RUDARENJE PODATAKA U PROJEKTOM MENADŽMENTU U OKVIRU RAZVOJA SOFTVERA

Morožin, Ana

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:237340

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET SPLIT



DIPLOMSKI RAD

RUDARENJE PODATAKA U PROJEKTOM MENADŽMENTU U OKVIRU RAZVOJA SOFTVERA

Mentor:

prof. dr. sc. Daniela Garbin Praničević

Student:

Ana Morožin

Broj indeksa: 2141981

Split, rujan 2017.

SADRŽAJ:

1. UVOD 4

1.1. PROBLEM ISTRAŽIVANJA 4

1.2. PREDMET ISTRAŽIVANJA 7

1.3. ISTRAŽIVAČKA HIPOTEZA 8

1.4. CILJEVI ISTRAŽIVANJA 9

1.5. METODE ISTRAŽIVANJA 10

1.6. DOPRINOS ISTRAŽIVANJA 13

1.7. STRUKTURA DIPLOMSKOG RADA 13

2. RUDARENJE PODATAKA 15

2.1. POJAM I RAZVOJ RUDARENJA PODATAKA 15

2.1.1. Što je rudarenje podataka? 15

2.1.2. Korištenje rudarenja podataka 18

2.1.3. Faze pretraživanja podataka 19

2.1.4. Uloga rudarenja podataka u svakodnevnom poslovanju 22

3. PROJEKTNI MENADŽMENT 24

3.1. POJAM I RAZVOJ PROJEKTNOG MENADŽMENTA 24

3.1.1. Značenje projektnog menadžmenta 24

3.1.2. Faze projektnog menadžmenta....26

3.1.3. Softveri za projektni menadžment....29

4. RAZVOJ SOFTVERA....31

4.1. METODE RAZVOJA SOFTVERA....31

4.1.1. Razvoj softvera....31

4.1.2. Osiguranje kvalitete (QA)....32

4.1.3. Procesi u razvoju softvera....34

5. REZULTATI ISTRAŽIVANJA I ANALIZA DOBIVENIH REZULTATA....38

5.1. UZORAK I METODOLOGIJA ISTRAŽIVANJA....38

5.2. ANALIZA PRIKUPLJENIH PODATAKA I INTERPRETACIJA....40

5.3. OGRANIČENJA ISTRAŽIVANJA....56

6. ZAKLJUČAK....57

LITERATURA....61

POPIS SLIKA....68

POPIS TABLICA....69

POPIS GRAFIKONA....70

PRILOZI....72

Anketa o rudarenju podataka u projektnom menadžmentu u okviru razvoja softvera....72

SAŽETAK....82

SUMMARY....82

1. UVOD

1.1. PROBLEM ISTRAŽIVANJA

U današnjem poslovanju organizacija, masovno prikupljanje podataka postaje svakodnevnica koja u suštini rezultira time da organizacije posjeduju znatan potencijal upavljanja vrijednim informacijama, koje su skrivene u tim podacima. Stoga, iskorištavanje i upravljanje informacijama kojima poduzeće raspolaže postaje izazov, ali i imperativ ukoliko žele konkurirati na tržištu. Također, da bi se uspješno izvršavali zadani ciljevi, potrebno je imati projektnog menadžera koji će dobivene informacije znati iskoristiti na najbolji mogući način. Projektni menadžment igra važnu ulogu u svakoj uspješnoj organizaciji, a upravljanje projektima omogućuje realizaciju određenog projekta na efikasan način. Pri tome se kombiniraju metode planiranja i kontrole, uz racionalno usklađivanje svih raspoloživih resursa.

