0.0167	Udio sudionika s nedovoljnim kompetencijama
17	CK_TM4	0.0163	Broj društveno izoliranih članova tima
18	CI_TM6	0.0163	U kolikoj mjeri članovi tima smatraju da sudjelovanje u timskim aktivnostima stvara iskustvo te rezultira novim rješenjima
19	CK_IN7	0.0161	Opća IT pismenost
20	CK_IN8	0.0161	Specifična IT pismenost

Kao što je potvrđeno nekim prijašnjim istraživanjima, indikatori *CI_IN3: udio vremena koje sudionici provode u diskusijama* i *CK_IN12: socijalne vještine* veoma su važni u inženjerskom kontekstu, što upućuje na važnost socio-tehničkog aspekta upravljanja projektima. Analizirajući indikatore iz kategorije *kompetencije i znanje* (osim već navedenog CK_IN2), kao najvažniji se profilirao *CI_IN1: rješavanje problema*, a slijede ga *CI_IN14: sposobnost učenja* i *CK_IN11: kreativnost*. Iako indikatori iz kategorije *inovativnost i ideacija* nisu svrstani visoko, već spomenuti *CK_IN1* i prvi rangirani *CI_TM4: koliko se članovi tima osjećaju ugodno dok se koriste već postojećim rješenjima*, itekako mogu pružiti povratnu informaciju o tom elementu intelektualnoga kapitala. Također je važno istaknuti da indikatori koji su vezani za ponovno korištenje znanjem od unutarnjih (*CI_TM1*) i vanjskih izvora (*CI_TM2*) imaju važnu ulogu, što opravdava njihovo uvrštavanje u model.

Iako je uočljivo preklapanje prvih šest indikatora u rezultatima obiju analiza (važnosti i utjecaja), vidljive su i razlike u dobivenim rezultatima važnosti i utjecaja indikatora. Indikator C*K_TM1: broj sudionika s nedovoljnim kompetencijama* koji je prema analizi mreže najutjecajniji nematerijalni indikator, prema provedenom proračunu Metodom potencijala nije svrstan u prvih 15 indikatora. Također, važnost pojedinih kompetencija znatno je manja na temelju metrika analize mreže. Razlika između dvaju provedenih postupaka rangiranja proizlazi iz različitih ulaznih podataka. Naime, za određivanje najutjecajnijih indikatora upotrijebljena je ulazna mreža s binarnim vrijednostima 0 (nema utjecaja) i 1 (utjecaj postoji), a za određivanje važnosti i težinskih faktora poslužila je ulazna mreža s ocijenjenom jačinom utjecaja u diskretnom rasponu od 0 do 4 (0 nema utjecaja između indikatora, 4 vrlo velik utjecaj između indikatora).

4.5. Model agregacije indikatora

Težinski faktori dobiveni Metodom potencijala [131] preduvjet su za formiranje agregacijskog modela za praćenje elemenata IK-a na individualnoj i timskoj razini. Prema Luterovoj podjeli [182], izračunati su težinski faktori subjektivni (procijenili su ih eksperti) i statički (težinski faktori nisu podložni promjenama).

Nakon prikupljanja podataka upotrebom različitih pristupa prikupljanja te njihovim preslikavanjem u vrijednosti nematerijalnih indikatora, potrebno je agregirati različite vrijednosti radi praćenja trenda i dinamike na razini svakog od četiriju elemenata IK-a koji su definirani kao fokus disertacije. Agregacija nematerijalnih indikatora može se provesti za kategorije *kompetencije i znanje*, *komunikacija i razmjena informacija, inovativnost i ideacija* i *motivacija i zadovoljstvo* na individualnoj i timskoj razini. Budući da je prilično zahtjevno pratiti velik broj indikatora (u našem slučaju 65), agregacija omogućuje praktično i jednostavno praćenje nematerijalnih aspekata. Agregirane vrijednosti olakšavaju donošenje odluka zbog koncizna oblika i prikaza informacije.

Iako se agregacija često provodi implicitno, radi boljeg razumijevanja i interpretacije agregirane vrijednosti, proceduru agregacije potrebno je prikazati eksplicitno. Agregacija se može provesti na nekoliko načina: 1. agregacija na individualnoj i timskoj razini, 2. agregacija prema kategoriji intelektualnoga kapitala te 3. agregacija kombiniranjem ovih dviju perspektiva. S obzirom na predmet i cilj istraživanja, agregacija će se u ovoj disertaciji provesti prema kategorijama IK-a na individualnoj i timskoj razini.

Koristeći se prije dobivenim težinskim faktorima $w_{i,j}$ pomoću Metode potencijala, agregirana vrijednost pojedine kategorije može se izračunati upotrebom najčešćeg oblika agregacije – diferencijalno ponderirane linearne agregacije:

$$ICK_j = \sum_{i=1}^{n} I_{i,j} \cdot w_{i,j}, \qquad j \in \{1,2,3,4,5,6,7,8\} \tag{9}$$

u kojoj $I_{i,j}$ (raspon vrijednosti od 0 do 10) predstavlja vrijednost pojedinog indikatora unutar kategorije j. Za zbroj svih težinskih faktora u jednoj kategoriji vrijedi sljedeći izraz:

$$\sum_{i=1}^{n} w_{i,j} = 1 \tag{10}$$

Kako bi se omogućila linearna agregacija indikatora (poglavlje 3.3), potrebno je prikupiti podatke za određivanje vrijednosti indikatora te provesti normalizaciju njihove vrijednosti. Normalizacija je iznimno važna pri definiranju postupka agregacije jer uvodi implicitne ili latentne sustava vrednovanja.

Za potrebe predloženog modela, indikatori koji su izraženi u postocima normalizirani su na skalu od 1 do 10, a indikatori koji su se prethodno koristili skalom od 1 do 10 zadržali su vrijednosti. Za indikatore čije su vrijednosti izražene na skali od 1 do 5 obavljena je promjena skale prema Dawesu [183]. Ovaj način promjene skale podrazumijeva da se krajevi skale od 1 do 5 zamijene s 1 do 10 te se zatim provodi interpolacija vrijednosti (Tablica 4-7).

Tablica 4-7. Promjena vrijednosti skale prema Dawesu [183]

Originalna vrijednost	Promijenjena vrijednost
1	1,00
2	3,25
3	5,50
4	7,75
5	10,00

Kao važan segment normalizacije potrebno je prilagoditi indikatore koji su postavljeni kao negativni (CK_TM1: *udio sudionika s nedovoljnim kompetencijama,* CK_TM3: *udio nezadovoljavajućih kompetencija* itd). Izraz za prilagodbu negativnih vrijednosti indikatora koji proizlaze iz ankete glasi:

$$PVI = (S + 1) - IVI \tag{11}$$

pri čemu S označava broj uporišnih točaka neke skale (indikatori koji su dobiveni iz ankete imaju vrijednosti $S = 5$ ili $S = 10$), a *PVI* i *IVI* prilagođenu i inicijalnu vrijednost indikatora. Ako se koristimo vrijednostima na skali od 0 do 10, izuzima se drugi pribrojnik u jednadžbi iznad.

Nakon provedene normalizacije, mogu se pridružiti vrijednosti indikatora težinskim faktorima te izračunati agregirane vrijednosti za navedene elemente IK-a. U poglavlju 6.4 prikaz je agregiranih vrijednosti za provedenu studiju slučaja.

5. Prikupljanje podataka za praćenje nematerijalnih indikatora

U petom su poglavlju prikazani predloženi pristupi prikupljanja podataka u okviru ove disertacije. Osim kratkog opisa načina korištenja, prednosti i nedostataka svakog od navedenih pristupa, u ovom je poglavlju objašnjena i njihova primjena i prilagodba za potrebe provedenog istraživanja.

5.1. Metode prikupljanja podataka

Zbog specifičnosti individualnog i timskog rada tijekom procesa razvoja proizvoda, za prikupljanje podataka potrebnih za određivanje vrijednosti nematerijalnih indikatora predložena je primjena triju metoda: 1. uzorkovanje rada, 2. ankete i 3. integracija s korporativnim IT sustavima. Dok su ankete i integracija s postojećim IT sustavima prilično uobičajeni i uvriježeni pristupi za mjerenje nematerijalnih indikatora, uzorkovanje rada do sada nije upotrijebljeno u ovom kontekstu te nudi brojne nove mogućnosti za kvantitativno i objektivnije prikupljanje podataka na individualnoj i timskoj razini.

5.2. Uzorkovanje rada

Uzorkovanje rada (engl. *work sampling*) metodički je pristup mjerenju radnih aktivnosti koji se provodi procjenom udjela vremena koje sudionici troše izvodeći pojedine aktivnosti. U literaturi se mogu pronaći i brojni drugi izrazi na engleskom jeziku koji se rabe za istu svrhu – *activity sampling*, *ratio delay*, *occurrence sampling*, *snap delay*. Najčešći je termin (koji će se uporijebiti u nastavku disertacije) uzorkovanje rada (engl. *work sampling*) [184]. Metoda se temelji na prikupljanju podataka u određenim vremenskim razmacima, što je razlikuje od klasičnih vremenskih studija. Koristeći se osnovnim statističkim principima, uzorkovanje rada provodi se prikupljanjem podataka za određeni uzorak radnih aktivnosti. Kao najpoznatija primjena ove metode u području razvoja tehničkih sustava može se navesti Robinsonova studija [99], [100] kojoj je cilj bilo proučavanje ponašanja inženjera s aspekta korištenja informacijama, ali i analiza vremena koje inženjeri troše na pojedine aktivnosti i zadatke tijekom razvojnih procesa [99], [100].

Matematički zapis uzorkovanja rada glasi:

$$udio\ vremena\ utrošenog\ na\ aktivnost\ A = \frac{vrijeme\ utrošeno\ na\ aktivnost\ A}{ukupno\ vrijeme\ utrošeno\ na\ sve\ aktivnosti} \times 100 \quad (12)$$

Za formulaciju valjane studije uzorkovanja rada potrebno je slijediti pet koraka: identifikacija aktivnosti koje su glavna svrha planirane studije; procjena razdoblja trajanja aktivnosti (postotak ukupnog vremena) relevantnog za ovaj tip studije; odabir razine preciznosti koja je zahtijevana za ovaj tip studije; definicija vremena kad će se mjerenje obaviti; ponovni izračun mjernih točaka kako bi se zadovoljila tražena razina preciznosti.

Za postizanje određene preciznosti studije potrebno je odrediti zahtijevani broj točaka uzorkovanja. Veličina uzorka može varirati od nekoliko stotina do nekoliko tisuća mjernih točaka. Povećanjem broja točaka smanjuje se mogućnost pogrešne procjene. Točan broj potrebnih dnevnih mjerenja ovisi o broju sudionika te o trajanju studije. Iako Dickson [185] u svojem istraživanju (farmaceutski sektor) nije pronašao nikakve velike razlike između rezultata opservacija obavljenih u fiksnim i slučajnim intervalima, preporuka je da točke uzorkovanja u danu budu slučajno raspoređene. Također, u literaturi se savjetuje ravnomjerna raspodjela mjernih točaka tijekom različitih dana studije te raspodjela točaka unutar dana koristeći se fiksnim i slučajnim intervalima. Slučajni intervali uzorkovanja omogućuju prikupljanje statistički valjanih i nepristranih rezultata. Slučajnost se može postići na nekoliko načina – od upotrebe tablica slučajnih brojeva do upotrebe generatora slučajnih brojeva primijenjenih na radno vrijeme sudionika uzorkovanja.

Prema Papeu [186] i Robinsonu [99], broj točaka uzorkovanja može se izračunati kao:

$$N = \frac{(1-p)(Z_{\lambda/2})^2}{p(R)^2} \quad (13)$$

u kojima su:

p – udio vremena koje sudionik provodi obavljajući određenu aktivnost, prikazan vrijednošću od 0 do 1.

R – razina preciznosti (točnosti) iskazana pomoću vrijednosti na skali od 0 do 1. Vrijednost prikazuje mjeru koliko je vrijednost p blizu stvarnoj vrijednosti p.

$Z_{\lambda/2}$ – broj standardnih devijacija kako bi se dobila željena razina pouzdanosti (npr. 1.96 za razinu pouzdanosti 95 %). Razina pouzdanosti vjerojatnost je da će p biti unutar raspona preciznosti.

Uspoređujući druge tehnike mjerenja i praćenja rada s uzorkovanjem rada, uočavaju se brojne prednosti metode kojom se koristilo u ovoj disertaciji. Uzorkovanje rada jednostavna je metoda koja zahtijeva minimalnu pripremu sudionika za samu provedbu studije. Troškovi su studije, također, znatno niži u usporedbi sa stalnom opservacijom. Metoda omogućuje neposredno prikupljanje podataka i od sudionika se ne zahtijeva procjena koliko vremena provode izvodeći pojedinu aktivnost. Također omogućuje prikupljanje podataka od većeg broja sudionika, ali se smanjuje detaljnost podataka. Stoga Finkler i dr. [187] tvrde da je nužno postići ravnotežu između broja sudionika i razine detalja.

Također, potrebno je uzeti u obzir nedostatke te metode. Ako proces, koji je predmet studije, prolazi kroz određene promjene, rezultati uzorkovanja rada neće biti reprezentativni. Budući da je metoda uzorkovanja ponajprije primjenjiva na radnim mjestima s većim postotkom rutinskih aktivnosti (manji broj aktivnosti s duljim trajanjem), zahtjevno je primijeniti i prilagoditi ovaj pristup za potrebe većeg broja aktivnosti s kraćim trajanjem.

Podaci za uzorkovanje rada mogu se prikupljati promatranjima (npr. [188]) ili samoizvještavanjem (npr. [99]). Promatranja zahtijevaju veliku količinu resursa jer je zahtijevana stalna prisutnost istraživača ili promatrača tijekom studije (katkad se prati samo jedan sudionik). Prema Finkleru i dr. [187], opservacija (promatranje) je prikladna tehnika ako se studija provodi na ograničenu području (npr. medicinske sestre u bolnici, radnici u proizvodnom pogonu). Ipak, za potrebe istraživanja u stvarnom organizacijskom okruženju rijetko se upotrebljavaju jednosmjerna zrcala ili videokamere zbog učestala kretanja sudionika, ali i ograničenja privatnosti.

Samoizvještavanje se provodi pomoću dnevnika rada [189] i upitnika [190]. Bitno je istaknuti da se ove metode temelje na retrospekciji jer ih sudionici ispunjavaju na kraju dana ili mjeseca. Takav način prikupljanja negativno utječe na točnost i preciznost prikupljenih podataka. Stoga je postojala potreba za trenutačnim unošenjem podataka, odnosno za prikupljanjem u stvarnom vremenu, kako bi se omogućio točniji zapis aktivnosti. Prikupljanje podataka pomoću papirnatih predložaka zahtijevalo je od sudionika mnogo vremena, što je ograničavalo količinu i detaljnost prikupljenih podataka. S napretkom tehnologije, inicijalno su poslužili osobni telekomunikacijski uređaji (engl. *pager*) za informiranje sudionika o vremenu kada je potrebno unijeti podatke samoizvještavanja (uz klasične papirnate predloške za zapisivanje podataka). Osim emitiranja podsjetnika, osobni su digitalni pomoćnici (engl. *PDA*) omogućili i digitalno prikupljanje podataka od sudionika uzorkovanja.

Takav način prikupljanja podataka imao je nekoliko prednosti [99]:

- nije potrebna prisutnost istraživača za provođenje studije te se zahtijeva znatno manje resursa za to
- omogućuje se jednostavnije praćenje većeg broja sudionika
- omogućuje se često i nepredvidivo ispitivanje sudionika
- omogućuje se prikupljanje podataka koji ovise o percepciji svakog sudionika i koje promatrač ne može prepoznati i prikupiti promatranjem.

Jednostavniji unos podataka omogućio je brže prikupljanje znatno veće količine informacija o uzorkovanoj aktivnosti. To je Robinson [99] iskoristio za uvođenje višedimenzijskog opisa aktivnosti te integrirao u postojeću PDA platformu.

U današnje su vrijeme PDA uređaji zastarjeli te je stoga u okviru izrade doktorskog rada razvijena aplikacija za uzorkovanje rada za pametne telefone. Pametni su telefoni lako dostupni i većina je ljudi naučena na njihovu svakodnevnu upotrebu koristeći se intuitivnim i praktičnim sučeljima te ekranima osjetljivim na dodir. Pregledom postojećih aplikacija pronađeno je nekoliko rješenja za uzorkovanje rada na mobilnim platformama, no glavni je problem bila njihova nefleksibilnost u smislu promjene načina uzorkovanja u skladu sa specifičnim potrebama ovog istraživanja. Zbog toga je osmišljena nova aplikacija za prikupljanje podataka u stvarnom vremenu o aktivnostima individualnog i timskog rada tijekom razvoja tehničkih sustava.

Budući da se prikupljanje podataka aplikacijom za uzorkovanje rada temelji na samoizvještavanju, potrebno je navesti njegove moguće nedostatke. Pri samoizvještavanju u organizacijskom okruženju, sudionici su skloni pogrešnu unošenju podataka zbog brojnih razloga, npr. straha od nadređenih ili zbog želje da se prikažu boljima od ostalih suradnika [191]. Emotivno stanje sudionika i njihova razina motivacije također znatno utječu na kvalitetu prikupljenih podataka. Moguće je i pogrešno korištenje aplikacijom te je stoga bilo potrebno osmisliti aplikaciju za razumljivo i jednostavno korištenje.

5.2.1. Mobilna aplikacija za uzorkovanje rada

Potaknuto Robinsonovim istraživanjem [99] te koristeći se analogijom s konceptom elektroničkog dnevnika (za samoizvještavanje), aplikacija je osmišljena kao niz ekrana s preddefiniranim izbornicima koji omogućuju odabir jedne ili više opcija na ekranu. Takvim se načinom prikupljanja znatno pojednostavnjuje i ubrzava unos podataka te omogućuje njihovo

prikupljanje o više aspekata razvojnih aktivnosti. Podaci o različitim aspektima razvojnih aktivnosti mogu se pritom kombinirati i zajednički analizirati, što daje detaljniju i potpuniju sliku o pojedinoj uzorkovanoj točki.

Budući da je uzorkovanje rada općenita metoda za prikupljanje podataka, popis ulaznih stavaka za unos podataka putem mobilne aplikacije potrebno je prilagoditi. Pri tome treba napomenuti da se ovom metodom mogu prikupiti podaci za sve indikatore koji su navedeni u tablici (Tablica 5-1). Popis mogućih ulaznih vrijednosti na izbornicima je osmišljen na temelju pregleda literature o uzorkovanju inženjerskih aktivnosti, ali i prethodne analize nematerijalnih indikatora. Izbornike je potrebno izraditi tako da ulazne stavke imaju sljedeće karakteristike [192]:

1. lako se mogu razlikovati
2. jasne su (moguće je jednostavno odrediti što pojedina ulazna vrijednost znači)
3. iscrpne su (pokrivaju sve opcije koje bi pojedini sudionik želio odabrati)
4. ne preklapaju se (trenutačni opis aktivnosti moguć je samo jednom ulaznom vrijednosti).

Poštujući navedena pravila izrade ulaznih stavaka, u konačnici je osmišljeno 10 izbornika (primjeri ulaznih vrijednosti navedeni su u zagradama):

1. *odabir projekta* (npr. projekt 1., projekt 2. itd.)
2. *tip radne aktivnosti* (individualan tehnički rad, individualan administrativni rad, timski rad, prekidi u radu)
3. *vrsta individualne ili timske aktivnosti* (diskusija, sastanak, izvještaj itd.)
4. *vrsta aktivnosti iz perspektive razvoja proizvoda* (planiranje, analiza, donošenje odluka, konceptualizacija, inovativne aktivnosti itd.)
5. *kontekst aktivnosti* (tehnički proizvod, tehnički proces itd.)
6. *suradnici u aktivnosti* (članovi tima – organizacijska je struktura prije početka uzorkovanja rada unesena u aplikaciju putem administracijskog sučelja, naručitelj, dobavljač itd.)
7. *način provođenja aktivnosti* (licem u lice, e-pošta, videokonferencija itd.)
8. *priroda obrade informacije u aktivnosti* (traženje informacija, primanje, slanje itd.)
9. *relevantnost informacije za trenutačnu fazu projekta* (ocjena 1-5)
10. *razina osobne motivacije* (ocjena 1-5)

Tablica 5-1. Nematerijalni indikatori za koje će se podaci prikupljati uzorkovanjem rada

Oznaka indikatora	Naziv indikatora	Mjera indikatora
Individualna razina		
Komunikacija i razmjena informacija		
CI_IN3	Udio vremena utrošen na diskusije	Udio vremena (0-100%)
CI_IN4	Udio vremena utrošen na formalne sastanke	Udio vremena (0-100%)
CI_IN5	Udio vremena utrošen na sastanke tima	Udio vremena (0-100%)
CI_IN6	Udio vremena utrošen na primanje informacije	Udio vremena (0-100%)
CI_IN7	Udio relevantnih primljenih informacija	Udio vremena utrošenog na primanje informacije tijekom koje je informacija ocijenjena visoko relevantnom (0-100%)
CI_IN8	Udio informacija primljenih licem-u-lice	Udio vremena utrošenog na primanje informacije licem-u-lice (0-100%)
CI_IN9	Udio vremena utrošen na slanje informacije	Udio vremena (0-100%)
CI_IN10	Udio relevantnih poslanih informacija	Udio vremena utrošenog na slanje informacije tijekom koje je informacija ocijenjena visoko relevantnom (0-100%)
CI_IN11	Udio informacija poslanih licem-u-lice	Udio vremena utrošenog na slanje informacije licem-u-lice (0-100%)
CI_IN12	Udio vremena utrošen na izmjenu informacija	Udio vremena (0-100%)
CI_IN13	Udio relevantnih izmijenjenih informacija	Udio vremena utrošenog na izmjenu informacija tijekom koje je informacija ocijenjena visoko relevantnom (0-100%)
Inovativnost i ideacija		
II_IN1	Broj individualnih ideacijskih aktivnosti vezanih za domenu proizvoda	Broj individualnih ideacijskih aktivnosti (#)
II_IN2	Udio individualnih ideacijskih aktivnosti vezanih za domenu proizvoda s visokom relevantnošću informacije	Udio individualnih ideacijskih aktivnosti (0-100%)
II_IN3	Broj individualnih ideacijskih aktivnosti vezanih za ostale dom ene	Broj individualnih ideacijskih aktivnosti (#)
II_IN4	Udio individualnih ideacijskih aktivnosti vezanih za ostale do mene s visokom relevantnošću informacije	Udio individualnih ideacijskih aktivnosti (0-100%)
Motivacija i zadovoljstvo		
MS_IN1	Motivacija tijekom individualnih aktivnosti	Ocjena motivacije tijekom uzorkovanih individualnih aktivnosti (1-5)
Timska razina		
Kompetencije i znanje		
CK_TM4	Broj društveno izoliranih članova tima	Broj Simmelianovih veza
CK_TM5	Udio resursa koji nisu korišteni u zadovoljavajućoj mjeri	Stupanj centralnosti resursa (eng. Degree centrality)
Komunikacija i razmjena informacija		
CI_TM11	Broj slabih komunikacijskih veza	Udio interakcija između sudionika uzorkovanja (0-100%)
CI_TM12	Broj jakih komunikacijskih veza	Udio interakcija između sudionika uzorkovanja (0-100%)
Inovativnost i ideacija		
II_TM5	Broj timskih ideacijskih aktivnosti vezanih za domenu	Broj timskih ideacijskih aktivnosti (#)
II_TM6	Udio timskih ideacijskih aktivnosti vezanih za domenu proizvoda s visokom relevantnošću informacije	Udio timskih ideacijskih aktivnosti (0-100%)
II_TM7	Broj timskih ideacijskih aktivnosti vezanih za ostale domene	Broj timskih ideacijskih aktivnosti (%)
II_TM8	Udio timskih ideacijskih aktivnosti vezanih za ostale domene s visokom relevantnošću informacije	Udio timskih ideacijskih aktivnosti (0-100%)
Motivacija i zadovoljstvo		
MS_TM1	Motivacija tijekom timskih aktivnosti	Ocjena motivacije tijekom uzorkovanih timskih aktivnosti (1-5)
MS_TM3	Udio aktivnosti s višom razinom motivacije	Udio vremena utrošenog na aktivnosti pri kojima je motivacija visoko ocijenjena (0-100%)
MS_TM4	Udio aktivnosti s višom razinom relevantnosti informacije	Udio vremena utrošenog na aktivnosti pri kojima je relevantnost informacija visoko ocijenjena (0-100%)

Potpuna struktura svih opcija dostupnih na izbornicima prikazana je u sljedećoj tablici (Tablica 5-2). Prva dva izbornika *odabir projekta* i *tip radne aktivnosti* na prvom su ekranu aplikacije. Ovisno o odabiru tipa radne aktivnosti (individualni tehnički rad, individualni administrativni rad, timski rad, prekidi rada), definirana su četiri različita scenarija izbornika.

Ulazne stavke u izbornicima *vrsta individualne ili timske aktivnosti* i *kontekst aktivnosti* kreirane su na temelju prethodnog Robinsonova rada [100] iako su napravljene neke preinake. U usporedbi s Robinsonovim izbornicima [100], izbornik *kontekst aktivnosti* sadržava

detaljniju podjelu tehničkoga konteksta aktivnosti te nudi mogućnost odabira određenog aspekta proizvoda (npr. elektronički, mehanički ili softverski dio) i procesa.

Tablica 5-2. Struktura opcija za unos koje su dostupne na izbornicima aplikacije za uzorkovanje rada

		Opis rada							
Vrsta rada		**Vrsta timske aktivnosti**	**Vrsta razvojne aktivnosti**	**Kontekst**	**Suradnici**	**Način provođenja**	**Obrada informacije**	**Relevantnost informacije**	**Razina motivacije**
	Timski rad	Diskusija (neformalna)	**Upravljačke aktivnosti**	**Tehnički - proizvod**	Član tima 1	Licem-u-lice	Slanje informacija	1	1
		Sastanci (formalni)	Planiranje	Elektronički dio	Član tima 2	Telefon	Primanje informacija	2	2
		Sastanci tima	Rješavanje konflikata	Mehanički dio	Član tima 3	Video konferencija	Procesuiranje informacija	3	3
		Izvještavanje/prezentacija	Dodjela resursa	Softverski dio	Član tima 4	Email	**Traženje informacija**	4	4
			Pregovaranje	**Tehnički - proces**	Izvan tima	Ostalo timski način	Unutarnji izvori	5	5
			Evaluacijske aktivnosti	Proizvodnja	Kupac		informacija		
			Analiza	Instalacija	Dobavljač		Vanjski izvori informacija		
			Donošenje odluka	Održavanje	Administrator				
			Mjerenje	Odlaganje	Ostali-vanjski				
			Praćenje i nadzor	Zaposlenici					
			Evaluacija	Postrojenja					
			Definicijske aktivnosti	Ostali timski kontekst					
			Konceptualizacija						
			Detaljiranje i kodiranje						
			Inovativne aktivnosti						
			Korisnička podrška						
			Prodaja i nabava						
			Izvještavanje						
			Ostale timske aktivnosti						
	Individualni tehnički rad	Ne koristi se	**Upravljačke aktivnosti**	**Tehnički - proizvod**	Nema suradnika	Email	Slanje informacija	1	1
			Planiranje	Elektronički dio		Inženjerski softver	Primanje informacija	2	2
			Rješavanje konflikata	Mehanički dio		Uredski softver	Procesuiranje informacija	3	3
			Dodjela resursa	Softverski dio		ERP	**Traženje informacija**	4	4
			Pregovaranje	**Tehnički - proces**		PDM/PLM	Unutarnji izvori	5	5
			Evaluacijske aktivnosti	Proizvodnja		Internet	informacija		
			Analiza	Instalacija		Ostali individualni	Vanjski izvori informacija		
			Donošenje odluka	Održavanje		tehnički načini			
			Mjerenje	Odlaganje					
			Praćenje i nadzor	Zaposlenici					
			Evaluacija	Postrojenja					
			Definicijske aktivnosti	Ostali individualni					
			Konceptualizacija	kontekst					
			Detaljiranje i kodiranje						
			Inovativne aktivnosti						
			Korisnička podrška						
			Prodaja i nabava						
			Izvještavanje						
			Ostale individualne aktivnosti						
	Individualni administrativni rad	Evidentiranje rada	Ne koristi se	Administracija	Nema suradnika	Email	Ne koristi se	Ne koristi se	1
		Dogovaranje sastanka				Uredski softver			2
		Rezerviranje smještaja				ERP			3
		Prijevoz				Internet			4
		Ispunjavanje naloga				Ostali individualni			5
		Fotokopiranje				admin. načini			
		Unos podataka							
		Provjera emaila							
		Ostalo - Administracija							
	Prekidi u radu	Ne koristi se	Ne koristi se	Ne koristi se	Ne koristi se	Ne koristi se	Ne koristi se	Ne koristi se	Ne koristi se

Pri kreiranju ulaznih stavki za izbornik *vrsta aktivnosti iz perspektive razvoja proizvoda* korištena je ontologija aktivnosti razvoja proizvoda koju su predložili Sim i Duffy [193]. S obzirom na apstraktnost pojmova unutar ontologije, pojedine su stavke grupirane kako bi

korisnici aplikacije mogli lakše naći traženu aktivnost. Naime, prema navedenoj ontologiji broj stavaka bio bi predugačak i onemogućio bi jednostavan odabir aktivnosti u aplikaciji. Radi potpunosti ulaznih stavki, od odjela ljudskih potencijala tvrtke u kojoj se provodila studija slučaja zatražene su prethodne analize radnih aktivnosti (ako pojedina razvojna aktivnost nije bila uključena u navedenoj ontologiji).

Prethodna analiza aktivnosti omogućila je normalizaciju ulaznih stavaka i potvrdila potpunost inicijalnog popisa priređenog na temelju pregleda literature. Služeći se terminologijom dobivenom od odjela ljudskih potencijala, prilagođeni su nazivi stavaka kako bi ih sudionici bolje razumjeli.

Prije početka studije uzorkovanja bilo je potrebno prilagoditi izbornik *suradnici u aktivnosti* za potrebe uzorkovanih projekata. Koristeći se administracijskim sučeljem aplikacije, prije izvođenja studije uneseni su podaci o članovima tima zaduženima za izvođenje određenih projekata. Sudionici uzorkovanja odabirom projekta na prvom izborniku (*odabir projekta*), utjecali su na prikaz ulaznih stavki u izborniku *suradnici u aktivnosti* jer su bili prikazani samo članovi tima zaduženi za odabrani projekt.

Za izradu izbornika *način provođenja aktivnosti*, kao predložak poslužio je rad Allard i dr. [194] koji ujedinjuje način komunikacije i korištenje računalnim alatima, a ulazne su stavke za izbornik *priroda obrade informacije* temeljene na radu Casha i dr. [195].

Posljednja dva izbornika: *relevantnost informacije za trenutačnu fazu projekta* i *razina osobne motivacije* koriste se Likertovim skalama (1-5) za određivanje njihove razine tijekom uzorkovane aktivnosti (kratka je rasprava o skalama u poglavlju 5.3).

5.3. Ankete za prikupljanje podataka

Osim uzorkovanja radnih aktivnosti, za prikupljanje podataka poslužile su ankete. One su provedene na istoj skupini ljudi kao i uzorkovanje rada, kako bi se dobili komplementarni podaci – potrebni za utvrđivanje vrijednosti indikatora koji se ne mijenjaju dnevno ili tjedno.

Prikupljanje podataka anketama odabrano je iz nekoliko razloga. Prvo, ankete se uobičajeno upotrebljavaju za verifikaciju postojećih stavova. Takav način prikupljanja nije prikladan za otkriće novih fenomena te stoga istraživači moraju prethodno imati određene predodžbe o očekivanu rezultatu. Stoga anketa apsolutno odgovara potrebama istraživanja jer su indikatori već prethodno definirani. Drugo, ovim se pristupom mogu prikupiti stajališta pojedinaca u

timu o objektu istraživanja. Ankete su „neosoban“ način prikupljanja podataka, koji se u današnje vrijeme najčešće provodi putem e-pošte ili mrežnog servisa za anketiranje, pa su prikupljanje i obrada podataka jeftiniji. Ankete putem e-pošte povećavaju vjerojatnost dobivenih odgovora u stvarnim organizacijama jer ispitanici mogu odgovoriti u terminu koji im odgovara, za razliku od anketa u kojima je prisutan istraživač i koje se provode uživo. Prednost je mrežne ankete i to da istraživač ne mora biti prisutan pri njezinu ispunjavanju.

Anketa je i praktičan pristup koji ne zahtijeva znatnu količinu resursa ili pripremu (zaposlenika) prije provođenja [196]. Uz provođenje uzorkovanja koje je zahtjevno, anketa je odabrana kao pristup koji će brzo i jednostavno omogućiti prikupljanje podataka.

Prema Grayu [197], pri izradi ankete u sklopu istraživanja potrebno je zadovoljiti sljedeće korake:

1. Istraživač mora jasno iznijeti koju informaciju traži te prema tome oblikovati pitanja.
2. Ispitanik treba razumjeti i interpretirati pitanje onako kako bi istraživač želio da se njegovo pitanje interpretira.
3. Ispitanik mora odgovoriti na način na koji istraživač zahtijeva.
4. Istraživač mora interpretirati odgovor onako kako bi ispitanik želio da se njegov odgovor interpretira.

Ipak, moguće je da se zbog određenih nedostataka ankete ne zadovolje svi potrebni koraci. Ankete su, kao način prikupljanja podataka, podložne iskrivljenoj interpretaciji sudionika te je uputno prethodno poslati anketu manjem broju njih. Kad su posrijedi ankete s osjetljivim sadržajem, može se očekivati da određeni sudionici neće željeti odgovoriti na pojedina pitanja ili će smatrati da će biti kažnjeni iznesu li vlastite stavove koji nisu u skladu sa stavovima nadređenih ili organizacije. Nedostatak je anketa njihova nefleksibilnost i nemogućnost promjene tijekom prikupljanja podataka. Nakon slanja ankete, jako je teško znatno utjecati na sadržaj ankete (dodavanje sadržaja anketi ili zamjena pitanja) [198]. Pri izradi ankete potrebno je pripaziti i na njezinu duljinu kako se to ne bi negativno odrazilo na količinu prikupljenih odgovora [196].

Za potrebe istraživanja u sklopu ove disertacije anketa je provedena elektroničkom poštom koja je sadržavala uvodni tekst, opis svrhe i načina njezina provođenja te predložak s pitanjima. U uvodnom je tekstu istaknuto da će svi prikupljeni podaci biti smatrani anonimnima te će se upotrijebiti radi istraživanja. Prethodno je anketa poslana upravitelju

odjela i jednom članu tima kako bi se provjerila jasnoća postavljenih pitanja. Anketa je poslana na točno određene e-adrese samo članovima tima kako bi se izbjeglo prikupljanje odgovora od zaposlenika kojima ona nije bila namijenjena. S obzirom na povjerljivost studije, osjetljivost podataka s aspekta intelektualnog vlasništva tvrtke te zaštite privatnosti, nisu upotrijebljeni mrežni alati za anketiranje (kao npr. FormSite, Surveymonkey itd.).

Na temelju opisa pojedinih indikatora (Tablica 5-3) osmišljena su pitanja i definiran je sadržaj ankete. S obzirom na potrebu za kodifikacijom i kvantifikacijom odgovora te njihovom usporedbom, sva su pitanja bila zatvorenog tipa s unaprijed definiranim odgovorima što se u literaturi sugerira za vrstu ankete s osjetljivim sadržajem. S obzirom na mali broj sudionika u anketi, svi su odgovori prikupljeni u dva tjedna (podsjetnik je poslan poslije tjedan dana).

Predloženi indikatori zahtijevaju kvantifikaciju vrijednosti dobivenih anketom te je stoga važno razmotriti upotrebu različitih skala. Najčešće se u literaturi preporučuje uporaba 5- ili 7-stupanjskih skala (npr. [199]), ali se 10- ili 11-stupanjske skale također često upotrebljavaju [183]. Svaki tip skale ima određene prednosti i nedostatke te će argumentacija za njihovu upotrebu biti razjašnjena i objašnjena u nastavku.

Anketa, koja je provedena poslije uzorkovanja, bila je podijeljena na dva dijela. U prvom dijelu prikupljali su se podaci potrebni za određivanje vrijednosti indikatora kategorije *kompetencije i znanje*, a u drugom dijelu za kategorije *komunikacija i razmjena informacija*, *inovativnost i ideacija* te *motivacija i zadovoljstvo*.

5.3.1. Anketa 360-stupanjske procjene izvedbe kompetencija sudionika

Za prikupljanje podataka potrebnih za kategoriju indikatora *kompetencije i znanje* koristilo se anketom s posebnom izvedbom 360-stupanjske procjene izvedbe (engl. *360-degree feedback* ili *Multisource feedback*). Ova se metoda često primjenjuje u organizacijama za mjerenja izvedbe zaposlenika [200], [201] te ju je prema Carruthersu [202] čak 90 % *Fortuneovih 500* organizacija upotrijebilo u 2002. godini.

Glavna je ideja 360-stupanjske procjene izvedbe postaviti pojedinca (člana tima) kao objekt evaluacije te procijeniti njegovu izvedbu u smislu kompetencija, vještina i osobnih karakteristika iz različitih perspektiva (suradnici, nadređeni, ali i samovrednovanjem). Obuhvaćajući različita gledišta, omogućuje se objektivnija procjena kompetencija pojedinaca koja ne proizlazi isključivo iz gledišta nadređenih [203]. Evaluacija se provodi prema

prethodno definiranim kriterijima (u našem slučaju kompetencijama). Ovaj jedinstven pristup omogućuje prepoznavanje slabosti te prednosti pojedinih članova tima, ali i cijeloga tima.

Tablica 5-3. Nematerijalni indikatori za koje će se podaci prikupljati anketom

Oznaka indikatora	Naziv indikatora	Mjera indikatora
Individualna razina		
Kompetencije i znanje		
CK_IN1	Rješavanje problema	Ocjena kompetencija (1-10)
CK_IN2	Donošenje odluka	Ocjena kompetencija (1-10)
CK_IN3	Pružanje brze i detaljne povratne informacije	Ocjena kompetencija (1-10)
CK_IN4	Sposobnost definiranja i razumijevanja uloga i odgovornosti	Ocjena kompetencija (1-10)
CK_IN5	Sposobnost praćenja/ocjenjivanja izvedbe tima	Ocjena kompetencija (1-10)
CK_IN6	Liderstvo	Ocjena kompetencija (1-10)
CK_IN7	Opća IT pismenost	Ocjena kompetencija (1-10)
CK_IN8	Specifična IT pismenost	Ocjena kompetencija (1-10)
CK_IN9	Relevantnost individualnih kompetencija za opis posla	Ocjena kompetencija (1-10)
CK_IN10	Tehničko znanje	Ocjena kompetencija (1-10)
CK_IN11	Kreativnost	Ocjena kompetencija (1-10)
CK_IN12	Socijalne vještine	Ocjena kompetencija (1-10)
CK_IN13	Odgovornost	Ocjena kompetencija (1-10)
CK_IN14	Sposobnost učenja	Ocjena kompetencija (1-10)
Motivacija i zadovoljstvo		
MS_IN2	Osobno zadovoljstvo	Ocjena zadovoljstva (1-5)
Timska razina		
Kompetencije i znanje		
CK_TM1	Udio članova tima s nedovoljnim kompetencijama	Udio članova tima (0-100%)
CK_TM2	Udio izvrsnih članova tima	Udio članova tima (0-100%)
CK_TM3	Udio nezadovoljavajućih kompetencija	Udio kompetencija (0-100%)
Komunikacija i razmjena informacija		
CI_TM1	U kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od internih izvora	Ocjena (1-5)
CI_TM2	U kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od eksternih izvora	Ocjena (1-5)
CI_TM3	U kolikoj mjeri se znanje pohranjuje u internim bazama podataka	Ocjena (1-5)
CI_TM4	U kolikoj mjeri se članovi tima osjećaju ugodno dok koriste već postojeća rješenja	Ocjena (1-5)
CI_TM5	U kolikoj mjeri se članovi tima osjećaju motivirano da dijele znanje s drugim članovima tima	Ocjena (1-5)
CI_TM6	U kolikoj mjeri članovi tima smatraju da sudjelovanje u timskim aktivnostima stvara iskustvo te rezultira novim rješenjima	Ocjena (1-5)
CI_TM7	U kolikoj mjeri se članovi tima osjećaju ugodno dijeleći znanje s drugim članovima tima	Ocjena (1-5)
CI_TM8	U kolikoj mjeri članovi tima smatraju da je jednostavno naći kolege s potrebnim kompetencijama	Ocjena (1-5)
CI_TM9	U kolikoj mjeri članovi tima smatraju da su interne baze podataka jednostavne za korištenje	Ocjena (1-5)
CI_TM10	Učestalost obavještavanja o novim unosima i rješenjima u internim bazama podataka	Ocjena (1-5)
Inovativnost i ideacija		
II_TM1	U kolikoj mjeri okruženje prihvaća način razmišljanja "izvan kutije"	Ocjena (1-5)
II_TM2	U kolikoj mjeri okruženje podržava stvaranje novih ideja i odbacivanje postojećih	Ocjena (1-5)
II_TM3	U kolikoj mjeri su inovacije cilj menadžmenta	Ocjena (1-5)
II_TM4	U kolikoj mjeri menadžment podržava inovativnost u projektima	Ocjena (1-5)

360-stupanjska procjena izvedbe smatra se superiornim pristupom u usporedbi s tradicionalnim oblicima evaluacije jer pruža potpuniju i precizniju sliku kompetencija, vještina i osobnih karakteristika zaposlenika [204]. Tradicionalna procjena izvedbe, svedena

na pojedinačnu procjenu nadređenog, ne omogućuje objektivnu i točnu povratnu informaciju o zaposleniku. Naime, tradicionalna procjena izvedbe, u kojoj je zaposlenike ocijenila jedna osoba, podložna je pogrešci i ograničenu pogledu na kompetencije, vještine i osobne karakteristike pojedinca [205]. Kao i u drugim metodama procjene izvedbe, nedostatak je 360-stupanjske procjene izvedbe to što njezina uspješnost ovisi o sposobnosti da se dobiju pouzdani podaci od „nepouzdanih“ izvora (u ovom slučaju zaposlenika).

Za uklanjanje nedostataka i uspješnije provođenje metode, Carey [206] navodi nekoliko postavki koje je potrebno zadovoljiti pri njezinoj primjeni:

1. Svi sudionici moraju biti upoznati sa svrhom procjene izvedbe.
2. Dobiveni rezultati ne smiju biti temeljna odrednica za dodjeljivanje nagrada, promocija ili kazni u organizaciji.
3. Rezultati moraju biti prikazani anonimno.
4. Upravljačka struktura mora podržati proces.

Prije prikupljanja podataka, navedene su postavke bile ispunjene. Pri izlaganju prije provođenja kružnog ispitivanja, tj. 360-stupanjske procjene izvedbe, objašnjeno je da rezultati neće poslužiti za potrebe evaluacije, već mogućega osobnoga razvoja. Ovaj dio provođenja 360-stupanjske procjene izvedbe iznimno je važan jer su prihvaćanje metode i povjerenje ključni za njezino uspješno provođenje [207]. Ako ispitanici smatraju da ocjenjivanje nije anonimno, moguće je da neće ocijeniti voditelja tima ili će prilagoditi ocjene kako bi izbjegli sukob s nadređenim. Zbog navedenih razloga, ispitanici moraju vjerovati u povjerljivost ankete te da se njihove ocjene neće dalje prosljeđivati bez njihova znanja.

Za potrebe ovog istraživanja, metoda 360-stupanjske procjene izvedbe djelomično je izmijenjena. Naime, iz zapisa aktivnosti dobivenih uzorkovanjem rada proizišle su informacije o interakciji između pojedinih sudionika. Na temelju tih podataka za svakog su sudionika određeni članovi tima s kojima je bio najčešće u interakciji. Pretpostavka kojom smo se služili jest da sudionik može kvalitetnije ocijeniti drugog člana tima s kojim je bio u interakciji nego onog s kojim samo dijeli odjel prema organizacijskoj strukturi. Prema Fleenor i Prince [204], sudionici bi trebali biti u krugu utjecaja pojedinog zaposlenika i trebali bi moći promatrati ponašanje i izvedbu zaposlenika kako bi mogli kvalitetno ocijeniti drugog člana tima. Dakle, na temelju podataka o interakciji definirani su individualizirani upiti za svakog sudionika. Iako se ovakvim pristupom djelomično izgubila anonimnost, izbjegla se mogućnost ocjenjivanja suradnika koji aktivno ne surađuju.

Hirsch [208] navodi da je broj ispitanika koji su potrebni za ocjenjivanje određenog sudionika važna odluka pri provođenju evaluacije. Ograničavanje broja ocijenjenih sudionika po ispitaniku utječe na kvalitetu pojedinačnih ocjena jer u suprotnom ocjenjivanje zahtijeva mnogo vremena i uloženog truda. Iako se standardno upotrebljava od pet do deset ocjena po sudioniku, Hirsch [208] predlaže od tri do četiri. Za provođenje metode u sklopu ovog istraživanja svaki je sudionik trebao ocijeniti četiri druga sudionika te obaviti samovrednovanje. Samovrednovanje potpomaže uspješnost 360-stupanjske procjene izvedbe jer sudionici pokazuju više povjerenja u proces u kojem su i oni jedni od faktora evaluacije [204].