Također, u poslovanju organizacija ili poduzeća važnu ulogu igra i poslovna inteligencija (engl. business intelligence) koja, prema Čeriću, predstavlja "skup metoda koje organizacijama omogućuju iskorištavanje informacija koje posjeduju i na temelju njih steknu uvid u prirodu poslovanja, što im omogućuje donošenje kvalitetnijih poslovnih odluka"[1]. Ne postoji univerzalna definicija za termin rudarenja podataka, budući da postoje brojne definicije koje su postavili brojni autori. Prema Klepacu i Mršiću, najjednostavnije rečeno, rudarenje podataka (eng. data mining) bismo mogli definirati kao "pronalaženje zakonitosti u podacima"[2]. Rošić pojašnjava kako se sam termin rudarenja često poistovjećuje sa 2 različita procesa, a to su: otkrivanje i predviđanje znanja. Proces otkrivanja znanja implicira korisnikovo razumijevanje eksplicitnih informacija za koje je bitno da su u čitljivom obliku, dok se predviđanje odnosi na buduće događaje, te u nekim pristupima može biti čitljivo i prozirno, a u drugim pak neprovidno[3]. Početkom devedesetih godina prošlog stoljeća rudarenje podataka se obično prepoznavalo kao pod proces u širom procesu zvanom "otkrivanje znanja u bazama podataka" (Knowledge Discovery in Databases – KDD). Jedna od najkorištenjih

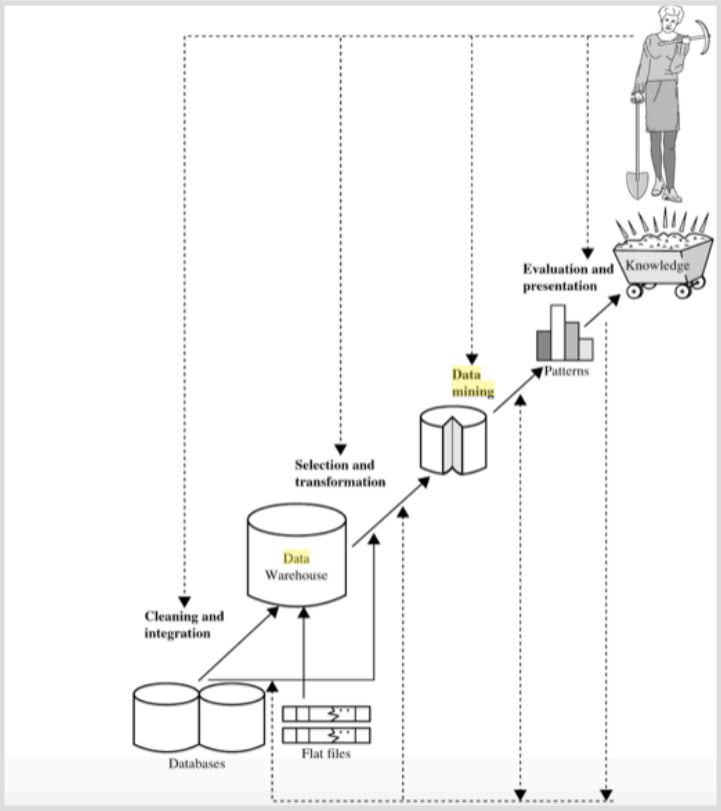
[1] Čerić, V., Informacijska tehnologija i poslovanje. *element.hr* Dostupno na: https://element.hr/artikli/file/1377 [pristupljeno 03.03.2017.] str. 10.

[2] Klepac, G. i Mršić, L., 2006. Poslovna inteligencija kroz poslovne slučajeve. *TIM press i Lider press*; Zagreb. Dostupno na: http://www.goranklepac.com/index.asp?j=HR&iz=1&sa=1&vi=1&hi=1 eno [pristupljeno 01.03.2017.]

[3] Rošić, S., 2017. Taopis the autopoetic information system. Fakultet organizacije i informatike. Dostupno na: http://www.autopoiesis.foi.hr/wiki.php?edit=yes&name=Skladišta+podataka&page=rudarenje+podataka&lang=de&lang=hr [pristupljeno 05.03.2017.]

definicija „KDD“ procesa je ona od autora Fayyed et al. odnosno, to je „složeni proces identificiranja novih, validnih, potencijalno korisnih te konačno, razumljivih obrazaca iz podataka u bazama podataka”[4]. Rudarenje podataka je zapravo samo jedan korak u procesu otkrivanja znanja, kao što je vidljivo na slici 1.

Slika 1: Rudarenje podataka kao samo jedan korak u procesu otkrivanja znanja



Izvor: Han, J., Pei, J. i Kamber, M., 2012. Data Mining: Concepts and Techniques, *Elsevier Inc.,* USA, str. 7.

Dakle, postoji nekoliko koraka ili faza (vidljivo na slici 1) koje moramo izvršiti kako bismo mogli izvući neke zaključke iz velike količine podataka, a to su: čišćenje i integracija, selekcija i transformacija, te evaluacija i prezentacija podataka. Svaka od ovih faza je bitna, međutim, čišćenje podataka oduzima najviše vremena, ali ima direktan utjecaj na krajnji rezultat. Ukoliko se nije dobro izvršilo čišćenje podataka, tada se dobije neiskoristivo “znanje” na kraju procesa, tzv. koncept

[4] Fayyad et al.1996. From data Mining to Knowledge Discovery in Database, Al Magazine Vol.17, No.3, dostupno na: http://www.aaai.org/ojs/index.php/aimagazine/article/viewFile/1230/1131 [pristupljeno 09.03.2017.]

GIGO (Garbage In Garbage Out)[5]. Kako bi se dobile korisne informacije iz prethodnih projekata u projektnom menadžmentu u okviru razvoja softvera, važno je pravilno provesti svaku od navedenih faza. Prema IEEE (The Institute of Electrical and Electronics Engineers) softver se može najjednostavnije definirati kao "sveobuhvatni zbir informatičkih programa, procesa, te dokumentacije i datoteka koje su usko vezane uz operacije određenog informatičkog sustava"[6], odnosno to je "bilo koji skup instrukcija koji stroj može pročitati i uputiti procesor na izvršavanje neke specifične radnje"[7,8].

U poslovanju tvrtki nužno je smisleno upravljanje projektima, kako bi se dogovoreni poslovi mogli realizirati u točno određenom roku. Upravljanje projektima može se definirati kao primjena "znanja, vještina, alata i tehnika u projektnim aktivnostima kako bi se ispunili projektni zahtjevi"[9,10] , dok je projekt "zajednički posao koji poduzima pojedinac ili grupa ljudi koji za cilj ima proizvesti jedinstveni proizvod ili uslugu i ima ograničeno trajanje"[11,12]. Ukoliko je glavni fokus usmjeren na projektima razvoja poslovnog softvera, tada je zajednički posao u tom slučaju razvoj softvera (testiranje, programiranje, projektiranje i sl.) jedinstveni proizvod ili usluga je poslovni softver (aplikacija), a ograničeno trajanje, odnosno period za isporuku proizvoda ili usluge je maximalno 16 mjeseci, budući da su u današnjem poslovnom okruženju projekti s dužim trajanjem upitne korisnosti.

---

[5] Quinion, M., 2005. Garbage in, garbage out. *World Wide Words.* Dostupno na: http://www.worldwidewords.org/qa/qa-gar1.htm [pristupljeno 19.03.2017.]

[6] EEE Software Engineering Standard 792-1983.,1990. IEEE Standard Glossary of Software Engineering Terminology. *The Institute of Electrical and Electronics Engineers.* 345 East 47th Street, New York, NY 10017, USA. [pdf] Dostupno na: http://www.mit.jyu.fi/ope/kurssit/TIES462/Materiaalit/IEEE_SoftwareEngGlossary.pdf [pristupljeno 23.03.2017.] str. 66.

[7] Krneta, P., Upravljanje projektima razvoja softvera za potporu poslovnim procesima tvrtke. [pdf] Dostupno na. http://www.inf.uniri.hr/files/datoteke/majam/upravljanje_projektima_razvoja_softvera_za_ppp_tvrtke_v1.pdf [pristupljeno 24.03.2017.] str.1.

[8] Wikipedia, 2017. Software. Dostupno na: https://en.wikipedia.org/wiki/Software [pristupljeno 25.03.2017.]

[9] Krneta, P., op.cit. str.1.

[10] A Guide to the Project Management Body of Knowledge (PMBOK® Guide)—Fifth Edition, 2013. *Project Management Institute.* Dostupno na: http://epm.bpharmed.com/pmo/PMBOK/PMBOK2012-5rd%20Edition.pdf?Mobile=1&Source=%2Fpmo%2F_layouts%2Fmobile%2Fview.aspx%3FList%3D473cddfb%252D7264%252D45bd%252Da478%252Dec282a672ead%26View%3D4739149c%252Dc28d%252D4758%252Da547%252D19f2a323efbd%26CurrentPage%3D1 [pristupljeno 23.03.2017.] str.5.