Većina procedura za provođenje 360-stupanjske procjene izvedbe koristi se upitnicima sa skaliranim stavkama [209], ali pojedine procedure uključuju i pitanja otvorenog tipa. S obzirom na prirodu indikatora, isključivo su poslužila pitanja u kojima je trebalo odrediti razinu kompetencija brojčanom vrijednošću. Svaku je kompetenciju trebalo ocijeniti na skali od 1 (najniža vrijednost) do 10 (najviša vrijednost). Ovakav je tip skale odabran jer omogućuje bolju diversifikaciju između pojedinih razina kompetencija te je prikladan pri ocjenjivanju kompetencija, vještina i osobnih karakteristika. Najčešće se u ovakvim skalama (1-10) ne upotrebljava verbalni opis zbog finoće granularnosti koju je teško objasniti riječima. Stoga su u ovoj anketi definirane samo krajnje fiksne točke te dani njihovi opisi. Budući da nema točno definiranog opisa za svaku numeričku vrijednost na skali, rezultati korištenja takvim skalama uvelike ovise o ispitanicima te razlikama u njihovoj interpretaciji numeričkih odgovora. Ipak, smatra se da je ovaj nedostatak nadomješten intuitivnošću te poznavanjem skale i ocjenjivanja na skali „od 1 do 10“.

5.3.2. Anketa za prikupljanje podataka o kontekstu i okruženju razvojnog tima

Drugi dio ankete bio je vezan za kontekst radnog okruženja te je proveden kako bi se dobila šira slika o načinu funkcioniranja tima sa stajališta intelektualnoga kapitala. Ovim se načinom prikupljaju podaci vezani za kategorije *komunikacija i razmjena informacija*, *inovativnost i ideacija* i *motivacija i zadovoljstvo*. Ovaj je dio ankete sadržavao dva uvodna pitanja koja su bila vezana uz radno iskustvo (radni staž) sudionika unutar tvrtke i ukupno trajanje profesionalne karijere. Slijedila su pitanja vezana za pojedine tematske kategorije u kojima su se sudionici trebali izjasniti o učestalosti pojedinog zbivanja ili o mjeri suglasnosti s pojedinom izjavom. Sudionici su odgovarali služeći se Likertovom skalom čiji se verbalni opis međusobno razlikovao ovisno o sadržaju pitanja (*nikad, rijetko, ponekad, često, uvijek*;

potpuno se ne slažem, ne slažem se, niti se ne slažem niti se slažem, slažem se, potpuno se slažem). U 5-stupanjskim skalama jednostavna je izrada verbalnih deskriptora što uvelike olakšava interpretaciju prikupljenih podataka. Za potrebe ovog dijela ankete upotrijebljena je 5-stupanjska skala radi precizinijeg opisa pojedine kategorije. Također, pretpostavka je da korištenje većom skalom ne bi donijelo dodatnu vrijednost.

Prikupljeni su podaci pretvoreni u numeričke vrijednosti od 1 do 5 te su rezultati ankete izravno preslikani u vrijednosti odgovarajućih indikatora na timskoj razini što je prikazano u poglavlju 5.5.

5.4. Integracija s postojećim korporativnim IT sustavima

Kao posljednji pristup prikupljanja podataka za predložene indikatore (Tablica 5-4), predviđena je integracija s postojećim korporativnim IT sustavima ili bazama podataka. Ovakvo je prikupljanje podataka jednostavnije jer omogućuje automatsku ekstrakciju podataka te nema potrebe za velikom količinom resursa. Različite su vrste indikatora za koje bi podaci mogli biti ovako prikupljeni, ovisno o tipu informacijskog sustava.

Primjena informacijskih sustava postala je važan dio inženjerskih aktivnosti i njome se svladavaju brojne poteškoće uzrokovane tradicionalnim principima sljedivosti i korištenjem različitom papirnatom dokumentacijom [210], [211]. Tako primjena informacijskih sustava potpomaže i unapređuje produktivnost razvojnih timova [212].

Dosadašnja istraživanja u razvoju tehničkih sustava upozoravaju na brojne digitalne objekte koji nastaju tijekom procesa ([39], [211], [213], [214]), bilo kao rezultat komunikacije ili drugih inženjerskih aktivnosti. Komunikacijski alati mogu biti e-pošta, videokonferencije i društvene mreže, a digitalnim se objektima smatraju npr. proračunske tablice, CAD (engl. *Computer Aided Design*) modeli ili simulacijski modeli.

Snider i dr. [39] i Gospill i dr. [211] navode da, iako su provedena brojna istraživanja kojima je cilj proučavanje informacijskih sustava tijekom razvoja tehničkih sustava, evolucija digitalnih objekata tijekom razvojnog procesa do sada nije istražena. Ipak, njihovo istraživanje kreće u tom smjeru i njihovi preliminarni rezultati upozoravaju na to da informacije preuzete iz informacijskih sustava i vezane za komunikaciju i digitalne objekte mogu poslužiti kao indikatori stanja razvojnog projekta. Također, smatraju da analiza profila i obrazaca korištenja određenim digitalnim objektima i komunikacijskim alatima može potpomoći razumijevanju inženjerskih aktivnosti.

Za potrebe ovog istraživanja predviđeno je korištenje ovim pristupom prikupljanja za mali broj indikatora. Naime, podaci prikupljeni ovim pristupom uglavnom služe za „opipljivije“ i materijalne aspekte razvojnih procesa [211]. Stoga je integracijom s korporativnim informacijskim sustavima predviđeno prikupljanje informacija za indikatore CI_IN1: *„best practicea“ po sudioniku*, CI_IN2: *broj rješenja po sudioniku* i CI_IN14: *broj transferiranih MB po sudioniku* koji ujedinjuju nekoliko zasebnih elemenata digitalnih objekata. Naime, uzorkovanjem rada omogućeno je prikupljanje podataka vezano za različite digitalne objekte, pritom omogućujući prikupljanje podataka i za brojne neformalne aktivnosti koje se ne mogu prikazati „materijalnim“ digitalnim objektima. Stoga se uzorkovanje rada nameće kao superiorniji i cjelovitiji pristup prikupljanju podataka te omogućuje bolji uvid u inženjerske aktivnosti.

Za potrebe prikupljanja podataka za indikatore unutar predloženog modela drugi je tip korporativnih informacijskih sustava vezan za područje ljudskih resursa. U posljednja dva desetljeća naglo se povećao broj organizacija koje prikupljaju, pohranjuju i analiziraju podatke vezane za ljudske resurse korištenjem specijaliziranim informacijskim sustavima [215] te je stoga predložen ovakav način prikupljanja podataka. Korištenjem takvim informacijskim sustavima omogućuje se automatizacija i olakšavanje rutinskih administrativnih aktivnosti koje se provode u organizacijskim odjelima ljudskih resursa. Važno je istaknuti da se brojne organizacije još ne koriste softverima za praćenje metrika ljudskih resursa što može uvelike otežati prikupljanje podataka ovim pristupom. Jednako tako, ovi informacijski sustavi često nisu integrirani i kompatibilni s informacijskim sustavima drugih odjela što znatno otežava pristup podacima [216]. Korištenjem ovim tipom IT sustava omogućuje se prikupljanje podataka za indikatore CK_IN15: *troškovi razvoja kompetencija i vještina po sudioniku*, CI_IN15: *razmjene, učenje, osobni razvoj* i MS_TM2: *vrijeme provedeno na društvene aktivnosti koje nisu vezane za rad*.

Iako su indikatori CK_IN15 i CI_IN15 materijalne prirode (izraženi pomoću troškova i broja sati), za potrebe predloženog modela važni su za davanje potpunije slike o kompetencijama i učenju promatranog tima te su stoga uključeni u model. Za indikatore CK_IN15, CI_IN15 i MS_TM2 predviđeno je prikupljanje svaka tri mjeseca, a za ostale se indikatore podaci mogu prikupljati i tjedno i mjesečno.

Iako je unutar modela predviđeno korištenje ovim indikatorima, nažalost tijekom studije slučaja nisu prikupljeni podaci za navedene indikatore zbog nemogućnosti pristupa korporativnim IT sustavima u analiziranoj tvrtki (Tablica 5-4).

Tablica 5-4. Nematerijalni indikatori za koje će se podaci prikupljati integracijom s postojećim korporativnim IT sustavima

Oznaka indikatora	Naziv indikatora	Mjera indikatora
Individualna razina		
Kompetencije i znanje		
CK_IN15	Troškovi razvoja kompetencija i vještina po sudioniku	Trošak (EUR)
Komunikacija i razmjena informacija		
CI_IN1	Broj "best practice"-a po sudioniku	Broj unosa u korporativni informacijski sustav
CI_IN2	Broj rješenja po sudioniku	Broj unosa u korporativni informacijski sustav
CI_IN14	Broj transferiranih MB po sudioniku	Promet MB-a
CI_IN15	Razmjene, učenje, osobni razvoj	Broj sati
Timska razina		
Motivacija i zadovoljstvo		Metoda prikupljanja podataka
MS_TM2	Vrijeme provedeno na društvene aktivnosti koje nisu vezane uz rad	Broj sati

5.5. Preslikavanje prikupljenih podatka u vrijednosti indikatora

Statistička osnova uzorkovanja rada i anketa omogućuju prikupljanje kvantitativnih podataka potrebnih za određivanje vrijednosti pojedinih indikatora izvedbe IK-a u realnom vremenu.

Indikatori mogu imati vrijednosti broja ponavljanja određenog događaja (u našem slučaju aktivnosti), ali također mogu izražavati vrijednosti u postocima ili kao *boolean* varijabla, npr. je li se nešto dogodilo ili nije [177], [217].

Najčešći pristup preslikavanja između prikupljenih vektora uzorkovanih podataka i indikatora izvedbe izračun je omjera broja ispitivanih uzorkovanih točaka i ukupnog broja uzorkovanih točaka. Na primjer, za proračun vrijednosti indikatora *udio vremena utrošen na diskusije* potrebno je izračunati postotak od ukupnog vremena koje pojedini član tima provodi u raspravama (neformalni sastanci). Zbog velikog broja točaka uzorkovanja, proračun postaje statistički relevantan te omogućuje kvantifikaciju izvedbe pojedinoga nematerijalnog indikatora koju je inače teško definirati u takvu obliku.

Druga skupina indikatora, koja proizlazi iz podataka dobivenih uzorkovanjem, prikazuje postotak vremena u pojedinoj aktivnosti (npr. – II_IN2-*udio individualnih ideacijskih aktivnosti vezanih za proizvod s visokom relevantnošću informacije*).

U trećoj su skupini svi indikatori koji su dobiveni vrednovanjem na skali. Indikatori za čiji se izračun upotrijebila dimenzija razine motivacije temelje se na upotrebi skala od 1 do 5 što omogućuje neposredno preslikavanje prikupljenih podataka u vrijednosti indikatora. U ovoj su skupini i svi indikatori koji su prikupljeni anketom. U prvom dijelu ankete, za određivanje razine kompetencija pojedinih sudionika upotrijebljena je skala od 1 do 10, a u drugom dijelu ankete – od 1 do 5. U poglavlju 4.5 objašnjeno je provođenje normalizacije indikatora na zajedničku skalu.

Četvrta se skupina indikatora temelji na kombinaciji drugih indikatora tako da njihove vrijednosti kombinira u složeniju mjeru koristeći se postocima dobivenim iz prve ili druge skupine indikatora. Na primjer, povezivanjem različitih perspektiva mogu se izračunati vrijednosti indikatora kao što je MS_TM3-*udio aktivnosti s visokom razinom motivacije*.

U posljednjoj su skupini indikatori čija se vrijednost dobiva direktnim brojenjem ponavljanja određene aktivnosti, kao npr. II_IN1-*broj individualnih ideacijskih aktivnosti vezanih za proizvod*.

Koristeći se navedenim pristupima preslikavanja podataka u vrijednosti indikatora, u sljedećem poglavlju pomoću studije slučaja bit će prikazana njihova primjena tijekom praćenja realnoga procesa razvoja proizvoda.

6. Studija slučaja

Svrha je studije slučaja prikaz primjene identificiranih indikatora u stvarnoj organizaciji na temelju prikupljenih podataka. Dan je prikaz rezultata analize podijeljen u tri cjeline: 1. Analiza prikupljenih podataka uzorkovanjem rada, 2. Analiza vrijednosti indikatora, 3. Analiza agregiranih vrijednosti za pojedine elemente IK-a. Rezultati dobiveni provedenom studijom slučaja uspoređeni su s rezultatima drugih istraživanja.

6.1. Analiza uzorkovanja rada

Studija slučaja provedena je u I&R tvrtki čije su istraživačke i razvojne djelatnosti vezane uz sustave proizvodnje, distribucije i transformacije električne energije. Tvrtka, u kojoj se provodila studija, može se okarakterizirati kao malo i srednje poduzeće. Unutar tvrtke, za provođenje studije slučaja odabran je jedan odjel čije su aktivnosti vezane za razvoj sustava kontrole za potrebe željezničkog prijevoza.

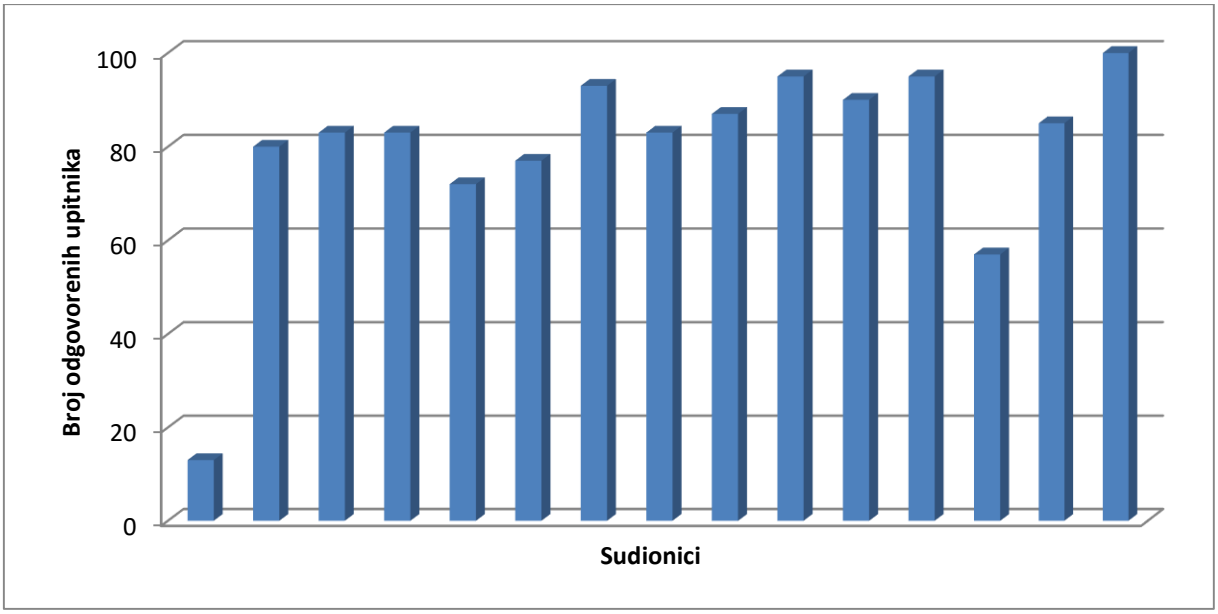
Za uzorkovanje aktivnosti odabrano je ukupno 15 sudionika (13 članova tehničkog tima, voditelj projekta i voditelj odjela) koji su u vrijeme uzorkovanja radili na više projekata. Projekti su bili u različitim fazama pa su sudionici uzorkovanja imali različitu raspodjelu radnog opterećenja. Kako bi se upoznali s metodologijom uzorkovanja i aplikacijom, sudionici su prije početka uzorkovanja jedan dan testirali aplikaciju te su im na zajedničkoj radionici objašnjeni ciljevi i način na koji će se uzorkovanje provoditi. Tako su pomoću aplikacije za uzorkovanje rada prikupljeni podatkovni vektori uzorkovanja koji su zatim pohranjeni u bazu podataka te naknadno analizirani. Početna je analiza prikupljenih podataka uzorkovanja rada provedena radi boljeg razumijevanja konteksta uzorkovanja te je uvod u analizu indikatora.

Uzorkovanje rada trajalo je 10 radnih dana (dva radna tjedna, tijekom radnih sati, bez vikenda) s nasumičnim brojem podsjetnika (6-12) u danu po sudioniku i s propisanim minimalnim razmacima od pola sata između dvaju podsjetnika te maksimalnim razmakom od 1,5 sati između podsjetnika.

U nastavku bit će prikazani anonimni rezultati istraživanja kako bi se poštovala pravila povjerljivosti provedene studije. Rezultati analize prikupljenih podataka za svakog sudionika zasebno raspoređeni su nasumično te redoslijed stupaca (koji odgovara pojedinom sudioniku) nije konzistentan u različitim grafikonima.

6.1.1. Analiza prikupljenih podataka za cijelo razdoblje uzorkovanja

Tijekom uzorkovanja emitirano je ukupno 1357 podsjetnika, a za njih 1193 sudionici su unijeli podatke, što je rezultiralo visokim postotkom od odgovorenih 87,9 % upitnika. Broj upitnika na koje su sudionici odgovorili varirao je od 57 do 100 tijekom razdoblja uzorkovanja, uz iznimku jednog sudionika koji je odgovorio na samo 13 upitnika (Slika 6-1).



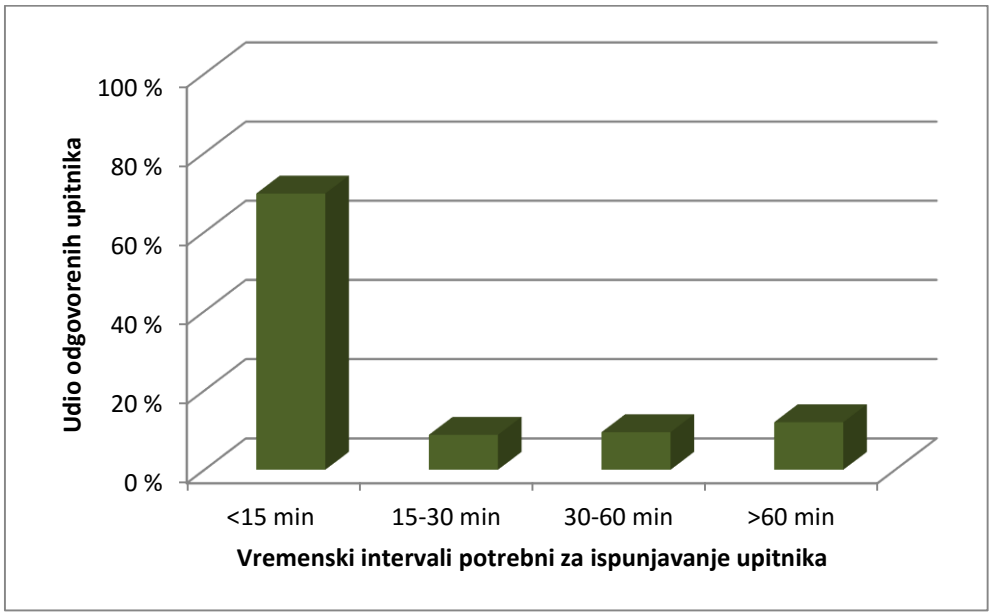
Slika 6-1. Pregled broja upitnika na koje je odgovoreno po članu tima tijekom razdoblja uzorkovanja

Radi povećanja vjerodostojnosti studije, podaci koji su prikupljeni tijekom prvog dana testiranja aplikacije uklonjeni su iz analize zbog privikavanja sudionika na aplikaciju i studiju.

Za relevantnost studije veoma je važno vrijeme potrebno pojedinom sudioniku za ispunjavanje upitnika koji se pojavljuje uz emitirani podsjetnik. Razdoblje potrebno za ispunjavanje upitnika definirano je kao vremenska razlika između trenutka kad je sudionik ispunio upitnik za određeni podsjetnik i trenutka emitiranja podsjetnika. Na slici (Slika 6-2) prikazani su definirani intervali koji su poslužili za analizu vremena potrebnog za ispunjavanje upitnika:

1. vrijeme od prvih 15 minuta nakon emitiranja podsjetnika,
2. vrijeme od 15. do 30. minute nakon emitiranja podsjetnika,
3. vrijeme od 30. do 60. minute nakon emitiranja podsjetnika,
4. vrijeme dulje od 60 minuta nakon emitiranja podsjetnika.

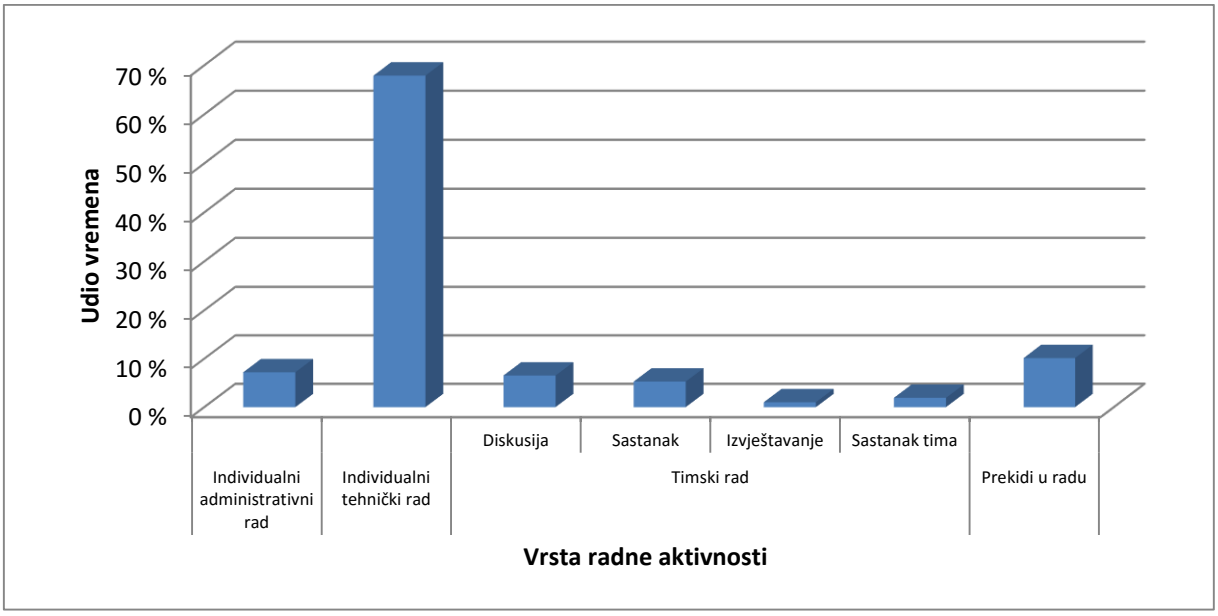
Na 69,7 % upitnika odgovoreno je u prvih 15 minuta nakon emitiranja podsjetnika, a još 8,8 % upitnika ispunjeno je u sljedećih 15 minuta, pa su rezultati reprezentativni za donošenje zaključaka o uzorkovanom razdoblju (Slika 6-2) [100].



Slika 6-2. Pregled udjela upitnika na koje je odgovoreno u specifičnom intervalu nakon trenutka emitiranja (vrijeme potrebno za odgovaranje na upitnike)

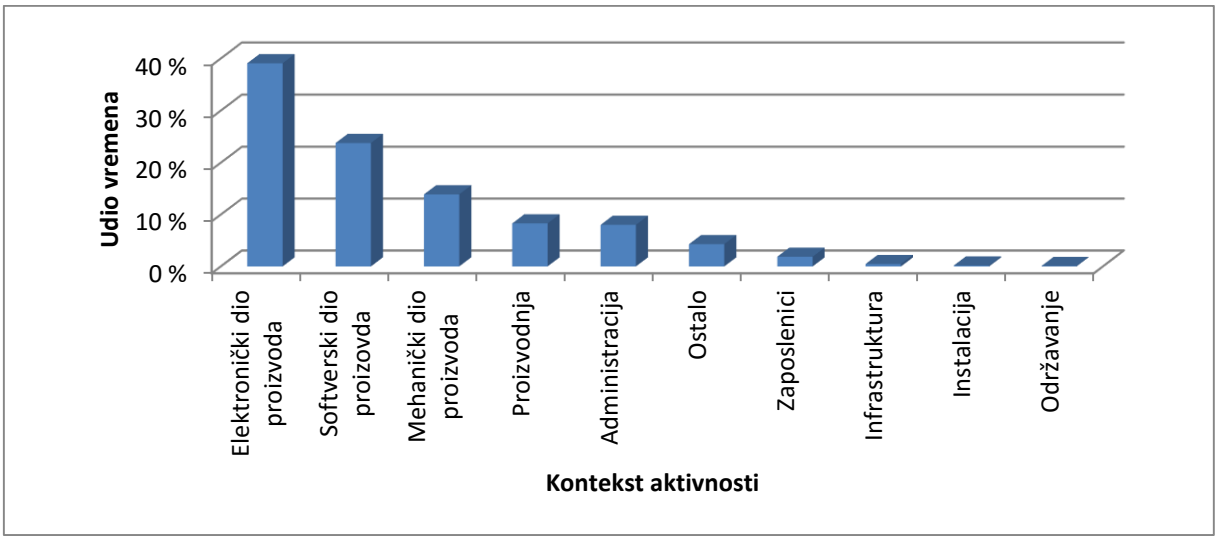
Primjenom jednadžbi uzorkovanja rada (poglavlje 5.2 – jednadžbe 12 i 13) može se odrediti točnost koju omogućuje prikupljeni broj točaka uzorkovanja. Broj točaka uzorkovanja tijekom istraživanja omogućuje prepoznavanje aktivnosti koje su 5 % radnog vremena, s +/- 20 % preciznosti i 90 % pouzdanosti [100]. Time, ako pojedina aktivnost traje 5 % ukupnoga radnog vremena (tj. 24 minute u standardnom 8-satnom radnom danu s prekidima u radu), moguće je s 90 % pouzdanosti ustvrditi da će stvarna vrijednost trajanja aktivnosti tijekom uzorkovanja biti između 4 % i 6 % (tj. trajanje između 19,2 i 28,8 minuta u standardnom 8-satnom radnom danu). Aktivnosti s većim ukupnim udjelom vremena od 5 % mogu se utvrditi i s većom pouzdanošću i preciznošću od navedenih, a za aktivnosti s manjim ukupnim udjelom vremena od 5 % vrijedi suprotno.

Rezultati analize prikupljenih podataka uzorkovanja rada za sve sudionike pokazali su da je tijekom uzorkovanja *individualni tehnički rad* dominirao sa 67,9 % ukupnog broja točaka uzorkovanja, a potom se 14,8 % odnosilo na *timski rad*, 10,1 % na *prekide u radu* i 7,2 % na *individualni administrativni* rad. Na slici (Slika 6-3) prikazani su udjeli uzorkovanih točaka u svakoj pojedinoj kategoriji s timskim radom razloženim na sljedeće potkategorije: *diskusija, sastanak, izvještavanje* i *sastanak tima*.



Slika 6-3. Pregled udjela upitnika na koje je odgovoreno sa specifičnim tipom rada (s dodatnom podjelom timskih aktivnosti)

Analiza konteksta aktivnosti (Slika 6-4) upućuje na to da tijekom uzorkovanja pri *individualnom tehničkom* i *timskom* radu dominiraju aktivnosti vezane za različite aspekte proizvoda: *elektronički*, *softverski* i *mehanički* aspekt. S druge strane, pri *individualnom tehničkom* i *timskom* radu aspekti životnog vijeka proizvoda kao što su *proizvodnja*, *instalacija* i *održavanje* imaju znatno manji udio kao kontekst aktivnosti tijekom razdoblja uzorkovanja.



Slika 6-4. Pregled udjela upitnika na koje je odgovoreno, a vezanih za specifični kontekst

Osim konteksta aktivnosti, uzorkovanjem su prikupljeni podaci o vrsti razvojnih aktivnosti (u okviru *individualnog*, *tehničkog* i *timskog* rada) (Tablica 6-1). Promatrajući samo razvojne

aktivnosti, može se uočiti kako su tijekom uzorkovanja dominantne bile aktivnosti *konceptualizacije* i *detaljiranja/kodiranja* pri *individualnom tehničkom* radu.

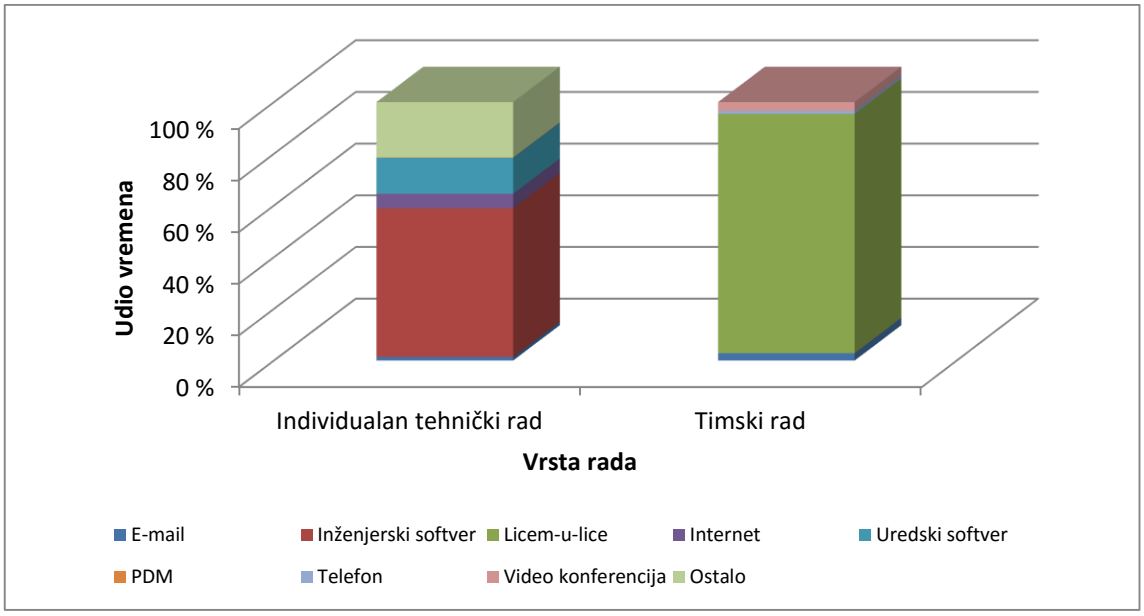
Također, tijekom *individualnog tehničkog* rada prilično su učestale aktivnosti *mjerenje* i *analiza* koje su također među vodećim aktivnostima pri *timskom* radu. Najčešće timske aktivnosti bile su *planiranje*, *analiza* i *konceptualizacija*.

Tablica 6-1. Udio tipa razvojnih aktivnosti u individualnom tehničkom i timskom radu

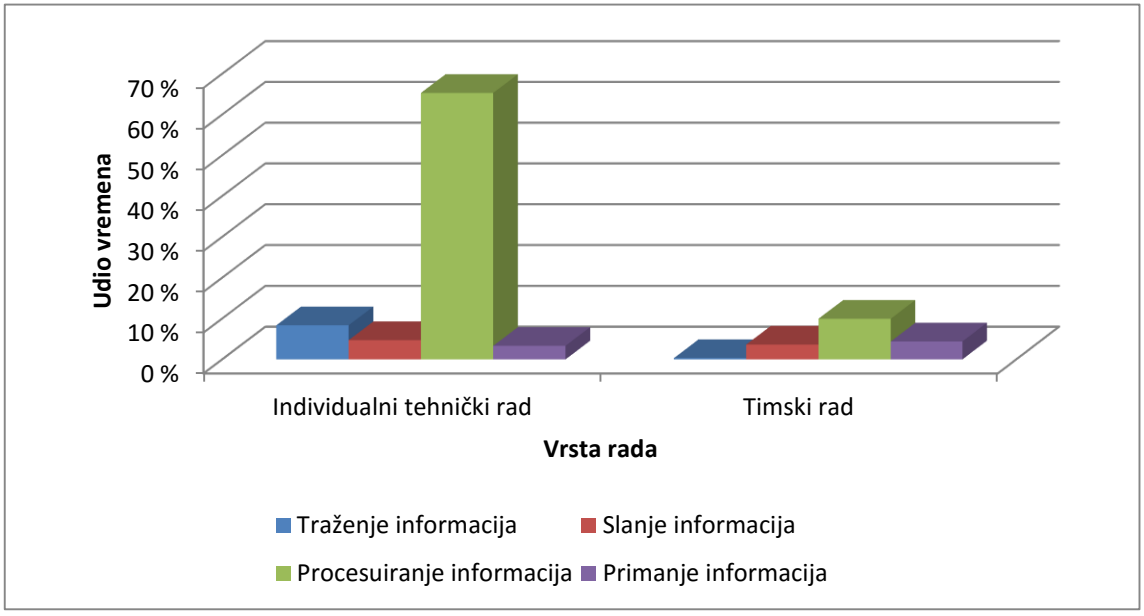
Tip aktivnosti	Individualan tehnički rad	Timski rad	Ukupan udio u razvojnim aktivnostima
konceptualizacija	32,35 %	13,07 %	28,90 %
detaljiranje i kodiranje	26,67 %	0,57 %	22,01 %
mjerenje	10,62 %	11,93 %	10,85 %
analiza	10,00 %	14,20 %	10,75 %
izvještavanje	5,56 %	2,84 %	5,07 %
inovativne aktivnosti	2,47 %	7,95 %	3,45 %
planiranje	0,62 %	15,34 %	3,25 %
ostalo individualno	3,83 %	0,00 %	3,14 %
donošenje odluka	1,36 %	8,52 %	2,64 %
praćenje i nadzor	2,59 %	0,57 %	2,23 %
rješavanje konflikata	1,23 %	5,68 %	2,03 %
korisnička podrška	0,37 %	5,68 %	1,32 %
prodaja i nabava	0,86 %	2,84 %	1,22 %
dodjela resursa	0,49 %	3,41 %	1,01 %
ostalo timski	0,00 %	5,11 %	0,91 %
evaluacija	0,49 %	2,27 %	0,81 %
pregovaranje	0,49 %	0,00 %	0,41 %
Ukupno	**100,00 %**	**100,00 %**	**100,00 %**

Razvojne su se aktivnosti, pri *individualnom tehničkom* i *timskom* radu, provodile na različite načine te korištenjem različitih resursa koji su prikazani na slici (Slika 6-5). U individualnom tehničkom radu najčešće je zabilježeno korištenje *inženjerskim softverom*, ali prilično je važna i uporaba *uredskog softvera* te *interneta*. U timskom su se radu, većinom, aktivnosti provodile *licem u lice*, ali koristeći se i drugim načinima komunikacije poput *e-pošte* i *videokonferencija*.

Rezultati vezani za prirodu transformacije informacija u promatranim razvojnim aktivnostima upućuju na to da, pri *individualnom tehničkom* radu, sudionici najčešće sudjeluju u *procesiranju informacija* (Slika 6-6).



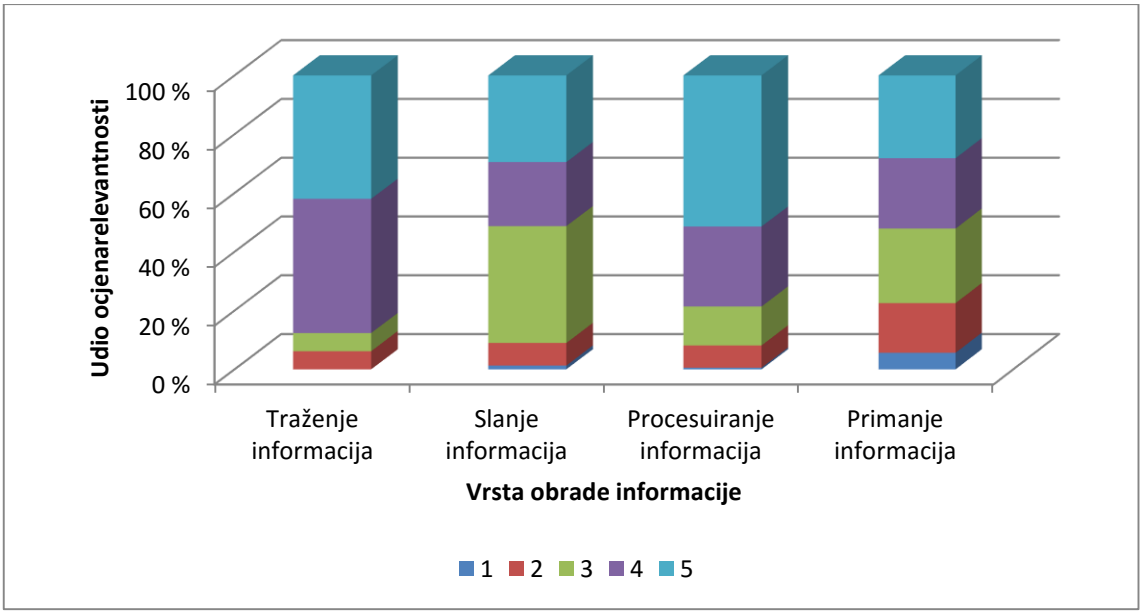
Slika 6-5. Pregled načina provođenja aktivnosti tijekom uzorkovanja s podjelom na individualni tehnički rad i timski rad



Slika 6-6. Priroda obrade informacija u okviru individualnoga i timskoga rada

Kao drugi najčešći oblik transformacije informacija pri *individualnom tehničkom* radu nameće se *traženje informacija*, s naglaskom na upotrebu unutarnjih (korporativne baze ili kolege) izvora podataka. U usporedbi s *traženjem informacija,* oblici transformacija *davanje* i *primanje informacija* bili su manje prisutni tijekom uzorkovanja. U *timskom radu*, udio vremena utrošen na *davanje*, *primanje* i *procesuiranje informacija* ravnomjerno je raspoređen tijekom promatranih razvojnih aktivnosti.

Na slici (Slika 6-7) prikazani su udjeli pojedinih ocjena relevantnosti informacije s obzirom na prirodu transformacije informacija. Pri *procesuiranju* i *traženju informacija* relevantnost informacija prilično je visoko ocijenjena, a viših je ocjena manje za *davanje* i *primanje informacija.*



Slika 6-7. Pregled ocjena relevantnosti informacija s obzirom na prirodu obrade informacije

U nastavku su spojena različita gledišta zabilježenih aktivnosti radi iscrpnije analize prikupljenih podataka. Udjeli vremena koje su sudionici proveli obavljajući aktivnosti u kategorijama *individualnog tehničkog* i *timskog* rada te njihova veza s pojedinim *kontekstom* i *razinom motivacije* prikazani su u tablici (Tablica 6-2).

Tijekom *individualnog tehničkog* i *timskog* rada sudionici najviše vremena provode u aktivnostima koje su povezane s kontekstom elektronike i softvera. Podjelom *timskih* aktivnosti uočljivo je da najveći udio pripada *neformalnim raspravama* te *formalnim sastancima*. Tijekom uzorkovanja, aktivnosti vezane uz *izvještavanje* bile su vezane za *razvoj softvera*, *interese zaposlenika* i *infrastrukturu*.

Motivacija za individualni i timski rad dosegla je najvišu razinu u aktivnostima vezanim uz kontekst proizvoda. Vrijedi istaknuti i visoku razinu motivacije pri individualnom radu u aktivnostima koje pripadaju kontekstu životnog vijeka proizvoda te pri timskom radu u aktivnostima koje pripadaju kontekstu infrastrukture.

Udio vremena koje sudionici provode u različitim tipovima razvojnih aktivnosti u okviru individualnoga tehničkog i timskog rada s obzirom na prirodu obrade informacija prikazan je

u tablici (Tablica 6-3). Razlika između ukupnog broja točaka uzorkovanja u ovim dvjema tablicama (Tablica 6-2 i Tablica 6-3) posljedica je nepotpuno ispunjenih upitnika pri određivanju prirode obrade informacije te izuzimanja podataka iz aktivnosti kao što su prekidi u radu i individualni administrativni rad koji nisu relevantni za prirodu obradu informacije.

Tablica 6-2. Kontekst razvoja proizvoda prema tipu radne aktivnosti i razini motivacije za pojedinu aktivnost/kontekst

		Individualni tehnički rad			Timski rad														Individualni administrativni rad			Ukupno		
					Diskusija (neformalna)			Sastanak			Izvještavanje			Sastanak tima			Ukupno								
Kontekst		BO	PT	IM	BO	PT	IM	BO	PT	IM	BO	PT	IM	BO	PT	IM	BO	PT	IM	BO	PT	IM	BO	PT	IM
Proizvod	Elektronički dio	365	34,05	3,62	43	4,01	3,47	5	0,47	3,60				6	0,56	3,00	54	5,04	3,43				419	39,09	3,59
	Mehanički dio	139	12,97	3,27	8	0,75	2,63	1	0,09	3,00	1	0,09	4,00				10	0,93	2,80				149	13,90	3,24
	Softverski dio	210	19,59	3,92	24	2,24	3,79	10	0,93	4,00	6	0,56	4,50	5	0,47	4,00	45	4,20	3,96				255	23,79	3,93
Proces	Proizvodnja	79	7,37	2,92	2	0,19	2,50	5	0,47	3,40	1	0,09	2,00	2	0,19	3,00	10	0,93	3,00				89	8,30	2,93
	Instalacija							2	0,19	3,00							2	0,19	3,00				2	0,19	3,00
	Održavanje	1	0,09	3,00																			1	0,09	3,00
Zaposlenici		1	0,09	3,00				14	1,31	2,57	2	0,19	1,00	3	0,28	2,00	19	1,77	2,32				20	1,87	2,35
Postrojenja					1	0,09	3,00	1	0,09	3,00	2	0,19	4,00	1	0,09	3,00	5	0,47	3,40				5	0,47	3,40
Administracija																				86	8,02	3,20	86	8,02	3,20
Ostali kontekst		15	1,40	2,87				25	2,33	2,84				6	0,56	2,17	31	2,89	2,71				46	4,29	2,76
Ukupno		810	75,56	3,55	78	7,28	3,45	63	5,88	3,08	12	1,12	3,58	23	2,15	2,87	176	16,42	3,25	86	8,02	3,20	1072	100,00	3,47

Legenda: BO – broj odgovora, PT – postotak ukupnog vremena, IM – razina individualne motivacije

Velik udio *individualnog tehničkog* rada u kojem su sudionici *davali informacije* ostvaren je pri *definicijskim* aktivnostima, a za vrijeme *timskog* rada najčešće *predane informacije* poslužile su za *podršku korisnicima*. *Primanje informacija* u *individualnom tehničkom radu* najčešće se pojavljivalo pri *evaluacijskim aktivnostima*, a u *timskom* radu pri *aktivnosti planiranja. Procesuiranje informacija* pri *individualnom tehničkom* radu najčešće se odvijalo tijekom *definiranja proizvoda* (*konceptualizacija i detaljiranje/kodiranje*), a u *timskom radu* ta je priroda obrade informacije dominantna tijekom *evaluacijskih aktivnosti* (*analiza i mjerenje*). *Traženje informacija od internih izvora* najčešće je tijekom aktivnosti *mjerenja* u *individualnom tehničkom radu*, a *vanjski izvori* konzultirani su prilikom inovativnih aktivnosti. Pri *timskom radu*, *vanjski izvori* poslužili su tijekom *donošenja odluka.*

Relevantnost informacije u individualnom tehničkom radu najviša je za aktivnosti primanja i davanja informacije u rješavanju konflikata, dodjeljivanju resursa te pri praćenju i nadzoru. Pri timskom radu, najrelevantnije su informacije zabilježene pri davanju informacije tijekom aktivnosti analize, a to je zabilježeno i za primanje informacija pri detaljiranju/kodiranju.

Tijekom *individualnoga tehničkog* rada najrelevantnije su informacije *procesuirane* za potrebe *pregovaranja i mjerenja*, a u timskom radu za potrebe *mjerenja, praćenja i nadzora*.