[11] Krneta, P., op.cit. str.1.

[12] A Guide to the Project Management Body of Knowledge (PMBOK® Guide)—Fifth Edition. op.cit. str.3.

Osnovni problem istraživanja ovog rada je utvrditi kakve učinke ima rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera na primjeru tvrtki koje se bave razvojem softvera u gradu Stockholmu.

1.2. PREDMET ISTRAŽIVANJA

U skladu s navedenim problemom istraživanja, definiran je predmet istraživanja. Predmet istraživanja ovog rada je analiziranje u kojoj mjeri rudarenje podataka može utjecati na uspješnost budućih projekata, koristeći znanje iz prethodnih projekata, u okviru razvoja softvera.

Dobra razrada projekata je neizvediva bez potpore projektnog managementa, koji je zapravo "primjena znanja, vještina, alata i tehnika projektnim aktivnostima kako bi se ispunili zahtjevi projekta"[13]. U današnjem poslovanju tržišna situacija zahtjeva od moderne tvrtke fleksibilnost, ali i određenu razinu projektnog pristupa kod poslovanja, kao i ljudske resurse koji će izvršavati određene zadatke. Tvrtke nailaze na poteškoće prilikom upravljanja resursima i poslovanjem, bez obzira na to da li nastoje zadržati određenu poziciju ili namjeravaju rasti u budućnosti. Kaotičnost poslovanja najčešće otežava pravovremenost informacija na svim razinama poslovanja, što može dovesti do loših poslovnih odluka, što u današnjem okruženju može biti čak i kobno za poslovanje određene organizacije. Zbog toga, upravljanje projektima na razini organizacije omogućuje izvršnom managementu kao i svakoj organizacijskoj jedinici efikasnu orijentaciju na izvršenje projekata koji su u suglasju sa strateškim ciljevima tvrtke, a ukoliko se izvršava ispravno, može biti presudno za uspješnost tvrtke. Ukoliko tvrtke koriste određene principe, u stanju su "značajno reducirati troškove poslovanja uz istovremeno povećanje produktivnosti, te postići prednosti u odnosu na konkurenciju bržim povratom uloženog kapitala u projekte"[14].

Budući da postoji veliki potencijal iskorištavanja znanja iz prethodno dovršenih projekata, kako uspješnih i onih manje uspješnih, rudarenje podataka može pomoći u procesu učenja, odnosno poboljšanja poslovanja određene tvrtke. Važno je prepoznati očekivanja i potrebe korisnika, kako bi

[13] Project Management Institute (PMI)., 2017. What is Project Management? Dostupno na: https://www.pmi.org/about/learn-about-pmi/what-is-project-management [pristupljeno 01.04.2017].

[14] Algebra, otvoreno učilište., 2017. Zašto Projektni Management? Dostupno na: http://www.algebra.hr/edukacija/project-management-akademija/ [pristupljeno 03.04.2017].

se mogle uspješno realizirati pri razradi projekta. Određene temeljne aktivnosti pri razvoju softvera koje treba imati na umu su: 1.specificiranje potreba (identifikacija, transformacija potreba u zahtjeve, analiza, određivanje prioriteta, itd.); 2.dizajniranje problema (oblikovanje problema grafičkom notacijom, oblikovanje procesa, analiza, itd.); 3.implementacija (kodiranje, testiranje, uvođenje u rad, dokumentiranje, edukacija, itd.); 4.validacija (testiranje softverskog sustava, procjena kvalitete, itd.) i 5.evolucija (održavanje sustava, reinženjering, itd.)[15]. U radu se istražuje u kojoj mjeri rudarenje podataka u okviru razvoja softvera može utjecati na uspješnost budućih projekata, koristeći znanje iz prethodnih projekata. Radom se istražuje specifičnost ovog područja na teorijskoj razini, uz pomoć prikupljene domaće i strane literature, te se putem anketnih upitnika i metode intervjua provodi empirijsko istraživanje. U razmatranje se uzimaju firme raznih veličina orijentirane razvoju softvera koje se nalaze u gradu Stockholmu, u Švedskoj. Analizira se koje metode rudarenja podataka firme najčešće koriste u projektnom menadžmentu u okviru razvoja softvera. Radom se zapravo želi istražiti da li određene tvrtke pri razvoju softvera koriste rudarenje podataka kako bi poboljšali projekte u budućnosti, koje metode koriste, te u kojoj mjeri im rudarenje podataka uistinu pomaže.