Pri *traženju informacija od internih izvora*, pak, najrelevantnije su informacije bile u aktivnostima *donošenja odluka* i *analize*, a *vanjski izvori* najrelevantnije informacije pružali su za potrebe aktivnosti *stvaranja novih ideja* i *unapređenja (inovativne aktivnosti).*

Tablica 6-3. Tip razvojnih aktivnosti prema prirodi transformacije informacija i relevantnosti informacije u pojedinoj aktivnosti

		Slanje informacija			Primanje informacija			Procesuiranje informacija			Traženje informacija						Ukupno		
											Interni izvori			Eksterni izvori					
		BO	PT	RI	BO	PT	RI	BO	PT	RI	BO	PT	RI	BO	PT	RI	BO	PT	RI
Individualni tehnički rad		44	4,72	3,55	31	3,32	3,60	609	65,27	4,25	70	7,50	4,29	8	0,86	3,88	762	81,67	4,19
Upravljačke aktivnosti	Planiranje							4	0,43	3,50	1	0,11	4,00				5	0,54	3,60
	Rješavanje konfilkata	2	0,21	5,00	1	0,11	5,00	7	0,75	4,71							10	1,07	4,80
	Dodjela resursa	1	0,11	4,00				2	0,21	4,00	1	0,11	2,00				4	0,43	3,50
	Pregovaranje							4	0,43	5,00		0,00					4	0,43	5,00
Evaluacijske aktivnosti	Analiza	2	0,21	3,00	15	1,61	3,36	50	5,36	3,92	3	0,32	4,67	1	0,11	3,00	71	7,61	3,80
	Donošenje odluka	3	0,32	3,33				6	0,64	3,50	2	0,21	5,00				11	1,18	3,73
	Mjerenje				3	0,32	4,67	29	3,11	4,79	50	5,36	4,40	1	0,11	4,00	83	8,90	4,54
	Praćenje i nadzor	1	0,11	5,00				18	1,93	4,78							19	2,04	4,79
	Evaluacija	1	0,11	3,00				3	0,32	4,33							4	0,43	4,00
Definicijske aktivnosti	Konceptualizacija	1	0,11	3,00	1	0,11	5,00	258	27,65	4,48	1	0,11	4,00				261	27,97	4,48
	Detaljiranje i kodiranje	15	1,61	3,93	5	0,54	4,20	174	18,65	4,38	1	0,11	3,00	3	0,32	3,33	198	21,22	4,32
	Generiranje ideja/Unaprjeđenje	2	0,21	2,00	2	0,21	4,50	7	0,75	3,29				3	0,32	4,67	14	1,50	3,57
Korisnička podrška		2	0,21	3,50							1	0,11	4,00				3	0,32	3,67
Izvještavanje					1	0,11	2,00	40	4,29	2,25	3	0,32	2,00				44	4,72	2,23
Prodaja i nabava		6	0,64	3,00				1	0,11	3,00							7	0,75	3,00
Ostalo individualno		8	0,86	3,38	3	0,32	1,67	6	0,64	4,33	7	0,75	4,71				24	2,57	3,79
Timski rad		34	3,64	3,91	41	4,39	3,46	93	9,97	3,95				3	0,32	4,00	171	18,33	3,82
Upravljačke aktivnosti	Planiranje	5	0,54	4,00	8	0,86	4,13	14	1,50	4,00							27	2,89	4,04
	Rješavanje konfilkata	2	0,21	3,50	3	0,32	4,67	4	0,43	3,75				1	0,11	4,00	10	1,07	4,00
	Dodjela resursa	1	0,11	3,00	3	0,32	3,00	2	0,21	4,00							6	0,64	3,33
Evaluacijske aktivnosti	Analiza	2	0,21	5,00	4	0,43	3,75	19	2,04	3,84							25	2,68	3,92
	Donošenje odluka	4	0,43	4,25				9	0,96	4,00				2	0,21	4,00	15	1,61	4,07
	Mjerenje				2	0,21	4,50	14	1,50	4,50							16	1,71	4,50
	Praćenje i nadzor							1	0,11	5,00							1	0,11	5,00
	Evaluacija	1	0,11	4,00				3	0,32	4,00							4	0,43	4,00
Definicijske aktivnosti	Konceptualizacija	4	0,43	4,25	5	0,54	4,00	14	1,50	4,21							23	2,47	4,17
	Detaljiranje i kodiranje				1	0,11	5,00										1	0,11	5,00
	Generiranje ideja/Unaprjeđenje	3	0,32	4,67	4	0,43	3,00	7	0,75	3,43							14	1,50	3,57
Korisnička podrška		7	0,75	4,14	1	0,11	2,00	2	0,21	3,50							10	1,07	3,80
Izvještavanje		1	0,11	3,00	3	0,32	2,67	1	0,11	2,00							5	0,54	2,60
Prodaja i nabava		3	0,32	2,67	1	0,11	3,00	1	0,11	4,00							5	0,54	3,00
Ostalo timski		1	0,11	1,00	6	0,64	2,00	2	0,21	1,50							9	0,96	1,78
Ukupno		78	8,36	3,71	72	7,72	3,52	702	75,24	4,21	70	7,50	4,29	11	1,18	3,91	933	100,00	4,12

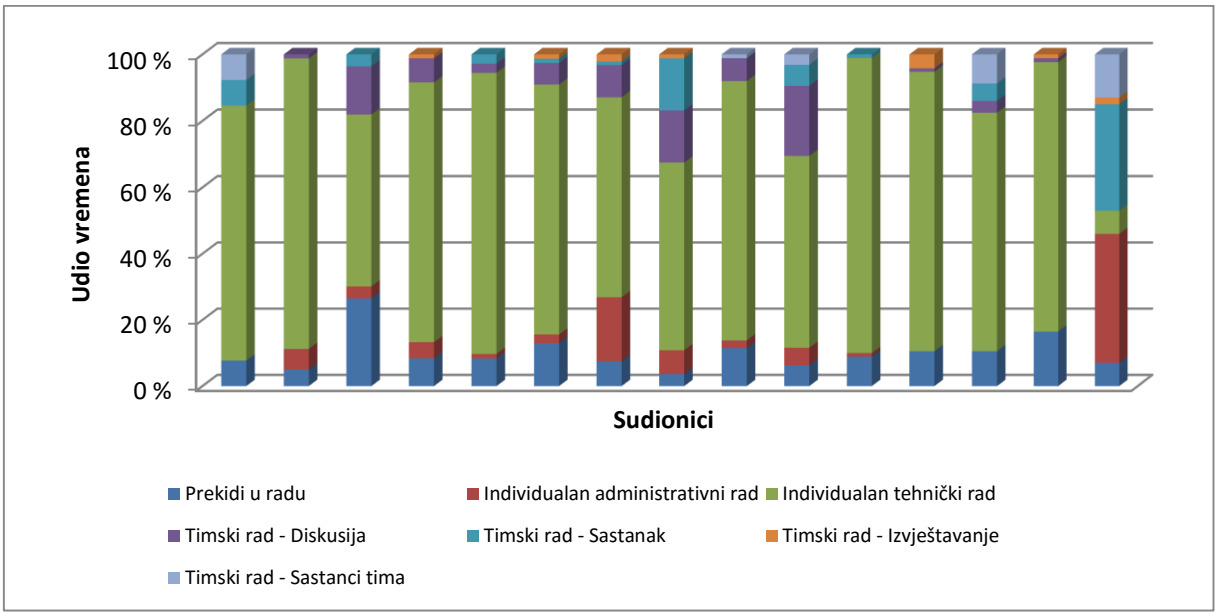
Legenda: BO – broj odgovora, PT – postotak ukupnog vremena, RI – razina relevantnosti informacije

6.1.2. Analiza prikupljenih podataka za cijelo razdoblje uzorkovanja za svakog sudionika zasebno

Analiza prikupljenih podataka za svakog sudionika zasebno omogućuje raščlambu pojedinih segmenata aktivnosti za svakog člana tima. Iz analize rezultata za svakog pojedinca kvantitativnim podacima uzorkovanja vezanima za pojedini projekt, tip rada i vrstu aktivnosti može se dati kvalitativna dimenzija te, time, omogućiti bolje razumijevanje i interpretaciju

konteksta uzorkovanja. Rezultati uzorkovanja rada za svakog pojedinca omogućuju dodatan pogled na raspodjelu radnih aktivnosti među članovima tima te na način provođenja aktivnosti.

Na slici (Slika 6-8) prikazan je udio pojedinog tipa rada s razrađenim timskim aktivnostima za svakoga sudionika. Iako je dominacija *individualnih* aktivnosti već ustanovljena, iz ovih se rezultata zapaža da samo nekoliko članova tima ima veći udio *timskih* aktivnosti. Također, iz rezultata se može jasno razlikovati voditelja tima i preostale sudionike zbog većeg udjela *administrativnog rada* te *sastanaka*.

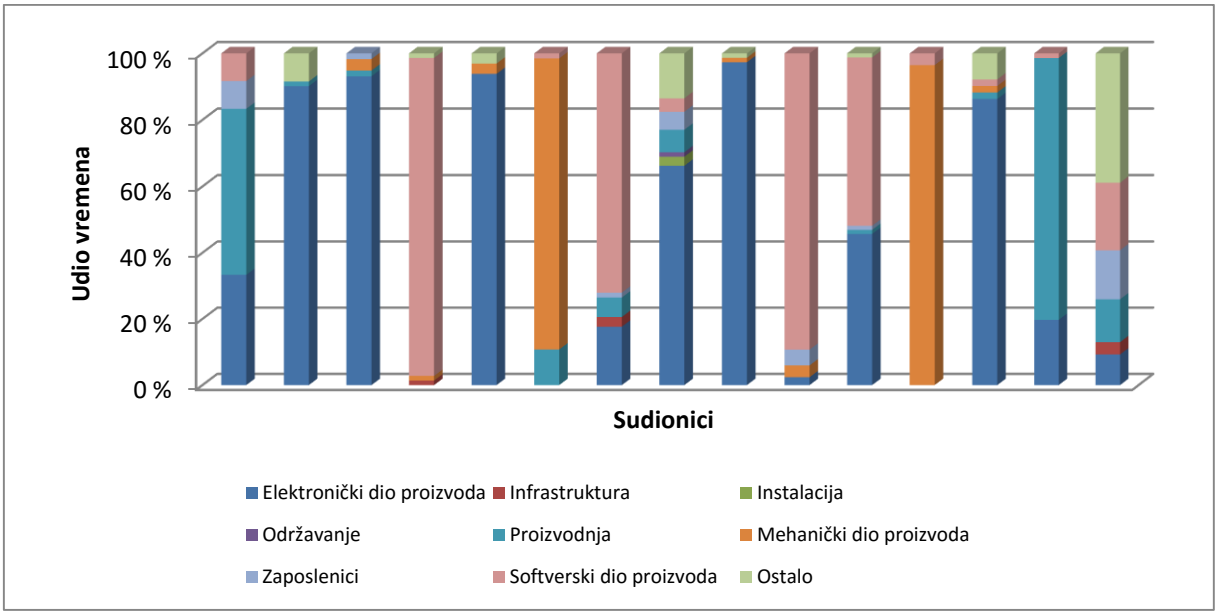


Slika 6-8. Pregled udjela vremena provedenog na pojedinom tipu rada (za svakog sudionika)

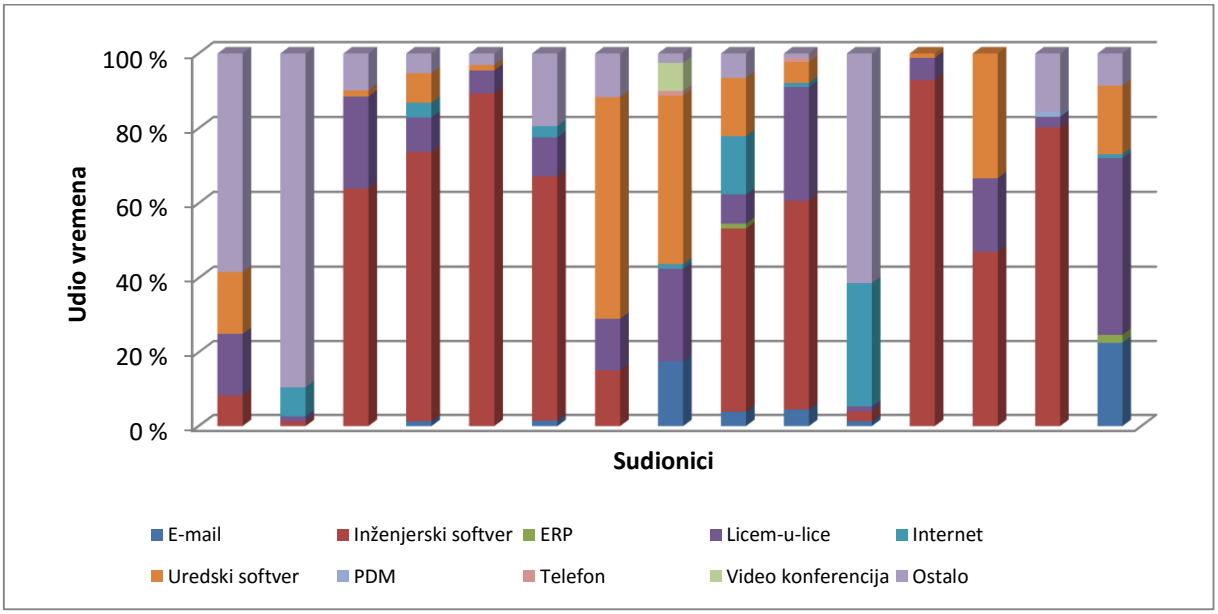
Analizirajući kontekst aktivnosti za svakog sudionika zasebno, članovi tima mogu se podijeliti na tri podskupine (Slika 6-9):

- sudionici u čijim je aktivnostima najveći udio - razvoj elektroničkog dijela proizvoda (6 sudionika)
- sudionici u čijim je aktivnostima najveći udio - razvoj softverskog dijela proizvoda (5 sudionika)
- sudionici u čijim je aktivnostima najveći udio - razvoj mehaničkog dijela proizvoda i proizvodnje (4 sudionika)

Analiza načina provođenja aktivnosti tijekom uzorkovanja omogućuje uvid u količinu vremena koje pojedini sudionici provode koristeći se specifičnim resursima i načinima komunikacije (Slika 6-10).



Slika 6-9. Pregled udjela vremena provedenog za pojedini kontekst (za svakog sudionika) pri individualnom tehničkom i timskom radu



Slika 6-10. Pregled udjela različitih načina provođenja aktivnosti (za svakog sudionika) pri individualnom tehničkom i administrativnom radu te timskom radu

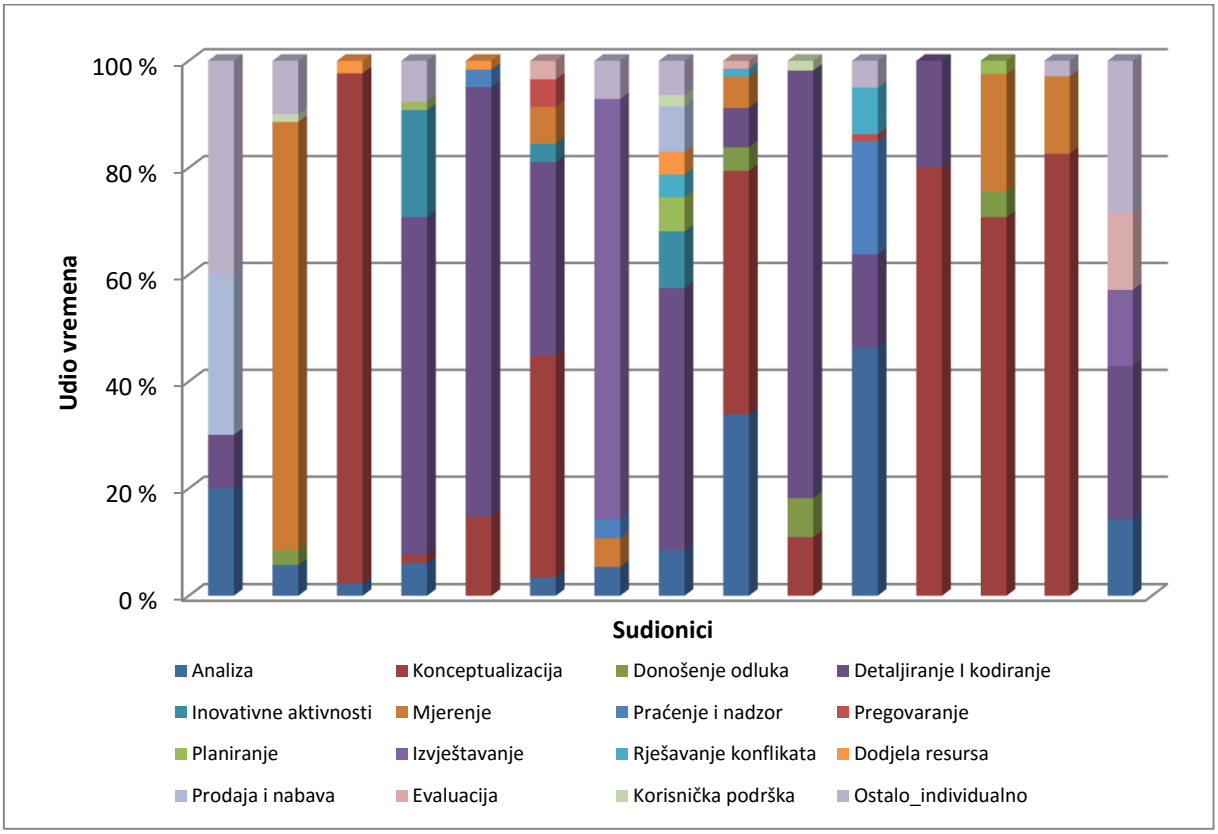
Rad s *inženjerskim softverom* bio je najčešći način provođenja aktivnosti tijekom uzorkovanja te je zabilježen kod devet sudionika. Preostali su sudionici izvodili aktivnosti uz čestu uporabu *uredskog softvera* ili na načine koji su bili svrstani u kategoriju *ostalo*. Od različitih načina komunikacije, najčešći je *licem u lice* te je on znatan u svih sudionika.

Kako su skupine razvojnih aktivnosti (aktivnosti upravljanja, definicije i evaluacije) dodatno raspodijeljene na pojedinačne razvojne aktivnosti, pri njihovoj je analizi teže definirati zajedničke značajke u različitih sudionika uzorkovanja. Također, potrebno je uzeti u obzir

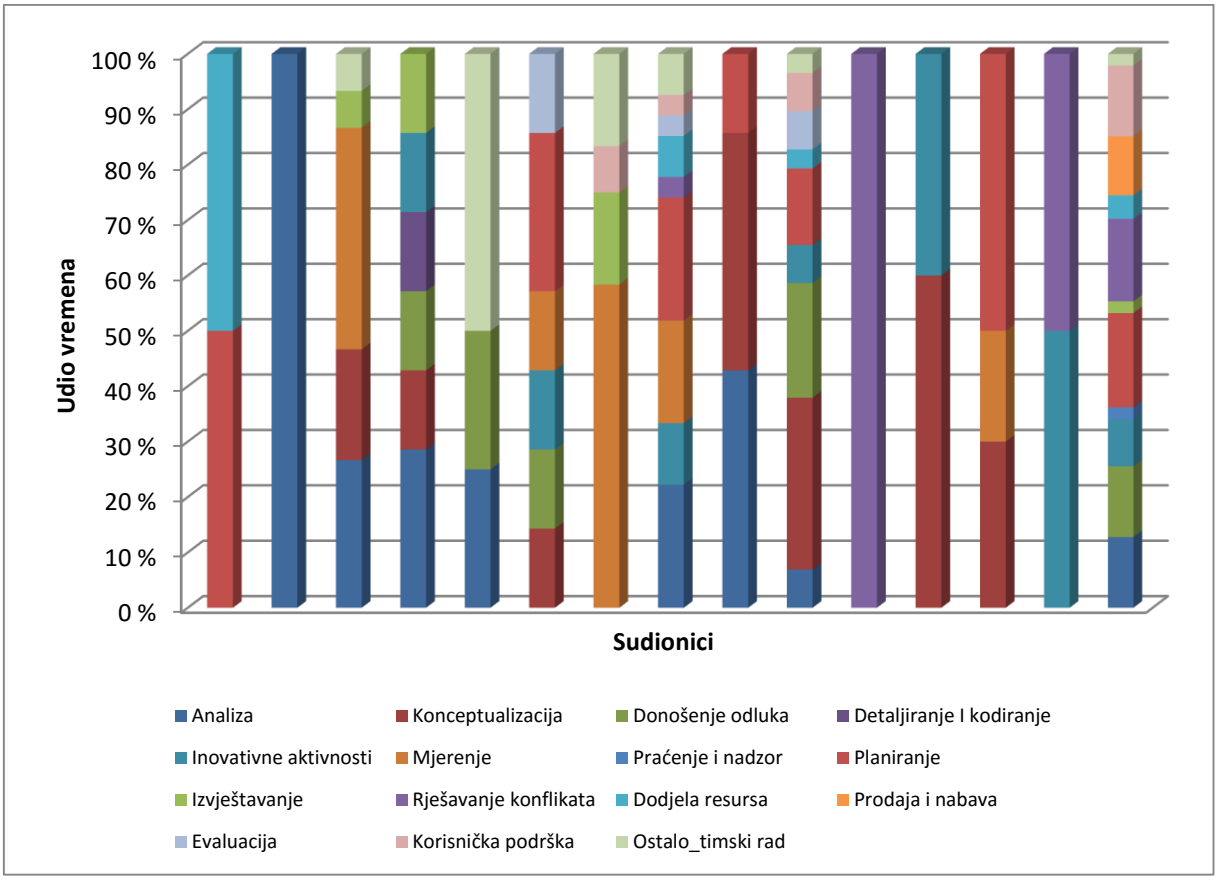
različite profile sudionika pri individualnom tehničkom i timskom radu. Stoga su u nastavku analize razvojne aktivnosti razmatrane zasebno za individualni tehnički i timski rad (Slika 6-11).

Analizom razvojnih aktivnosti u okviru individualnog tehničkog rada uočljiva je velika raznolikost kod tri sudionika, a u ostalih sudionika dominira manji broj različitih razvojnih aktivnosti. Definicijske aktivnosti (uglavnom konceptualizacija i detaljiranje/kodiranje) pri individualnom tehničkom radu najčešće su u deset sudionika, s tim da je i između njih uočljiva podjela na članove tima sa žarištem na konceptualizaciju, odnosno detaljiranje/kodiranje (uz izuzetak jednog sudionika u kojeg su te dvije aktivnosti ravnomjerno raspoređene). U ostalih se sudionika može uočiti po jedna izrazito dominantna razvojnu aktivnost (npr. izvještavanje ili analiza).

U okviru *timskog rada* udjeli vremena, utrošeni na razvojne aktivnosti, ravnomjernije su raspoređeni te je u mnogih sudionika nemoguće identificirati samo jednu ili dvije dominantne razvojne aktivnosti.



a) individualni tehnički rad



b) timski rad

Slika 6-11. Pregled udjela razvojnih aktivnosti u okviru: a) individualnoga tehničkog rada b) timskog rada (za svakog sudionika)

6.1.3. Zaključci na temelju analize prikupljenih podataka za cijelo razdoblje uzorkovanja rada

Uzorkovanje rada provedeno je pomoću aplikacije za mobilne uređaje koja je omogućila brzo i jednostavno samoizvještavanje. Kako je aplikacija izrađena za platformu Android, odabir sudionika uzorkovanja znatno je ovisio o tipu mobitela te korištenoj mobilnoj platformi. Sukladno tome, za potrebe uzorkovanja dio je sudionika dobio nove mobitele, ali su i dva potencijalna sudionika morala biti isključena iz uzorkovanja (prvi jer se ne služi engleskim jezikom, a drugi zbog svoje eksterne konzultantske uloge).

Sudionici su aplikaciju imali na raspolaganju jedan dan prije početka uzorkovanja kako bi je mogli testirati te se upoznati s njezinom osnovnom funkcionalnosti. U razgovoru sa sudionicima poslije provođenja uzorkovanja ustanovljeno je da su postojale i određene poteškoće s razumijevanjem pojedinih opcija unosa, unatoč tomu što im je na raspolaganju bio dokument s uputama za korištenje aplikacijom i opisom svih izbornika te stalna autorova podrška.

Uzorkovanje je trajalo dva tjedna te je bitno istaknuti kako to sigurno nije dovoljno za donošenje općenitih zaključaka. Za to bi bilo potrebno uzorkovati radne aktivnosti u duljem razdoblju. Zbog relativno kratkog trajanja uzorkovanja, bilo je nužno emitirati više podsjetnika (oko 8 u prosjeku) po danu kako bi se prikupio dovoljan broj podatkovnih vektora za provođenje dovoljno vjerodostojne analize.

Kako je uzorkovanje provedeno neposredno nakon izrade aplikacije, unutar aplikacije još su bili prisutni pojedini tehnički problemi. Zbog tehničkih problema, npr. usklađivanja sa središnjom bazom podataka i nedovoljna broja podsjetnika, na početku drugog tjedna od sudionika uzorkovanja zatražena je instalacija nove verzije aplikacije. Uporaba nove verzije aplikacije povećala je broj podsjetnika tijekom drugog tjedna, koji je u pojedinim danima premašio željeni broj podsjetnika u danu. Sudionici su prepoznali da je učestalost podsjetnika tijekom drugog tjedna bila viša te da se podsjetnici nisu emitirali u prethodno zadanim razmacima, što je rezultiralo nižim zadovoljstvom vezanim za rad aplikacije. Ipak, ukupno gledajući, broj podsjetnika za svakog sudionika tijekom uzorkovanja prosječno je bio oko 8 po danu, pa je studija reprezentativna [100]. Razlika u broju ispunjenih upitnika među pojedinim sudionicima proizlazi iz slučajnog broja podsjetnika po sudioniku te iz manjeg udjela odgovorenih upitnika pojedinih sudionika. Analizom prikupljenih podataka uočeno je da pojedini sudionici nisu ispunjavali upitnike u sve dane uzorkovanja, što je također uzrokovalo ukupan manji broj odgovorenih upitnika u tih sudionika (izostanak s posla).

Velik broj upitnika na koje je odgovoreno u prvih 30 minuta nakon emitiranja podsjetnika uvelike pridonosi relevantnosti studije. Na samo 12 % upitnika odgovoreno je poslije 60 minuta, što upućuje na to da je većina sudionika ispunjavala upitnike ubrzo pošto su poslani. Brzo ispunjavanje upitnika poslije emitiranja podsjetnika upućuje na uspješnu prilagodbu sudionika zahtjevima uzorkovanja te omogućuje prikupljanje podataka u realnom vremenu.

Analizirajući tip rada, primjetna je dominacija individualnoga tehničkog rada koja odražava kasnije faze uzorkovanih projekata. Jedan od projekata s najvećim vremenskim udjelom bio je u završnoj fazi konstruiranja hardverskih komponenata. Svi tehnički zahtjevi bili su definirani i većina je nedoumica u tehničkom dijelu bila razjašnjena. Također, uloge i zadaci već su bili definirani i dodijeljeni pojedinim sudionicima. Stoga je udio timskoga rada u analiziranom razdoblju manji nego u nekim drugim usporedivim istraživanjima.

Udio timskog rada od 14,8 % sličan je vrijednostima od 11,3 % dobivenim u istraživanju koje su proveli Webster i Higgs [218], ali se značajno razlikuje od 40,4 % timskih aktivnosti u

Robinsonovu [100] istraživanju. Redoslijed i odnos potkategorija timskih aktivnosti podudaraju se s Robinsonovim istraživanjem, iako se njihovi udjeli znatno razlikuju. Udio diskusija od 6,5 % uvelike se razlikuje od 26,3 % dobivenih Robinsonovim istraživanjem. Formalni sastanci, kao potkategorija timskog rada, u našem uzorkovanju zauzimaju 5,3 % timskih aktivnosti, što je manje nego u usporedivim istraživanjima. Naime, Robinson i dr. [100] te Lowe i dr. [190] navode da je udio sastanaka u njihovu istraživanju bio oko 13 %, a Marsh [219] 9 %. Rezultati vezani za aktivnosti izvještavanja podudaraju se s Robinsonovim istraživanjem (5,03 % ≈ 4,78 %).

Ipak, najznačajnija razlika se uočava uspoređivanjem udjela individualnoga tehničkog rada. Naime, tijekom uzorkovanja individualni tehnički rad ima najveći udio od 67,9 % te se znatno razlikuje od Robinsonovih 37,9 % za tehnički i individualni rad. S druge strane, 58 % individualnih tehničkih aktivnosti u istraživanju Lowea i dr. [190] mnogo je bliže vrijednosti dobivenoj tijekom provedenog uzorkovanja. Potrebno je istaknuti da razlike u kategorizaciji tipova rada u različitim istraživanjima uvelike otežavaju njihovu usporedbu te da iz njih djelomično proizlazi i razlika u rezultatima usporedivih istraživanja.

Tijekom analiziranog razdoblja prevladavale su aktivnosti vezane za elektronički i softverski dio proizvoda što je prilično očekivano s obzirom na prirodu projekata i profesionalan profil sudionika uzorkovanja (diplomirani inženjeri elektrotehnike i strojarstva). Također, s obzirom na njihove aktivnosti i zaduženja, logično je da su konceptualizacija i detaljiranje/kodiranje dvije najčešće zabilježene aktivnosti. Potrebno je istaknuti relativno visok udio aktivnosti planiranja i analize na timskoj razini. Inovativne aktivnosti češće su se provodile na timskoj (8,0 %) nego na individualnoj (2,5%) razini, ali općenito su imale nizak udjel tijekom uzorkovanja.

Velik udio individualnoga tehničkog rada provodio se upotrebom inženjerskog softvera što se očituje u njegovu vodećem mjestu među načinima provođenja aktivnosti. Kao i u Robinsonovu istraživanju, otprilike polovica aktivnosti provodila se na računalu, iako je primjetan gotovo tri puta veći udio korištenja inženjerskim softverom (38,7 % >12,5 %).

Timske su se aktivnosti najčešće provodile licem u lice i takva je komunikacija uobičajena za procese razvoja u kojima su svi članovi tima na istoj lokaciji. Također, omjer vremena utrošenog na komunikaciju licem u lice i na korištenje e-poštom je 3,6:1, a u Robinsona je on 2,3:1. Iako pojedina istraživanja poput onog Patrashkova-Volzdoske i dr. [220] sugeriraju ravnomjernu podjelu različitih načina komunikacije u inženjerskim timovima, provedenim

uzorkovanjem nisu se mogli potvrditi takvi rezultati, što je vjerojatno posljedica zajedničke lokacije sudionika. Zbog zajedničke lokacije sudionika, e-pošta je znatno manje zastupljen način komunikacije, iako brojna istraživanja (npr. [211], [214]) upozoravaju na njegovu važnost u inženjerskom kontekstu.

Uz takav način komunikacije usko je vezana i priroda transformacije informacija na timskoj razini. Procesuiranje informacija na timskoj razini dominira tijekom aktivnosti koje uključuju sudjelovanje u diskusijama, sastancima i ostalim tipovima timskog rada. Procesuiranje informacija na individualnoj razini vezano je uz velik udio uzorkovanih točaka u kojima je zabilježeno sudjelovanje u konceptualizaciji i detaljiranju.

Uspoređujući dobivene vremenske udjele za različite prirode transformacije informacije s rezultatima Marshova istraživanja [219], primjetan je nešto manji udio vremena u kojem su sudionici primali informacije (7,7 % < 12 %) te podjednaki vremenski udjeli pri kojima su davali informacije (8,3 % ≈ 8 %). Lowe i dr. [190] navode da je udio vremena koje sudionici razvojnog procesa provode tražeći informaciju 21 %, što je znatno više od 8,7 % koliko je dobiveno u ovdje prikazanom istraživanju. Prema Robinsonu [99], inženjeri u razvojnom procesu na primanje informacije troše 11,5 % vremena, na njihovo traženje 14,2 %, a na davanje informacija čak 22,6 %. Dakle, u Robinsonovu istraživanju [99] vremenski udjeli utrošeni na primanje, traženje i davanje informacija viši su nego u ovdje prikazanom istraživanju.

Rezultati vezani za relevantnost informacija i njihovu ovisnost o prirodi obrade informacije upućuju na to da su relevantnijima ocijenjene informacije u aktivnostima vezanim za pojedinca, npr. procesuiranje i traženje informacija. S druge strane, pri jednosmjernoj izmjeni informacija (davanje i primanje informacija), relevantnost informacija ocijenjena je nižom ocjenom. Relevantnost informacije pri davanju informacija ocijenjena je višom ocjenom nego pri primanju informacija upozoravajući na to da sudionici smatraju kako su informacije koje oni šalju relevantnije od onih koje primaju. Iako se relevantnost informacije pokazala važnim kriterijem u provedenoj analizi uzorkovanja, opravdana je sumnja u nerazumijevanje ili nedovoljno dobro objašnjenje uloge i značenja relevantnosti informacije. Prema Eppleru [221], relevantnost informacije obuhvaća potkriterije opsežnosti, preciznosti, jasnoće i primjenjivosti informacije te na taj način agregira navedene kriterije. Nakon provođenja uzorkovanja, sudionici su istaknuli da im je u pojedinim aktivnostima bilo teško ocijeniti relevantnost. Daljnja rasprava o relevantnosti informacije vezana za nematerijalne indikatore nalazi se u poglavlju 6.2.2.

Analiza rezultata spojenih gledišta upozorila je na vezu između konteksta i tipa rada. Logično je očekivati, s obzirom na profesiju sudionika i tematiku projekta, da je većina diskusija bila vezana za elektronički i softverski dio proizvoda, no uočeno je i više formalnih sastanaka vezanih za pitanja ljudskih resursa. Potonji tip aktivnosti zahtijeva daljnju razradu, posebno uzme li se u obzir to da je pritom motivacija sudionika bila uvjerljivo najniža od svih zabilježenih aktivnosti.

Rezultate koji su dobiveni analizom spojenih gledišta treba uzeti s posebnim oprezom jer se čvrsti zaključci ne mogu donijeti na temelju samo nekoliko točaka uzorkovanja koje su vezane za pojedinu razvojnu aktivnost. Naime, više ocjene relevantnosti informacije ili motivacije za pojedinu razvojnu aktivnost ili kontekst mogu proizići iz manjeg broja točaka za pojedinu aktivnost ili kontekst. Zbog manjeg broja točaka uzorkovanja, dodatna raščlamba pojedinih gledišta može nas navesti na pogrešne zaključke o cijelom timu. Iako je iz analize spojenih gledišta moguće doći do preliminarnih zaključaka, za donošenje čvršćih zaključaka potrebno je duže razdoblje i više točaka uzorkovanja.

Kumulativna analiza provedena za svakog sudionika zasebno ponudila je dodatne mogućnosti i poglede na prikupljene podatke. Analiza tipa radnih aktivnosti za svakog sudionika zasebno upućuje na veliku sličnost između sudionika uzorkovanja u smislu približno jednakog udjela individualnoga administrativnog, individualnoga tehničkog i timskoga rada. Iznimka su tri sudionika koji se razlikuju zbog većeg udjela timskog rada. Udio je timskoga rada općenito bio malen u cijelom razdoblju uzorkovanja, a bio je još i manji u većine sudionika. Dakle, ionako malen udio timskih aktivnosti razdijeljen je na malen broj sudionika. Ovakva raspodjela timskih aktivnosti upućuje na to da mali broj sudionika sudjeluje u većini timskih aktivnosti te je više u interakciji s ostalim sudionicima, a u ostalih su sudionika timske aktivnosti znatno manje. Zbog većeg udjela individualnog administrativnog rada, ali i većeg broja formalnih sastanaka, može se jasno razlikovati voditelj tima. Veći udio individualnoga administrativnog rada u jednoga sudionika eventualno se može povezati s profesionalnim neiskustvom te kratkim radnim stažem u organizaciji, zbog čega je moguće da su mu dodijeljeni takvi zadaci.

Analiza konteksta aktivnosti za svakog sudionika zasebno te podjela sudionika na tri podskupine (elektronički, softverski i mehanički dio) prema tom kriteriju omogućuje bolje razumijevanje njihova rada. S obzirom na jedan dominantan kontekst aktivnosti u velikog broja sudionika, nameće se zaključak da nema mnogo interakcije između sudionika koji

pripadaju različitim podskupinama. Na taj način, sudionici čije su aktivnosti povezane s elektroničkim aspektom proizvoda, jako malo sudjeluju u radu sa sudionicima zaduženim za mehanički dio proizvoda. Takva raspodjela aktivnosti upućuje na striktnu raspodjelu ekspertiza i pripadajućih zaduženja te na slabiju interakciju između sudionika različitih profesionalnih profila, a s druge se strane potiče interakcija između sudionika sličnih ili istih profila.

Sudjelovanje u timskim aktivnostima u većoj se mjeri odražava i na prirodu obrade informacije pa je stoga u dvaju sudionika veći udio procesuiranja informacija na timskoj razini nego u ostalih sudionika. Procesuiranje informacija na timskoj razini odražava se i na učestalo komuniciranje licem u lice. Zbog većeg udjela komunikacije licem u lice, moguće je identificirati voditelja tima.

Korištenjem inženjerskim softverom proveden je veći udio konceptualizacije i detaljiranja pri individualnom tehničkom radu. U sudionika koji je zabilježio veći broj administrativnih aktivnosti primjetan je veći udio korištenja uredskim softverom u usporedbi s ostalima. Ipak, povećano korištenje uredskim softverom u drugih dvoje sudionika te u triju sudionika najveći udio kategorije „ostalo“ ostavljaju pitanje korištenja resursima otvorenim.

Izrazita dominacija definicijskih razvojnih aktivnosti u pojedinih se sudionika može povezati s individualnih tehničkim radom. Naime, može se uočiti da su neke perspektive jako međusobno povezane; npr. iz rezultata se može povezati razvojna aktivnost konceptualizacija s individualnim tehničkim radom, kontekstom proizvoda te procesuiranjem informacija. Time su jedine varijabilne perspektive bile razine relevantnosti informacije, razina motivacije te način provođenja aktivnosti.

Timske su razvojne aktivnosti ravnomjernije raspoređene te je primjetan veći udio evaluacijskih i upravljačkih aktivnosti nego u individualnim razvojnim aktivnostima, što je opravdano jer se razvojne aktivnosti kao npr. donošenje odluka i planiranje uobičajeno provode kao timski rad. Pri interpretaciji udjela razvojnih aktivnosti potrebno je uzeti u obzir znatno manji ukupan broj timskih aktivnosti (u usporedbi s individualnim aktivnostima). Stoga je u sudionika u kojih se može identificirati sudjelovanje u razvojnoj aktivnosti u timskom radu potrebno uzeti vrijednosti s oprezom jer je moguće da one proizlaze iz malog broja točaka uzorkovanja.

6.2. Analiza dinamike vrijednosti indikatora u promatranom razdoblju

Nakon inicijalne analize uzorkovanja rada, može se dobiti bolja predodžba o analiziranom razvojnom timu te projektima tijekom razdoblja uzorkovanja. Nakon opisa procedura prikupljanja i preslikavanja podataka u vrijednosti indikatora (poglavlje 5.5) te provedene preliminarne analize uzorkovanja rada (poglavlje 6.1), u ovom poglavlju bit će prikazane vrijednosti pojedinačnih indikatora uz dinamiku njihovih vrijednosti. Kao što je prethodno pokazano, za prikupljanje podataka poslužila su tri pristupa: 1. uzorkovanje rada, 2. ankete i 3. integracija s korporativnim IT sustavima.

Prema prije definiranoj podjeli i redoslijedu elemenata intelektualnoga kapitala za individualnu i timsku razinu, definirana je struktura ovog poglavlja. Poslije prikaza indikatora svake pojedinačne kategorije intelektualnoga kapitala na individualnoj i timskoj razini uslijedit će kratka rasprava pojedinih vrijednosti indikatora te usporedba s drugim istraživanjima u razvoju tehničkih sustava. Također, analizom indikatora unutar iste kategorije, ali i između različitih kategorija također se mogu potvrditi prethodno postavljene veze između nematerijalnih indikatora.

Iako se rezultati prikazani u ovom poglavlju temelje na prikupljanju podataka za samo jednu organizaciju, ovakav je prikaz potreban i dovoljan za opravdavanje i djelomičnu validaciju popisa indikatora.

U nastavku poglavlja, nematerijalni su indikatori označeni prema prikazu u tablicama (Tablica 4-4 i Tablica 4-5).

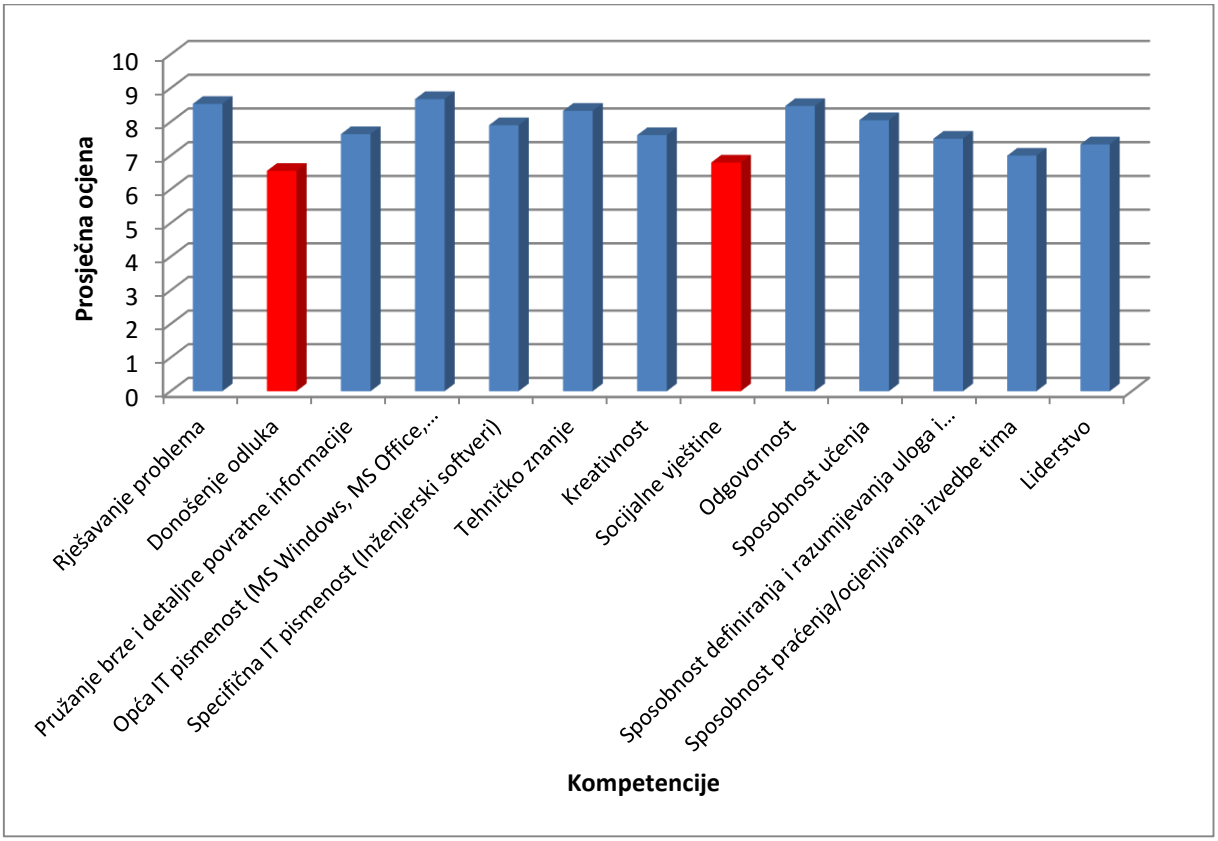
6.2.1. Indikatori izvedbe za element *kompetencije i znanje*

6.2.1.1. Individualna razina

Indikatori za element *kompetencije i znanje* označeni su u tablici (Tablica 4-4) oznakama od CK_IN1 do CK_IN14. Vrijednosti za većinu indikatora u ovoj kategoriji određene su izravnim preslikavanjem podataka prikupljenih u prvom dijelu ankete.

Pregled općih ocjena kompetencija i ocjena sudionika prikazan je na slikama (Slika 6-12 i Slika 6-13). Slika 6-12 prikazuje prosječne ocjene kompetencija, vještina i osobnih karakteristika (u nastavku će se upotrebljavati naziv *kompetencije*) ukupno za cijeli tim. Vrijednost na slici (Slika 6-12) za određenu kompetenciju označava prosječnu vrijednost ocjena svih članova tima za istu kompetenciju. Na slici (Slika 6-13) prikazan je pregled

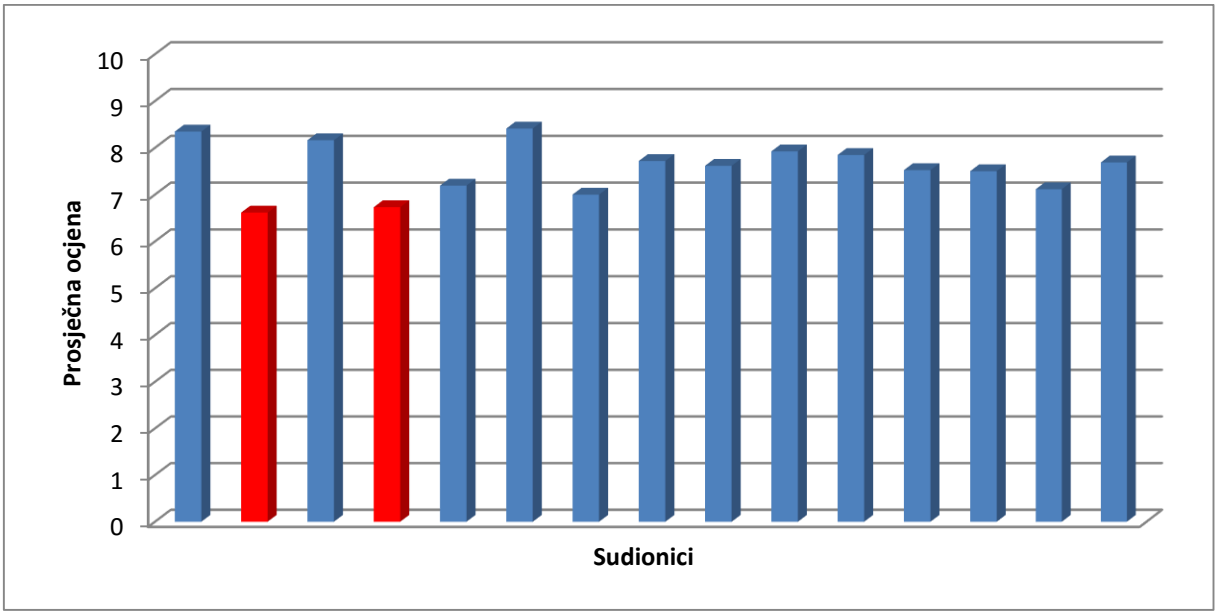
prosječnih ocjena za svakoga sudionika. Prosječna se vrijednost za svakog sudionika određuje izračunom prosječne vrijednosti ocjena svih njegovih pojedinačnih kompetencija.