1.3. ISTRAŽIVAČKA HIPOTEZA

Nakon definiranog problema, te predmeta istraživanja definirana je istraživačka hipoteza. Glavni cilj kod postavljanja dolje navedene hipoteze je opovrgnuti ili potvrditi postavljenu hipotezu. U ovom radu istražuje se jedna hipoteza koja objedinjuje nekoliko elemenata.

H 1*: Rudarenje podataka unapređuje faze projektnog menadžmenta u okviru razvoja softvera*

Ovom hipotezom nastoji se utvrditi povezanost rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera, sa uspješnošću projekta, odnosno njegovim pozitivnim učinkom na planiranje i provođenje projekata. To znači da rudarenje podataka može poslužiti kao instrument pomoću kojeg se otkrivaju strukture među podacima i kao takav može pomoći kod boljeg poslovanja tvrtke, odnosno povećanja uspješnosti određenih projekata. Na isti način pomoću ove hipoteze će se saznati da li rudarenje podataka omogućuje precizniju i bržu izradu projekata, odnosno kakav je učinak

[15] Požgaj, Ž., Procesi razvoja softvera. Ekonomski Fakultet Zagreb, Zagreb. [pdf] Dostupno na: http://web.efzg.hr/dok/inf/pozgaj/pisani%20materijali/T03%20Modeli%20razvoja%20softvera.pdf [pristupljeno 05.04.2017].

rudarenja podataka na precizniju i bržu izradu projekata. To znači da bi se znanje iz prethodnih projekata dobiveno rudarenjem podataka moglo koristiti za određena predviđanja, odnosno za neke buduće događaje.

Prethodno definirana istraživačka hipoteza se istražuje i analizira uz pomoć primarnih podataka koji se prikupljaju putem anketa, te uz pomoć metode individualnog intervjua.

1.4. CILJEVI ISTRAŽIVANJA

Informacijska tehnologija u današnjem svijetu omogućuje bilježenje svake aktivnosti u obliku digitalnih podataka, a te količine podataka su ogromne (mjere se u gigabajtima ili terabajtima). Za dobivanje korisnih informacija iz tolikih količina podataka pomaže rudarenje podataka koje uvelike pridonosi u donošenju odluka, znanosti i poslovanju[16]. Uz pomoć rudarenja podataka moguće je poboljšati znanje, lakše donositi poslovne odluke na različitim razinama upravljanja, te imati bolji uvid u planiranje budućih trendova i ponašanja u nekim odlukama.

U skladu s uočenim problemom, definiranim predmetom istraživanja te postavljenom hipotezom, cilj istraživanja ovog rada je utvrditi kakve učinke ima rudarenje podataka na uspješnost budućih projekata u okviru razvoja softvera, odnosno prikazati kako se primjenom tehnika rudarenja već postojeći podaci u tvrkama mogu koristiti za donošenje kvalitetnijih odluka, čime se poboljšava poslovni rezultat, odnosno razina uspješnosti projekta.

Uz glavni cilj definirani su i sekundarni ciljevi ovog rada, a to su:

- otkrivanje najpopularnijih metoda rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera;
- definiranje uloge i značaja rudarenja podataka u današnjem poslovanju;
- utvrđivanje utjecaja rudarenja podatka u projektnom menadžmentu na zadovoljstvo i uspješnost projektnih menadžera;
- utvrđivanje razloga za rast popularnosti rudarenja podataka u današnjem poslovanju;
- otkrivanje najpopularnijih standarda kod pretraživanja podataka.