Slika 6-12. Pregled prosječnih vrijednosti indikatora za pojedinu kompetenciju na razini cijelog tima

Uzimajući u obzir sve ocjene za sve kompetencije izračunata je prosječna vrijednost i standardna devijacija za cijeli skup ocjena. Pomoću tih dviju vrijednosti izračunata je donja granična vrijednost. Donja granična vrijednost definirana je kao razlika prosječne vrijednosti svih ocjena kompetencija i polovice vrijednosti standardne devijacije istog skupa. Donja granična vrijednost omogućuje identifikaciju kompetencija čije vrijednosti nisu zadovoljavajuće u kontekstu analiziranog tima te za analizirani skup ocjena iznosi 6,82. Sve vrijednosti ispod donje granične vrijednosti okarakterizirane su nezadovoljavajućim te su označene crvenom bojom. Važno je istaknuti da su indikatori CK_IN4, CK_IN5 i CK_IN6 definirani samo za voditelja odjela.

Ukupno gledajući, samo su dva sudionika ocijenjena ispod donje granične vrijednosti, iako je potrebno istaknuti da tek uvid u vrijednosti pojedinačnih indikatora sudionika daje potpunu sliku o stanju kompetencija u analiziranom timu.



Slika 6-13. Prosječne ocjena svih kompetencija za pojedinog sudionika

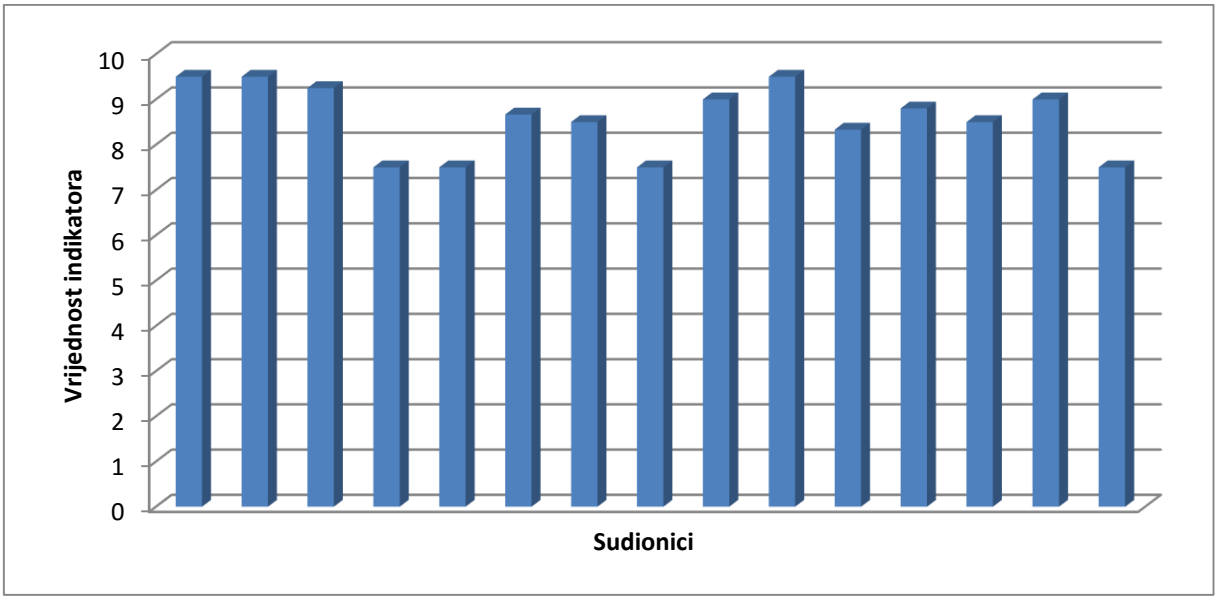
Analizirajući prvi indikator za kompetenciju *rješavanje problema*, primjetno je da nijedan sudionik nema vrijednosti indikatora ispod donje granične vrijednosti. Za ovaj indikator čak tri sudionika imaju vrijednost 9,5. Najnižu vrijednost (7,5) indikatora imaju četiri sudionika, ali su i te vrijednosti iznad donje granične vrijednosti.

S indikatorom za kompetenciju *donošenje odluka* znatno je drukčije. Naime, čak devet sudionika imaju vrijednost indikatora ispod donje granične vrijednosti. Najniža je vrijednost indikatora 5,0 (dva sudionika), a najviša je vrijednost indikatora za nekog sudionika 8,3.

Najviša je vrijednost indikatora za kompetenciju pružanje brze i detaljne povratne informacije 9,00 (dva sudionika), a najniža je vrijednost indikatora dodijeljena nekom sudioniku 5,5. Prema vrijednostima indikatora pružanje brze i detaljne povratne informacije mogu se identificirati tri sudionika čija je vrijednost indikatora okarakterizirana nezadovoljavajućom.

Vrijednosti indikatora za kompetenciju opća IT pismenost uglavnom su izrazito visoke te čak devet sudionika ima vrijednost indikatora jednaku ili višu od 9,0. Niske vrijednosti jedino su dodijeljene dvojici sudionika (5,0 i 6,8).

Vrijednosti indikatora specifična IT pismenost u prosjeku su ipak malo niže od vrijednosti indikatora za opću IT pismenost, iako i u ovom slučaju čak sedam sudionika ima vrijednost indikatora 9,0 ili višu. Sudionik, koji ima najnižu vrijednost indikatora za kompetenciju opća IT pismenost, ima i najnižu vrijednost indikatora za kompetenciju specifična IT pismenost (2,5). To je i jedina vrijednost indikatora ispod donje granične vrijednosti za *specifičnu IT pismenost*.



Slika 6-14. Primjer prikaza vrijednosti indikatora za određenu kompetenciju

Za indikator *tehničko znanje*, unutar analiziranog tima najviša je vrijednost 9,5 (tri sudionika), a najniže su vrijednosti 6,0 i 6,5. Dvije najniže vrijednosti jedine su ispod donje granične vrijednosti za indikator *tehničko znanje*.

Kreativnost je jedan od indikatora s najujednačenijim vrijednostima po sudioniku. Naime, iako četiri sudionika imaju nižu vrijednost indikatora od donje granične vrijednosti, nijedan od njih nema vrijednost ispod 6,0. S druge strane, samo se jedan sudionik ističe s vrijednosti indikatora većom od 9,0.

Socijalne vještine jedan su od dvaju indikatora čije su vrijednosti u prosjeku ispod donje granične vrijednosti (pet sudionika ispod donje granične vrijednosti). Analizirajući vrijednosti indikatora pojedinačno po sudionicima, uočava se da je najniža vrijednost 4,0. Važno je istaknuti da je čak sedam sudionika okarakterizirano s vrijednošću 7,0, što je neznatno više od donje granične vrijednosti. Samo je za dva sudionika vrijednost indikatora *socijalne vještine* visoka (8,7 i 8,5).

Odgovornost je jedan od indikatora s najvišom prosječnom vrijednošću u analiziranom timu – 8,5. Najviša vrijednost za indikator *odgovornost* iznosi 10,0, a najniža 6,0.

Najviša vrijednost indikatora za *sposobnost učenja* iznosi 9,5 (dva sudionika), a samo je za jednog sudionika vrijednost indikatora *sposobnost učenja* okarakterizirana kao nezadovoljavajuća (6,0). Prosječna vrijednost za indikator *sposobnost učenja* iznosi 8,1.

Rezultati indikatora CK_IN4, CK_IN5 i CK_IN6 koji su prikupljeni samo za voditelja odjela prikazani su u tablici (Tablica 6-4), u kojoj je vidljivo da su vrijednosti indikatora iznad donje

granične vrijednosti te su prema tom kriteriju zadovoljavajuće. Ipak, važno je istaknuti da je razlika između vrijednosti indikatora CK_IN5 i CK_IN6 te donje granične vrijednosti jako mala.

Tablica 6-4. Vrijednosti indikatora CK_IN4, CK_IN5 i CK_IN6

Oznaka	Naziv indikatora	V
CK_IN4	sposobnost definiranja i razumijevanja uloga i odgovornosti	8,0
CK_IN5	sposobnost praćenja/ocjenjivanja izvedbe tima	7,0
CK_IN6	liderstvo	7,0

6.2.1.2. Timska razina

Za potrebe ovog istraživanja vrijednosti indikatora za kategoriju *kompetencije i znanje* na timskoj razini određene su na temelju vrijednosti indikatora kategorije *kompetencije i znanje* na individualnoj razini te pomoću mjera dobivenih analizom mreža komunikacije i resursa u analiziranom timu.

Vrijednosti prvih triju indikatora (CK_TM1, CK_TM2, CK_TM3) na timskoj razini proizlaze iz vrijednosti indikatora na individualnoj razini. Preslikavanje indikatora na individualnoj razini u vrijednosti indikatora na timskoj razini zahtijeva određivanje graničnih vrijednosti kako bi se mogle odrediti kategorije kao što su *nedovoljne kompetencije* i *izvrsni članovi tima*. Nedovoljnim kompetencijama definirane su one čija je prosječna ocjena niža od već prije izračunate donje granične vrijednosti (6,8). Na isti način, izračunata je gornja granična vrijednost koja se upotrebljava za prepoznavanje izvrsnih članova tima. Gornja granična vrijednost zbroj je prosječne vrijednosti ocjena i polovice standardne devijacije izračunate na istom skupu ocjena. Gornja granična vrijednost za ovaj skup ocjena iznosi 8,3. Nakon uspostave dviju graničnih vrijednosti moguće je odrediti vrijednosti indikatora (CK_TM1, CK_TM2, CK_TM3) za analizirani tim.

Vrijednost indikatora *udio sudionika s nedovoljnim kompetencijama* broj je sudionika koji minimalno imaju jednu nezadovoljavajuću vrijednost indikatora za neku kompetenciju. Prema provedenoj analizi, 11 sudionika ima barem jednu nezadovoljavajuću vrijednost indikatora (73,3 %), a četiri sudionika nemaju vrijednost nijednog indikatora ispod donje granične vrijednosti.

Iako je relativno mala razlika između članova tima s najvišim i najnižim ukupnim prosječnim vrijednostima svih indikatora (1,8), samo dva člana tima (Tablica 6-5) imaju veću prosječnu

vrijednost od gornje granične vrijednosti te se mogu okarakterizirati izvrsnima. Iz prosječnih vrijednosti svih indikatora za svakog člana tima proizlazi vrijednost indikatora CK_TM2 koja iznosi 13,3 %.

Tablica 6-5. Vrijednosti indikatora CK_TM1, CK_TM2 i CK_TM3

Oznaka	Naziv indikatora	V	V(%)
CK_TM1	udio sudionika s nedovoljnim kompetencijama	11/15	73,3 %
CK_TM2	udio izvrsnih članova tima	2/15	13,3 %
CK_TM3	udio nezadovoljavajućih kompetencija	2/13	15,4 %

Za određivanje vrijednosti indikatora *udio nezadovoljavajućih kompetencija* korišten je prikaz na slici (Slika 6-12). Analizom ukupnih rezultata ocjenjivanja kompetencija proizlazi da su dvije vrijednosti indikatora kompetencija okarakterizirane nezadovoljavajućima: *donošenje odluka* (6,6) i *socijalne vještine* (6,8).

Za izračun vrijednosti indikatora CK_TM4 i CK_TM5 (Tablica 6-8) upotrijebljena je analiza mreža. Vrijednost indikatora CK_TM4 dobivena je analizom mreže komunikacije između sudionika (M1, poglavlje 3.4). Za određivanje društveno izoliranih članova tima (indikacija o socijalnim vještinama na timskoj razini) upotrijebljen je normalizirani broj Simmelovih veza [149]. Broj Simmelovih veza mjera je koja služi za određivanje jakih veza unutar pojedine skupine, a temelji se na trijadama [149]. Simmelova se veza može interpretirati i kao osnovni element klike. Kako bi se omogućila lakša usporedba između sudionika, upotrebljavaju se normalizirane vrijednosti koje su prikazane u tablici (Tablica 6-6). Prema dobivenim vrijednostima (sve su unutar jedne standardne devijacije), može se ustanoviti da je udio društveno izoliranih članova tima 0.

Za određivanje vrijednosti indikatora CK_TM5 upotrijebljena je mreža pristupa resursima (M3). Upotrebom mjere centralnosti stupnja pojedinog resursa u mreži pristupa resursima izračunata je vrijednost CK_TM5. Na temelju dobivenih rezultata, udio resursa koji nisu upotrijebljeni u zadovoljavajućoj mjeri također iznosi 0, jer su normalizirane vrijednosti za sve resurse unutar jedne standardne devijacije (Tablica 6-7).

Tablica 6-6. Prikaz normaliziranih vrijednosti potrebnih za određivanje indikatora *udio društveno izoliranih članova tima* (CK_TM4)

Redoslijed	Normalizirane vrijednosti
1. sudionik	0,792
2. sudionik	0,792

3. sudionik	0,833
4. sudionik	0,833
5. sudionik	0,833
6. sudionik	0,833
7. sudionik	0,875
8. sudionik	0,875
9. sudionik	0,875
10. sudionik	0,875
11. sudionik	0,917
12. sudionik	0,917
13. sudionik	0,917
14. sudionik	0,958
15. sudionik	1

Tablica 6-7. Prikaz normaliziranih vrijednosti potrebnih za određivanje indikatora *udio resursa koji nisu upotrijebljeni u zadovoljavajućoj mjeri* (CK_TM5)

Redoslijed	Resurs	Normalizirane vrijednosti
1	PDM/PLM	0,001
2	ERP	0,002
3	telefon	0,003
4	ostalo administrativno	0,006
5	videokonferencija	0,006

Tablica 6-8.Vrijednosti indikatora CK_TM4 i CK_TM5

Oznaka	Naziv indikatora	V	V (%)
CK_TM4	udio društveno izoliranih članova tima	0/15	0 %
CK_TM5	udio resursa koji nisu upotrijebljeni u zadovoljavajućoj mjeri	0	0 %

6.2.1.3. Rasprava o rezultatima za element kompetencije i znanje

Vrijednosti indikatora na individualnoj i timskoj razini upućuju na općenito stanje kompetencija unutar tima. Velik broj članova tima s barem jednom nedovoljno ocijenjenom kompetencijom upućuje na to da je pojedinim sudionicima potrebno daljnje usavršavanje i podizanje kompetencija. Iz analize nezadovoljavajućih kompetencija može se prepoznati da je potrebno istaknuti podizanje sljedećih kompetencija: *donošenje odluka* i *socijalne vještine*. Visoke vrijednosti indikatora za kompetencije *rješavanje problema* i *tehničko znanje*, ali i dovoljna razina *kreativnosti* dobri su preduvjeti za inovativnost i stvaranja inovativnih rješenja. S obzirom na učestalost korištenja uredskim i inženjerskim softverima, veoma su važne visoko ocijenjene kompetencije *opća* i *specifična IT pismenost*. Kao preduvjet za daljnji razvoj kompetencija ohrabruju visoke vrijednosti indikatora *odgovornost* i *socijalne vještine.*

Rješavanje problema jedina je kompetencija za koju ni jedan sudionik nema vrijednost indikatora ispod donje granične vrijednosti, a za kompetencije *IT pismenosti* samo jedan sudionik ima nezadovoljavajuću vrijednost indikatora. Uvid u vrijednosti indikatora *donošenje odluka* za pojedinca upozoravaju na nisku razinu spomenute kompetencije, što svakako zahtijeva daljnju razradu te analizu. Vrijednosti indikatora *socijalne vještine* za sve sudionike upozoravaju na njihovu nižu razinu u usporedbi s vrijednostima ostalih indikatora, što se može povezati i s manjim udjelom timskih aktivnosti, ali i sa nižom motivacijom tijekom timskog rada. Zanimljivo je uočiti da vrijednosti indikatora *broj društveno izoliranih članova tima* na timskoj razini nisu u skladu s kompetencijom *socijalne vještine*. Iako su vrijednosti indikatora *tehničko znanje* među najvišima s obzirom na profesionalne profile i iskustvo sudionika, uočljivo je da su najniže ocijenjeni inženjeri s kratkim radnim stažem. Za indikatore CK_IN4, CK_IN5 i CK_IN6, koji se odnose samo na voditelja odjela, trebalo bi razmotriti mogućnost prikupljanja podataka i za ostale članove tima radi prepoznavanja potencijala za vođenje skupine.

Zanimljivo je primijetiti da sudionik koji ima najniže vrijednosti indikatora u timu za kompetencije IT pismenosti, ima najviše vrijednosti indikatora (od svih članova tima) za kompetencije *tehničko znanje* i *rješavanje problema*. Upravo paralelnim pregledom većeg broja kompetencija može se ustanoviti da pojedini sudionici imaju izrazito različite vrijednosti indikatora za različite kompetencije, ali i povezanost između pojedinih kompetencija. Pojedini članovi tima imaju iznimno visoku razinu pojedinih kompetencija te istodobno niže vrijednosti indikatora za druge kompetencije.

S obzirom na relativno mali broj ocjena za svakog sudionika na temelju kojih su izračunate vrijednosti indikatora, potrebno je uzeti u obzir način ocjenjivanja. Uočljivo je da su se pojedini sudionici koristili cijelom skalom vrijednosti (od 1 do 10), a u pojedinih je sudionika prisutno samo ocjenjivanje na gornjem dijelu skale (od 7 do 10). Korištenjem isključivo gornjim dijelom skale pri ocjenjivanju kompetencija raspodjela ocjena pomaknuta je udesno te je relativno visoka donja granična vrijednost (6,8). Budući da je raspodjela ocjena znatno pomaknuta udesno, opravdano je korištenje skalom od 1 do 10 koje je omogućilo finije ocjenjivanje kompetencija. Također, s obzirom na osjetljivost tematike ocjenjivanja, bilo je očekivano korištenje gornjim dijelom skale i nekorištenje niskim ocjenama. S druge strane, moguće je da pojedine niže ocjene kompetencija proizlaze upravo iz manjeg broja ocjena kompetencija po sudioniku te percepcije malog broja sudionika koji su izrazito niskom ocjenom znatno smanjili prosječnu ocjenu kompetencije određenom članu tima.

Posljednji korišteni indikator dobiven analizom mreže jest *udio resursa koji nisu upotrijebljeni u zadovoljavajućoj mjeri*. Indikator CI_TM5 koji nam govori o korištenju, odnosno nekorištenju pojedinim resursima tijekom razvojnih aktivnosti upozorava da su svi ponuđeni načini provođenja aktivnosti korišteni, čak i tijekom ovog kratkog razdoblja uzorkovanja. Manja uporaba ERP-a i PDM-a može se objasniti neostvarivanjem implementacije koja bi omogućila svim sudionicima pristup, a manje korištenje telefonom i učestalo komuniciranje licem u lice razumljivo je s obzirom na zajedničku lokaciju.

Iako vrijednosti indikatora ovog elementa IK-a daju dobru predodžbu o stanju kompetencija u timu, potrebno je navesti pojedine nedostatke indikatora na timskoj razini. Jedan je od nedostataka indikatora u kategoriji *kompetencije i znanje* na timskoj razini nepostojanje indikatora koji je vezan za timske kompetencije (npr. [222]). Naime, određivanje vrijednosti indikatora timske razine temeljeno na vrijednostima indikatora individualne razine ima određene nedostatke. Srednja vrijednost može upozoravati na „prosječnog“ člana tima, iako pojedini član tima može biti jedini koji ima određenu kompetenciju. Indikatori timske razine agregiraju vrijednosti indikatora individualne razine i stoga se vrijednosti CK_TM1 i CK_TM2 mogu razmatrati kao orijentacijske, ali nipošto ne kao odlučujuće.

Upravo iz tih razloga, ideja indikatora na individualnoj razini daje detaljniju sliku i bolji uvid u prednosti i nedostatke pojedinog člana tima. Praćenjem indikatora kategorije *kompetencije i znanje* na individualnoj razini omogućuje se identifikacija članova tima s izrazito visokim razinama pojedinih kompetencija te članova tima s izrazito niskim razinama kompetencija. Informacije o visokim i niskim razinama kompetencija za pojedine članove zatim omogućuju ciljano unapređenje kompetencija ovisno o potrebi, ali i bolji sastav timova s različitim komplementarnim kompetencijama. Nadalje, dostupnost pojedinih kompetencija u timu utječe na manju potrebu za njihovim razvojem u sudionika koji imaju niže vrijednosti indikatora za pojedine kompetencije. Ako pojedini sudionik ima nisko ocijenjenu kompetenciju koja je općenito visoko ocijenjena u timu, moguće je da nema potrebe za unapređenjem razine kompetencije za navedenog sudionika. Stoga je uputno paralelno pratiti indikatore na individualnoj i na timskoj razini jer se dobivene informacije međusobno nadopunjuju i daju potpuniju sliku elementa *kompetencije i znanje*. Time se voditelju tima omogućuje upravljanje timom ovisno o rasporedu i dostupnosti pojedinih kompetencija u njemu.

Osvrtom na provođenje analize, važno je napomenuti ulogu standardne devijacije za određivanje graničnih vrijednosti. Ipak, vrijednosti dobivene upotrebom standardne devijacije

potrebno je uzeti s oprezom. Definiranje „krutih“ graničnih vrijednosti može pridonijeti pogrešnim zaključcima jer su dobivene vrijednosti odvojene od konteksta. Ipak, pristup sa standardnom devijacijom omogućuje definiranje granica za različite skupove podataka i ostavlja mogućnost usporedbe s drugim budućim istraživanjima.

Uspoređujući dobivene vrijednosti unutar elementa *kompetencije i znanje* s rezultatima istraživanja koje su proveli Durackova i dr. [223], mogu se uočiti neke razlike u vrijednostima indikatora kompetencija. Durackova i dr. [223] poslužili su se ocjenama kompetencija kao jednim od ključnih indikatora izvedbe pri analizi izvedbe organizacije čije područje djelovanja obuhvaća razvoj tehničkih sustava.

Iako je u njihovu istraživanju upotrijebljena skala od samo tri razine, mogu se uočiti sličnosti i razlike između vrijednosti indikatora. Očito je podudaranje rezultata iz *opće IT pismenosti* i *rješavanja problema* koji su u oba slučaja najbolje ocijenjene kompetencije. Može se uočiti da su rezultati kompetencija *donošenje odluka* i *socijalnih vještina* osjetno viši nego u ovdje opisanom slučaju. *Tehničko znanje* ne može se usporediti u ova dva istraživanja jer je u istraživanju Durackove i dr. [223] ta kompetencija razložena na segmente. Ipak, promatrajući agregirane rezultate, očito je da je razina *tehničkog znanja* znatno niže ocijenjena nego u ovdje prikazanoj analizi. Temeljeno na nekoliko studija slučaja koje su Coates i dr. [224] proveli u proizvodnim organizacijama, dobivene su ocjene kompetencija za pojedina područja *tehničkog znanja*. Na isti način, kao i u prethodnoj usporedbi, *tehničko znanje* u njihovu je istraživanju općenito lošije ocijenjeno. U oba su spomenuta istraživanja niže ocjene *tehničkog znanja* logične jer ocjenjivanje *tehničkog znanja* razloženo na segmente može bolje upozoriti na pojedine nedostatke kompetencija, nego agregirana vrijednost. Stoga je potrebno razmotriti proširenje popisa indikatora za kategoriju *kompetencije i znanje* na individualnoj razini s kompetencijama kao što su npr. *analitičko razmišljanje* i *sklonost detaljima*, ali i *analiza tržišta i troškova*.

6.2.2. Indikatori izvedbe za element *komunikacija i razmjena informacija*

6.2.2.1. Individualna razina

Izuzevši četiri indikatora (CI_IN1, CI_IN2, CI_IN14, CI_IN15) za koje je predviđeno prikupljanje podataka korištenjem korporativnim informacijskim sustavima, za ostalih jedanaest indikatora ove kategorije podaci su prikupljeni uzorkovanjem. Iz prikupljenih podataka inicijalno je izračunat udio vremena u izvođenju određenog tipa aktivnosti (individualni administrativni rad, individualni tehnički rad, timski rad). Timski rad dodatno je

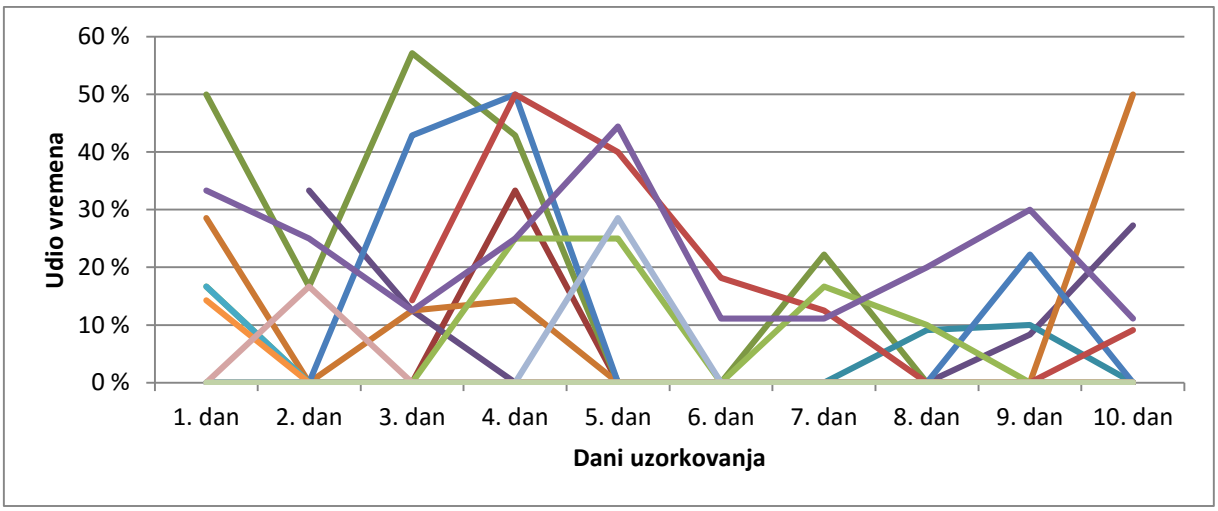
razložen na potkategorije *diskusija*, *sastanaka* i *sastanaka tima*. Tako se može odrediti udio vremena utrošenog na *rasprave*, *sastanke* i *sastanke tima*, odnosno vrijednosti indikatora CI_IN3, CI_IN4 i CI_IN5.

Na slici (Slika 6-15.a, 15.b, i 15.c) prikazana je promjena vrijednosti indikatora CI_IN3, CI_IN4 i CI_IN5 za svih 15 sudionika. Iz prikaza se mogu iščitati velike oscilacije u vrijednostima indikatora. Analizirajući promjenu vrijednosti indikatora CI_IN3, može se uočiti da samo jedan sudionik ima svakodnevne diskusije tijekom cijelog razdoblja uzorkovanja. Potrebno je također izdvojiti da su tri sudionika češće od ostalih sudjelovali u diskusijama. S druge strane, neki sudionici (njih 5) su samo 1 dan zabilježili diskusije kao tip timskog rada, a dva sudionika nemaju ni jedan takav zapis.

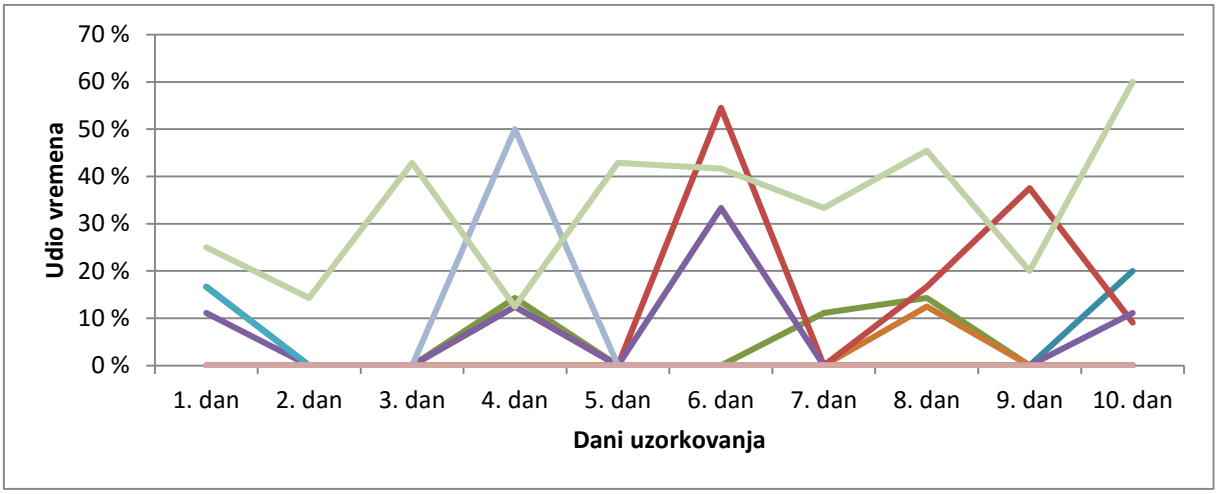
Analizirajući promjenu vrijednosti indikatora CI_IN4, može se uočiti kako dva sudionika imaju znatno veći udio sastanaka od ostalih, pri čemu je samo jedan od njih svakodnevno sudjelovao na sastancima. Dvoje sudionika sudjelovali su na sastancima malo manje, a ostali samo jedan dan (7 sudionika) ili nisu sudjelovali uopće (4 sudionika).

Tijekom uzorkovanja, samo tri sudionika zabilježila su sudjelovanje na *sastancima tima* (CI_IN5), pri čemu jedan od njih znatno prednjači u ovom tipu timskog rada (zapisi za čak 5 dana). Preostali sudionici nisu uopće sudjelovali u *sastancima tima* ili imaju zapise o takvu tipu aktivnosti samo za jedan dan (2 sudionika).

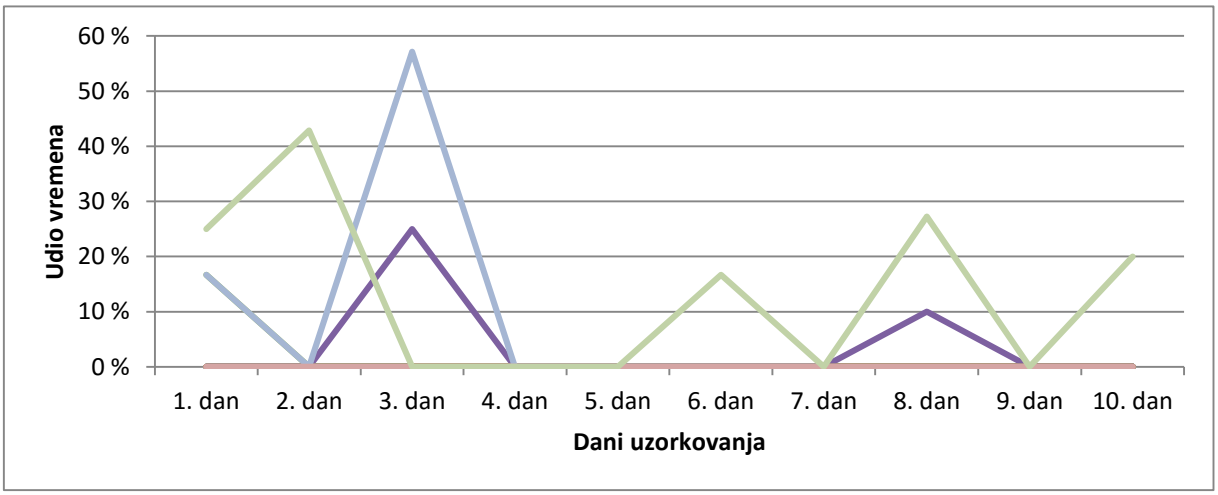
Na slici (Slika 6-16) prikazana je promjena vrijednosti indikatora koji se odnose na udjele vremena koje sudionici troše na *davanje, primanje* i *razmjenu informacija*.



a) ***Udio vremena utrošen na rasprave*** **(CI_IN3)**



b) ***Udio vremena utrošen na formalne sastanke*** **(CI_IN4)**



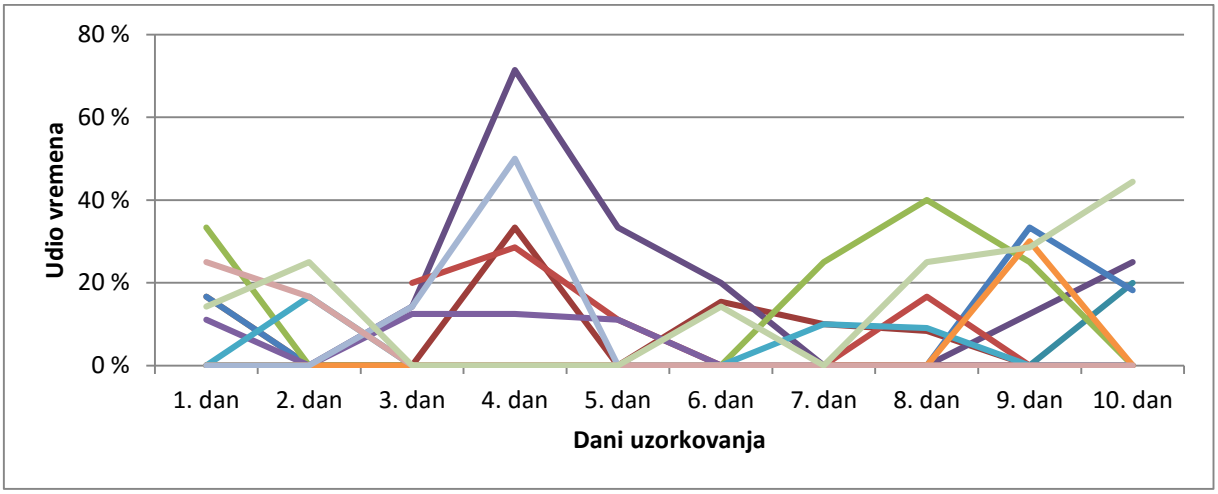
c) ***Udio vremena utrošen na sastanke tima*** **(CI_IN5)**

Slika 6-15. Promjena vrijednosti indikatora CI_IN3, CI_IN4 i CI_IN5

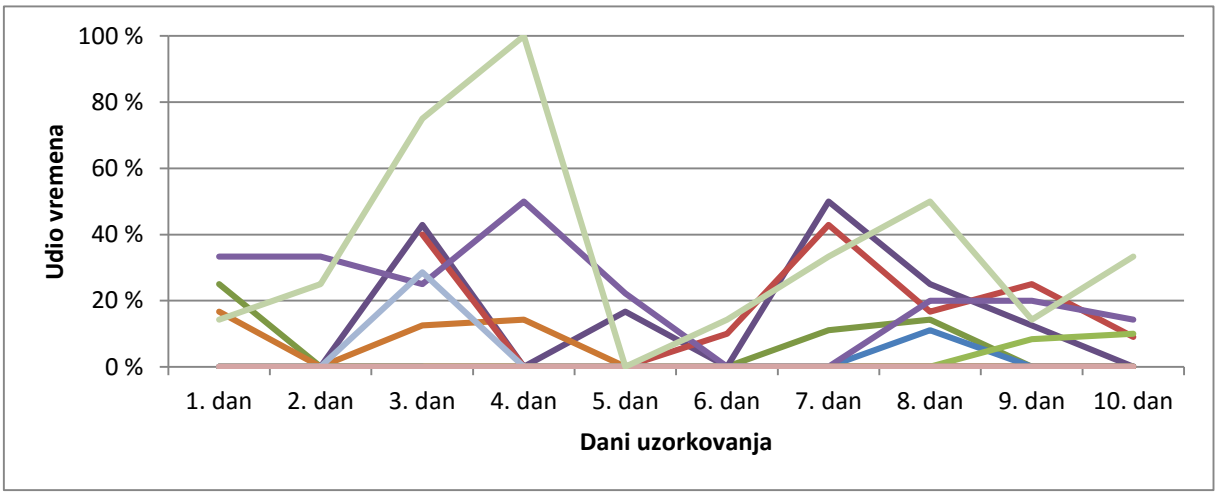
Analizom indikatora CI_IN6 ustanovljeno je da u zapisima triju sudionika prevladava *primanje informacija* najveći broj dana. S druge strane, jedan sudionik nije zabilježio nijednu takvu prirodu obrade informacije.

Nadalje, iz vrijednosti indikatora CI_IN9 može se vidjeti koji sudionici dominiraju u *davanju informacije* (CI_IN9). U ovom se dijelu najviše ističu četiri sudionika koji imaju zapise o ovakvoj prirode obrade informacija za najmanje pet dana tijekom promatranog razdoblja. U pet sudionika nije zabilježena ni jedna takva obrada informacije.

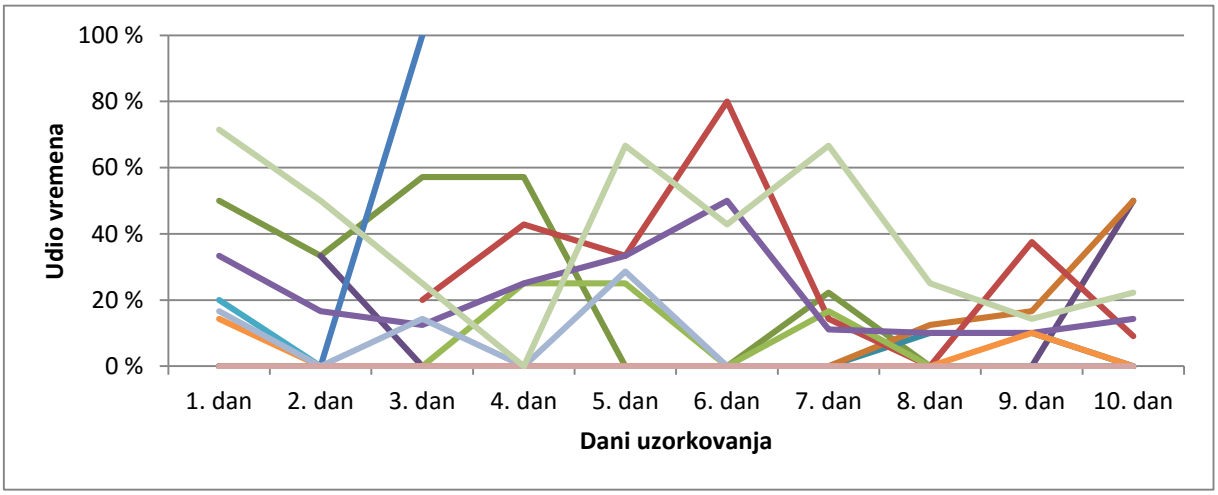
Promjena vrijednosti indikatora CI_IN12 upućuje na gotovo svakodnevnu (9/10 dana) razmjenu informacije u dvaju sudionika. *Izmjena informacija* malo je manja u drugih dvoje sudionika (5/10 dana), a dva sudionika nisu zabilježila nijednu takvu prirodu obrade informacije. Preostali su sudionici zabilježili *izmjenu informacija* samo 2 ili 3 dana tijekom razdoblja promatranja.



a) ***Udio vremena utrošen na primanje informacije*** **(CI_IN6)**



b) ***Udio vremena utrošen na davanje informacije*** **(CI_IN9)**



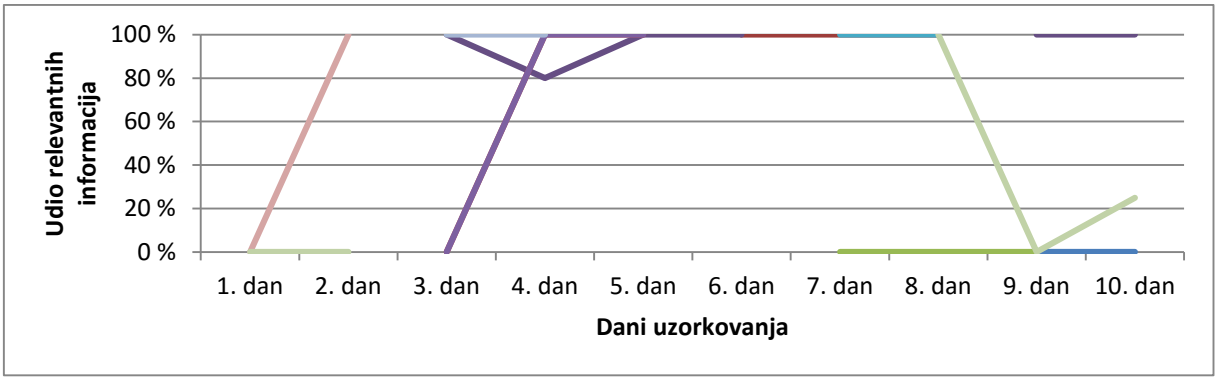
c) ***Udio vremena utrošen na izmjenu informacija*** **(CI_IN12)**

Slika 6-16. Promjena vrijednosti indikatora CI_IN6, CI_IN9 i CI_IN12

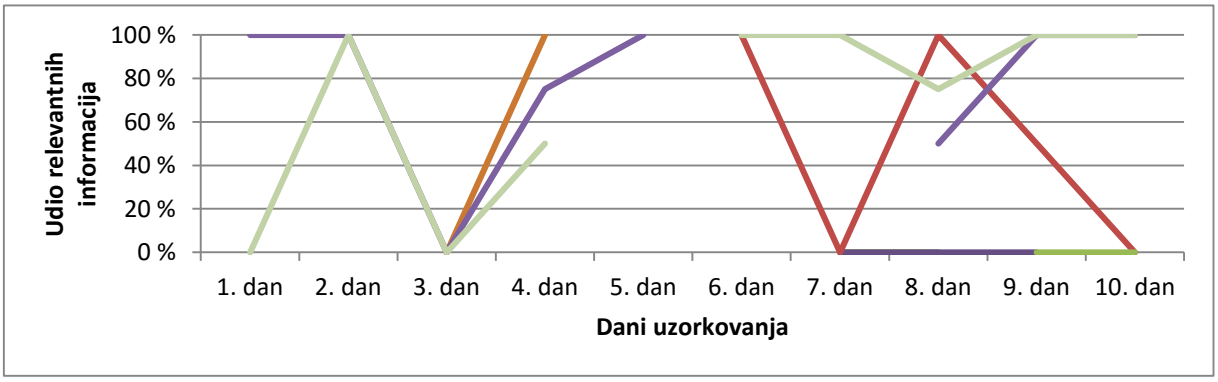
Udio relevantnih poslanih, primljenih i izmijenjenih informacija (indikatori CI_IN7, CI_IN10 i CI_IN13) prikazan je na slici (Slika 6-17). Na isti način kao i za prethodni element IK-a, *kompetencije i znanje*, definirana je granična vrijednost indikatora. Granična vrijednost koja

se upotrebljava za određivanje relevantnih poslanih i primljenih informacija iznosi 3,62 (M = 4,13; STD = 1,01). Sve obrade informacije s relevantnošću informacije nižom od te vrijednosti smatraju se manje relevantnim, a za obrade s vrijednostima relevantnosti višima od granične vrijednosti vrijedi suprotno.

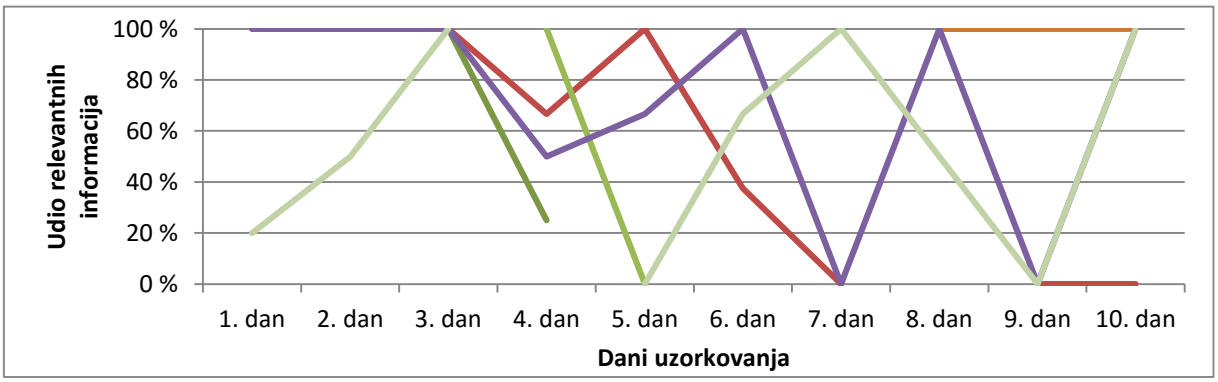
Iz prikaza na slici (Slika 6-17) teško je donijeti čvrste zaključke zbog malog broja zapisa po pojedinom sudioniku te kratkog razdoblja uzorkovanja. Ipak, primjetno je (vidi CI_IN13) da su pojedinih dana sudionici ocjenjivali relevantnost jako nisko, a katkad je udio visokoocijenjenih relevantnih informacija (neovisno o prirodi obrade) 100 % po danu.



a) ***Udio relevantnih primljenih informacija*** **(CI_IN7)**



b) ***Udio relevantnih poslanih informacija*** **(CI_IN10)**



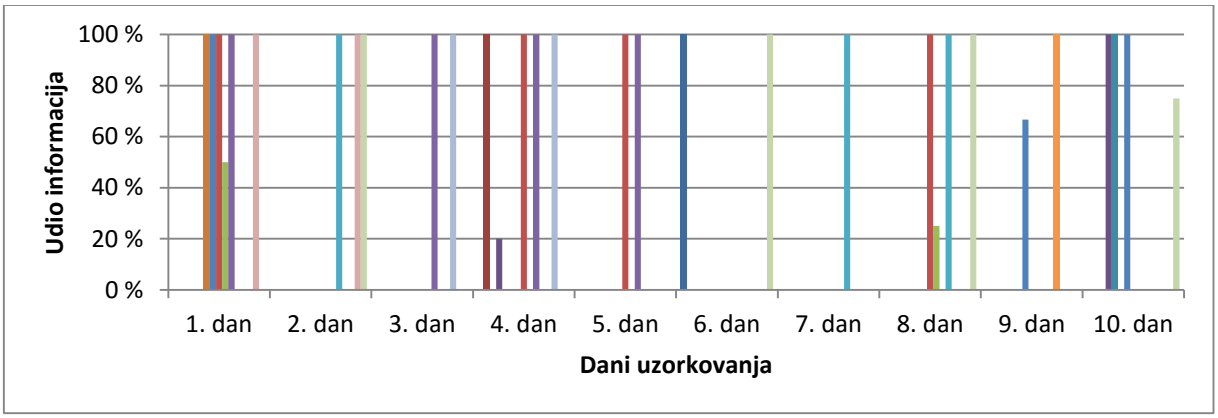
c) ***Udio relevantnih izmijenjenih informacija*** **(CI_IN13)**

Slika 6-17. Promjena vrijednosti indikatora CI_IN7, CI_IN10 i CI_IN13

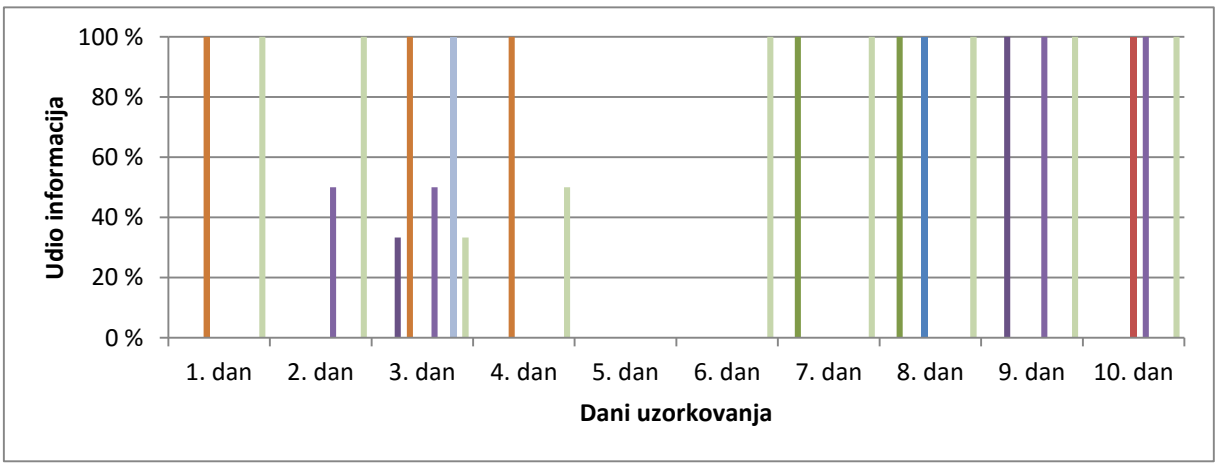
Preostali indikatori čija je vrijednost dobivena na temelju podataka prikupljenih uzorkovanjem odnose se na način izvođenja informacijski intenzivnih aktivnosti u smislu davanja i primanja informacija licem u lice (CI_IN8 i CI_IN11), što je prepoznato kao glavni način za izmjenu informacija tijekom promatranog razdoblja (Slika 6-18).