[16] Pejić-Bach, M., Varga, M., 2006. Profil stručnjaka za rudarenje podataka. Ekonomski fakultet Zagreb, Katedra za informatiku. *skladištenje.com* Dostupno na: http://www.skladistenje.com/profil-strucnjaka/ [pristupljeno 10.04.2017.]

1.5. METODE ISTRAŽIVANJA

U ovom radu provodi se teorijsko i empirijsko istraživanje. Teorijsko istraživanje se bazira na prikupljenoj, već postojećoj stručnoj i znanstvenoj literaturi, dok se empirijsko istraživanje provodi putem anketa i metode intervjua. Teorijsko istraživanje u ovom radu bazira se na sljedećim metodama znanstveno - istraživačkog rada: metoda analize, metoda apstrakcije, induktivno-deduktivna metoda, metoda sinteze, metoda klasifikacije, metoda deskripcije, metoda dokazivanja, metoda opovrgavanja, metoda kompilacije, metoda anketiranja, metoda intervjua te metoda grafičkog prikazivanja podataka[17]. Navedene metode su pojašnjene u tekstu koji slijedi.

- *Metoda analize* je postupak raščlanjivanja složenih pojmova, sudova i zaključaka na jednostavnije sastavne dijelove te izučavanje svakog dijela za sebe i u odnosu na druge dijelove, odnosno cjeline. Ovom metodom se opisuju funkcionalnosti i uloge najznačajnijih metoda tj. tehnika rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera, odnosno opisuju se funkcionalnosti svake tehnike za sebe, te se uspoređuju s drugim tehnikama.

- *Metoda apstrakcije* je misaoni postupak kojim se namjerno odvajaju nebitni, a ističu bitni elementi i osobine određenog predmeta ili pojave istraživanja. Zajedno s apstrakcijom, najčešće se provodi i *metoda konkretizacije*-misaoni postupak suprotan apstrakciji. Pomoću ove metode se analiziraju pojmovi vezani uz rudarenje podataka, projektni menadžment i razvoj softvera.

- *Induktivno-deduktivna metoda* je način zaključivanja u kojem se na temelju pojedinačnih ili posebnih činjenica dolazi do zaključaka o općem sudu, odnosno u kojem se iz općih postavki dolazi do konkretnih pojedinačnih zaključaka. Može se reći kako je dedukcija definirana kao zaključivanje od općeg prema posebnom, dok je indukcija zaključivanje od posebnog prema općem. Analizom dobivenih rezultata istraživanja dolazi se do saznanja koje su najzastupljenije metode rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera, koliko se zapravo koriste, te u kojoj mjeri rudarenje podataka pomaže u uspješnosti projekata u budućnosti u okviru razvoja softvera.

[17] Zelenika, R., 2000. *Metodologija i tehnologija izrade znanstvenog i stručnog djela.* 4. izd. Rijeka: Ekonomski fakultet u Rijeci, str. 323-381.

- *Metoda sinteze* je postupak znanstvenog istraživanja i objašnjavanja putem spajanja dijelova jednostavnih misaonih elemenata u složene, a složene u još složenije, povezujući izdvojene elemente, pojave, procese i odnose u jedinstvenu cjelinu u kojoj su njezini dijelovi međusobno povezani. Pomoću ove metode utvrđuju se najpopularnije metode rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera. U radu se koristi kako bi se problematika koja se istražuje prikazala na što jednostavniji način.

- *Metoda deskripcije* je postupak jednostavnog opisivanja ili očitavanja činjenica, procesa i predmeta te empirijsko potvrđivanje njihovih veza i odnosa. Ova metoda se koristi u radu kako bi se opisali osnovni pojmovi kao što su rudarenje podataka, baze podataka, skladišta podataka, softver, projektni menadžment i sl. te utvrdili odnosi između rudarenja podataka u projektnom menadžmentu pri razvoju softvera i uspješnosti projekta u budućnosti na temelju informacija prikupljenih rudarenjem podataka.

- *Metoda klasifikacije* je postupak raščlanjivanja općeg pojma na posebne, tj. jednostavnije pojmove. U radu se koristi kako bi se što bolje objasnio cijeli proces rudarenja podataka.

- *Metoda dokazivanja* je misaono-sadržajni postupak kojim se utvrđuje istinitost pojedinih spoznaja, stavova ili teorija. Prilikom dokazivanja traže se pretpostavke koje određenu hipotezu trebaju dokazati. Pomoću ove metode utvrđuje se veza između rudarenja podataka sa uspješnošću projekta, odnosno njegovim pozitivnim učinkom na planiranje i provođenje projekata, te da li rudarenje podataka omogućuje precizniju i bržu izradu projekata.

- *Metoda opovrgavanja* je suprotni postupak u odnosu na postupak dokazivanja. To je metodski postupak kojim se umjesto dokazivanja teze, ona odbacuje i pobija. Ona se sastoji u dokazivanju pogrešnosti teze. Navedena metoda služi kako bi se na temelju rezultata istraživanja odlučilo hoće li se postavljenu hipotezu opovrgnuti.

- *Metoda komparacije* je postupak uočavanja i uspoređivanja sličnosti i razlika te zajedničkih obilježja dvaju ili više događaja, pojava ili objekata. U radu se koristi kako bi usporedili rezultate drugih autora koji su proveli slična istraživanja vezana uz tematiku ovog rada.

- *Metoda kompilacije* je postupak preuzimanja tuđih rezultata znanstvenoistraživačkog rada, odnosno tuđih opažanja stavova, zaključaka i spoznaja. Ova metoda je neizostavna kod

pisanja istraživačkih i diplomskih radova, gdje se sukladno pravilnicima citira sva korištena literatura za pisanje rada. Ova metoda se uvijek koristi u kombinaciji s drugim metodama.

- *Metoda anketiranja* predstavlja postupak kojim se na temelju anketnog upitnika istražuju i prikupljaju podaci, informacije, mišljenja i stavovi o predmetu istraživanja. Ova je metoda pouzdana u tolikoj mjeri u kolikoj su mjeri pouzdane same informacije prikupljene tom metodom.

- *Metoda intervjua (standardizirani intervju)* je formalno i sadržajno razrađen, tako da je govor ispitanika vođen unaprijed pripremljenim pitanjima. Prakticira se u ekstezivnim istraživanjima radi provjeravanja postavljene hipoteze.

- *Grafičko prikazivanje* statističkih podataka je metoda kojom se grafičkim prikazivanjem podataka omogućuje interpretacija rezultata statističkog istraživanja. Pomoću ove metode rezultati istraživanja se mogu vizualno iščitati, pritom izbjegavajući opširne deskripcije.

U skladu sa različitostima zahtjeva svakog pojedinog dijela ovog rada, koriste se različite metodologije, a sve u cilju potvrđivanja, odnosno odbacivanja postavljene hipoteze. U ovom radu koriste se primarni i sekundarni podaci. Teorijski dio rada temelji se na prikupljanju i analiziranju relevantne stručne i znanstvene literature, odnosno prikupljanjem sekundarnih izvora podataka. Za potrebe ovog rada pri prikupljanju sekundarnih podataka korištene su razne knjige, članci, te različite baze podataka. Popis korištene literature je naveden na kraju rada, a obuhvaća pretragu pojmova kao što su rudarenje podataka, projekt, projektni menadžment, softver. Teorijski dio rada temeljen na prikupljenim sekundarnim podacima koristi metodu apstrakcije, klasifikacije, komparacije te kompilacije. Emiprijski dio rada temeljen na podacima dobivenim provedenim istraživanjem koristi slijedeće metode: metoda analize, induktivno-deduktivna metoda, metoda sinteze, metoda deskripcije, metoda dokazivanja, metoda opovrgavanja, metoda anketiranja, metoda intervjua i grafičko prikazivanje. Empirijsko istraživanje se provodi putem anketnog upitnika, nad slučajnim uzorkom ispitanika, odnosno tvrtki koje se bave razvojem softvera na području grada Stockholma u Švedskoj. Sama distribucija anketnih upitnika vrši se osobno, elektroničkim putem ili putem društvenih mreža (npr.LinkedIn). Empirijsko istraživanje se također provodi pomoću metode intervjua koji je formalno i sadržajno razrađen, a govor ispitanika je vođen unaprijed pripremljenim pitanjima. Dobiveni podaci obrađuju se u softverskom paketu koji služi za obradu statističkih podataka SPSS-u, odnosno (Statistical Package for the Social Sciences).