Analizom vrijednosti indikatora *udjela informacija primljenih licem u lice* (CI_IN8) u pojedinih se sudionika uočavaju i drugi načini komunikacije za primanje informacija, što se posebno odnosi na četiri sudionika. Naime, u tih je sudionika uočljiv manji udio primanja informacija licem u lice nego u ostalih sudionika. Ostali su sudionici primali informacije isključivo licem u lice ili su drukčiji način komunikacije zabilježili samo jedan dan.

U četiriju sudionika primjetan je manji udio *davanja informacija licem u lice*, a u jednog je sudionika ovakav način komunikacije pri davanju informacije najčešći (čak sedam dana 100 % predanih informacija licem u lice).



a) *Udio informacija primljenih licem u lice* (CI_IN8)



b) *Udio informacija poslanih licem u lice* (CI_IN11)

Slika 6-18. Promjena vrijednosti indikatora CI_IN8 i CI_IN11

6.2.2.2. Timska razina

Podaci za određivanje vrijednosti indikatora elementa IK-a *komunikacija i razmjena informacija* na timskoj razini prikupljeni su uglavnom na temelju odgovora iz drugog dijela ankete. Vrijednosti pojedinih indikatora prikazane su u tablici (Tablica 6-9) s pripadajućim rednim oznakama, prosječnim vrijednostima i vrijednostima standardne devijacije.

Tablica 6-9. Vrijednosti indikatora iz kategorije *komunikacija i razmjena informacija* na timskoj razini

Oznaka	Naziv indikatora	V	STD
CI_TM1	U kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od internih izvora	3,7	0,48
CI_TM2	U kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od vanjskih (eksternih) izvora	3,3	0,67
CI_TM3	U kolikoj mjeri se znanje pohranjuje u internim bazama podataka?	3,1	1,10
CI_TM4	U kolikoj mjeri se članovi tima osjećaju ugodno dok koriste već postojeća rješenja	4,1	0,57
CI_TM5	U kolikoj mjeri se članovi tima osjećaju motivirano da dijele znanje s drugim članovima tima	3,8	0,74
CI_TM6	U kolikoj mjeri članovi tima smatraju da sudjelovanje u timskim aktivnostima stvara iskustvo te rezultira novim rješenjima	3,9	0,67
CI_TM7	U kolikoj mjeri se članovi tima osjećaju ugodno dijeleći znanje s drugim članovima tima	4,0	0,63
CI_TM8	U kolikoj mjeri članovi tima smatraju da je jednostavno naći kolege s potrebnim kompetencijama	3,7	0,67
CI_TM9	U kolikoj mjeri članovi tima smatraju da su interne baze podataka jednostavne za korištenje	3,3	1,05
CI_TM10	Učestalost obavještavanja o novim unosima i rješenjima u internim bazama podataka	3,0	0,85

Donja granična vrijednost nije definirana zasebno za svaki indikator, već je izračunata za skup svih podataka u drugom dijelu ankete, kako bi se uzeo u obzir način ocjenjivanja i interpretacija numeričkih odgovora. Dakle, za skup svih ocjena iz drugog dijela ankete, donja granična vrijednost je definirana kao razlika prosječne vrijednosti svih ocjena i polovice vrijednosti standardne devijacije. Budući da je raspodjela ocjena iz drugog dijela ankete pomaknuta udesno (kao i u kompetencija), donja je granična vrijednost za podatke prikupljene u drugom dijelu ankete 3,07. Jedini indikator kojem je vrijednost ispod donje granične vrijednosti jest CI_TM10 vezan za učestalost obavještavanja o novim unosima i rješenjima u internim bazama podataka.

Iz ove analize proizlazi da se ispitanici rjeđe služe *vanjskim izvorima informacija* nego *izvorima unutar tvrtke*. Ipak, iz njihovih odgovora proizlazi da se interne baze znanja smatraju slabije pristupačnima te da nisu jednostavne za uporabu. Također, smatraju da se znanje ne pohranjuje često u interne baze te da nisu dovoljno informirani o novim unosima i rješenjima koja se pohranjuju.

Vrijednosti posljednjih dvaju indikatora određene su korištenjem podacima prikupljenim uzorkovanjem rada. Rezultati za indikatore CI_TM11 i CI_TM12 izračunati su na temelju mreže komunikacije (M1, poglavlje 3.4) između sudionika uzorkovanih aktivnosti (Tablica 6-10). Za potrebe indikatora određivala se težina veza koja je dobivena pomoću broja zajedničkih aktivnosti između dvaju ili više sudionika tijekom razdoblja uzorkovanja. Koristeći se istim principom izračuna gornje i donje granične vrijednosti kao u drugim kategorijama (M = 3,41; STD = 3,62), određene su njihove vrijednosti koje su primijenjene na broj zajedničkih aktivnosti. Veze, čija je težina iznad gornje granične vrijednosti, okarakterizirane su jakima, a one čija je težina ispod donje granične vrijednosti slabima.

Tablica 6-10. Prikaz vrijednosti indikatora CI_TM11 i CI_TM12

Oznaka	**Naziv indikatora**	**V (%)**
CI_TM11	udio slabih komunikacijskih veza	8,16 %
CI_TM12	udio jakih komunikacijskih veza	16,31 %

6.2.2.3. Rasprava o rezultatima za element komunikacija i razmjena informacija

Iz dnevne dinamike vrijednosti indikatora za pojedine sudionike može se iščitati raspodjela timskih aktivnosti za promatrano razdoblje. Na primjer, voditelj tima ističe se redovitim sudjelovanjem u timskim sastancima te u formalnim sastancima, za razliku od većine ostalih sudionika koji pretežito sudjeluju u diskusijama.

Kao što je već prije naznačeno, udio timskih aktivnosti bio je relativno malen tijekom razdoblja uzorkovanja. Većina provedenih timskih aktivnosti bile su diskusije zbog zajedničke lokacije sudionika, no nekoliko je sudionika zabilježilo sudjelovanje u samo jednoj diskusiji tijekom dva tjedna uzorkovanja. Potrebno je napomenuti da isti sudionici tijekom dva tjedna nisu sudjelovali ni u sastancima tima ni u formalnim sastancima, pa se može zaključiti da su bili prilično izolirani tijekom razdoblja promatranja, iako prema indikatoru CK_TM4 nema društveno izoliranih članova.

S obzirom na kasnije faze projekata koje su bile obuhvaćene ovom studijom slučaja, moguće je da su zadaće sudionika bile jasno definirane te da nije bilo potrebe za timskim radom. Ukupno gledajući, jedan je sudionik zabilježio sve tipove timskih aktivnosti, pri čemu se ističu svakodnevne rasprave. Ovakav profil sudionika upućuje na njegovu učestalu razmjenu informacije (jednosmjernu ili dvosmjernu) te dobru povezanost s ostalim članovima tima. Indikator CK_TM4 (*broj društveno izoliranih članova tima*) na neki način ujedinjuje različite tipove timskog rada te nam vrijednosti indikatora CI_IN3 (*udio vremena utrošen na diskusije*), CI_IN4 (*udio vremena utrošen na formalne sastanke*) i CI_IN5 (*udio vremena utrošen na sastanke tima*) mogu poslužiti kao potvrda za CK_TM4.

Ipak, jedan od sudionika ističe se niskim brojem Simmelovih veza (za određivanje CK_TM4), unatoč učestalim raspravama i sastancima. Budući da se trijade navedenog sudionika ne razlikuju od trijada ostalih sudionika (nema kontakta ni s jednim eksternim sudionikom), njegove su vrijednosti Simmelovih veza niže.

Poslije analize prikupljenih podataka ustanovljeno je da indikatori vezani za relevantnost informacije pri pojedinim prirodama obrade informacije ne daju dovoljno dobru povratnu informaciju voditelju projekta. Ovakav se zaključak nameće iz nekoliko razloga. Zbog malog broja točaka uzorkovanja za određenu prirodu obrade informacije tijekom jednog dana, ne mogu se dobiti statistički valjani zaključci. Dakle, u daljnjem tijeku istraživanja potrebno je preformulirati predložene indikatore ili ih ukloniti s dosadašnjeg popisa. Također, potrebno je razmotriti mogućnost primjene indikatora relevantnosti informacije na timskoj razini, kako bi se vrijednosti pratile kumulativno za cijeli tim. Veći broj točaka koji bi pritom bio obuhvaćen omogućio bi svakodnevno praćenje relevantnosti informacije.

Indikatori CI_IN8 (*udio informacija primljenih licem u lice*) i CI_IN11 (*udio informacija poslanih licem u lice*) upućuju na to da su u velikoj većini jednosmjerne izmjene informacija provedene komunikacijom licem u lice. S obzirom na zajedničku lokaciju sudionika tima, ovaj indikator ne daje dodatnu vrijednost u provedenom uzorkovanju, nego samo raščlanjuje već otprije poznate podatke. U projektima u kojima sudjeluje više vanjskih sudionika te u geografski raspršenim projektima ovi bi indikatori mogli pridonijeti boljem razumijevanju komunikacije i načina rada sudionika.

Vrijednosti indikatora na timskoj razini pobliže objašnjavaju kontekst i okruženje iz perspektive *komunikacije i razmjene informacija*. Članovi tima češće se služe znanjem (rješenjima) od internih izvora (CI_TM1) nego od eksternih izvora iz nekoliko razloga. Prvi je

razlog pristupačnost i dostupnost internih izvora – kolega ili korporativnih baza podataka. Sljedeći je visoka razina kompetencija *tehničko znanje* i *rješavanje problema* prema rezultatima dobivenim za CK_IN1 i CK_IN10. Također, sudionici se osjećaju ugodno dijeleći znanje s drugim članovima tima (CI_TM7) te malo manje motivirano (CI_TM5). Nadalje, članovi tima koriste se internim izvorima jer se tako može i uštedjeti vrijeme [225]. U suprotnom, član tima mora sam pretraživati druge izvore informacija i znanja unutar i izvan organizacije. Za tip znanja i informacija koje su vezane za kontekst razvojnog procesa ili organizacije, kolege su najčešći izvor jer često nema propisanog i službenog načina za dokumentaciju takvih informacija i znanja [226]. Rezultati dobiveni u ovoj studiji u skladu su s prijašnjim istraživanjima poput onog Allarda i dr. [194] prema kojem se sudionici češće koriste znanjem od internih izvora kao što su kolege, repozitoriji dokumenata ili postojeća tehnička dokumentacija u usporedbi s eksternim izvorima.

Ipak, budući da indikator CI_TM1 (U kolikoj mjeri članovi tima ponovno koriste znanje (rješenja) od internih izvora) ima vrijednost 3,7, očito je da postoje negativne strane tog aspekta te razlozi zašto se sudionici češće ne služe internim izvorima. Naime, sudionici su dodijelili najniže vrijednosti indikatorima vezanim za pohranu podataka u interne baze podataka te za učestalost informiranja o novim unosima i rješenjima u interne baze podataka. Smatraju i da interne baze podataka nisu jednostavne za uporabu. Očito je da indikatori koji su vezani za interne baze podataka imaju najniže vrijednosti i da u ovom dijelu ima još mjesta za napredak.

Indikator CI_TM4 vezan je za ponovno korištenje postojećim rješenjima te je najviše ocijenjen od svih indikatora iz ove kategorije. Iz perspektive *inovativnosti i ideacije,* ovaj rezultat može upozoriti na nedostatak potrebe i želje za pronalaskom novih ideja i rješenja, što je u skladu s prethodno analiziranim rezultatima uzorkovanja koji upućuju na rjeđe ideacijske aktivnosti, pogotovo individualne.

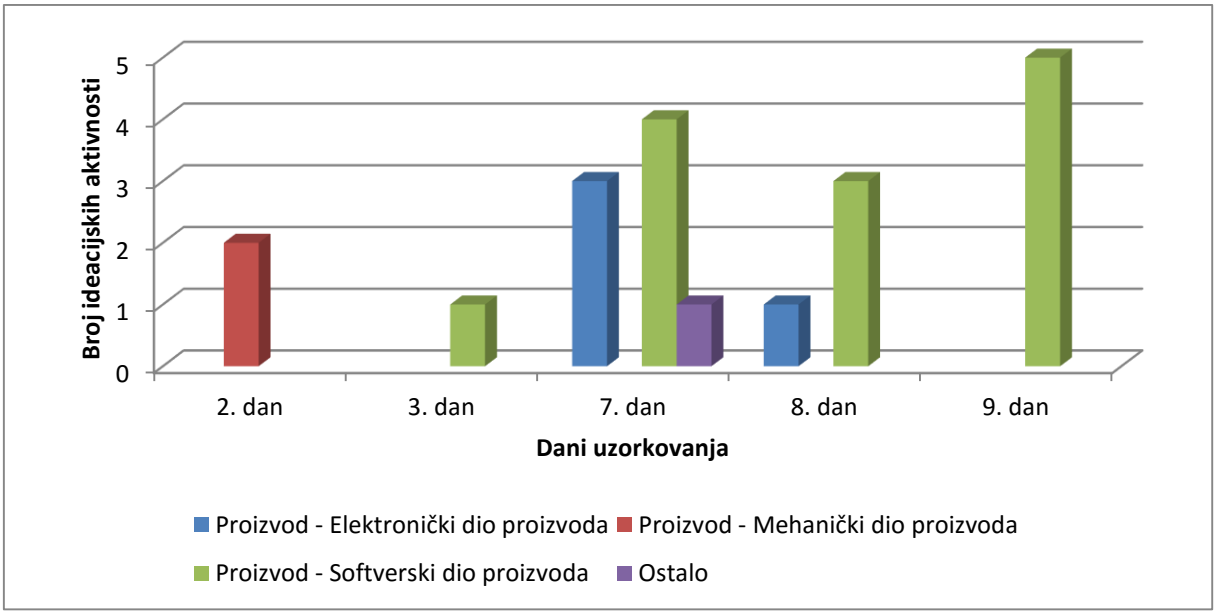
Posljednja dva indikatora, CI_TM11 i CI_TM12, koji govore o jačini pojedinih veza između sudionika na temelju njihove učestalosti, upućuju na mali udio slabih komunikacijskih veza (8,2 %) te malo veći udio jakih komunikacijskih veza (16,3 %) u cijelom timu. Budući da je razdoblje uzorkovanja trajalo samo dva tjedna, potrebna je daljnja analiza veza koje su okarakterizirane na jedan, odnosno drugi način. Detaljnija bi analiza omogućila objašnjenje održavanja pojedinih veza, ali i uputila na moguće potrebe za uspostavljanje trenutačno nepostojećih veza.

6.2.3. Indikatori izvedbe za element *inovativnost i ideacija*

6.2.3.1. Individualna razina

Uzorkovanje rada poslužilo je kao jedini izvor podataka za vrijednosti indikatora iz kategorije *inovativnost i ideacija* na individualnoj razini. Na temelju analize upitnika u kojima su sudionici zabilježili opciju *inovativne (ideacijske) aktivnosti* na izborniku aplikacije *vrsta aktivnosti iz perspektive razvoja proizvoda*, dobivene su vrijednosti potrebne za ove indikatore.

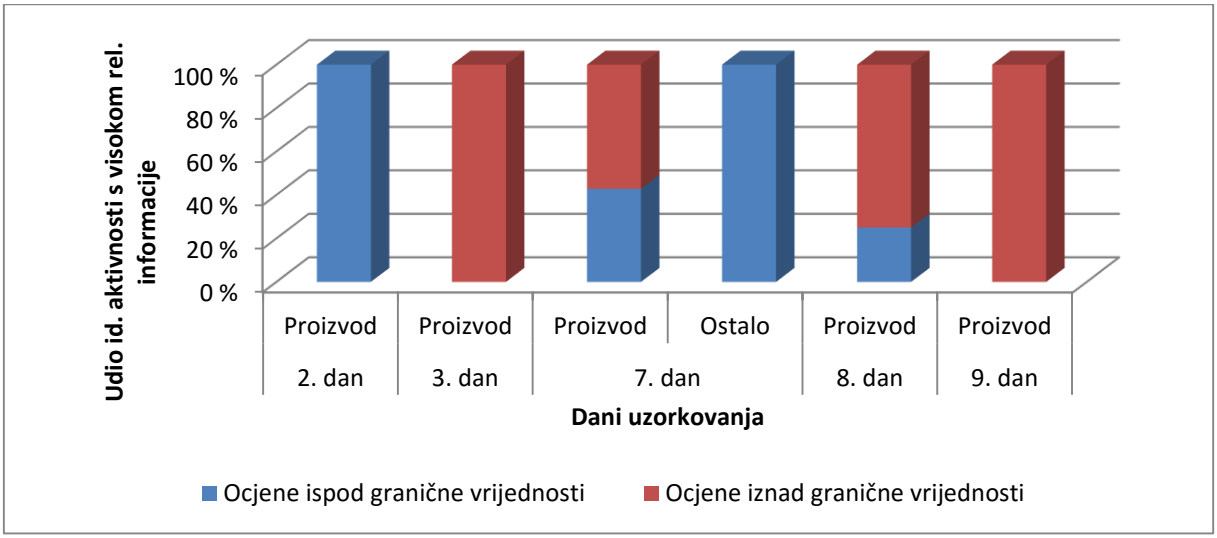
Broj ideacijskih aktivnosti i dinamika promjene vrijednosti vezana za kontekst (proizvod ili ostalo) – II_IN1 i II_IN3, prikazani su na slici (Slika 6-19). Iz slike (Slika 6-19) može se očitati da individualne ideacijske aktivnosti nisu bile svakodnevne te da 19 individualnih ideacijskih aktivnosti unutar konteksta proizvoda dominira u usporedbi sa samo jednom individualnom ideacijskom aktivnosti vezanom za ostale domene. Poslije razlaganja konteksta proizvoda na njegove potkategorije, uočljivo je da je čak 65 % od ukupnih ideacijskih aktivnosti orijentirano na *softverski dio proizvoda*, a samo 10 % na *mehanički dio proizvoda*. Samo su tri sudionika zabilježila individualne ideacijske aktivnosti tijekom promatranog razdoblja.



Slika 6-19. Promjene vrijednosti indikatora II_IN1 (*broj individualnih ideacijskih aktivnosti vezanih za proizvod*) i II_IN3 (*broj individualnih ideacijskih aktivnosti vezanih za ost. aspekte*)

Kao i s indikatorima CI_IN7, CI_IN10 i CI_IN13, ista se granična vrijednost upotrebljava i za sljedeće indikatore (II_IN2 i II_IN4). Pri analizi indikatora II_IN2 i II_IN4 može se uočiti

kako je relevantnost informacija ocijenjena i visokim i niskim ocjenama za domenu proizvoda, a pri ideacijskoj aktivnosti vezanoj za ostale domene relevantnost informacija ocijenjena je niskom (Slika 6-20).



Slika 6-20. Promjena vrijednosti indikatora II_IN2 (*udio individualnih ideacijskih aktivnosti vezanih za proizvod s visokom relevantnošću informacije*) i II_IN4 (*udio individualnih ideacijskih aktivnosti vezanih za ost. aspekte s visokom relevantnošću informacije*)

6.2.3.2. Timska razina

Podaci potrebni za prva četiri indikatora ove skupine prikupljeni su iz drugog dijela ankete te su njihove vrijednosti prikazane u tablici (Tablica 6-11) s obzirom na to da su konstantne za promatrano razdoblje. Donja granična vrijednost, čije je određivanje već prije objašnjeno, iznosi 3,07.

Koristeći se navedenom graničnom vrijednosti, uočljivo je da su vrijednosti indikatora II_TM2 i II_TM4 ispod tražene razine (označene crvenom bojom) za promatrano razdoblje. Rezultati upućuju na manju važnost aspekta inovativnosti u okviru aktivnosti analiziranog tima. Najniže vrijednosti indikatora vezane su uz podršku tvrtke u smislu financija i vremena te podršku okruženja za stvaranje novih ideja i rješenja.

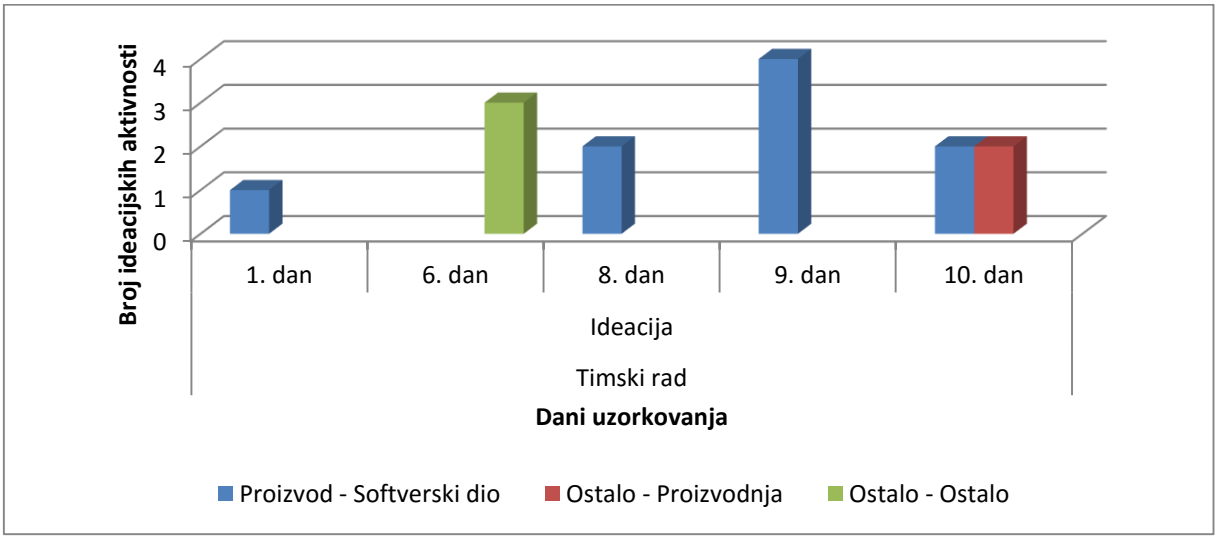
Vrijednosti za druga četiri indikatora iz ove skupine proizlaze iz podataka prikupljenih uzorkovanjem rada (na isti način kao i za indikatore *inovativnosti i ideacije* na individualnoj razini). Tijekom uzorkovanja zabilježen je manji broj timskih ideacijskih aktivnosti u usporedbi s brojem individualnih ideacijskih aktivnosti. Uočljivo je da su ideacijske aktivnosti ravnomjernije tematski raspodijeljene. Naime, omjer timskih ideacijskih aktivnosti vezanih za proizvod i za ostale domene jest 64 % prema 36 %. S gledišta konteksta proizvoda, sve timske

ideacijske aktivnosti u ovom razdoblju uzorkovanja bile su vezane za *softverski* dio proizvoda (Slika 6-21).

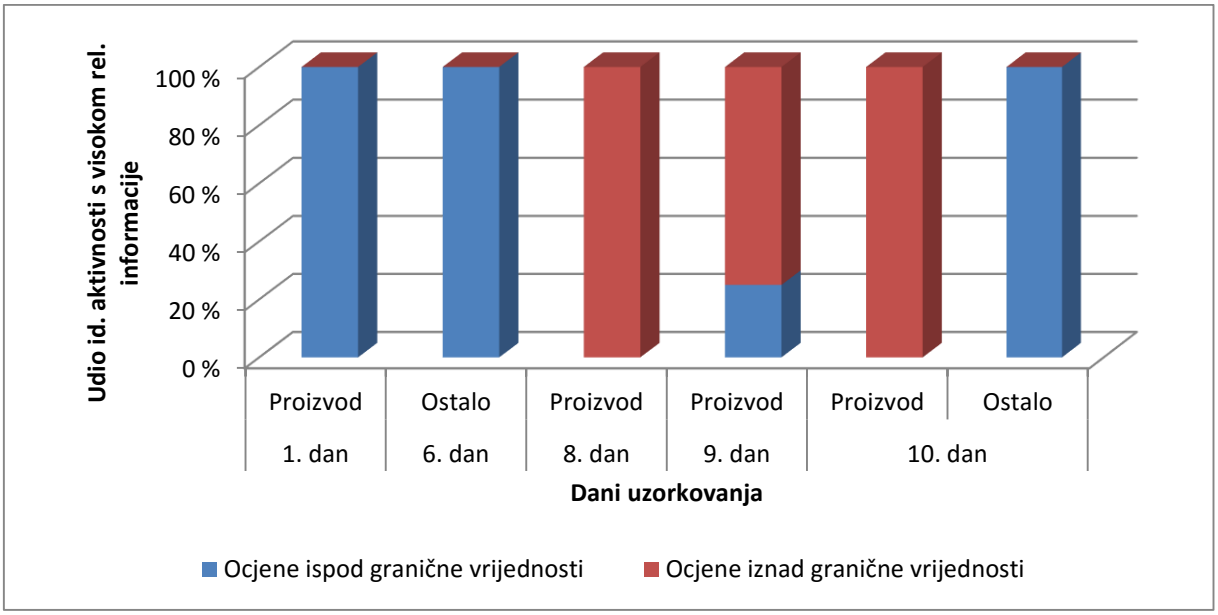
Tablica 6-11. Vrijednosti timskih indikatora za *inovativnost i ideaciju* koje su prikupljene anketom (II_TM1, II_TM2, II_TM3, II_TM4)

Oznaka	Naziv indikatora	V	STD
II_TM1	U kolikoj mjeri okruženje prihvaća način razmišljanja „izvan kutije“	3,50	0,71
II_TM2	U kolikoj mjeri okruženje podržava kulturu stvaranja novih ideja	3,00	0,82
II_TM3	U kolikoj mjeri su inovacije cilj menadžmenta	3,40	0,84
II_TM4	U kolikoj mjeri okruženje podržava inovativnost u projektima	3,00	0,94

Relevantnost informacija tijekom timskih ideacijskih aktivnosti ocijenjena je na isti način kao i za individualne ideacijske aktivnosti. Dakle, relevantnost informacija tijekom timskih ideacijskih aktivnosti vezanih za kontekst proizvoda bolje je ocijenjena nego tijekom timskih ideacijskih aktivnosti vezanih za ostale domene (Slika 6-22).



Slika 6-21. Promjena vrijednosti indikatora II_TM5 (*broj timskih ideacijskih aktivnosti vezanih za proizvod*) i II_TM7 (*broj timskih ideacijskih aktivnosti vezanih za ost. aspekte*)



Slika 6-22. Promjena vrijednosti indikatora II_TM6 (*udio timskih ideacijskih aktivnosti vezanih za domenu proizvoda s visokom relevantnošću informacije*) i II_TM8 (*udio timskih ideacijskih aktivnosti vezanih za ost. domene s visokom relevantnošću informacije*)

6.2.3.3. Rasprava o rezultatima za element inovativnost i ideacija

S obzirom na tip i tematiku projekta, ali i ekspertizu sudionika studije slučaja, moglo se pretpostaviti da će najveći dio ideacijskih aktivnosti biti vezan za elektronički i softverski dio proizvoda i na individualnoj i na timskoj razini. Na sličan način, kao i u raspodjeli konteksta aktivnosti, raspodijeljene su i ideacijske aktivnosti.

Rezultati na individualnoj razini upućuju na samo tri sudionika koji su zabilježili ideacijske aktivnosti tijekom uzorkovanja, iako indikatori *kreativnosti*, *rješavanja problema* i *tehničkog znanja* upućuju na solidan potencijal za stvaranje novih ideja u cijelom timu. Amabile [227] navodi da su upravo sposobnost kreativnog razmišljanja, stručnost i motivacija tri komponente koje definiraju kreativnost pojedinca te bi trebale utjecati na učestalost ideacijskih aktivnosti, iako dobiveni rezultati to nisu potvrdili.

Iako je udio ideacijskih aktivnosti u okviru individualnog tehničkog rada (2,5 %) manji od udjela ideacijskih aktivnosti u okviru timskog rada (8,0%), ukupan je broj timskih ideacijskih aktivnosti u usporedbi s ukupnim brojem individualnih ideacijskih aktivnosti manji. Prema Girotri i dr. [228], broj novih ideja mnogo je veći pri individualnom radu, što može poslužiti kao objašnjenje za manji broj timskih ideacijskih aktivnosti u usporedbi s individualnim ideacijskim aktivnostima.

Rezultati upućuju na više vrijednosti relevantnosti informacija tijekom individualnih i timskih ideacijskih aktivnosti vezanih uz kontekst proizvoda u usporedbi s ideacijskim aktivnostima vezanima uz druge domene. Više vrijednosti relevantnosti mogu se protumačiti boljim poznavanjem i većom stručnošću u tom aspektu razvojnog procesa. Kao i u analizi *komunikacije i razmjene informacija*, potrebno je razmotriti mogućnost primjene indikatora vezane za relevantnost informacije kumulativno za cijelo razdoblje. Praćenjem relevantnosti informacije tijekom ideacijskih aktivnosti u duljem razdoblju uključio bi se više promatranih točaka te omogućio bolji uvid u tu perspektivu ideacijskih aktivnosti.

S obzirom na adaptivne razvojne procese karakteristične za analizirani tim, vrijednosti indikatora II_TM2 koji se odnosi na kulturu stvaranja novih ideja bile su očekivane. Dodatna potvrda stava o niskoj razini inovativnosti u analiziranom timu proizlazi iz vrijednosti indikatora II_TM4 koji upućuje na manju podršku organizacijskog okruženja inovativnosti i novim idejama. Preostali indikatori vezani za okruženje u smislu inovativnosti upućuju na nedostatnu podršku menadžmenta. Takva percepcija zaposlenika sigurno znatno utječe na njihovu izvedbu u smislu inovativnosti i njihovu ustrajnost u potrazi za novim i inovativnim rješenjima. Ovakvi kontekstualni indikatori daju dodatan pogled te pobliže objašnjavaju rezultate indikatora dobivenih uzorkovanjem te su u skladu s konstatacijama o učestalosti ideacijskih aktivnosti. Budući da su za određivanje vrijednosti kontekstualnih indikatora na timskoj razini upotrijebljene iste skale kao i u kontekstualnih indikatora *komunikacije i razmjene informacija*, može se ustvrditi da ove vrijednosti indikatora upućuju na još lošiju izvedbu. Naime, vrijednosti kontekstualnih indikatora za kategoriju *inovativnost i ideacija* znatno su niže.

Daljnja analiza ideacijskih aktivnosti pridonijela bi njihovu razumijevanju te ponudila odgovore na pitanja o potrebama za ideacijskim pristupima unutar razvojnih projekata u kojima sudjeluju članovi analiziranog tima. Ideacijske se aktivnosti u literaturi najčešće promatra iz triju različitih perspektiva. Prvi je aspekt vezan za količinu ideja i podrazumijeva da veći broj ideja rezultira i njihovom većom kvalitetom. U drugoj je perspektivi naglasak isključivo na procjeni kvalitete ideja, a u trećoj na stvaranju ideja, neovisno o evaluaciji i njihovu odabiru [228].

U istraživanju provedenom pri izradi ove disertacije nisu praćene ideje niti je od sudionika zahtijevana ocjena njihove kvalitete te stoga nije moguća izravna usporedba s drugim rezultatima istraživanja. Naime, s obzirom na apstraktnost ideje kao pojma, u sklopu ovdje

prikazanog istraživanja pratila se učestalost ideacijskih aktivnosti, odnosno koliko su često pojedini sudionici pokušali pronaći novu ideju ili rješenje za određeni problem. Dosadašnja istraživanja vezana za stvaranje ideja često su se odnosila na analizu pojedinačnih sesija ili niza sesija, pritom ne uzimajući u obzir njihovu učestalost tijekom realnih razvojnih procesa. Dulje praćenje ideacijskih aktivnosti na individualnoj i timskoj razini omogućilo bi donošenje čvršćih zaključaka, ali i moguću potvrdu uspješnosti hibridnog pristupa stvaranju novih ideja u realnom okruženju [229]. Također, praćenjem ideacijskih aktivnosti te ostalih tipova timskog rada mogu se identificirati obrasci koji potiču pojedince na kreiranje novih ideja te time utječu na promjenu svoje organizacijske rutine.

Uporabom i praćenjem predloženih indikatora u kategoriji *inovativnost i ideacija* zajedno s indikatorima iz drugih kategorija tijekom duljeg razdoblja omogućila bi se provjera brojnih prethodnih istraživanja ideacije, ali s pomoću podataka prikupljenih u realnom vremenu. Longitudinalne studije ovog tipa omogućile bi proučavanje brojnih fenomena i potvrdu prijašnjih istraživanja poput utjecaja suradnje [230], motivacije [231] i međupovezanosti pojedinaca i timova [232] na ideaciju.

6.2.4. Indikatori izvedbe za element *motivacija i zadovoljstvo*

6.2.4.1. Individualna razina

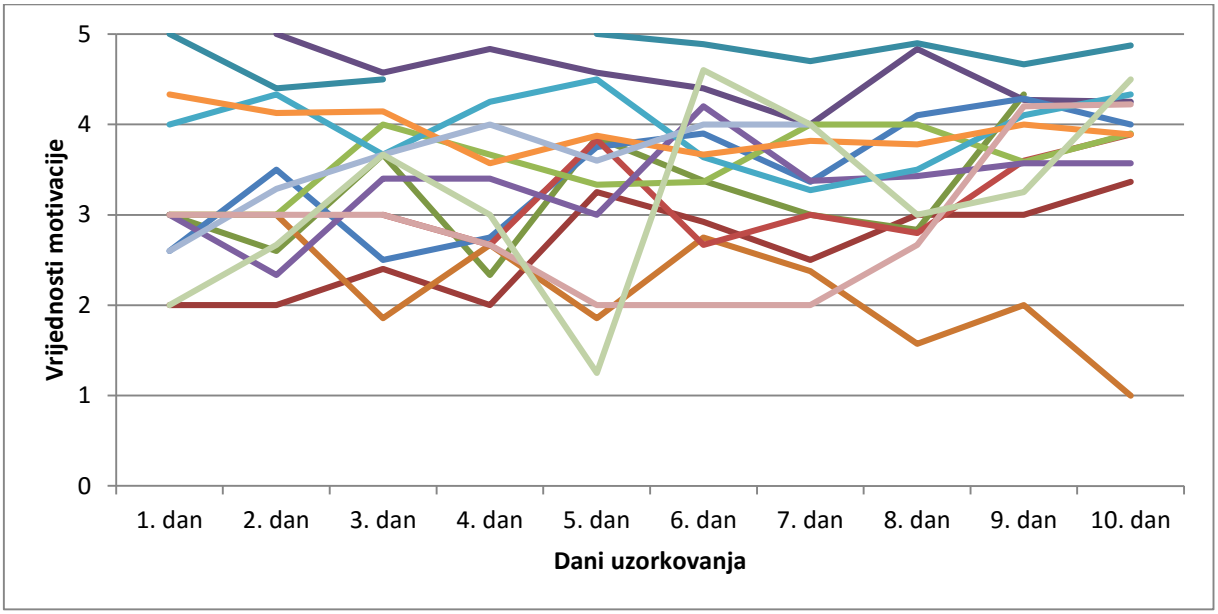
U ovoj su skupini predložena samo dva indikatora. Za indikator MS_IN1 podaci se prikupljaju uzorkovanjem rada, a za indikator MS_IN2 (*osobno zadovoljstvo)* anketom.

Vrijednosti indikatora MS_IN1 (*motivacija tijekom individualnih aktivnosti*) određene su na temelju analize odgovora zabilježenih u aplikaciji za uzorkovanje rada (izbornik *razina motivacije*). Za praćenje dinamike indikatora MS_IN1 pojedinog sudionika kreiran je prikaz na slici (Slika 6-23). Na slici su prikazane prosječne vrijednosti motivacije sudionika za određeni dan te trend promjene motivacije sudionika tijekom individualnih aktivnosti.

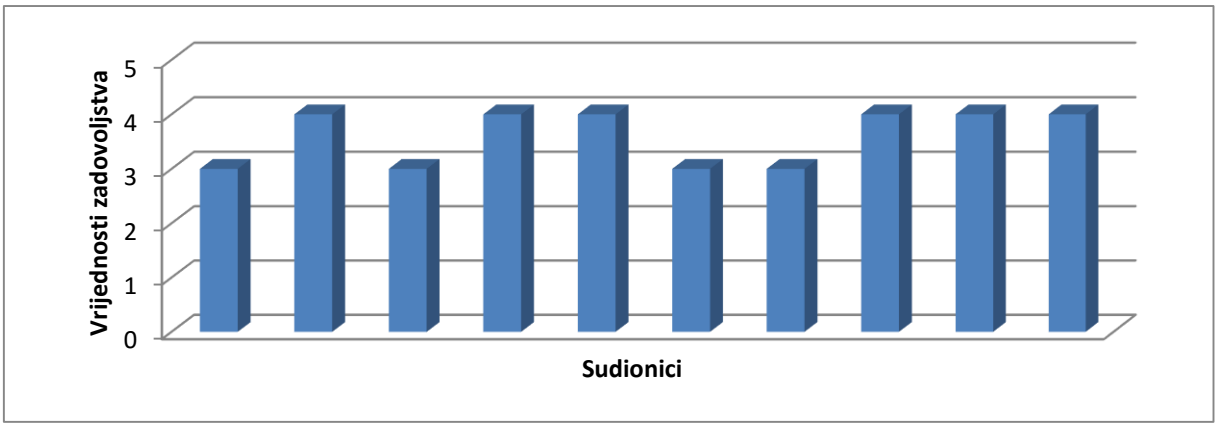
Dok je u pojedinih sudionika zabilježena konstantna visoka razina motivacije (tri sudionika), neki su sudionici zabilježili konstantno niže vrijednosti motivacije (dva sudionika). Također, u pojedinih sudionika mogu se uočiti znatne oscilacije tijekom uzorkovanog razdoblja.

Anketom su prikupljeni podaci za indikator MS_IN2 (*osobno zadovoljstvo*). S obzirom na samo 10 prikupljenih odgovora vezanih za razinu zadovoljstva, nije se mogao izraditi prikaz

indikatora za svih 15 članova tima. Vrijednosti indikatora prikazane su na slici (Slika 6-24). Četiri su sudionika ocijenili svoje zadovoljstvo ocjenom 3, a njih šest ocjenom 4.



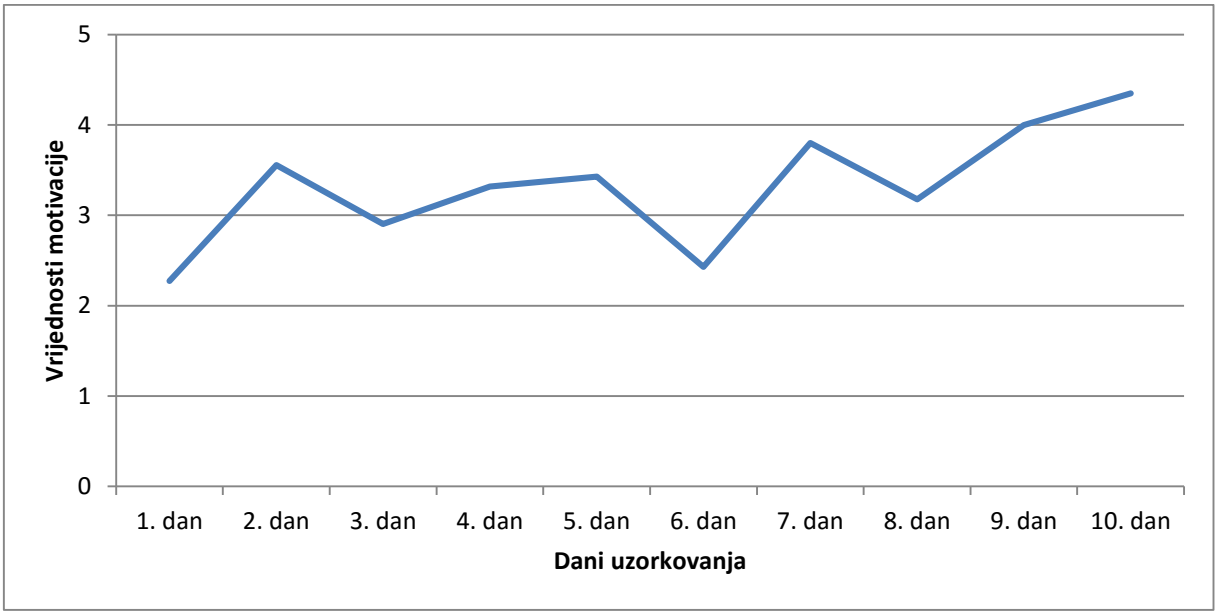
Slika 6-23. Promjena vrijednosti indikatora *motivacija tijekom individualnih aktivnosti* (MS_IN1)



Slika 6-24. Prikaz vrijednosti indikatora *osobno zadovoljstvo* (MS_IN2)

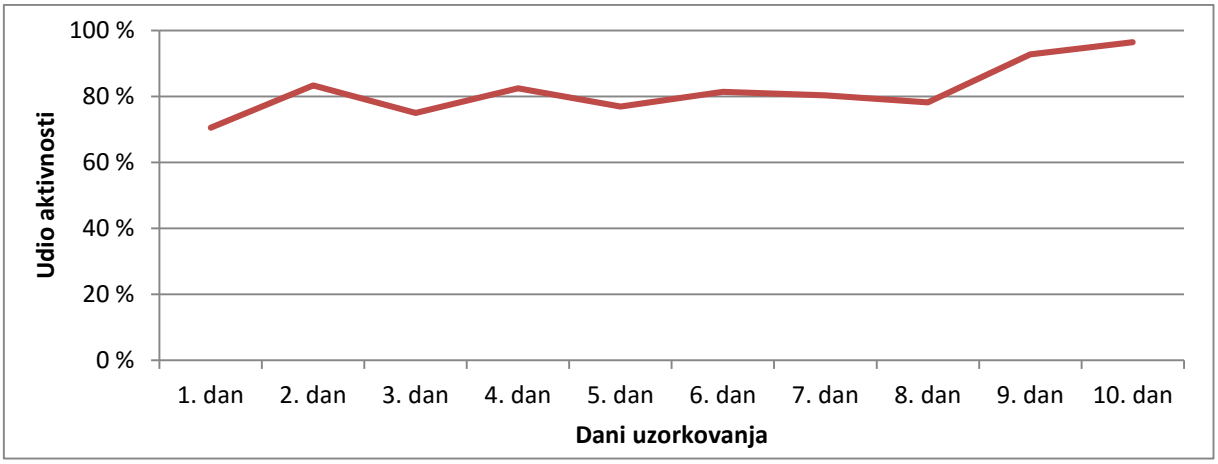
6.2.4.2. Timska razina

Podaci potrebni za određivanje vrijednosti indikatora u ovoj skupini prikupljeni su uzorkovanjem rada. Prvi navedeni indikator MS_TM1 služi za praćenje razine *motivacije tijekom timskih aktivnosti* kao što su diskusije, sastanci, sastanci tima i aktivnosti izvještavanja (Slika 6-25). Prosječne vrijednosti motivacije za timske aktivnosti izračunate po danima prilično osciliraju tijekom razdoblja uzorkovanja, ali općenito se može ustanoviti da su niže nego tijekom individualnog rada.



Slika 6-25. Promjena vrijednosti indikatora *motivacija tijekom timskih aktivnosti* (MS_TM1)

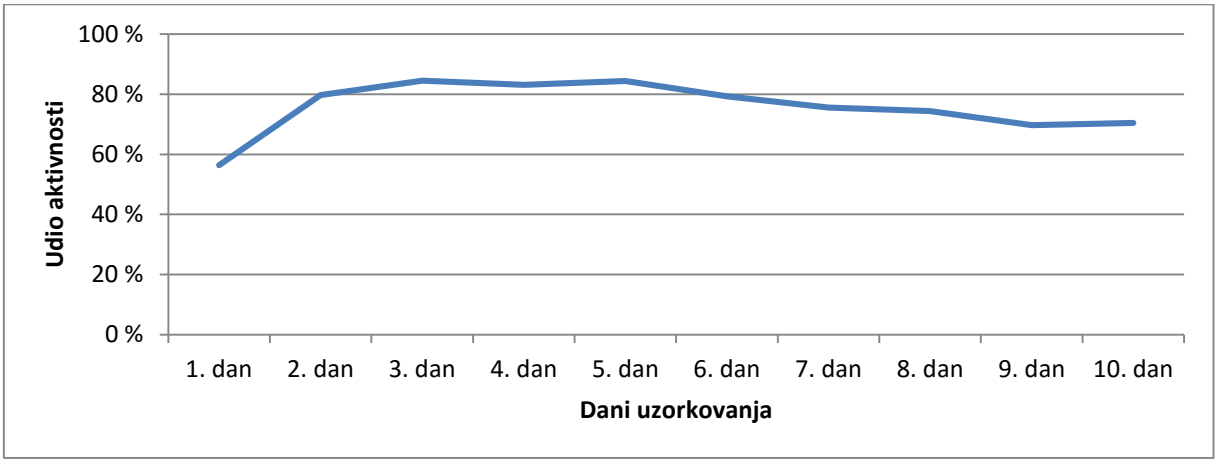
Sljedeći indikator, MS_TM3, koji proizlazi iz uzorkovanja rada, vezan je za *udio aktivnosti s višom razinom motivacije* (Slika 6-26). Granična je vrijednost izračunata na isti način kao i donja granična vrijednost u prijašnjim kategorijama te iznosi 2,9 (M = 3,47; STD = 1,06). Aktivnosti koje imaju razinu motivacije ocijenjenu ocjenom 3 ili više smatraju se aktivnostima s višom razinom motivacije. Na slici (Slika 6-26) prikazana je promjena udjela aktivnosti s višom razinom motivacije tijekom uzorkovanja. Udio aktivnosti s višom razinom motivacije varira između vrijednosti 70,5% (1. dan) i 96,4 % (10. dan).



Slika 6-26. Promjena vrijednosti indikatora *udio aktivnosti s višom razinom motivacije* (MS_TM3)

Posljednji je indikator, MS_TM4, *udio aktivnosti s višom razinom relevantnosti informacije* (Slika 6-27). Granična vrijednost za relevantnost informacije iznosi 3,62 (M = 4,13; STD = 1,01) koja dijeli aktivnosti s nižom i višom razinom relevantnosti informacija. Udio aktivnosti

s višom razinom relevantnosti informacija oscilira tijekom razdoblja uzorkovanja između 56,3 % (1. dan) i 84,5 % (3. dan).



Slika 6-27. Promjena vrijednosti indikatora *udio aktivnosti s višom razinom relevantnosti informacije* (MS_TM4)

6.2.4.3. Rasprava o rezultatima za element motivacija i zadovoljstvo

Prema dobivenim rezultatima, ocjene motivacije tijekom individualnih aktivnosti uglavnom ovise o zaposleniku, a ne o tipu njegove aktivnosti ili rada. Iz dnevne dinamike vrijednosti motivacije uočene su manje oscilacije u sudionika. Također, primjetan je općenit rast motivacije 5. i 10. dana, najvjerojatnije zbog kraja radnog tjedna. Vrijednosti motivacije tijekom individualnih aktivnosti većinom su od 3 do 5, s iznimkom dvaju sudionika čija je motivacija kontinuirano ipak nešto niža. Za svakog se sudionika može spojiti indikator motivacije s aktivnostima i načinom te kontekstom njihova izvođenja kako bi se mogli identificirati uzroci i obrasci niže i više razine motivacije u sudionika. Analizom uzoraka i obrazaca niže i više razine motivacije mogu se prikupiti dodatna saznanja o elementima intrinzične motivacije. Prema Coelhu i Augustu [233], intrinzična je motivacija definirana kao individualno uzbuđenje i zadovoljstvo vlastitim radnim aktivnostima te interesom u provođenju tih aktivnosti.

Zanimljivo je da je jedan od sudionika s kontinuirano nižim stupnjem motivacije i jedan od triju sudionika koji su zabilježili individualne ideacijske aktivnosti. Prema Amabile [227], motivacija je jedna od ključnih komponenata kreativnosti i stvaranja novih ideja, ali dobiveni rezultati vezani za navedenog sudionika to ne potvrđuju. U svojoj teoriji kreativnosti, Amabile i dr. [234] tvrde da su ljudi najkreativniji ponajprije kad im je aktivnost zanimljiva, izazovna i kad u njoj uživaju. Stoga je potreba za praćenjem razine motivacije u realnom vremenu te za korištenjem navedenim indikatorima još važnija.

Podaci potrebni za određivanje vrijednosti indikatora MS_IN2 nisu prikupljeni za sve sudionike zato što pojedini od njih nisu ispunili taj dio ankete. Sudionici koji su sudjelovali u anketi izrazili su svoje zadovoljstvo ocjenama 3 (dobrim) i 4 (vrlo dobrim), što se dobrim dijelom očituje u njihovoj razini motivacije. Za donošenje čvršćih zaključaka bilo bi potrebno dulje praćenje zadovoljstva zaposlenika te provođenje kvalitativnih studija koje bi potpomogle interpretaciju ovih rezultata.

U timskim je aktivnostima uočljiva niža razina motivacije nego u individualnima. Uzrok tomu moglo bi biti nezadovoljstvo ishodima timskih aktivnosti, ali i već ranije spomenuta niža razina socijalnih vještina. Također, znatno je veći udio tehničkih aktivnosti pri individualnom radu, u usporedbi s timskim radom. Rezultati koji upućuju na višu razinu motivacije pri tehničkom radu u skladu su s istraživanjem Perlow i Bailyn [235] čiji rezultati upućuju na veće zadovoljstvo inženjera pri izvođenju tehničkih aktivnosti. U kontekstu kasnih faza projekata u kojima su sudjelovali, moguće je da su sudionici timski rad shvaćali kao dodatno opterećenje koje nije pridonosilo izvršavanju njihovih zadataka. Također, vrijednost indikatora CI_TM5**,** koji govori o motiviranosti za dijeljenjem znanja s drugim članovima tima, upućuje na nižu motivaciju tijekom timskih aktivnosti. Najveća razina motivacije tijekom timskih aktivnosti dosegnuta je tijekom 9. i 10. dana, a mogla bi biti povezana sa završetkom jednog od većih projekata 8. dana uzorkovanja. Završetak većeg projekta ujedno može biti i uzrok za pad relevantnosti informacije tijekom drugog tjedna.

S obzirom na drukčiji način prikupljanja podataka nego u prijašnjim studijama, teško se mogu usporediti rezultati s drugim istraživanjima, pogotovu zato što razina motivacije nije praćena dnevno tijekom inženjerskih procesa. Jedino usporedivo istraživanje proveo je Robinson [100] koji je analizirao razinu zadovoljstva pri provođenju aktivnosti. U ovdje prikazanom istraživanju razina motivacije bila je viša pri individualnom radu nego timskom, a u Robinsona nije bilo veće razlike između individualnog i timskog rada. Iako je Robinson [99] u svojem istraživanju analizirao i razinu zanimljivosti, kreativnosti i kontrolabilnosti inženjerskih aktivnosti, rezultati nisu objavljeni te usporedba nije moguća.

Indikatori iz kategorije *motivacija i zadovoljstvo* daju uvid u razinu motiviranosti tijekom izvođenja pojedinih aktivnosti. Specifičnost indikatora vezanih za individualnu razinu omogućuje longitudinalno prikupljanje podataka o razini intrinzične motivacije te dublje razumijevanje konteksta. S obzirom na moguću spregu indikatora s različitim aspektima individualnih aktivnosti, nakon duljeg praćenja razvojnih procesa u realnom vremenu mogu

se ustanoviti uzroci moguće niske razine intrinzične motivacije te u skladu s time reagirati pravodobno.

6.3. Određivanje agregirane vrijednosti nematerijalnih indikatora za elemente intelektualnoga kapitala

Pošto su primjenom Metode potencijala određeni apsolutni težinski faktori za sve nematerijalne indikatore, grupirani su prema elementima IK-a na individualnoj i timskoj razini. U literaturi postoje brojni pristupi mjerenju i vrednovanju IK-a fokusirani na specifične elemente IK-a ili na IK kao cjelinu izraženu vrijednošću jedinstvenog indeksa [108]. U ovdje prikazanoj agregaciji za svaki element IK-a na individualnoj i timskoj razini izračunati su relativni težinski indikatori koji vrijede unutar određenog elementa.

Zatim su upotrebom linearne agregacije određene vrijednosti za svaki element IK-a na individualnoj i timskoj razini. Zbog nedostupnosti podataka iz korporativnih IT sustava, bilo se nužno odlučiti za daljnju proceduru s podacima koji nedostaju. Najlakši je postupak uklanjanje indikatora s popisa, čime se služila i Halim [158] u svojoj statističkoj analizi indikatora intelektualnoga kapitala. Stoga će se pri ovdje predloženoj agregaciji zanemariti težinski faktori nematerijalnih indikatora za koje podaci nisu prikupljeni.

Agregirane su vrijednosti za pojedine kategorije izračunate za svaki radni dan, a za neke od njih izračunata je jedna agregirana vrijednost za cijelo razdoblje uzorkovanja. Koliko je izračunato agregiranih vrijednosti za pojedinu kategoriju, ovisilo je o tipu indikatora od kojih su se sastojale. Ako su podaci prikupljeni anketom te postoji samo jedna kumulativna vrijednost za cijelo razdoblje, onda je izračunata samo jedna agregirana vrijednost za određeni element IK-a (Tablica 6-12).

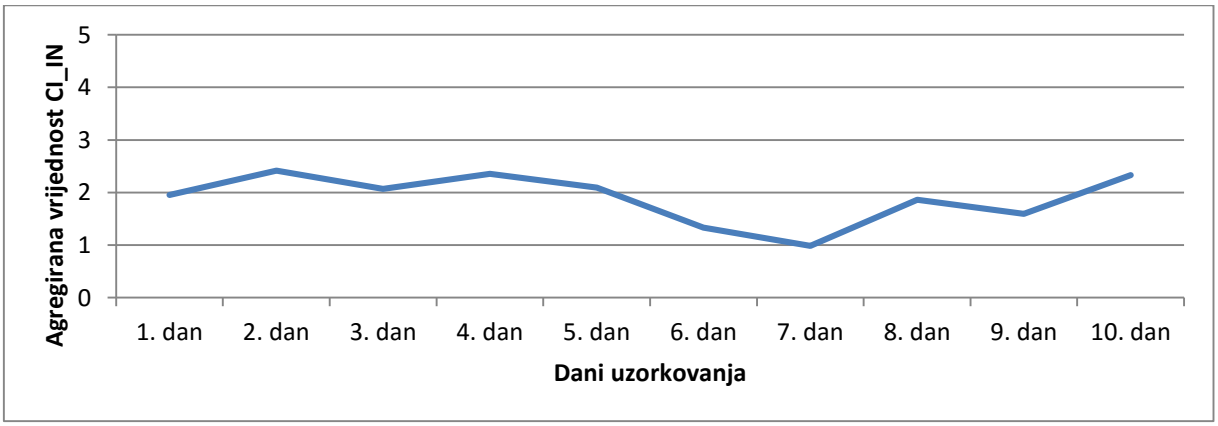
Tablica 6-12. Agregirane vrijednosti za CK_IN, CK_TM i CI_TM

CK_IN	agregirana vrijednost za kategoriju *kompetencije i znanje* na individualnoj razini	7,74
CK_TM	agregirana vrijednost za kategoriju *kompetencije i znanje* na timskoj razini	6,25
CI_TM	agregirana vrijednost za kategoriju *kompetencije i znanje* na timskoj razini	6,69

Za kategoriju *kompetencije i znanje* na individualnoj i timskoj razini izračunata je agregirana vrijednost za cijelo razdoblje jer su podaci prikupljeni anketom (prikazano u tablici – Tablica

6-12). Jedna agregirana vrijednost za cijelo razdoblje izračunata je i za kategoriju *komunikacija i razmjena informacija* na timskoj razini te iznosi *6,69*. Valja istaknuti da su agregirane vrijednosti za ove tri kategorije apsolutno opravdane jer ih čini velik broj pojedinačnih indikatora koji su iste prirode (a nisu samo izraženi na istoj skali).

Na individualnoj razini za element *komunikacija i razmjena informacija* zabilježene su uvjerljivo najniže vrijednosti (Slika 6-28) jer su svi indikatori koji čine ovaj element prikupljeni uzorkovanjem rada te su inicijalno izraženi u postocima, a zatim svedeni na skalu od 1 do 10. Iznimno niske vrijednosti ovoga elementa izričito zahtijevaju analizu pojedinačnih indikatora kako bi se potpomoglo razumijevanje agregirane vrijednosti. Agregirana vrijednost jedino u ovoj kategoriji nije opravdala svoju svrhu zato što se pojedinačni indikatori djelomično preklapaju te mogu navesti na pogrešne zaključke. Na primjer, agregacija indikatora koji su vezani za davanje i primanje informacija na individualnoj razini ne može se izvesti na ovaj način jer se međusobno preklapaju. Također, logično je da vrijednosti indikatora ne mogu biti znatno više unutar ovog elementa uzimajući u obzir njihovu prirodu i predmet njihova praćenja. U daljnjem istraživanju svakako bi trebalo razmotriti druge načine agregacije koji bi mogli uputiti na trendove i izvedbu elementa *komunikacija i razmjena informacija*. Treba napomenuti da četiri indikatora koji su inicijalno predviđeni za ovaj element nisu bili uvršteni zbog nedostatka podataka, što je također utjecalo na izračun agregirane vrijednosti.

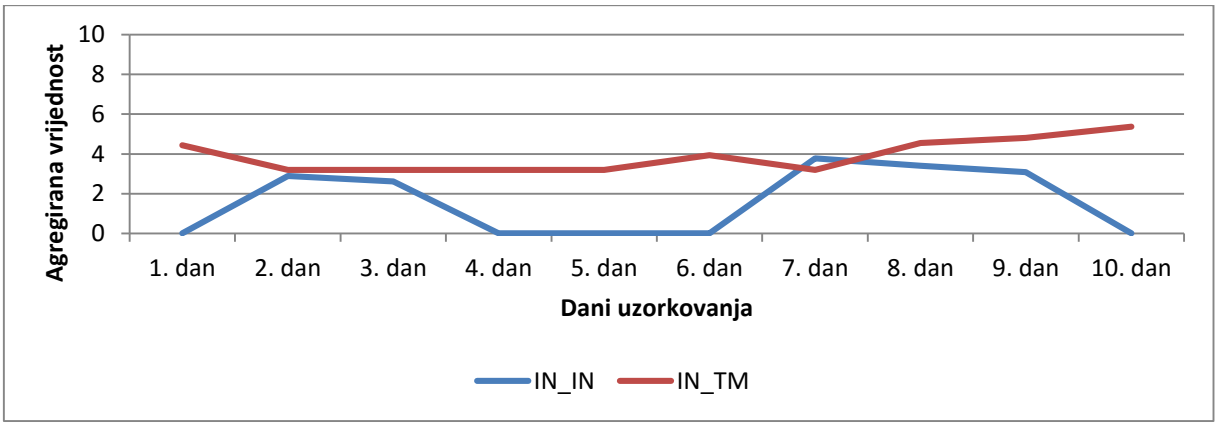


Slika 6-28. Agregirane vrijednosti za CI_IN po danima

Za preostale elemente IK-a izračunate su agregirane vrijednosti za svaki pojedini dan uzorkovanja jer su indikatori barem dijelom prikupljeni uzorkovanjem rada.

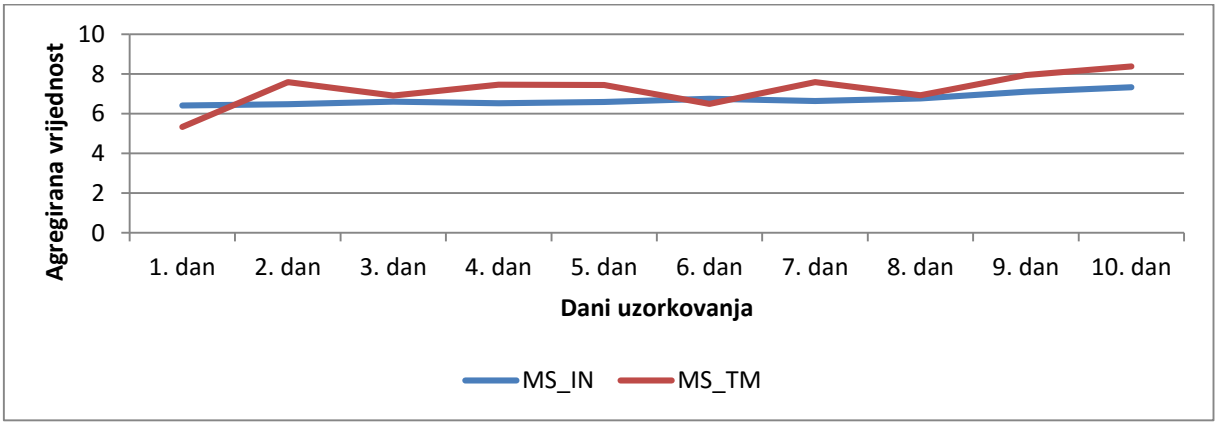
Za element *inovativnost i ideacija* na individualnoj i timskoj razini vrijednosti su prikazane na slici (Slika 6-29). Na timskoj je razini agregirana vrijednost nešto viša nego na individualnoj razini, no može se uočiti da ovaj element ima niže vrijednosti u usporedbi s drugim

elementima. Također se može zaključiti da element *inovativnost i ideacija* na timskoj razini ima malo više vrijednosti jer nekoliko indikatora unutar tog elementa proizlazi iz ankete.



Slika 6-29. Agregirane vrijednosti za IN_IN i IN_TM po danima

Na slici (Slika 6-30) su prikazane agregirane vrijednosti za element *motivacija i zadovoljstvo*. Za ovaj je element na individualnoj razini primjetna mala oscilacija tijekom razdoblja uzorkovanja zbog manjeg broja indikatora (samo 2) koji su poslužili za izračun agregirane vrijednosti. Podaci za jedan od indikatora dobiveni su anketom te su konstantni tijekom razdoblja uzorkovanja. Agregirana vrijednost za element *motivacija i zadovoljstvo* na timskoj razini u prosjeku je malo više od agregirane vrijednosti za individualnu razinu.



Slika 6-30. Agregirane vrijednosti za MS_IN i MS_TM po danima

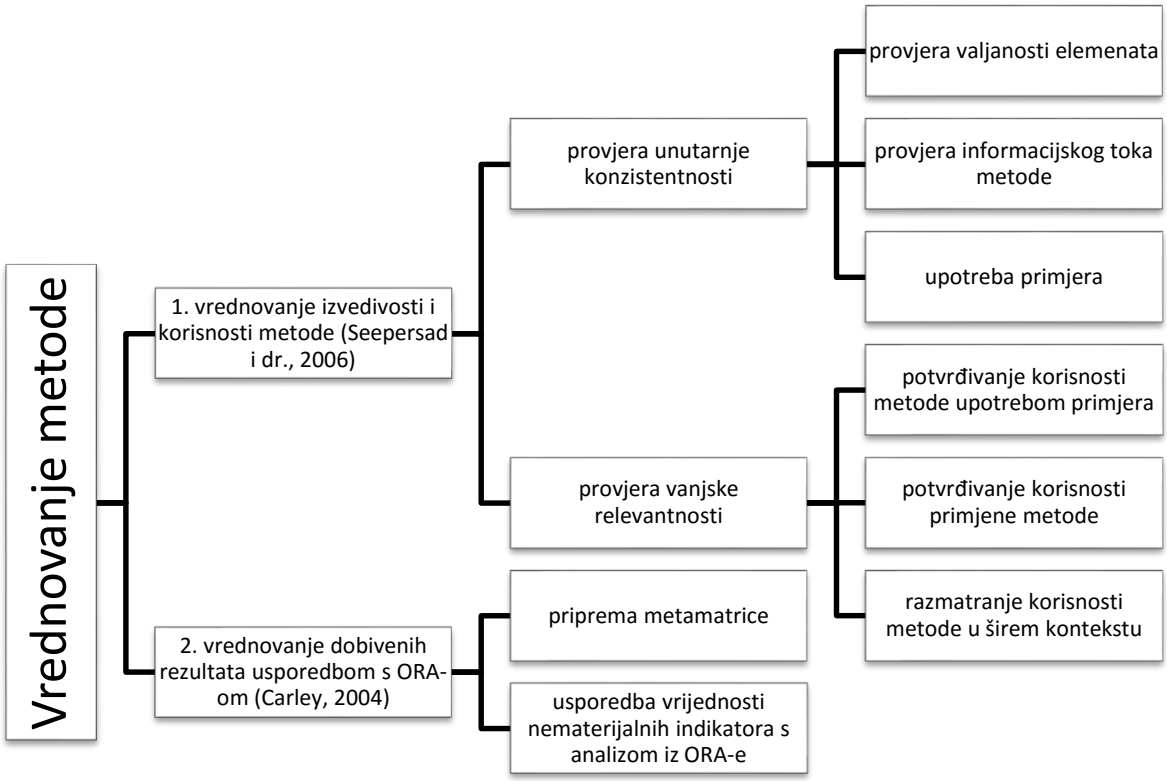
Iako dobivene agregirane vrijednosti mogu upozoriti na trend i razinu pojedinog elementa, bitno je istaknuti da je ove vrijednosti potrebno pratiti s vrijednostima pojedinačnih indikatora. Jedino takav način praćenja indikatora omogućuje pravilnu interpretaciju vrijednosti za pojedini element. Također, očite su razlike u agregiranim vrijednostima elemenata čiji se indikatori većinom temelje na podacima prikupljenim anketom, odnosno uzorkovanjem rada jer su vrijednosti prikupljene anketom konstantne za cijelo razdoblje studije slučaja.

7. Vrednovanje predložene metode

Poslije prikaza provedene studije slučaja, u sedmom poglavlju prikazan je postupak vrednovanja predložene metode koja se sastoji od upotrebe metode „validacijskoga kvadrata“ i usporedbe s metodom za analizu organizacijskih rizika.

7.1. Metodologija vrednovanja

Prema metodologiji istraživanja koja se primjenjuje u području upravljanja projektima razvoja tehničkih sustava, vrednovanje je nužno provesti radi procjene izvedivosti i vjerodostojnosti predložene metode. S obzirom na prirodu istraživanja u području razvoja tehničkih sustava, otežano je provođenje „formalne, rigorozne i kvantitativne“ validacije i verifikacije. Iako se velik dio istraživanja u području razvoja tehničkih sustava temelji na matematičkom modeliranju, postoje i brojna druga potpodručja koja se osnivaju na subjektivnim stavovima i percepcijama. Za potrebe vrednovanja predložene metode u okviru izrade ove doktorske disertacije, postupak vrednovanja može se podijeliti na dva glavna dijela (Slika 7-1).



Slika 7-1. Postupak vrednovanja

U prvom dijelu vrednovanja primijenit će se postupak Seepersada i dr. [23] za validaciju izvedivosti i korisnosti pristupa i metoda u upravljanju razvojem tehničkih sustava pod nazivom „validacijski kvadrat“.

U drugom dijelu vrednovanja, rezultati i saznanja dobiveni nematerijalnim indikatorima usporedit će se s rezultatima ključnih i kritičnih entiteta organizacijske strukture.

7.2. Vrednovanje izvedivosti na temelju validacijskoga kvadrata

Prema metodi „validacijski kvadrat“ (engl. *validation square*) [23], strukturirani postupak vrednovanja sastoji se od provjere unutarnje konzistentnosti i vanjske relevantnosti metode.

Provjera unutarnje konzistentnosti obuhvaća teorijski (1. i. 2. korak) i empirijski dio (3. korak):

1) *Provjera valjanosti elemenata metode*. Kritičkim osvrtom na literaturu u području intelektualnoga kapitala može se ustanoviti koliko su pojedinačni elementi (ovdje su to indikatori i kategorije indikatora) pravilno postavljeni. Također, u ovom dijelu bit će objašnjene razlike između postojećih pristupa u literaturi i metode predložene u ovoj disertaciji.

   Uspoređujući predloženi popis indikatora s postojećim mjerama u literaturi, uočava se jasna razlika u pristupu istraživanju navedene problematike. U literaturi se mogu pronaći brojni radovi u kojima se spominju kriteriji za evaluaciju IK-a te njegovih sastavnica – ljudskog, strukturnog i relacijskoga kapitala (npr. [7], [61]). Naime, takva se istraživanja provode radi određivanja utjecaja sastavnica na ukupni IK te utjecaja između sastavnica. Međutim, takvi indikatori ne daju uvid u trenutačno provođenje procesa, već su isključivo usredotočeni na potencijal IK-a u nekoj organizaciji. Također, iako je jasno naznačeno da su pojedini kriteriji kvalitativni i kvantitativni, redovito se upotrebljavaju isključivo Likertove skale za provođenje anketa te se njihove analize ne temelje na podacima prikupljenim iz realnih organizacijskih procesa. Bitno je istaknuti da spomenuti kriteriji često nisu jasno i jednoznačno definirani što dodatno dovodi u pitanje ishode pojedinih istraživanja. Nadalje, kriterijima odnosno indikatorima nedostaju metrike te jasno definirane metode prikupljanja podataka.

   Indikatori, predloženi u ovoj disertaciji, upotrebljivi su za pojedince i timove te nude drukčiju sliku IK-a na temelju realnoga provođenja projekta. Na temelju kriterija IK-a

pronađenih u literaturi, definirani su indikatori koji omogućuju praćenje elemenata IK-a pri provođenju realnih procesa s jasno određenim pristupima prikupljanja podataka te postupcima preslikavanja u vrijednosti indikatora.

Isključivo istražujući ljudski kapital, uočljive su razlike između broja indikatora koje navode pojedini istraživači. Broj indikatora koji je vezan za kompetencije u predloženome modelu veći je nego u nekim istraživanjima [82], [157], [158] upozoravajući na veću detaljnost predložena popisa indikatora (npr. profesionalna kompetencija razložena je na veći broj kompetencija od kojih se sastoji). S druge strane, uspoređujući s dijelom literature o kompetencijskim modelima (npr. [236]), broj predloženih indikatora za kompetencije znatno je niži jer je prilagođen potrebama voditelja projekta.

Indikatori iz kategorija *komunikacija i razmjena informacija* i *inovativnost i ideacija* nisu pronađeni na drugim popisima kriterija ljudskoga i intelektualnoga kapitala iako konceptualno ondje pripadaju. Za potrebu identifikacije indikatora iz elemenata IK-a *komunikacija i razmjena informacija* i *inovativnost i ideacija* poslužila je literatura iz područja upravljanja znanjem.

Iako su Arisha i Ragab [178] predložili metrike za praćenje individualnog znanja te su se isključivo orijentirali na perspektivu pojedinca, pojedini se dijelovi njihova modela dobro podudaraju s modelom predloženim u ovoj disertaciji. Na primjer, primjetno je podudaranje indikatora kompetencija IT pismenosti, iako u njihovu radu nije jasno definiran način prikupljanja podataka što je jedan od temeljenih preduvjeta pri uspostavi indikatora. To vrijedi i za njihove indikatore u kategoriji *komunikacija* za koje se jasno navodi metrika (broj), ali opet bez metode prikupljanja podataka. Za timsku su razinu preuzeti pojedini indikatori koje su predložili Orr i Persson [177], iako je važno istaknuti da je njihov pristup isključivo okrenut timskoj i organizacijskoj razini, pritom zanemarujući perspektivu pojedinca. Detaljnom se analizom literature može ustanoviti da se popis indikatora predložen u ovoj disertaciji uvelike razlikuje od postojećih te ujedinjuje različite elemente intelektualnoga kapitala u jednu cjelinu.

Usporedbom s dosadašnjim istraživanjima na području mjerenja i praćenja izvedbe u kontekstu razvoja tehničkih sustava također su uočljive razlike u odnosu prema postojećim modelima i pristupima. Gries i Restrepo [124] navode da je zbog nedeterminističke prirode procesa razvoja tehničkih sustava malo dostupne literature o indikatorima u tom kontekstu. Iako Kitinaka i dr. [237] navode da u istom kontekstu

još prevladavaju financijske mjere, Gries i Restrepo [124] u svojoj studiji slučaja koriste se i kriterijima vremena i kvalitete. Taylor i Ahmed-Kristensen [125] sugeriraju da je za mjerenje izvedbe razvoja tehničkih sustava nužno proširiti postojeće popise indikatora, pritom se fokusirajući na kontekst globalnog razvoja proizvoda. Indikatori upotrijebljeni u njihovu pristupu [125] materijalni su te za kategoriju *komunikacija* navode indikatore kao što su *broj postignutih dogovora, učestalost komunikacijskih problema,* a za kategoriju *razmjena informacija – dostupnost dokumentacije.* Može se uočiti da predložene metrike ne omogućuju praćenje izvedbe u realnom vremenu i nisu vezane za pojedini projekt. Također, u njihovu radu nisu precizno definirane metode prikupljanja podataka. Nadalje, Dombrowski i dr. [126] u svojoj analizi indikatora u području razvoja tehničkih sustava ističu važnost sposobnosti pojedinaca, ali ne predlažu indikatore za njihovo praćenje.

Zajednička je značajka analiziranih pristupa nedostatak metrika i metoda prikupljanja podataka za indikatore koji pripadaju kategorijama intelektualnoga kapitala, što je bio glavni predmet istraživanja u ovoj doktorskoj disertaciji. Uspoređivanjem s drugim istraživanjima može se ustanoviti da drugi pristupi još ne uključuju perspektivu intelektualnoga kapitala u većoj mjeri unutar svojih sustava za praćenje izvedbe razvoja tehničkih procesa, iako su brojni istraživači već prije isticali njezinu važnost. Budući da je „odozdo prema gore“ bio temeljni pristup provedenog istraživanja, logično je da je pristup mjerenja izvedbe u provedenom istraživanju bio orijentiran na praćenje pojedinca ili tima, za razliku od ostalih istraživanja u kontekstu razvoja tehničkih sustava koja su uglavnom orijentirana na organizacijsku razinu.

Predložene metode za prikupljanje podataka potrebnih za određivanje vrijednosti nematerijalnih indikatora u skladu su sa zaključcima Aisenberga Ferenhofa i dr. [238], koji su na temelju pregleda brojnih postojećih okvira za mjerenje intelektualnoga kapitala ustanovili jasnu potrebu za operacionalizacijom različitih mjera trećeg reda u kontekstu intelektualnoga kapitala. Iako je tijekom godina predložen velik broj metrika, ostaje dojam da se one uglavnom temelje na lako dostupnim podacima [39], [211], a ne na informacijama koje je potrebno skupiti za prikaz aktualnosti projekta. U disertaciji su prikazani indikatori i pripadajuće metode prikupljanja za praćenje dnevnih i tjednih aktivnosti koji omogućuju longitudinalne studije evolucije intelektualnoga kapitala.

2) *Provjera informacijskog toka metode.* Poštujući pravila izrade indikatora izvedbe, jasno je definiran pristup za prikupljanje podataka i preslikavanje prikupljenih podataka u vrijednosti indikatora. Iako je omogućena analiza pojedinačnih indikatora, provođenjem agregacije nudi se mogućnost određivanja agregirane vrijednosti nematerijalnih indikatora. Prvi su skup vrijednosti potreban za izračun agregirane vrijednosti težinski faktori koji su određeni na temelju prethodno izrađene mreže indikatora, a drugi su skup pojedinačne vrijednosti indikatora. Matematička pozadina Metode potencijala [131] omogućuje izračun težinskih faktora nematerijalnih indikatora, a pravila preslikavanja (poglavlje 5.5) omogućuju izračun normaliziranih vrijednosti indikatora. Diferencijalno ponderirana linearna agregacija tih dvaju skupova vrijednosti omogućuje izračun agregirane vrijednosti za svaki element IK-a na individualnoj i timskoj razini.
3) *Upotreba primjera.* Kako bi se provjerila prikladnost i upotrebljivost metode za predviđenu namjenu, potrebno je provesti primjer. Upotrebom primjera moguće je ustanoviti može li se predloženi pristup primijeniti za namijenjeni problem te ispunjava li namijenjenu svrhu u smislu unutarnje konzistentnosti. U 6. poglavlju prikazane su vrijednosti indikatora te analizirane njihove veze na temelju stvarnih vrijednosti prikupljenih aplikacijom za uzorkovanje rada i anketama. Također, prikazan je postupak određivanja agregirane vrijednosti korištenjem stvarnim prikupljenim podacima. Dakle, nakon upotrebe primjera može se potvrditi da predložena metoda ispunjava namijenjenu svrhu u okviru unutarnje konzistentnosti.

Provjera vanjske relevantnosti također se sastoji od triju koraka:

4) *Potvrđivanje korisnosti metode upotrebom primjera.* Cilj je ovoga koraka potvrđivanje koliko pojedini indikatori zadovoljavaju namijenjenu svrhu, tj. omogućuju li oni praćenje onih segmenata za koje su namijenjeni u smislu vanjske relevantnosti. Ovaj korak validacije iznimno je važan jer je velik broj metoda i alata u području razvoja tehničkih sustava razvijen u „izolaciji“ [239].

   Na temelju dobivenih rezultata može se uočiti da indikatori većinom na zadovoljavajući način prikazuju perspektive za koje su namijenjeni. Prije početka studije slučaja, provedene su brojne diskusije s članovima dviju tvrtki u kojima je potvrđena važnost i razumijevanje indikatora. Nakon provedene studije slučaja, razgovarano je s članovima tima koji su sudjelovali u uzorkovanju i anketama te je potvrđena upotrebljivost i primjenljivost indikatora u stvarnom okruženju. Osim

članovima tima, rezultati su prikazani i upravi razvojne tvrtke u kojoj je provedena studija slučaja. Kao potvrda korisnosti metode može se navesti nastavak istraživanja u suradnji s navedenom organizacijom radi daljnjeg praćenja i unapređenja timskog rada i upravljanja razvojnim projektima.

Poslije provedene studije slučaja može se ustanoviti da su indikatori relevantnosti informacije jedini koji ne daju dovoljno dobru povratnu informaciju voditelju projekta. Naime, zbog manjeg broja uzorkovanih točaka s pojedinom prirodom transformacije informacije, vrijednosti indikatora nisu jasne. Također, u raspravama poslije razdoblja uzorkovanja sudionici su izjavili da u pojedinim situacijama nisu znali kako bi ocijenili relevantnost informacije. Stoga se u daljnjem istraživanju zahtijeva detaljnije objašnjenje pojma relevantnosti informacije ili izbacivanje indikatora koji sadržavaju navedenu dimenziju.

Nakon studije slučaja s popisa indikatora uklonjen je indikator relevantnosti pojedinačnih kompetencija za pojedini zadatak, s obzirom na česte promjene aktivnosti sudionika.

Nadalje, iako indikatori prikupljeni u drugom dijelu ankete upućuju na jače i slabije strane analiziranog tima, moguće je da bi upotreba veće skale (od 1 do 10) omogućila bolje razlikovanje odgovora i bolji uvid u postojeće stanje unutar analiziranog tima. Također, upotrebom skale od 1 do 10 u anketi izbjegla bi se potreba za normalizacijom vrijednosti [183].

Indikatore za koje su podaci trebali biti prikupljeni integracijom s korporativnim IT sustavima potrebno je detaljno razmotriti. U pojedinim razvojnim organizacijama traženi podaci nisu dostupni zbog nedostatka praćenja navedenih parametara ili su pohranjeni u korporativnim bazama podataka koje nisu u računalnom obliku. U trenutačnome modelu agregacije indikatori, za koje se podaci prikupljaju integracijom s korporativnim sustavima, zanemaruju se što znatno utječe na agregirane vrijednosti kategorija. Ipak, s obzirom na velik broj indikatora, agregirane su vrijednosti opravdale svoju svrhu pružajući širu sliku određenog elementa IK-a.

5) *Potvrđivanje korisnosti primjene metode.* S obzirom na veliku problematiku prikupljanja podataka u stvarnim organizacijama tijekom duljeg razdoblja, radi jednostavnijeg pristupa za prikupljanje podataka izrađena je aplikacija za mobilne uređaje. Robinson [99] je već prije dokazao upotrebljivost uzorkovanja rada u kontekstu razvoja tehničkih sustava, ali je za ovo istraživanje bilo potrebno razviti

novu aplikaciju za mobilne uređaje te prenamijeniti, preformulirati i kreirati nove izbornike u aplikaciji. Za prikupljanje podataka o aktivnostima razvoja tehničkih sustava uglavnom se koriste opservacijske studije [195] ili *ex-post* (na kraju dana ili tjedna) izvještavanje. Upotreba uzorkovanja rada za prikupljanje podataka, u kontekstu određivanja nematerijalnih indikatora, inovativna je. Time je omogućen pristup prije nedostupnim podacima te se zbog praktičnosti aplikacije omogućuje prikupljanje podataka u duljim razdobljima.

Predloženi nematerijalni indikatori daju dodatnu vrijednost voditeljima projekata, ali pri potvrđivanju njihove korisnosti u svakodnevnoj primjeni potrebno je uzeti u obzir ograničenja implementacije. Na početku je važno napomenuti sva ograničenja svojstvena predloženim pristupima prikupljanja podataka – uzorkovanju rada (poglavlje 5.2), anketama (poglavlje 5.3) i integraciji s korporativnim informacijskim sustavima (poglavlje 5.4).

Iako je aplikacija za uzorkovanje rada osmišljena tako da omogućuje jednostavan i praktičan način unošenja podataka vezan za realno izvođenje aktivnosti, ovakav pristup od sudionika zahtijeva dodatan napor. Dok pri provođenju ankete ili prikupljanjem podataka iz korporativnih IT sustava ovakva problematika ne postoji, uzorkovanje rada zahtijeva od sudionika svakodnevno višekratno unošenje podataka te ih prekida u trenutačnu izvođenju aktivnosti. U duljim razdobljima uzorkovanja rada potrebno je razmotriti optimalan broj podsjetnika po danu za svakog sudionika. Prikupljanje podataka koje zahtijeva toliko intenzivan angažman sudionika obično je popraćeno određenim oblicima ekstrinzične motivacije (npr. naknada). Naime, ako bi razdoblje uzorkovanja trajalo dulje, bila bi upitna motivacija sudionika za unošenje podataka.

U provedbi ovog pristupa prikupljanja podataka dodatan je problem podrška upravljačke strukture organizacije s naglaskom na provođenje 360-stupanjske procjene izvedbe i uzorkovanja rada.

6) *Razmatranje korisnosti metode u širem kontekstu.* Uzimajući u obzir dosad provedeno istraživanje, može se opravdati i potvrditi uporaba pristupa provedenom studijom slučaja te tako utvrditi da su predloženi model i metoda valjani na temelju empirijskog istraživanja. Kao što je već istaknuto, analizirani se tim bavio razvojem upravljačkih sustava za prijevozni i energetski sektor. S obzirom na općenitost indikatora, može se pretpostaviti da se predloženi pristup praćenja nematerijalnih indikatora može

primijeniti pri razvoju tehničkih sustava i u drugim sektorima. Također, moguće je pretpostaviti da je ovakav sustav praćenja i vrednovanja nematerijalnim indikatorima primjenjiviji u većim i kompleksnijim organizacijama koje se bave razvojem tehničkih sustava, s naglaskom na znanjem intenzivne organizacije, u kojima je intelektualni kapital iznimno važan.

Iako je preporuka da se 4., 5. i 6. korak provode upotrebom kvantitativnih metrika [23], s obzirom na prirodu istraživanja takav tip validacije nije bio moguć. Stoga je provedeno i dodatno vrednovanje predloženih nematerijalnih indikatora usporedbom s rezultatima dobivenim analizom organizacijskih rizika.

7.3. Vrednovanje dobivenih rezultata usporedbom s metodom za analizu organizacijskih rizika

Analiza organizacijskih rizika provedena je korištenjem programskim paketom *ORA – Organisational Risk Analyser* [24]. Rezultati dobiveni ORA-om upozorit će na ključne i kritične sudionike, kompetencije, resurse i aktivnosti koji čine organizacijsku strukturu. Budući da je za provođenje takve analize potreban ulazni skup podataka koji se prikazuje u obliku metamatrice, kao preduvjet se nameće njezino popunjavanje na temelju prikupljenih podataka. Namjena analize organizacijskih rizika nije isključivo praćenje elemenata intelektualnoga kapitala, ali dobiveni se rezultati mogu upotrijebiti za potvrdu vrijednosti nematerijalnih indikatora.

7.3.1. Priprema metamatrice

Prije opisa pojedinačnih podmatrica, potrebno je objasniti elemente organizacijske strukture koji čine metamatricu (poglavlje 3.4).

Za potrebe ove validacije, *agenti* će biti sudionici studije slučaja. Sudionici su svi članovi tima, ali i svi ostali pojedinci s kojima su članovi tima bili u interakciji tijekom studije slučaja.

Za potrebe druge domene *znanje* koristit će se podaci o kompetencijama prikupljeni anketom. Prema Carley i Remingiju [24], znanje se u metamatrici može prikazati u obliku kompetencija pojedinih sudionika.

Za treću domenu, *resursi,* poslužili su podaci prikupljeni uzorkovanjem rada, a koji objedinjuju način komunikacije te resurse upotrijebljene tijekom provođenja aktivnosti.

Za provođenje validacije, posljednja domena bit će *aktivnosti*. Radi boljeg razlikovanja razvojnih aktivnosti, svakoj je od njih dodijeljen pripadajući tip rada (ITR – individualni tehnički rad, IAR – individualni administrativni rad, TR – timski rad) i kontekst (elektronički dio, softverski dio, mehanički dio itd.) što je u konačnici rezultiralo s 110 različitih razvojnih aktivnosti.

Za ispunjavanje pojedinačnih matrica M1-M10 (Tablica 3-1) poslužili su podaci prikupljeni uzorkovanjem (M1, M3, M4, M9, M10) i anketom (M2) te ekspertnim znanjem (M5, M6, M7, M8). Prikupljeni podaci mapirani su na matrice poštujući pravila navedena u nastavku.

Matrica M1 (*sudionici* x *sudionici*), koja označava interakciju između pojedinih sudionika, ispunjena je koristeći se podacima prikupljenim uzorkovanjem rada (izbornik *suradnici u aktivnosti* u aplikaciji). Za postavljanje veze između dvaju sudionika jedan je sudionik morao zabilježiti sudjelovanje drugog sudionika (ili više njih) s kojim je u interakciji. Ako je kao oblik komunikacije navedena videokonferencija ili licem u lice, postavljena je veza između svih sudionika (zbog pretpostavke da su tada svi sudionici bili u interakciji). Radi dobivanja simetrične matrice, veze su neusmjerene. Težina veze definirana je kao ukupan broj interakcija između određenih sudionika.

Na temelju zapisa o načinu provođenja aktivnosti (izbornik *način provođenja aktivnosti* u aplikaciji) dobivenih uzorkovanjem rada, može se kreirati matrica M3 (*sudionici* x *resursi*). Pošto je sudionik zabilježio korištenje pojedinim resursom, stvorena je veza između resursa i njega. Ako je, pri tome, sudionik naveo i druge sudionike za istu aktivnost, postavljene su veze između svih sudionika i navedenog resursa.

Na isti način kao i matrica M3, kreirana je i matrica M4 (*sudionici* x *aktivnosti*). Dakle, na temelju zapisa o tipu razvojne aktivnosti, definirana je veza između sudionika i aktivnosti. Ako je zabilježeno sudjelovanje većeg broja sudionika u nekoj aktivnosti, definirane su veze između svih sudionika i aktivnosti. Težina veze u objema matricama (M3 i M4) definirana je kao broj veza između određenog sudionika i resursa, odnosno sudionika i aktivnosti.

Za kreiranje matrice M9 (*aktivnosti* x *resursi*) bilo je potrebno postaviti nekoliko pravila. Ako je sudionik naveo da se pri izvršavanju određene aktivnosti koristio određenim resursom, stvorena je veza između aktivnosti i resursa. Težina veze između aktivnosti i resursa definirana je kao ukupan broj upitnika na koje je odgovoreno, a pri kojima su sudionici naveli dotičnu kombinaciju. Također, težina je veze nepromjenjiva ako je više sudionika sudjelovalo u istoj aktivnosti.

Matrica 10 (*aktivnosti* x *aktivnosti*) posljednja je koja je kreirana na temelju podataka prikupljenih uzorkovanjem rada. Inicijalno su podaci podijeljeni na projekte te je za svaki od njih bio izrađen gantogram aktivnosti. Trajanje aktivnosti izraženo je u danima i definirano kao razlika između posljednjeg i prvog dana kad je zabilježena određena aktivnost. U svakom su projektu veze stvorene tako da je određena aktivnost povezana sa svim aktivnostima koje su završile prije njezina početka. Za razliku od M1, u ovoj su matrici veze usmjerene te upućuju na redoslijed izvršavanja zadataka. Matrica M10 zatim je kreirana agregirajući sve projekte, radi izračuna konačne težine identificiranih veza. Ako je unutar svakog od n uzorkovanih projekata određena aktivnost prethodila drugoj, težina veze između tih aktivnosti iznosit će n.

Korištenjem podacima o ocjenama kompetencija dobivenih anketom kreirana je matrica M2 (*sudionici* x *kompetencije*). Svakom sudioniku dodijeljene su njegove prosječne ocjene kompetencija te su tako ostvarene veze između sudionika i kompetencija.

Matrica M5 osmišljena je na temelju dijela mreže indikatora čije su kreiranje i validacija objašnjeni u poglavlju 4.2. Dio mreže koji se sastoji isključivo od indikatora elementa *kompetencije i znanje* na individualnoj razini upotrijebljen je za kreiranje matrice M5.

Preostale tri matrice, M6, M7 i M8, izrađene su na temelju pregleda literature i razgovora sa sudionicima uzorkovanja poslije provođenja uzorkovanja.

7.4. Rezultati analize organizacijskih rizika

Nakon provedenog proračuna svojstava metamatrice, dobivene su ukupne mjere za izvedbu elemenata organizacijske strukture (Tablica 7-1).

Rezultati dobiveni analizom u ORA-i uključuju velik broj mrežnih mjera koje su korištene za analizu svake matrice pojedinačno, ali i za analizu većeg broja matrica. Svaka matrica je prikaz određene mreže.

Za sve upotrijebljene mrežne mjere ukratko će se objasniti njihovo značenje u kontekstu zadane domene. Zbog povjerljivosti podataka, rezultati će biti prokomentirani samo za cijeli tim, a ne pojedinačno. Također, vrijednosti pojedinih mjera bit će objašnjene s pomoću normaliziranih vrijednosti.

Tablica 7-1. Vrijednosti ukupnih mjera izvedbe organizacije

Ukupna kompleksnost gustoća metamatrice kao cjeline	0,181
Društvena gustoća gustoća komunikacijske mreže M1	0,787
Društvena gustoća s težinskim faktorom gustoća komunikacijske mreže M1 uzimajući u obzir težinu veza	0,065
Društvena fragmentacija fragmentacija komunikacijske mreže M1 (u smislu broja čvorova koji nisu povezani)	0
Efikasnost komunikacije Koliko sudionici komuniciraju kad je to potrebno za uspješno obavljanje aktivnosti. Savršeno slaganje zahtjeva simetričnu M1 komunikacijsku mrežu.	1
Efikasnost znanja Mjera sličnosti između znanja koje je pridruženo aktivnosti preko sudionika i znanja koje je zahtijevano za obavljanje aktivnosti. Savršena efikasnost nastaje kad sudionici imaju pristup znanju koje je potrebno za obavljanje aktivnosti.	1
Uspješnost izvedbe Mjera koliko uspješno sudionici izvode dodijeljene aktivnosti temeljena na pristupu znanju i resursima.	0,473
Prosječna brzina komunikacije Prosječna brzina kojom bilo koja dva agenta mogu biti u interakciji. Ova je mjera inverzna od prosječnoga najkraćeg puta bilo kojeg para čvorova. Ako čvor nije dostupan drugom čvoru, tada je minimalna brzina komunikacije 0.	0,417
Promjer komunikacije (Communication Network Diameter) Maksimalni najkraći put između bilo koja dva čvora u mreži s N čvorova. Ako postoji čvor koji nije dostupan drugom čvoru, tada je promjer matematički gledano beskonačan.	4

7.4.1. Analiza rezultata za domenu *agenti*

Prva upotrijebljena mjera u ovoj domeni naziva se „lider u nastajanju“ (engl. *emergent leader*) te omogućuje mjerenje ukupnog kognitivnog truda koji svaki sudionik troši na izvršavanje svojih zadataka, povezivanje različitih sudionika itd [24]. Sudionici koji imaju više vrijednosti prema ovoj mjeri, nisu samo povezani s velikim brojem sudionika, aktivnosti, kompetencija i resursa, već su uključeni u kompleksnije zadatke za koje možda navedeni sudionici nemaju sve potrebne resurse i znanje te stoga moraju koordinirati drugima. Na isti je način definirana i mjera „najmanje integrirani sudionik“, ali kao rezultat nudi tri najlošija sudionika prema mjeri „lider u nastajanju“. Za izračun vrijednosti kao ulazni podaci upotrebljavaju se sve mreže koje uključuju sudionike (*sudionici* x *sudionici, sudionici* x *kompetencije, sudionici x resursi, sudionici x aktivnosti*), ali i mreže *resursi x aktivnosti* i *kompetencije x aktivnosti*. Prema mjeri „lider u nastajanju“, dva sudionika imaju vrijednost jednu standardnu devijaciju iznad prosjeka što označava njihovu utjecajnost u timu, a s druge

se strane ni jedan sudionik ne ističe slabom integriranošću.

Sljedeća mjera omogućuje identifikaciju sudionika koji su „u toku“ (engl. *in-the-know*). Sudionici koji su „u toku“ jesu oni koji su povezani s brojnim drugim sudionicima i zbog svoje pozicije imaju pristup idejama i razmišljanjima drugih. Za izračun mjere upotrebljava se ukupna centralnost stupnja u mreži *sudionici* x *sudionici*. Sudionici koji su visoko rangirani prema ovoj mjeri imaju mnogo veza s ostalim sudionicima u mreži. Osim dvojice prije spomenutih sudionika koji se ističu kao „lideri u nastajanju“, prema mjeri koliko je pojedini sudionik „u toku“ ističe se i još jedan dodatni sudionik.

Za bilo koji čvor u mreži, izlazne su veze poveznice između promatranog čvora i ostalih čvorova. Na primjer, u mreži *sudionici x kompetencije* broj izlaznih veza određenog sudionika jednak je broju kompetencija s kojim je povezan. Sudionici s visokom izlaznom centralnosti stupnja u kontekstu kompetencija imaju više kompetencija te su povezani s više različitih kompetencija u usporedbi s ostalim sudionicima. Provedena analiza upućuje na dva sudionika koji se prema mjeri „sudionici s najviše znanja“ ističu visokom razinom kompetencija. Na isti način, iz mreže *sudionici x resursi,* može se odrediti koji sudionici upotrebljavaju više resursa te su povezani s više različitih resursa u usporedbi s ostalim sudionicima. Za mjeru „sudionici koji upotrebljavaju najviše resursa“ također se mogu uočiti tri sudionika sa znatno većim vrijednostima od prosjeka.

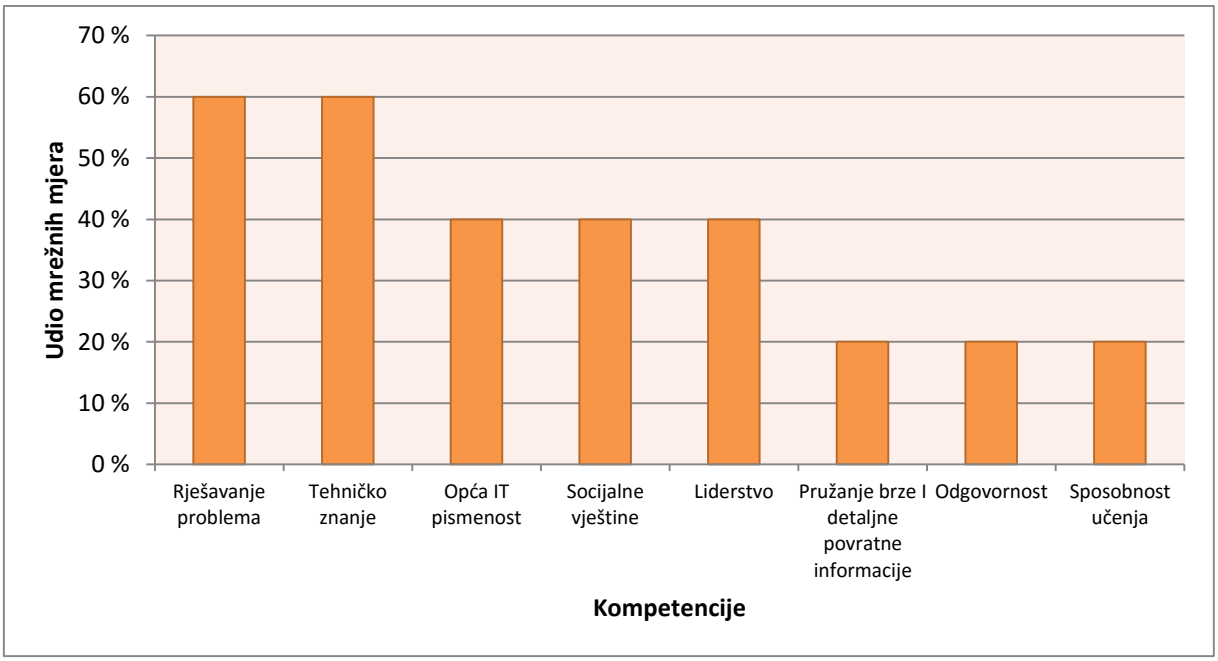
Također, može se upotrijebiti broj izrazitih klika kao mrežna mjera za određivanje skupina u analiziranom tima. Klika je definirana kao skupina triju ili više sudionika koji međusobno imaju mnogo veza, a relativno mali broj veza s ostalim sudionicima u drugim skupinama. Dva se sudionika ističu brojem klika, a jedan je od njih i prvi prema mjeri „potencijalno utjecajni sudionici“. Sudionici, koji bi potencijalno mogli imati velik utjecaj u timu, pozicionirani su na posredničkim vezama između skupina tako da mogu potencijalno utjecati na jednu ili drugu skupinu. Mjera „potencijalno utjecajni sudionici“ upućuje na sudionike koji se pojavljuju u velikom broju najkraćih putova između drugih sudionika. Za izračun mjere „potencijalno utjecajni sudionici“ upotrebljava se centralnost međupoloženosti u mreži *sudionici* x *sudionici*. Korištenjem mjerom „potencijalno utjecajni sudionici“, unutar analiziranog tima mogu se identificirati dva sudionika koji imaju vrijednost veću od jedne standardne devijacije iznad prosjeka te se nameću kao potencijalno utjecajni.

Pojedine mjere služe za određivanje središta ili autoriteta unutar mreže. Sudionici, koji se ponašaju kao središta, šalju informacije većem broju ostalih sudionika od kojih velik broj

drugih sudionika prima informacije (centralnost središta). Tehnički gledano, sudionik se smatra središtem ako su njegove izlazne veze prema sudionicima koji imaju mnogo poveznica s drugim sudionicima. S druge strane, sudionik se smatra autoritetom ako su njegove ulazne veze od sudionika koji imaju mnogo poveznica s drugim sudionicima. Čvor se smatra autoritetom onoliko koliko njegovi ulazni čvorovi imaju izlaznih čvorova (centralnost autoriteta). Za određivanje središta ili autoriteta unutar domene *agenti* upotrebljava se mreža *sudionici* x *sudionici*. Ista se tri sudionika ističu „kao središta“ i „kao autoriteti“ u analiziranom timu te jedini imaju vrijednosti jednu standardnu devijaciju iznad prosjeka prema objema mjerama.

7.4.2. Analiza rezultata za domenu *znanje*

Na slici (Slika 7-2) prikazan je poredak najbolje rangiranih kompetencija prema mrežnim mjerama. Vrijednosti na slici (Slika 7-2) pokazuju postotak mrežnih mjera u kojima je pojedina kompetencija svrstana među tri s najvećom vrijednosti.



Slika 7-2. Kompetencije poredane po utjecaju prema mjerama iz org. metamatrice

Prva mjera koja se upotrebljava za domenu *znanje* naziva se „dominantne kompetencije“ i za njezin se izračun upotrebljava ukupna centralnost stupnja. Sve unimodalne (npr. *kompetencije x kompetencije*) i bimodalne (npr. *sudionici x kompetencije*) mreže koje uključuju kompetencije poslužile su za izračun ove mjere. Najdominantnije su kompetencije *tehničko znanje* i *rješavanje problema* (Tablica 7-2).

Tablica 7-2. Pregled mjera za domenu *znanje* (prvi dio)

Redoslijed	Dominantne kompetencije	Najpotrebnije kompetencije
1	tehničko znanje (0,515)	tehničko znanje (0,682)
2	rješavanje problema (0,411)	liderstvo (0,318)
3	opća IT pismenost (0,358)	socijalne vještine (0,264)
4	specifična IT pismenost (0,346)	rješavanje problema (0,209)
5	pružanje brze i detaljne povratne informacije (0,344)	kreativnost (0,191)

Pomoću izlazne centralnosti stupnja omogućeno je detektiranje dostupnih i potrebnih kompetencija. Dakle, u transponiranoj matrici *sudionici x kompetencije*, broj izlaznih veza pojedine kompetencije označava broj sudionika s kojima je povezana. Potrebne se kompetencije mogu identificirati opet korištenjem izlaznom centralnosti stupnja, ali unutar mreže *kompetencije* x *aktivnosti*. U analiziranom su timu najpotrebnije kompetencije *tehničko znanje* i *liderstvo*, a najdostupnije *opća IT pismenost* i *rješavanje problema.*

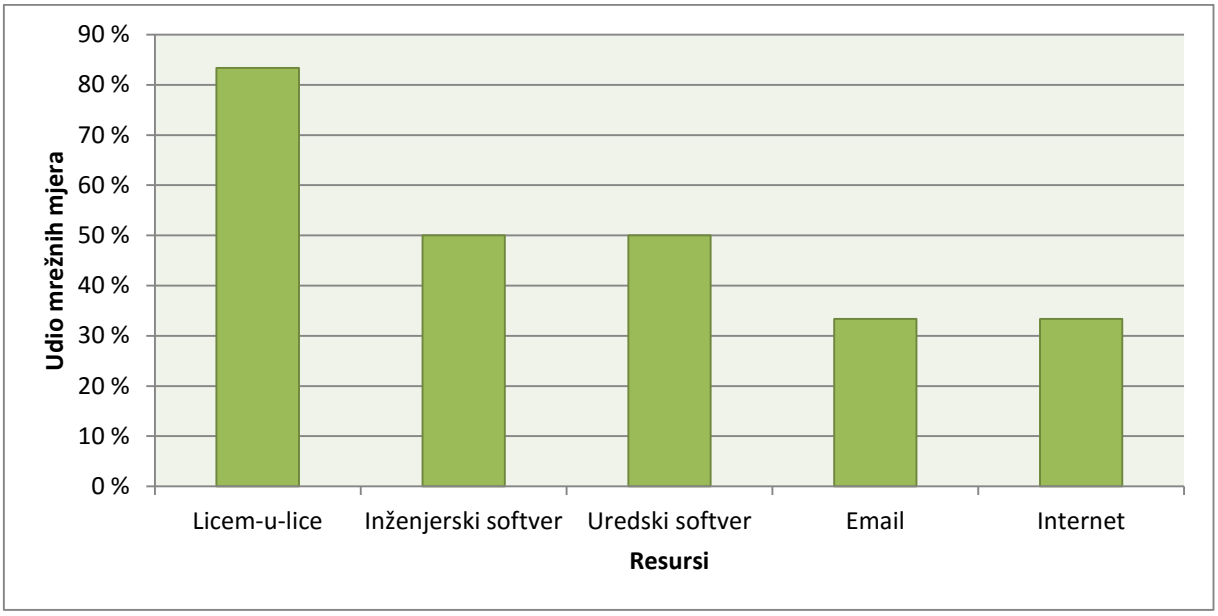
Korištenjem mjerom ulazne centralnosti stupnja na mreži *sudionici* x *kompetencije* omogućuje se određivanje najslabijih kompetencija na razini tima, a to su *donošenje odluka* i *socijalne vještine* (Tablica 7-3).

Tablica 7-3. Pregled mjera za domenu *znanje* (drugi dio)

Redoslijed	Najdostupnije kompetencije	Najslabije kompetencije
1	opća IT pismenost (0,555)	donošenje odluka (0,419)
2	rješavanje problema (0,546)	socijalne vještine (0,435)
3	odgovornost (0,542)	kreativnost (0,487)
4	tehničko znanje (0,533)	pružanje brze i povratne informacije (0,489)
5	sposobnost učenja (0,515)	specifična IT pismenost (0,506)

7.4.3. Analiza rezultata za domenu *resursi*

Na slici (Slika 7-3) prikazan je poredak najbolje rangiranih resursa prema mrežnim mjerama. Vrijednosti na slici (Slika 7-3) pokazuju udio mrežnih mjera u kojima je pojedini resurs svrstan među tri s najvećom vrijednosti. Kao i u domeni *znanje*, prva je mjera ukupan zbroj svih veza pojedinog čvora te u domeni *resursi* govori o „dominantnosti“ pojedinog resursa. Sve unimodalne (npr. *resursi x resursi*) i bimodalne (npr. *sudionici x resursi*) mreže koje uključuju resurse poslužile su za izračun ove mjere.



Slika 7-3. Resursi poredani po utjecaju prema mjerama iz org. metamatrice

Za potrebe određivanja najpotrebnijih resursa opet je poslužila i izlazna centralnost stupnja, ali ovaj put na mreži *resursi x aktivnosti* (Tablica 7-4).

Tablica 7-4. Pregled mjera za domenu *resursi*

Redoslijed	Dominantni resursi	Najpotrebniji resursi
1	inženjerski softver (0,064)	inženjerski softver (0,047)
2	licem u lice (0,036)	licem u lice (0,016)
3	uredski softver (0,021)	uredski softver (0,015)
4	ostali načini – individualni tehnički rad (0,015)	ostali načini – individualni tehnički rad (0,011)
5	internet (0,008)	internet (0,005)

Najdominantnijim i najpotrebnijim resursima nameću se inženjerski i uredski softver. Iako je svrstan pod resurse, *licem u lice* način je komunikacije koji je najčešće upotrijebljen tijekom studije slučaja.

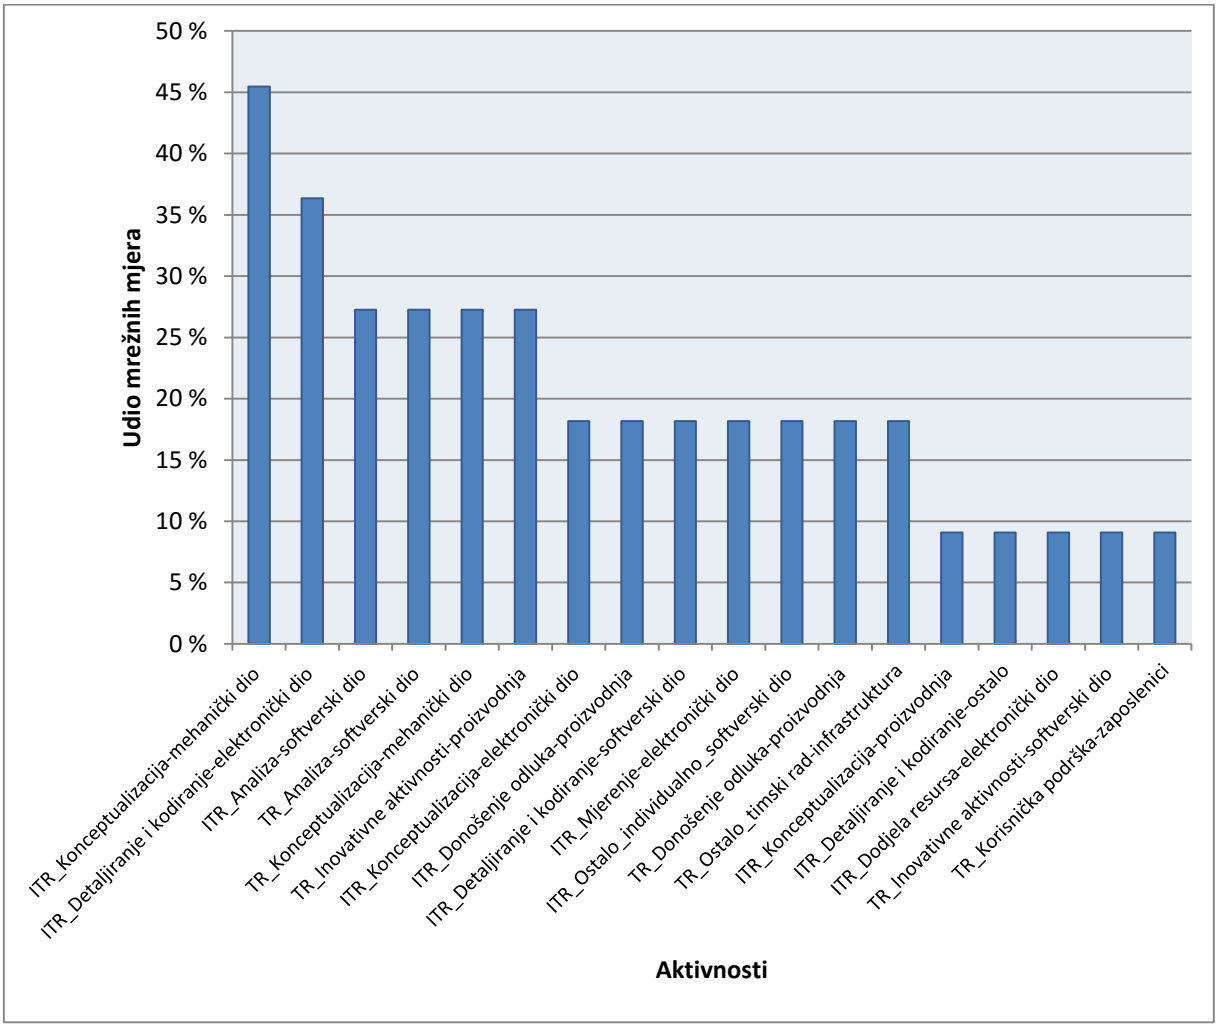
7.4.4. Analiza rezultata za domenu *aktivnosti*

Na slici (Slika 7-4) prikazan je poredak aktivnosti koje se ponavljaju kao najbolje svrstane prema mrežnim mjerama. Vrijednosti na slici (Slika 7-4) pokazuju postotak mrežnih mjera u kojima je pojedina aktivnost svrstana među pet s najvećom vrijednosti.

Korištenjem ukupnom centralnosti stupnja (normalizirani zbroj ulazne i izlazne centralnosti stupnja), mogu se odrediti aktivnosti koje imaju najviše veza s ostalim aktivnostima tijekom

uzorkovanja. Dobiveni rezultati upućuju na centralnost timskih inovativnih aktivnosti (u kontekstu proizvodnje) i na individualne aktivnosti analize (u kontekstu softverskog dijela proizvoda).

Kao i u domeni *agenti*, upotrijebljene su mjere koje proučavaju ponašanje određenog čvora (u ovom slučaju aktivnosti) kao središta (centralnost središta – engl. *hub*), odnosno kao autoriteta. Aktivnost se smatra središtem onoliko koliko njezini izlazni čvorovi imaju mnogo ulaznih čvorova, a autoritetom onoliko koliko njezini ulazni čvorovi imaju mnogo izlaznih čvorova. Najistaknutije su aktivnosti prema ovim dvjema mjerama individualne aktivnosti konceptualizacije i timske inovativne aktivnosti (Tablica 7 5).



Slika 7-4. Aktivnosti poredane po utjecaju prema mjerama iz org. metamatrice

Tablica 7-5. Pregled mjera za domenu *aktivnosti*

Središnje aktivnosti	Aktivnosti „kao središte“	Aktivnosti „kao autoritet“
TR_inovativne aktivnosti – proizvodnja (0,139)	ITR_konceptualizacija – mehanički dio (0,325)	TR_inovativne aktivnosti – proizvodnja (0,376)
ITR_analiza –softverski dio (0,128)	TR_konceptualizacija – mehanički dio (0,325)	ITR_ostalo_individualno –softverski dio (0,354)
ITR_konceptualizacija-mehanički dio (0,128)	ITR_detaljiranje i kodiranje –elektronički dio (0,237)	ITR_analiza-softverski dio
TR_analiza – softverski dio (0,128)	ITR_donošenje odluka – proizvodnja (0,237)	TR_analiza – softverski dio (0,351)
TR_konceptualizacija – mehanički dio (0,128)	TR_donošenje odluka – proizvodnja (0,237)	TR_ostalo_timski – infrastruktura (0,308)

7.5. Usporedba rezultata predložene metode s rezultatima dobivenim ORA-om

Rezultati dobiveni analizom organizacijske metamatrice povezuju četiri različite perspektive organizacije: zaposlenici, znanja, resursi i aktivnosti. Praktična i jednostavna analiza velikog skupa podataka sadržanog u metamatrici omogućena je korištenjem brojnim mrežnim mjerama. U kontekstu analize izvedbe sudionika, indikatori daju sliku pojedinih aspekata intelektualnoga kapitala, a mrežna analiza dobivena ORA-om obuhvaća elemente organizacijske strukture na koje indikatori upućuju. Zbog toga se rezultati dobiveni ORA-om mogu upotrijebiti za validaciju rezultata.

Izračun ključnih entiteta pomoću ORA-e upućuje na važnost trojice sudionika. S obzirom na njihovu interakciju s drugim sudionicima, ali i uključenost u kompleksnije zadatke koji zahtijevaju dodatnu koordinaciju resursa, profilirali su se kao ključni sudionici analiziranog tima. Navedeni su sudionici ujedno vodeći prema različitim nematerijalnim indikatorima *komunikacije i razmjene informacija* na individualnoj razini, ali i prema indikatorima *kompetencije i znanja* na individualnoj razini. Iz analize također proizlazi da u analiziranom timu neke aktivnosti izvršavaju samo tri sudionika. Takva raspodjela aktivnosti utječe na važnost spomenutih sudionika u timu iz druge perspektive jer govori o njihovoj mogućoj „nezamjenjivosti“ za dane aktivnosti. Rezultati analize dobivene ORA-om također upućuju na najmanje integrirane članove tima, uzimajući u obzir njihovu interakciju s drugim članovima, razinu ekspertiza te kompleksnost zadataka na kojima sudjeluju. Najmanje integrirani sudionici mogu se identificirati i korištenjem predloženim nematerijalnim indikatorima

(*komunikacija i razmjena informacija* na individualnoj razini, *kompetencije i znanje* na individualnoj razini) jer imaju najniže vrijednosti indikatora. Mreža M1 (*sudionici* x *sudionici*) omogućuje analizu na temelju interakcija između pojedinih sudionika, ali ne govori o tipu timskog rada u kojem je ostvarena. Vrijednosti dobivene indikatorima CI_IN3, CI_IN4 i CI_IN5 upućuju na udjele pojedinog tipa timskog rada, a u ulaznoj su matrici M1 različiti tipovi timskog rada uneseni kumulativno.

Budući da se u literaturi [149] sugerira korištenje Simmelovih veza za određivanje povezanosti između članova tima, indikator CI_TM4 bio je definiran na taj način. Upotreba te mrežne mjere kao indikatora potvrđena je i rezultatima ORA-e.

Analizirajući perspektivu znanja korištenjem mrežnom analizom, najvažnije su kompetencije *tehničko znanje* i *rješavanje problema*. Tip i tematika projekta najviše zahtijevaju odgovarajuću razinu *tehničkog znanja* jer velik broj aktivnosti zahtijeva upravo takve kompetencije. Velik broj sudionika ima visoku razinu *opće IT pismenosti* pa je ta kompetencija najdostupnija u timu. Usporedbom rezultata dobivenih ORA-om s vrijednostima indikatora opet se mogu potvrditi njihovi rezultati. Mrežne mjere upućuju na iste dominantne i potrebne kompetencije te sugeriraju koje kompetencije treba unaprijediti. Ipak, indikatori kategorije *kompetencije i znanje* na individualnoj razini daju dodatan uvid u vrijednosti kompetencija za svakog sudionika. Analiza kompetencija provedena u ORA-i daje drukčiji pogled na njihov međusoban utjecaj i vezu s aktivnostima za koje su te kompetencije potrebne. Na taj način, osim indikatora koji upućuju na razinu pojedinačnih kompetencija u timu, ORA-ina analiza obuhvaća i veze kompetencija s ostalim elementima organizacijske strukture (resurse i aktivnosti) i upućuje na kritične entitete organizacije.

Vrijednosti indikatora za perspektivu načina provođenja aktivnosti također su potvrđene analizom resursa u sklopu ORA-e. Najčešći je i najkorišteniji način provođenja aktivnosti inženjerski softver i komunikacija licem u lice. Na taj način uspostavljena je i veza s indikatorima CK_TM5, ali i sa CI_IN8 i CI_IN11.

Iz rezultata analize mreže aktivnosti inovativne su aktivnosti proizišla kao one s najviše veza s drugim zadacima, a slijede je aktivnosti analize i konceptualizacije. Iako je iz analize rezultata uzorkovanja već poznata uloga inovativnih aktivnosti, ova analiza upućuje na njezinu centralnost u smislu povezivanja više različitih aktivnosti. Ipak, najveći dio sudionika radi na konceptualizaciji vezanoj za različite aspekte proizvoda te je time i najveći dio pojedinačnih

aktivnosti vezan uz taj tip razvojne aktivnosti. Zbog apstraktnosti pojedinih mjera upotrijebljenih za ovu analizu otežana je interpretacija mrežne analize aktivnosti.

Indikatori relevantnosti informacije i prirode transformacije informacije daju dodatan uvid u tip interakcije između sudionika, ali nisu uključeni u metamatricu. Budući da podaci o relevantnosti informacije i prirodi transformacije informacije nisu uneseni u metamatricu, ne mogu se usporediti i potvrditi rezultati dobiveni tim nematerijalnim indikatorima. Podaci o motivaciji pojedinog sudionika također nisu integrirani u metamatricu pa ni tu perspektivu nije bilo moguće analizirati ORA-om.

Potrebno je istaknuti da pri ovom vrednovanju rezultati dobiveni ORA-om daju sliku o ključnim i kritičnim sudionicima, aktivnostima, resursima i znanju, no zbog zahtjevne matematičke pozadine otežana je interpretacija pojedinih mjera. Rezultati dobiveni ORA-om svedeni su na normalizirane vrijednosti kako bi se omogućilo rangiranje sudionika, aktivnosti, resursa i znanja te lakša interpretacija dobivenih rezultata. Potrebno je uzeti u obzir i prije navedene nedostatke svih metoda prikupljanja podataka koje su primijenjene za popunjavanje metamatrice. Ovaj je nedostatak uočen i u prikupljanju podataka za indikatore, ali važna je razlika u načinu obrade podataka. Također, potrebno je napomenuti da granične vrijednosti koje su u ORA-i često ne daju pravu povratnu informaciju o pojedinim iznimno dobrim ili lošim entitetima iz perspektive određene mjere.

Analiza u ORA-i napravljena je na skupu svih prikupljenih podataka (iako se mogla napraviti analiza za svaki dan) kako bi se općenito mogli potvrditi rezultati nematerijalnih indikatora. Prikazana analiza metamatrice svakako može poslužiti za validaciju nematerijalnih indikatora u gore opisanom kontekstu. Vrijednosti se indikatora za pojedine kategorije IK-a prilično dobro podudaraju s vrijednostima mrežnih mjera kojima se koristi ORA, iako je način njihova izračuna različit. Međutim, ORA-ina je namjena drukčija te je stoga nužno uzeti u obzir razlike, ali i zajedničke značajke ovih dvaju pristupa. Kao što je pokazano primjerima, uspoređujući ORA-ine mjere i predložene nematerijalne indikatore moguće je doći do zaključka da su navedeni pristupi komplementarni. Pojedini segmenti koji su obuhvaćeni indikatorima kao što je motivacija, kontekst aktivnosti ili tip rada nadopunjuju rezultate dobivene ORA-om jer ORA nije inicijalno namijenjena praćenju elemenata IK-a. S druge strane, vrijednosti dobivene ORA-om daju mnogo širu sliku ukupne organizacijske izvedbe, pa ona u pojedinim dijelovima nije toliko detaljna.

8. Zaključak

U završnom su poglavlju sažetak istraživanja, rasprava i smjerovi budućeg istraživanja. Odgovarajući na istraživačka pitanja postavljena u uvodnom poglavlju, objašnjeni su ishodi i doprinos provedenog istraživanja.

U radu su definirane značajke, prednosti i nedostaci postojećih pristupa za mjerenje i praćenje izvedbe IK-a i projekata razvoja tehničkih sustava. Budući da su utvrđeni nedostaci postojećih metoda, predloženi su nematerijalni indikatori za individualnu i timsku razinu u organizacijama. U ovoj je disertaciji osobito istaknuto stvaranje valjane i čvrste metodologije prikupljanja podataka te preslikavanje podataka u vrijednosti indikatora kako bi se definirali upotrebljivi i učinkoviti nematerijalni indikatori.

Za individualnu i timsku razinu nematerijalni su indikatori svrstani u četiri cjeline IK-a: *kompetencije i znanje, komunikacija i razmjena informacija, inovativnost i ideacija* te *motivacija i zadovoljstvo*. Nematerijalni indikatori u razvojnim projektima upotpunjuju tradicionalnu praksu upravljanja projektima te dodatno razjašnjavaju fenomene koji nastaju u socio-tehničkom okruženju (prijenos znanja, učenje, ali i rizike vezane za pojedince i sastav tima). Jednako tako, nematerijalni indikatori mogu uputiti na nezadovoljavajuću izvedbu projekta sa stajališta IK-a te dati pravodobnu povratnu informaciju voditelju projekta tijekom izvođenja projekta. Na temelju predloženih nematerijalnih indikatora i njihove nezadovoljavajuće izvedbe mogu se identificirati rizici ljudskoga i strukturnoga kapitala.

Za bolje razumijevanje nematerijalnih indikatora, na temelju ekspertnog znanja osmišljena je mreža njihova međuutjecaja. Poslije provedene statističke analize mreže nematerijalnih indikatora, identificirane zajednice indikatora potvrdile su jaku povezanost indikatora izvedbe na individualnoj razini s onima na timskoj razini u istoj kategoriji IK-a, ali su također uputile i na veze između elemenata IK-a na višoj razini.

Popis nematerijalnih indikatora poslužio je kao polazna točka za izradu ankete, razvoj aplikacije za uzorkovanje rada i osmišljavanje integracije s IT sustavima čime bi se omogućilo praćenje aktualne izvedbe pojedinaca i timova u realnom vremenu. Dok su ankete i integracija s postojećim IT sustavima prilično uobičajeni i uvriježeni pristupi za mjerenje nematerijalnih indikatora, uzorkovanje rada do sada nije korišteno u ovom kontekstu te nudi

brojne nove mogućnosti za kvantitativno i objektivnije prikupljanje podataka na individualnoj i timskoj razini.

Koristeći se analogijom s konceptom elektroničkog dnevnika (za samoizvještavanje), razvijena je aplikacija za uzorkovanje rada za mobilne uređaje. Aplikacija je osmišljena kao niz preddefiniranih izbornika koji omogućuju odabir jedne ili više opcija za pojedini kontekst uzorkovanja. Mobilna aplikacija za uzorkovanje rada omogućuje manje intruzivno prikupljanje podataka nužno za provođenje longitudinalnih studija u stvarnim okruženjima. Kontinuirano prikupljanje podataka vezano za izvođenje razvojnih aktivnosti glavni je preduvjet za proučavanje dugoročnih učinaka individualnog i timskog rada na poslovnu vrijednost organizacije i organizacijsku izvedbu u pogledu inovacija, rasta tržišta i kompetitivnosti. Osim uzorkovanja rada, provedene su i ankete u istoj skupini sudionika kako bi se dobili komplementarni podaci potrebni za utvrđivanje vrijednosti indikatora čija frekvencija promjene nije dnevna ili tjedna.

Studija slučaja provedena je u I&R tvrtki čije su istraživačke i razvojne djelatnosti vezane uz sustave za proizvodnju, distribuciju i transformaciju električne energije. Poslije provedene studije slučaja, analiza indikatora omogućila je detaljan uvid u izvođenje aktivnosti tijekom razvoja ugradbenih upravljačkih sustava te omogućila praćenje izvedbe nematerijalnih indikatora u razvojnim projektima u stvarnom vremenu.

Osim popisa i mreže nematerijalnih indikatora, definiran je i model agregacije koji omogućuje izračun agregiranih vrijednosti za elemente IK-a. Agregirane vrijednosti olakšavaju praćenje trenda pojedinog elementa IK-a, zbog smanjenja količine informacije koju voditelj projekta ili donositelj odluke treba obraditi. Ipak, za cjelovito praćenje nematerijalnog aspekata projekata predlaže se uporaba obaju pristupa – agregiranih i pojedinačnih vrijednosti nematerijalnih indikatora.

Postupak vrednovanja predložene metode bio je podijeljen na dva dijela – *vrednovanje izvedivosti i korisnosti metode* i *vrednovanje rezultata*. *Vrednovanje izvedivosti i korisnosti metode* obuhvaćalo je usporedbu s literaturom, upotrebu primjera i razmatranje primjene metode u širem kontekstu. Prvi korak vrednovanja potvrdio je da su pojedinačni indikatori pravilno postavljeni i da predložena metoda ispunjava svrhu u smislu unutarnje konzistentnosti i vanjske relevantnosti. Za potrebe *vrednovanja rezultata* nematerijalnih indikatora poslužila je usporedba s metodom za analizu organizacijskih rizika upotrebom organizacijske metamatrice (društvena mreža, mreža znanja, mreža resursa, mreža zadataka).

Rezultati dobiveni analizom organizacijskih rizika, potvrdili su dobivene rezultate nematerijalnih indikatora. S obzirom na drukčiju namjenu pristupa nematerijalnih indikatora i analize organizacijskih rizika može se zaključiti da su ova dva pristupa komplementarna.

8.1. Rasprava

Istraživanje prikazano u ovoj disertaciji provedeno je radi razvoja modela i metode za praćenje i mjerenje izvedbe projekata razvoja tehničkih sustava nematerijalnim indikatorima na individualnoj i timskoj razini te identifikacije organizacijskih rizika vezanih uz njih.

Tijekom istraživanja, razmatrana su sljedeća istraživačka pitanja:

1. Koje se metode za mjerenje elemenata intelektualnoga kapitala na individualnoj i timskoj razini mogu primijeniti u projektima razvoja tehničkih sustava?

Pregledom dostupne literature zaključeno je da ne postoje metode za praćenje intelektualnoga kapitala na individualnoj i timskoj razini unutar projekata razvoja tehničkih sustava. Za unapređenje upravljanja projektima u području razvoja tehničkih sustava stoga je bilo potrebno proširiti postojeće modele, metode i alate radi uključivanja nematerijalnih aspekata projektne izvedbe i njezina praćenja u realnom vremenu. Proširenjem kriterija uspješnosti razvojnih projekata uzimajući u obzir nematerijalne aspekte i postavljanjem temelja za mjerenje intelektualnoga kapitala u okviru razvojnih projekata omogućio se širi pogled na praćenje i mjerenje izvedbe projekta.

Za praćenje i mjerenje nematerijalnih aspekata razvoja tehničkih sustava te obuhvaćanja socio-tehničke perspektive bilo je nužno osmisliti i kreirati indikatore izvedbe za individualnu i timsku razinu. Uporaba predloženih nematerijalnih indikatora te prikupljanje kvantitativnih podataka o aktualnim vrijednostima mjera za predložene indikatore u razvojnim aktivnostima omogućili su stvaranje realne slike o stanju elemenata IK-a na operativnoj razini (engl. *in action*). U usporedbi s tradicionalnim zakašnjelim indikatorima, upotrebom vodećih (eng. *leading*) nematerijalnih indikatora omogućen je točniji prikaz trenutačne situacije te praćenje projekata u stvarnom vremenu.

2. Kako se može modelirati međusoban utjecaj nematerijalnih indikatora na individualnoj i timskoj razini?

Za određivanje međusobna utjecaja između indikatora mogu poslužiti dva različita pristupa: analiza utjecaja temeljena na ekspertnom znanju ili statistička analiza prikupljenih podataka.

Tehnike temeljene na ekspertnom znanju ne zahtijevaju veliku količinu prikupljenih podataka, što olakšava njihovu upotrebu. Za stvaranje mreže nematerijalnih indikatora u ovoj disertaciji odabran je pristup temeljen na ekspertnom znanju radi definiranja utjecaja između nematerijalnih indikatora izvedbe i određivanja najutjecajnijih indikatora u modelu.

3. Kako prikupiti podatke o nematerijalnom aspektu aktivnosti tijekom razvoja tehničkih sustava?

Zbog specifičnosti individualnoga i timskoga rada tijekom razvojnih procesa, za prikupljanje podataka potrebnih za određivanje vrijednosti nematerijalnih indikatora predložena je primjena triju metoda: 1. uzorkovanje rada, 2. anketa i 3. integracija s korporativnim IT sustavima.

4. Kako odrediti doprinos pojedinih mjerenih nematerijalnih indikatora razvoju elemenata intelektualnoga kapitala za pojedince i timove?

Utjecaj mjerenih nematerijalnih indikatora na razvoj elemenata intelektualnoga kapitala na individualnoj i timskoj razini određen je pomoću težinskih faktora. Kreirana mreža indikatora (2. pitanje) ulazni je skup podataka za određivanje težinskih faktora za nematerijalne indikatore. Kako bi se u obzir uzela jačina utjecaja između indikatora koju su prethodno ocijenili validatori, za izračun težinskih faktora indikatora upotrijebljena je Metoda potencijala [131]. Prikupljanjem podataka uzorkovanjem rada i anketom te njihovim preslikavanjem određene su vrijednosti nematerijalnih indikatora. Pridruživanjem vrijednosti nematerijalnih indikatora težinskim faktorima provedena je agregacija pojedinačnih nematerijalnih indikatora za pojedinu kategoriju IK-a. Budući da su pri izračunu težinskih faktora u obzir uzete međuovisnosti između indikatora, upotrijebljena je diferencijalno ponderirana linearna agregacija za izračun agregiranih vrijednosti svih elemenata IK-a.

5. Kako identificirati rizike organizacijske strukture vezane za nematerijalnu perspektivu?

Identifikacija rizika organizacijske strukture provedena je tijekom vrednovanja izvedivosti i korisnosti metode. Prikupljeni podaci iz studije slučaja preslikani su u organizacijsku metamatricu te su zatim korištenjem mrežnim metrikama prepoznati ključni i kritični članovi tima, kompetencije, resursi i aktivnosti. Zaključci na temelju vrijednosti nematerijalnih indikatora podudaraju se sa zaključcima na temelju vrijednosti dobivenih mrežnom analizom metamatrice, iako je način njihovog izračuna različit. Ipak, uspoređujući mjere dobivene dinamičkom analizom mreže i predložene nematerijalne indikatore, može se zaključiti kako

su navedeni pristupi komplementarni te omogućuju identifikaciju različitih rizika. Nematerijalni indikatori orijentirani su isključivo na elemente IK-a, a analiza metamatrice upućuje na rizike vezane za različite elemente organizacijske strukture.

Poslije opisa rezultata istraživanja, može se ustvrditi da je potvrđena hipoteza istraživanja:

Sustav vrednovanja elemenata intelektualnoga kapitala omogućuje praćenje dinamike projekata razvoja tehničkih sustava i evaluaciju razvojnih projekata u realnom vremenu te se time unapređuju postojeći pristupi tradicionalnom upravljanju projektima razvoja tehničkih sustava.

Provedenim istraživanjem postignuti su prije definirani doprinosi:

1. teorijski doprinos u obliku modela i metoda za upravljanje socio-tehničkim aspektom projekata razvoja tehničkih sustava modeliranjem dinamike nematerijalnih indikatora i rizika u stvarnom vremenu

2. praktični doprinos procesu upravljanja projektima razvoja tehničkih sustava razvojem alata za mjerenje i praćenje socio-tehničkog aspekta projekata tijekom razvoja tehničkih sustava.

8.2. Smjerovi budućeg istraživanja

Istraživanje prikazano u ovoj disertaciji zatvorena je cjelina iako su njegovim provođenjem otvorena brojna nova istraživačka pitanja te novi smjerovi istraživanja.

Za daljnji razvoj modela i metode te moguća unapređenja potrebno je provesti dulje studije u više organizacija s različitim razvojnim procesima. Kao preduvjet za provođenje istraživanja u više organizacija, potrebno je detaljno razmatranje implementacije predloženih nematerijalnih indikatora u različitim sektorima. Veći broj provedenih studija omogućit će usporedbu između različitih tipova razvojnih procesa, ali i organizacija u cjelini te donošenje općenitijih zaključaka. Također, provođenjem duljih studija omogućila bi se i dodatna validacija veza identificiranih u mreži nematerijalnih indikatora na temelju podataka iz realnih razvojnih procesa.

Dulje studije zahtijevaju drukčiji način interpretacije dinamike indikatora radi prepoznavanja trendova i obrazaca tijekom projekata razvoja tehničkih sustava. Uporaba drugih istraživačkih

metoda (npr. intervjua) također bi mogla unaprijediti interpretaciju i razumijevanje vrijednosti nematerijalnih indikatora.

U nastavku istraživanja planirano je povezivanje nematerijalnih indikatora s materijalnim ishodima projekata razvoja tehničkih sustava u jedinstven okvir. Okvir koji bi obuhvaćao materijalnu i nematerijalnu perspektivu omogućio bi razvoj proširenih i novih metoda i alata za upravljanje kompleksnim razvojnim projektima.

Buduća istraživanja obuhvatit će i povezivanje nematerijalnih indikatora na individualnoj i timskoj razini s onima na organizacijskoj razini. Praćenje IK-a povezivanjem različitih organizacijskih razina omogućilo bi potpun uvid u IK organizacije.

9. Literatura

[1] Thamhain H. Managing Risks in Complex Projects. Project Management Journal. 2013;44 (2):20-35.

[2] Apgar D. Risk intelligence: Learning to manage what we don't know. Boston, MA: Harvard Business School Press; 2006.

[3] Danilovic M, Browning TR. Managing complex product development projects with design structure matrices and domain mapping matrices. International Journal of Project Management. 2007:25(3):300-314.

[4] Remington K, Zolin R, Turner R. A model of project complexity: distinguishing dimensions of complexity from severity. In: Proceedings of the 9th International Research Network of Project Management Conference. 11.10.-13.10.2009, Berlin. IRNOP; 2009.

[5] Marle F. A structured process to managing complex interactions between project risks. International Journal of Project Organisation and Management. 2014;6(1):4-32.

[6] Shenhar AJ, Dvir D. Reinventing Project Management: The Diamond Approach to Successful Growth and Innovation. Harvard Business Review Press; 2007.

[7] Gonzalez-Loureiro M, Figueroa Dorrego P. Intellectual capital and system of innovation: What really matters at innovative SMEs. Intangible Capital. 2012;8(2):239-274.

[8] Verbano C, Crema M. Measuring IC Following a Semi-qualitative Approach: An Integrated Framework. Intangible Capital. 2013;9(3):539-558.

[9] Lohman C, Fortuin L, Wouters M. Designing a performance measurement system: A case study. European Journal of Operational Research. 2004;156(2):267-286.

[10] Veleva V, Ellenbecker M. Indicators of sustainable production: framework and methodology. Journal of Cleaner Production. 2001;9(6):519-549.

[11] Chiesa V, Coughlan P, Voss C. Development of a technical innovation audit. Journal of Product Innovation Management. 1996;13(2):105-136.

[12] Kerssen-van Drongelen IC, Cook A. Design principles for the development of measurement systems for research and development processes. R&D Management. 1997;27(4):345-357.

[13] ISO. ISO 31000:2009(E) - Risk management - Principles and guidelines. International Organization for Standardization. Geneva, 2009.

[14] Hall DC. Making risk assessments more comparable and repeatable. Systems Engineering. 2011;14(2):173-179.

[15] Taroun A. Towards a better modelling and assessment of construction risk: Insights from a literature review. International Journal of Project Management. 2014;32(1):101-115.

[16] Ackermann F, Eden C. Using causal mapping with computer based group support system technology for eliciting an understanding of failure in complex projects: Some implications for organizational research. American Academy of Management Conference, Washington, USA; 2001.

[17] Remington K., Zolin R. Controlling chaos? The value and the challenges of applying complexity theory to project management. In: Cooke-Davies, Terry (Ed.) Aspects of Complexity: Managing Projects in a Complex World. Project Management Institute; 2011.

[18] Blessing L, Chakrabarti A. DRM: A design research methodology. Springer; 2009.

[19] Brannen J. Mixing Methods: The Entry of Qualitative and Quantitative Approaches into the Research Process. International Journal of Social Research Methodology. 2005;8(3):173-184.

[20] Saunders MNK, Tosey P. The Layers of Research Design. Rapport. 2012.

[21] Nissen ME, Snider KF. Lessons Learned to Guide Project Management Theory and Research: Pragmatism and Knowledge Flow. In: PMI Research Conference. Seattle, USA; 2002.

[22] Čaklović L. Measure of Inconsistency for the Potential Method. In: Torra V, Narukawa Y, López B, Villaret M. (Eds.), 'MDAI', Vol. 7647 of Lecture Notes in Computer Science, Springer, 2012., p. 102–114.

[23] Seepersad CC, Pedersen K, Emblemsvåg J, Bailey R, Allen JK, Mistree F. The validation square: how does one verify and validate a design method? In: Lewis KE, Chen W, Schmidt LC (Eds.). Decision Making in Engineering Design. New York: ASME Press; 2006.

[24] Carley KM, Reminga, J. ORA: Organization Risk Analyzer. Carnegie Mellon University Technical Report. CMUISRI-04-106, 2004.

[25] Crawford L, Pollack J, England D. Uncovering the trends in project management: Journal emphases over the last 10 years. International Journal of Project Management. 2006;24(2):175-184.

[26] Engwall M. No project is an island: linking projects to history and context. Research policy. 2003;32(5):789-808.

[27] Pinto JK, Slevin DP. Critical success factors. The Project Management Institute: Project management handbook; 1998.

[28] Reiss G. Project Management Demystified. E and F Spon; 1993.

[29] PMI. A guide to the project management body of knowledge. PA, US: Project Management Institute; 2004.

[30] Lock D. The essentials of project management. Ashgate Publishing, Ltd.; 2014.

[31] Pollack J. Project pluralism: Combining the hard and soft paradigms in IS/IT strategy development in the NSW public sector [dissertation]. University of Technology, Sydney; 2005.

[32] Daniel DW. Hard problems in a soft world. International Journal of Project Management. 1990;8(2):79-83.

[33] Murmann PA. Expected development time reductions in the German mechanical engineering industry. Journal of Product Innovation Management. 1994;11(3):236–252.

[34] White D, Fortune J. Current practice in project management - an empirical study. International Journal of Project Management. 2002;20(1):1-11.

[35] Rodrigues AG, Williams TM. System dynamics in project management: assessing the impact of client behavior on project performance. Journal of the Operational Research Society. 1998;49(1):2-15.

[36] Turner JR. The Handbook of Project-Based Management. McGrawHill; 1999.

[37] Katzel J. Benefits and pitfalls of software for project management. Plant Engineering. 1999;53(4):54-60.

[38] Atkinson R. Project management: cost, time and quality, two best guesses and a phenomenon, its time to accept other success criteria. International Journal of Project Management. 1999;17(6):337-342.

[39] Snider CM, Jones SL, Gopsill JA, Shi L, Hicks BJ. A framework for the development of characteristic signatures of engineering projects. In: DS 77: Proceedings of the DESIGN 2014 13th International Design Conference. Dubrovnik, Croatia, 19.05.-22.05.2014.

[40] Pollack J. The changing paradigms of project management. International Journal of Project Management. 2007;25(3):266-274.

[41] Posner BZ. What it takes to be a good project manager? Project Management Journal. 1987;18(1):51–54.

[42] Yeo KT. Critical failure factors in information system projects. International Journal of Project Management. 2002;20(3):241–246.

[43] Cooke-Davies T. The “real” success factors on projects. International Journal of Project Management 2002;20(3):185-190.

[44] Chapman R. The corporate blind spot: a subject some companies would rather ignore. Journal of the Australian Institute of Project Management. 2004;24(2),19.

[45] Lee-Kelley L, Kin Leong L. Turner's five-functions of project-based management and situational leadership in IT services projects. International Journal of Project Management. 2003;21(8):583-591.

[46] Gillard S. Soft skills and technical expertise of effective project managers. Issues in Informing Science and Information Technology. 2009;6(7):723-729.

[47] Davies A, Brady T. Organisational capabilities and learning in complex product systems: towards repeatable solutions. Research Policy. 2000;29(7):931-953.

[48] Shenhar AJ, Dvir D, Levy O, Maltz AC. Project success: a multidimensional strategic concept. Long range planning. 2001;34(6):699-725.

[49] Hobday M. The project-based organisation: an ideal form for managing complex products and systems? Research policy. 2000;29(7):871-893.

[50] Cicmil S, Williams T, Thomas J, Hodgson D. Rethinking Project Management; Researching the actuality of projects. International Journal of Project Management. 2006;24(8):675-686.

[51] Mathur G, Jugdev K, Fung TS. The Relationship between Project Management Process Characteristics and Performance Outcomes. Management Research Review. 2014;37(11):990-1015.

[52] Vuolle M, Lönnqvist A, van der Meer J. Measuring the intangible aspects of an R&D project. Measuring Business Excellence. 2009;13(2):25–33.

[53] Aronson ZH, Shenhar AJ, Patanakul P. Managing the Intangible Aspects of a Project: The Affect of Vision, Artifacts, and Leader Values on Project Spirit and Success in Technology-Driven Projects. Project Management Journal. 2013;44(1):35–58.

[54] Ozorhon B, Abbott C, Aouad G. Integration and leadership as enablers of innovation in construction: Case study. Journal of Management in Engineering. 2013;30(2):256-263.

[55] Maltz A, Shenhar AJ, Dvir D, Gao H. Success Comes in Many Dimensions: The Critical Role of the Human Capital and Preparing for the Future in Every Organizational Scorecard. Howe School Research Paper (2013-25); 2013.

[56] Turner N, Maylor H, Swart J. Ambidexterity in projects: An intellectual capital perspective. International Journal of Project Management. 2015;33(1):177-188.

[57] European Commission. Reporting Intellectual capital to augment research, development and innovation in SMEs, Report to the commission of the high level expert group on RICARDIS, Encourage corporate measuring and reporting on research and other forms of intellectual capital. Office for Official Publications of the European Communities, 2006.

[58] Edvinsson L, Sullivan P. Developing a model for managing intellectual capital. European Management Journal. 1996;14(4):356-364.

[59] Elsevier, http://www.scopus.com/, 2015

[60] Petty R, Guthrie J. Intellectual capital literature review: measurement, reporting and management. Journal of Intellectual Capital. 2000;1(2):155-76.

[61] Bozbura FT. Measurement and application of intellectual capital in Turkey. The Learning Organization. 2004;11(4/5):357–367.

[62] Youndt MA, Subramaniam M, Snell SA. Intellectual capital profiles: an examination of investments and returns. Journal of Management Studies. 2004;41(2):335–361.

[63] Yang CC, Lin CYY. Does intellectual capital mediate the relationship between HRM and organizational performance? Perspective of a healthcare industry in Taiwan. The International Journal of Human Resource Management. 2009;20(9):1965–1984.

[64] Zeghal D, Maaloul A. Analysing value added as an indicator of intellectual capital and its consequences on company performance. Journal of Intellectual Capital. 2010;11(1):39–60.

[65] Stewart TA. Intellectual Capital: The New Wealth of Organizations. New York: Doubleday/Currency; 1997.

[66] Bontis N. Intellectual capital: an exploratory study that develops measures and models. Management decision. 1998;36(2):63-76.

[67] Hayton JC. Competing in the new economy: the effect of intellectual capital on corporate entrepreneurship in hightechnology new ventures. R&D Management. 2005;35(2):137–155.

[68] Pil FK, Leana C. Applying organizational research to public school reform: the effects of teacher human and social capital on student performance. Academy of Management Journal. 2009;52(6):1101–1124.

[69] Walsh JP, Ungson GR. Organizational memory. Academy of management review. 1991;16(1):57–91.

[70] Erickson GS, Rothberg HN. Intellectual capital in business-to-business markets. Industrial marketing management. 2009;38(2):159–165.

[71] Chen CJ, Liu TC, Chu MA, Hsioa YC. Intellectual Capital and New Product Development. Journal of Engineering and Technology Management. 2014;33,July-September 2014:154-173.

[72] Matting J, Sanden B, Edvardsson B. New service development: learning from and with customers. International Journal of Service Industry Management. 2004;15(5):479–498.

[73] Patanakul P, Shenhar AJ, Milosevic DZ. How project strategy is used in project management: cases of new product development and software development projects. Journal of Engineering and Technology Management. 2012;29(3):391–414.

[74] Dumay J. Intellectual capital measurement: a critical approach. Journal of Intellectual Capital. 2009;10(2):190–210.

[75] Kitts B, Edvinsson L, Beding T. Intellectual capital: from intangible assets to fitness landscapes. Expert Systems with Applications. 2001;20(1):35-50.

[76] Viedma Marti JM. In Search of an Intellectual Capital Comprehensive Theory. The Electronic Journal of Knowledge Management. 2007;5(2):245–256.

[77] Kianto A. What do we really mean by the dynamic dimension of intellectual capital? International Journal of Learning and Intellectual Capital. 2007;4(4):342-356.

[78] Bratianu C, Jianu I, Vasilache S. Integrators for organisational intellectual capital. International Journal of Learning and Intellectual Capital. 2001;8(1):5-17.

[79] O'Donnell D, Henriksen LB, Voelpel SC. Guest editorial: becoming critical on intellectual capital. Journal of Intellectual Capital. 2006;7(19):5-11.

[80] Dumay J, Garanina T. Intellectual capital research: a critical examination of the third stage. Journal of Intellectual Capital. 2013;14(1):10–25.

[81] Riahi-Belkaoui A. Intellectual capital and firm performance of US multinational firms: a study of the resource-based and stakeholder views. Journal of Intellectual Capital. 2003;4(2):215-226.

[82] Chen J, Zhu Z, Yuan Xie H. Measuring intellectual capital: a new model and empirical study. Journal of Intellectual Capital. 2004;5(1):195-212.

[83] Firer S, Mitchell Williams S. Intellectual capital and traditional measures of corporate performance. Journal of Intellectual Capital. 2003;4(3):348-360.

[84] Mayo A. The Human Value of the Enterprise: Valuing People as Assets – Monitoring, Measuring, Managing. UK: Nicholas Brealey Publishing; 2001.

[85] Guthrie J, Ricceri F, Dumay J. Reflections and projections: a decade of intellectual capital accounting research. British Accounting Review. 2012;44(2):68-82.

[86] Dumay J. Reflections on interdisciplinary accounting research: the state of the art of intellectual capital. Accounting, Auditing & Accountability Journal. 2014;27(8):1257-1264.

[87] Cross N, Cross AC. Observations of teamwork and social processes in design. Design studies. 1995;16(2):143-170.

[88] Stemple J, Badke-Schaub P. Thinking in Design Teams – An Analysis of Team Communication. Design Studies. 2002;23(5):473–496.

[89] Chiu M. An Organizational View of Design Communication in Design Collaboration. Design Studies. 2002;23(2):187–210.

[90] Ensici A, Badke-Schaub P, Bayazıt N, Lauche K. Used and rejected decisions in design teamwork. CoDesign. 2013;9(2):113-131.

[91] Valkenburg AC. The Reflective Practice in Product Design Teams [dissertation]. Delft University of Technology; 2000.

[92] Kalay YE. Enhancing Multi-disciplinary Collaboration through Semantically Rich Representation. Automation in Construction. 2001;10(6):741–755.

[93] Brereton MF, Cannon DM, Mabogunje A, Leifer LJ. Collaboration in Design Teams: How Social Interaction Shapes the Product. In: Cross N., Christiaans H., Dorst K. (eds). Analysing Design Activity. Chichester: Wiley; 1996., p. 319-341.

[94] Hoegl M, Gemuenden HG. Teamwork quality and the success of innovative projects: A theoretical concept and empirical evidence. Organization science. 2001;12(4):435-449.

[95] Edmondson AC, Nembhard IM. Product development and learning in project teams: the challenges are the benefits. Journal of Product Innovation Management. 2009;26(2):123-138.

[96] Smith DM, Edmondson AC. Too Hot to Handle? How to Manage Relationship Conflict. California Management Review. 2006;49(1):6–31.

[97] Badke-Schaub P. Group effectiveness in design practice: Analysis and training by a critical-situation-approach. Psychologische beiträge 1999;41(3):338.

[98] Bucciarelli LL, Kuhn S. Engineering education and engineering practice: improving the fit. In: Barley SR, Orr JE. (Eds.), Between craft and science: Technical work in U.S. settings. London: Cornell University Press; 1997., p. 210-229.

[99] Robinson MA. An empirical analysis of engineers' information behaviors. Journal of the American Society for Information Science and Technology. 2010;61(4):640-658.

[100] Robinson MA. How design engineers spend their time: Job content and task satisfaction. Design Studies. 2012;33(4):391-425.

[101] Cooper RG, Kleinschmidt EJ. Benchmarking the firm's critical success factors in new product development. Journal of Product Innovation Management. 1995;12(5):374-391.

[102] Gupta AK, Wilemon D. Changing patterns in industrial R&D management. Journal of Product Innovation Management. 1996;13(6):497–511.

[103] Hong P, Doll WJ, Nahm AY, Li X. Knowledge sharing in integrated product development. European journal of innovation management. 2004;7(2):102-112.

[104] McKelvey B, Salmador MP, Morcillo P, Rodríguez-Antón JM. Toward an Econophysics View of Intellectual Capital Dynamics: From Self-organized Criticality to the Stochastic Frontier. Knowledge Management Research and Practice. 2013;11(2):142–161.

[105] Luthy DH. Intellectual capital and its measurement. Proceedings of the Asian Pacific Interdisciplinary Research in Accounting Conference (APIRA). Osaka, Japan, 04.08.-06.08.1998.

[106] Sveiby KE. Methods for Measuring Intangible Assets http://www.sveiby.com/articles/IntangibleMethods.htm, last updated on 27 April 2010.

[107] Wall A, Kirk R, Martin G. Intellectual Capital: Measuring the Immeasurable? Elsevier; 2003.

[108] Ramanauskaite A, Rudžioniene K. Intellectual capital valuation: methods and their classification. Ekonomika/Economics. 2013;92(2).

[109] Mouritsen J, Nikolaj Bukh P, Marr B. Reporting on intellectual capital: why, what and how? Measuring Business Excellence. 2004;8(1):46-54.

[110] Gogan LM, Draghici A. A performance model to evaluate intellectual capital. Review of Applied Socio-Economic Research. 2013;6(2):101-110.

[111] Bontis N, Fitz-enz J. Intellectual capital ROI: a current map of human capital antecedents and consequent. Journal of Intellectual Capital. 2002;3(3):223-47.

[112] Giuliani M. Investigating intellectual capital dynamics: a field study. International Journal of Learning and Intellectual Capital. 2014;11(1):20-32.

[113] Warhurst A. Sustainability indicators and sustainability performance management. Working paper No. 43. Institute for Environment and Development, London; 2002.

[114] Gericke, K. Enhancing Project Robustness: A Risk Management Perspective [dissertation]. Technische Universität Berlin, Germany; 2011.

[115] Neely A, Mills J, Platts K, Richards H, Gregory M, Bourne M, Kennerley M. Performance Measurement System Design: Developing and Testing a Process-Based Approach. International Journal of Operations and Production Management. 2000;20(10):1119-1145.

[116] O'Donnell FJ, Duffy AHB. Modelling design development performance. International Journal of Operations & Production Management. 2002;22(11):1198-1221.

[117] Bashir HA, Thomson V. Metrics for design projects: a review. Design Studies. 1999;20(3):263-277.

[118] Norden PV. Manpower utilization patterns in research and development projects [dissertation]. Columbia University; 1964.

[119] Griffin A. Metrics for measuring product development cycle time. Journal of Product Innovation Management. 1993;10(2):112–125.

[120] Bahill AT, Chapman WL. Case studies in system design. In: International Symposium and Workshop on Systems Engineering of Computer Based Systems. Piscataway, NJ; 1995.

[121] Jacome MF, Lapinskii V. NREC: risk assessment and planning of complex designs. Design and Test of Computers, IEEE. 1997;14(1):42–49.

[122] Griffin A, Page AL. PDMA success measurement project: recommended measures for product development success and failure. Journal of Product Innovation Management. 1996;13(6):478–496.

[123] Cooper R. Benchmarking new product performance. European Management Journal. 1998;16(1):1– 17.

[124] Gries B, Restrepo J. KPI Measurement in Engineering Design - A Case Study. In: DS 68-1: Proceedings of the 18th International Conference on Engineering Design (ICED11), Vol. 1: Design Processes. Lyngby/Copenhagen, Denmark, 15.08.-19.08.2011.

[125] Taylor TP, Ahmed-Kristensen S. Performance Measurement in Global Product Development. In: DS 75-9: Proceedings of the 19th International Conference on Engineering Design (ICED13), Vol.9: Design Methods and Tools. Seoul, Korea, 19.08-22.08.2013.

[126] Dombrowski U, Schmidtchen K, Ebentreich D. Balanced Key Performance Indicators in Product Development. International Journal of Materials, Mechanics and Manufacturing. 2013;1(1):27-31.

[127] Parmenter D. Key Performance Indicators (KPI): Developing, Implementing, and Using Winning KPIs. 2nd ed. John Wiley & Sons; 2010.

[128] Hsu YH, Fang W. Intellectual capital and new product development performance: The mediating role of organizational learning capability. Technological Forecasting and Social Change. 2009;76(5):664-677.

[129] Cuganesan S. Intellectual capital-in-action and value creation: A case study of knowledge transformations in an innovation project. Journal of Intellectual Capital. 2005;6(3):357–373.

[130] Hwang MI, Lin JW. Information dimension, information overload and decision quality. Journal of Information Science. 1999;25(3):213–218.

[131] Čaklović L. Teorija vrednovanja s naglaskom na metodu potencijala. Naklada Slap; 2014.

[132] Saaty TL. The Analytic Hierarchy Process: Decision Making with Dependence and Feedback. RWS Publications; 1996.

[133] Čaklović L, Radas S. Application of Potential Method to Survey Analysis. Mathematical communications. 2014;19(2):397-415.

[134] Munda G. Unitat d'Història Econòmica UHE Working Paper 2012_09; 2012.

[135] Detyniecki M. Mathematical aggregation operators and their application to video querying [dissertation]. Laboratoire d'Informatique de Paris 6; 2000.

[136] Podgórski D. Measuring operational performance of OSH management system–A demonstration of AHP-based selection of leading key performance indicators. Safety Science. 2015;73:146-166.

[137] Rodriguez RR, Saiz JJA, Bas AO. Quantitative relationships between key performance indicators for supporting decision-making processes. Computers in Industry. 2009;60(2):104-113.

[138] Ittner CD, Larcker DF. 2003. Coming up Short on Nonfinancial Performance Measurement. Harvard Business Review. 2003;81(11):88-95.

[139] Nardo M, Saisana M, Saltelli A, Tarantola S, Hoffman A, Giovannini E. Handbook on Constructing Composite Indicators: Methodology and User Guide. OECD Publishing; 2005.

[140] Jollands N, Lermit J, Patterson M. The usefulness of aggregate indicators in policy making and evaluation: a discussion with application to eco-efficiency indicators in New Zealand, Economics and Environment Network, Australian National University; 2003.

[141] Saisana M, Tarantola S. State-of-the-art report on current methodologies and practices for composite indicator development. European Commission, Joint Research Centre, Institute for the Protection and the Security of the Citizen, Technological and Economic Risk Management Unit, 2002.

[142] Perrow C. Complex organizations: A critical essay. New York: McGraw Hill; 1986.

[143] Carley KM, Hill V. Structural change and learning within organizations. In: Lomi A., Larsen E. (Eds.), Dynamics of organizations: Computational modeling and organization theories. Menlo Park, CA: MIT Press/AAAI; 2001., p. 66-82

[144] Coleman J. Social capital in the creation of human capital. American Journal of Sociology. 1988;94:95–120.

[145] Wright PM, Dunford BB, Snell SA. Human resources and the resource based view of the firm. Journal of Management. 2001;27(6):701-721.

[146] Ashworth MJ. Computational and empirical explorations of work group performance [dissertation]. Carnegie Mellon University; 2007.

[147] Argote L, Miron-Spektor E. Organizational learning: From experience to knowledge. Organization Science. 2011;22(5):1123-1137.

[148] Pisano GP, Bohmer RM, Edmondson AC. Organizational differences in rates of learning: Evidence from the adoption of minimally invasive surgery. Management Science. 2001;47(6):752-768.

[149] Krackhardt D. The ties that torture: Simmelian tie analysis in organizations. Research in the Sociology of Organizations. 1999;16(1):183-210.

[150] Burt RS. Toward a Structural Theory of Action: Network Models of Social Structure, Perception, and Action. New York: Academic Press; 1982.

[151] Kiesler S, Wholey D, Carley K. Coordination as linkage: The case of software development teams. In: D. Harris (ed.), Organizational Linkages: Understanding the Productivity Paradox. Washington, DC: National Academy Press; 1994., p. 214-239.

[152] Wiig KM. Knowledge management in public administration. Journal of Knowledge Management. 2002;6(3):224-239.

[153] Brass D. Being in the right place: A structural analysis of individual influence in an organization. Administrative Science Quarterly. 1984;29(4):331–348.

[154] Ashworth MJ. Identifying key contributors to performance in organizations: The case for knowledge-based measures. In: Proceedings of the First Annual Conference of the North American Association for Computational Social and Organizational Science, 22.06.-25.06.2003. Pittsburgh, PA; 2003.

[155] Brézillon P. Contextualizations in a social network. Revue d'Intelligence Artificielle. 2005;19(3):575-594.

[156] Krackhardt D, Carley KM. A PCANS Model of Structure in Organizations In: Proceedings of the 1998 International Symposium on Command and Control Research and Technology. Monterey, CA, 1998.

[157] Johanson U, Martensson M, Skoog M. Measuring and managing intangibles/eleven Swedish qualitative exploratory case studies. In: International Symposium Measuring and Reporting Intellectual Capital: Experiences, Issues, and Prospects. Amsterdam, Netherlands. OECD, 1999.

[158] Halim S. Statistical analysis on the intellectual capital statement. Journal of Intellectual Capital. 2010;11(1):61-73.

[159] Bueno E, Arrien M, Rodríguez O. Modelo intellectus. Medición y gestión del capital intelectual. IADE-CIC 5; 2003.

[160] Alwert K, Bornemann M, Kivikas M. Intellectual capital statement–Made in Germany. Guideline. Berlin: Federal Ministry for Economics and Technology, http://www.akwissensbilanz.org/Infoservice/Infomaterial/Leitfaden_english.pdf; 2004.

[161] Wang WY, Chang C. Intellectual capital and performance in causal models: Evidence from the information technology industry in Taiwan. Journal of Intellectual Capital. 2005;6(2):222-236.

[162] Bozbura FT, Beskese A, Kahraman C. Prioritization of human capital measurement indicators using fuzzy AHP. Expert Systems with Applications. 2007;32(4):1100-1112.

[163] Sharabati AAA, Jawad SN, Bontis N. Intellectual capital and business performance in the pharmaceutical sector of Jordan. Management Decision. 2010;48(1):105-131.

[164] Suraj OA, Bontis N. Managing intellectual capital in Nigerian telecommunications companies, Journal of Intellectual Capital. 2012;13(2):262-282.

[165] Wang Z, Wang N, Liang H. Knowledge sharing, intellectual capital and firm performance. Management Decision. 2014;52(2):230-258.

[166] Cardinal LB, Alessandri TM, Turner SF. Knowledge codifiability, resources, and science-based innovation. Journal of Knowledge Management. 2001;5(2):195-204.

[167] Han TS, Lin CYY, Chen MYC. Developing human capital indicators: a three-way approach. International Journal of Learning and Intellectual Capital. 2008;5(3):387-403.

[168] Marr B, Schiuma G, Neely A. The dynamics of value creation: mapping your intellectual performance drivers. Journal of Intellectual Capital. 2004;5(2):312-325.

[169] Leiponen A. Skills and innovation. International Journal of Industrial Organization. 2005;23(5-6):303-323

[170] Brooking A. Intellectual capital: Core assets for the third millennium enterprise. London: International Thomson Business Press; 1997.

[171] Roos J, Edvinsson L, Roos G. Intellectual capital: navigating in the new business landscape. New York University Press; 1998.

[172] Carmeli A, Tishler A. The relationships between intangible organizational elements and organizational performance. Strategic Management Journal. 2004;25(13):1257-1278.

[173] Nonaka I, Takeuchi H. The knowledge-creating company: How Japanese companies create the dynamics of innovation. Oxford University Press; 1995.

[174] Gallego I, Rodríguez L. Situation of intangible assets in Spanish firms: An empirical analysis. Journal of Intellectual Capital. 2005;6(1):105-126.

[175] Hsu I, Sabherwal R. Relationship between intellectual capital and knowledge management: An empirical investigation. Decision Sciences. 2012;43(3):489-524.

[176] Štorga M, Škec S. Intellectual Capital Performance Indicators for Complex Project Management. In: Proceedings of International Conference on Advanced Design Research and Education (ICADRE14). Singapore, 16.07– 18.07.2014.

[177] Persson M, Orr E. Performance Indicators för Measuring Performance of Activities in Knowledge Management Projects. Göteborg University; 2003.

[178] Arisha A, Ragab M. The MinK Framework: Developing Metrics for the Measurement of Individual Knowledge. In: Proceedings of KIM2013 Knowledge & Information Management Conference. UK; 2013.

[179] Powell WW, White DR, Koput KW, Owen-Smith J. Network dynamics and field evolution: the growth of interorganisational collaboration in the life sciences. American Journal of Sociology. 2005;110(4):1132-1205.

[180] CASOS. ORA software. http://www.casos.cs.cmu.edu/projects/ora/software.php. 2015.

[181] Newman M. Networks: an introduction. Oxford University Press; 2010.

[182] Lutero G. The aggregation problem in its hystorical perspective: a summary overview. Methods development of quarterly national accounts. ISTAT, National Accounts Directorate; 2010.

[183] Dawes JG. Do data characteristics change according to the number of scale points used? An experiment using 5 point, 7 point and 10 point scales. International Journal of Market Research. 2008;51(1).

[184] Badiru AB. Handbook of Industrial and Systems Engineering. 2nd ed. CRC Press; 2013.

[185] Dickson WM. Measuring Pharmacist Time Use: A Note on the Use of Fixed Interval Work Sampling. American Journal of Hospital Pharmacy. 1978;35(10):1241-43.

[186] Pape ES. Work sampling. In: S. Gael (Ed.), The job analysis handbook for business, industry, and government. NewYork, Wiley; 1988., p. 518–535.

[187] Finkler SA, Knickman SR, Hendrickson G, Lipkin M Jr, Thompson WG. A comparison of work-sampling and time-and-motion techniques for studies in health services research. Health Services Research. 1993;28(5):577-597.

[188] Buchholz B, Paquet V, Punnett L, Lee D, Moir S. PATH: a work sampling-based approach to ergonomic job analysis for construction and other non-repetitive work. Applied ergonomics. 1996;27(3):177-187.

[189] Pedgley O. Capturing and analysing own design activity. Design Studies. 2007;28(5):463-483.

[190] Lowe A, McMahon C, Culley S. Information access, storage and use by engineering designers, part 1. The Journal of the Institution of Engineering Designers. 2004;30(2):30-32.

[191] Donaldson SI, Grant-Vallone EJ. Understanding self-report bias in organizational behavior research. Journal of Business and Psychology. 2002;17(2):245-260.

[192] Kirwan B, Ainsworth LK. A guide to task analysis. London: Taylor& Francis Ltd; 1992.

[193] Sim SK, Duffy AHB. Towards an ontology of generic engineering design activities. Research in Engineering Design (RED). 2003;14(4):200-223.

[194] Allard S, Levine KJ, Tenopir C. Design engineers and technical professionals at work: Observing information usage in the workplace. Journal of the American Society for Information Science and Technology. 2009;60(3):443-454.

[195] Cash P. Characterising the relationship between practice and laboratory-based studies of designers for critical design situations [dissertation]. University of Bath; 2012.

[196] Gillham B. Developing a questionnaire. A&C Black, 2008.

[197] Gray DE. Doing research in the real world. Sage, 2013.

[198] Gable GG. Integrating case study and survey research methods: an example in information systems. European Journal of Information Systems. 1994;3(2):112-126.

[199] Malhotra N, Peterson M. Basic Marketing Research: A Decision-Making Approach. 2nd edn. New Jersey: Prentice Hall; 2006.

[200] Nowack KM. 360-degree Feedback: The Whole Story. Training and Development. 1993;69-72.

[201] Mabey C. Closing the Circle: Participant Views of a 360 Degree Feedback Programme. Human Resource Management Journal. 2001;11(1):41–53.

[202] Carruthers F. Nothing but the truth. Australian Financial Review. 2003;14(78).

[203] McCarty AM, Garavan TN. 360 degree feedback process: performance, improvement and employee career development. Journal of European Industrial Training. 2001;25(1):3-32.

[204] Fleenor JW, Prince JM. Using 360-degree feedback in organizations. Greensboro, North Carolina: Center for Creative Leadership; 1997.

[205] Moreno MCC. A 360-degree evaluation framework for doctoral programs. Global Engineering Education Conference (EDUCON). Istanbul, Turkey, 03.04.-05.04.2014. IEEE, 2014.

[206] Carey R. Coming around to 360-degree feedback, Performance. 1995;56-60.

[207] Atwater LE, Brett JF, Charles AC. Multisource feedback: Lessons learned and implications for practice. Human Resource Management. 2007;46(2):285-307.

[208] Hirsch MS. 360 degrees of evaluation. Working Woman. 1994;19(8):20-21.

[209] Yukl G, Lepsinger R. How to get the most out of 360-degree feedback. Training. 1995;32(12):45-50.

[210] Roy R, Kerr C, Makri C, Kritsilis D. Documenting technical specifications during the conceptualisation stages of aeroengine product development. In: DS 32: Proceedings of DESIGN 2004, the 8th International Design Conference. Dubrovnik, Croatia, 18.05.-21.05.2004.

[211] Gopsill JA, Jones SL, Snider CM, Shi L, McMahon C, Hicks BJ. Understanding the Engineering Design Process Through the Evolution of Engineering Digital Objects. In: DS 77: Proceedings of the DESIGN 2014 13th International Design Conference. Dubrovnik, Croatia, 19.05.-22.05.2014.

[212] Dyer JH, Nobeoka K. Creating and managing a high- performance knowledge-sharing network: the Toyota case, 2002.

[213] McMahon C, Lowe A, Culley S, Corderoy M, Crossland R, Shah T, Stewart D. Waypoint: An integrated search and retrieval system for engineering documents. Journal of Computing and Information Science in Engineering. 2004;4(4):329–338.

[214] Wasiak JO. A Content Based Approach for Investigating the Role and Use of E–Mail in Engineering Design Projects [dissertation]. University of Bath; 2010.

[215] Hussain Z, Wallace J, Cornelius NE. The use and impact of human resource information systems on human resource management professionals. Information & Management. 2007;44(1):74-89.

[216] Ashbaugh S, Miranda R. Technology for Human Resource Management: Seven Questions and Answers. Public Personnel Management. 2002;31(1):7-20.

[217] Armstrong M, Baron A. Performance Management: the New Realities. Wiltshire, England: Cromwell Press; 1998.

[218] Webster J, Higgs P. An analysis of drawing office activities. Building Services Engineer, 1973;40:246-257.

[219] Marsh R. The capture and utilisation of experience in engineering design [dissertation]. University of Cambridge; 1997.

[220] Patrashkova-Volzdoska RR, McComb SA, Green SG, Compton WD. Examining a curvilinear relationship between communication frequency and team performance in cross-functional project teams. IEEE Transactions on Engineering Management. 2003;50(3):262-269.

[221] Eppler MJ. Managing information quality: Increasing the value of information in knowledge-intensive products and processes. Springer Science & Business Media; 2006.

[222] Mishra AA, Shah R. In union lies strength: Collaborative competence in new product development and its performance effects. Journal of Operations Management. 2009;27(4):324–338.

[223] Durackova M, Lavin J, Karjust K. KPI optimization for product development process. Annals of DAAAM for 2012 & Proceedings of the 23rd International DAAAM Symposium. DAAAM International, Vienna; 2012.

[224] Coates G, Thompson CM, Duffy AHB, Hills W, Whitfield RI. Modelling skill competencies in engineering companies. Engineering Designer. 2009;35(5):16-19.

[225] Court AW, Ullman DG, Culley SJ. 1998. A comparison between the provision of information to engineering designers in the UK and the USA. International Journal of Information Management. 1998;18(6):409-425.

[226] Hertzum M, Pejtersen AM. The information-seeking practices of engineers: searching for documents as well as for people. Information Processing & Management. 2000;36(5):761-778.

[227] Amabile TM. Creativity in context: Update to „The Social Psychology of Creativity.". Westview press; 1996.

[228] Girotra K, Terwiesch C, Ulrich KT. Idea generation and the quality of the best idea. Management Science. 2010;56(4):591-605.

[229] Robbins SP, Judge T. Essentials of organizational behavior. Prentice Hall; 2003.

[230] Leonard D, Sensiper S. The role of tacit knowledge in group innovation. California Management Review. 1998;40(3):112-132.

[231] Amar AD. 2004. Motivating knowledge workers to innovate: a model integrating motivation dynamics and antecedents. European Journal of Innovation Management. 2004;7(2):89-101.

[232] Björk J, Magnusson M. Where Do Good Innovation Ideas Come From? Exploring the Influence of Network Connectivity on Innovation Idea Quality. Journal of Product Innovation Management. 2009;26(6):662-670.

[233] Coelho F, Augusto M. Job characteristics and the creativity of frontline service employees. Journal of Service Research. 2010.

[234] Amabile TM. Beyond talent: John Irving and the passionate craft of creativity. American Psychologist. 2001;56(4):333.

[235] Perlow L, Bailyn L. The senseless submergence of difference:engineers, their work, and their careers in R Barley and J E Orr (eds) Between craft and science: technical work in U.S. settings, Cornell University Press, London; 1997., p. 230-243

[236] Kurz R, Bartram D. Competency and Individual Performance: Modelling the World of Work. In: Robertson IT, Callinan M, Bartram D. (eds), Organizational Effectiveness: The Role of Psychology Chichester: John Wiley, 2002., p. 225-255.

[237] Kitanaka H, Matsui Y, Sato O, Shimada T. New product development and its interface functions of changes: An analysis of key determinant factors for new product development performance. In: Proceedings of the 4th P&OM World Conference/19th International Annual EurOMA Conference 2012. Amsterdam, Netherlands 01.07.-05.07.2012.

[238] Aisenberg Ferenhof H, Durst S, Zaniboni Bialecki M, Selig PM. Intellectual capital dimensions: state of the art in 2014. Journal of Intellectual Capital. 2015;16(1):58–100.

[239] Blessing L. What is this thing called Design Research? In: DS 31: Proceedings of ICED03, the 14th International Conference on Engineering Design. Stockholm, Sweden, 19.08.-21.08.2003.

Životopis

Stanko Škec rođen je 14. svibnja 1986. godine u Zagrebu, u kojem je završio osnovnu i srednju školu (V. gimnazija). Godine 2004. upisao je studij strojarstva na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu (FSB), a 2008. godine stekao je diplomu prvostupnika strojarstva. Dvije je godine poslije na FSB-u diplomirao kao magistar strojarstva. Nagrađen je medaljom Fakulteta strojarstva i brodogradnje za uspjeh na studiju. Od 2010. godine zaposlen je na Katedri za konstruiranje i razvoj proizvoda na FSB-u kao znanstveni novak na projektu *Modeli i metode upravljanja znanjem u razvoju proizvoda* (voditelj projekta prof. dr. sc. Dorian Marjanović). U studenom 2010. započeo je poslijediplomski studij na smjeru Teorija konstrukcija. Tijekom rada na fakultetu aktivno sudjeluje u nastavi kolegija Katedre na preddiplomskom i diplomskom studiju. Kao honorarni asistent također je sudjelovao u izvođenju nastave na informatičkom odjelu Tehničkoga veleučilišta u Zagrebu. Od 2012. godine sudjeluje u organizaciji međunarodnih znanstvenih skupova iz serije DESIGN, koji se bijenalno održavaju u Dubrovniku.

U okviru istraživanja bio je na PhD usavršavanju pod nazivom „Spring School on Systems Engineering“ koje se 2013. održavalo u Paderbornu (Njemačka) u organizaciji Tehničkog sveučilišta u Münchenu i Instituta Fraunhofer u Paderbornu. Sudjelovao je i na PhD ljetnoj školi pod nazivom „Summer School on Engineering Design Research 2013“ u čijoj su organizaciji sudjelovali Dansko tehničko sveučilište, Sveučilište u Luksemburgu te Tehničko sveučilište Ilmenau. Kao stipendist francuske vlade dio istraživanja proveo je na École Centrale Paris pod mentorstvom prof. Marije Janković.

Objavio je ukupno deset znanstvenih radova, od kojih je jedan objavljen u časopisu A kategorije, osam radova u zbornicima radova s međunarodnih znanstvenih skupova i jedan sažetak u zbornicima skupova. Osim toga, sudjelovao je na šest međunarodnih konferencija na kojima je predstavio svoje radove. Aktivno je sudjelovao na EUREKA-inu projektu „E 8723 Visually Augmented Analysis of the Information Structures Evolving in Socio-technical Systems – VISINEV“.

Služi se engleskim i ruskim jezikom.

Biography

Stanko Škec was born on May 14, 1986 in Zagreb, Croatia. He enrolled in the study of mechanical engineering at the Faculty of Mechanical Engineering and Naval Architecture University of Zagreb (UNIZAG-FSB) in 2004 and in 2008 he acquired Bachelor of Mechanical Engineering degree. Two years later, he graduated as Master of Mechanical Engineering at the same institution with specialization in the Applied Thermodynamics. He was awarded the "Medal of the Faculty of Mechanical Engineering and Naval Architecture" in 2010 for best undergraduate students. After graduation he applied for the position at the Chair of Design and Product Development at UNIZAG-FSB as a PhD researcher in the field of systems design theory. From 2010 until now, he has been working as a research assistant on the project entitled “Models and Methods of Knowledge Management in Product Development” (project leader prof. dr. sc. Dorian Marjanović) funded by the Ministry of Science, Education and Sports of the Republic of Croatia. In parallel, in November 2010 he started his PhD study. He is also involved in teaching through UNIZAG-FSB undergraduate and graduate study programs in product development and design theories. As a part-time assistant lecturer he held tutorials at the Study of Computer Science (Informatics) at the Polytechnics of Zagreb during 2012. From 2012, he participates in organization of biannual international DESIGN conferences in Dubrovnik.

In 2013, he attended the PhD training entitled "Spring School on Systems Engineering" which was held in Paderborn (Germany) and organized by the Technical University of Munich and Fraunhofer Institute in Paderborn. He also participated in the PhD summer school entitled "Summer School on Engineering Design Research 2013", organized by Technical University of Denmark, University of Luxembourg and Technical University of Ilmenau. After receiving scholarship from French government, part of the research was conducted at the Ecole Centrale Paris supervised by prof. Marija Jankovic.

He published several scientific papers as an author and co-author: 1 journal paper (category A), 8 conference papers with international peer-review, 1 conference abstract. In addition, he participated on six international conferences where he presented his papers. He actively participated on EUREKA project “E!8723 Visually Augmented Analysis of the Information Structures Evolving in Socio-technical Systems – VISINEV” as a project officer.

He is fluent in English, but he is also capable of using Russian on intermediate level.

Popis objavljenih radova

Znanstveni radovi u drugim časopisima:

1. Škec, Stanko; Štorga, Mario; Marjanović, Dorian. Mapping Risks on Various Product Development Process Types. Transactions of FAMENA. vol. 37, no. 3, pp. 1-16, 2013. (članak, znanstveni)

Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom:

1. Škec, Stanko; Štorga, Mario; Tečec Ribarić, Zlatka; Marjanović, Dorian. Work sampling approach for measuring intellectual capital elements in product development context. Proceedings of the 20th International Conference on Engineering Design (ICED 2015), Milano: The Design Society, 2015. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni) – prihvaćeno za objavljivanje
2. Škec, Stanko; Štorga, Mario; Rohde, Danijel; Marjanović, Dorian. Tailoring risk management approach for the product development environment. Proceedings of the 13th International Design Conference (DESIGN 2014), Marjanović, Dorian; Štorga, Mario; Pavković, Neven; Bojčetić, Nenad (ur.). Zagreb: Design Society, 2014. 385-396 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
3. Štorga, Mario; Škec, Stanko. Intellectual Capital Performance Indicators for Complex Project Management. Proceedings of International Conference on Advanced Design Research and Education ICADRE 14, Koh, Edwin (ur.), Singapore: National University of Singapore, 2014. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
4. Cash, Philip; Škec, Stanko; Štorga, Mario. A bibliometric analysis of the DESIGN 2012 conference. Proceedings of the 19th International Conference on Engineering Design (ICED 2013), Seoul, Korea: The Design Society, 2013. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
5. Peters, Christoph; Škec, Stanko; Leimeister, Jan Marco; Štorga, Mario. Systems Engineering Meets Service Science – Extending the Scope for Holistic Design of Product-Service-Systems Using a Telemedicine Example. Tag des Systems Engineering, Stuttgart, 2013. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)

6. Škec, Stanko; Stanković, Tino; Cash, Phil; Rohde, Danijel; Marjanović, Dorian. Pragmatic risk assessment approach for product development. Proceedings of the 9th IPD Workshop 2012, Sandor Vajna (ur.). Magdeburg: Otto-von-Guericke-University Magdeburg, 2013. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
7. Škec, Stanko; Štorga, Mario; Marjanović, Dorian. Mapping risk analysis methods on product development process. Proceedings of 3rd International Conference on Integration of Design, Engineering and Management for Innovation, A.A. Fernandes, R.M. Natal Jorge, L. Patrício, A. Medeiros (ur.). Porto, Portugal, 2013. (predavanje, međunarodna recenzija, objavljeni rad, znanstveni)
8. Škec, Stanko; Štorga, Mario; Stanković, Tino; Marjanović, Dorian. Mapping risks in product development. Proceedings of the 12th International Design Conference (DESIGN 2012), Marjanović, Dorian; Štorga, Mario; Pavković, Neven; Bojčetić, Nenad (ur.). Glasgow, Zagreb: Design Society, 2012. 311-320 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).

Sažeci u zbornicima skupova:

1. Škec, Stanko; Štorga, Mario; Marjanović, Dorian. Monitoring and Measurement of Intellectual Capital Performance Indicators in Complex Systems Development. PURESAFE Conference, CERN, Geneva, 2015. (pozvano predavanje, međunarodna recenzija, sažetak, znanstveni).