1.6. DOPRINOS ISTRAŽIVANJA

Doprinos rada ogleda se kroz proširenje trenutnih saznanja i broja empirijskih istraživanja, odnosno kroz proširenje postojeće literature o učincima rudarenja podataka na povećanje uspješnosti projekata u budućnosti, u okviru razvoja softvera. Uz pomoć empirijskog istraživanja donose se zaključci temeljeni na prikupljenim primarnim podacima, na području grada Stockholma. Stoga su očekivanja ovog rada približavanje spomenute problematika kroz nova saznanja, odnosno dokazivanjem ili opovrgavanjem postavljene istraživačke hipoteze. Konkretan doprinos ovog rada odnosi se na istraživanje definiranih odnosa utjecaja između rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera i njegovim pozitivnim učinkom na planiranje i provođenje projekata, kao i precizniju i bržu izradu projekata u budućnosti. Dobiveni zaključci mogu poslužiti za daljnja istraživanja ili kao zanimljiv prikaz tvrtkama koje se bave razvojem softvera, u kojoj mjeri rudarenje podataka uistinu pomaže kod tržišnog nastupa tvrtke. Ukoliko se ovaj rad koristi za neka daljnja istraživanja, tada se mogu uspoređivati dobiveni rezultati istraživanja ovog diplomskog rada sa rezultatima dobivenim iz nekog drugog sličnog rada, na području nekog drugog grada u Švedskoj, ili nekoj drugoj državi. Također, ukoliko neka poduzeća još uvijek ne koriste rudarenje podataka kao alat u unapređenju poslovanja, možda se ipak predomisle nakon dobivenih zaključaka ovog diplomskog rada. U današnjem poslovanju dolazi do tzv. eksplozije podataka. Podaci se gomilaju, ali do njih nije jednostavno i brzo doći, stoga rudarenje podataka postaje imperativ, a ne opcija ukoliko poduzeće želi biti konkurentno na tržištu. U podacima leži veliki potencijal i pravo bogatstvo, ali samo uz pomoć rudarenja podataka, ti podaci se mogu objediniti, obraditi i staviti na raspolaganje menadžmentu. U skladu s navedenim, cijeli rad približava problematiku korištenja rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera, kao alata u donošenju poslovnih odluka otkrivajući nova saznanja iz mnoštva podataka, a sve u svrhu poboljšanja poslovnih rezultata.

1.7. STRUKTURA DIPLOMSKOG RADA

Rad je strukturiran u šest poglavlja, uključujući uvod i zaključak.

U uvodnom, prvom poglavlju prikazuju se temeljne odrednice rada, a to su: definicija problema, predmet i ciljevi istraživanja, korištene metode, ostvareni doprinos istraživanja kroz postavljenu hipotezu, te prikaz strukture diplomskog rada.

U drugom dijelu rada teorijski se definiraju i objašnjavaju pojmovi vezani uz rudarenje podataka kao i njegov razvoj, pojmovi vezani uz korištenje tih tehnika, navedene su faze pretraživanja podataka kod rudarenja podataka, te se prikazuje uloga rudarenja podataka u svakodnevnom poslovanju.

U trećem poglavlju objašnjavaju se osnovni pojmovi vezani uz projektni menadžment i njegov razvoj. Definiraju se faze u projektnom menadžmentu, te se prikazuju najpopularniji softveri u projektnom menadžmentu.

U četvrtom dijelu se prikazuju osnovni pojmovi vezani uz razvoj softvera. Prikazuju se metode razvoja softvera, predstavlja se što je to osiguranje kvalitete (QA), te pokazuje koji su to procesi u okviru razvoja softvera.

U petom poglavlju predstavljaju se ciljevi i metode istraživanja, analiziraju prikupljeni podaci, te interpretiraju. U ovom dijelu predstavljen je empirijski dio istraživanja, odnosno testiranje postavljene istraživačke hipoteze, te su prikazana ograničenja koja su uočena prilikom istraživanja.

U šestom, posljednjem dijelu rada prikazan je zaključak do kojeg se došlo na temelju teorijskih spoznaja u kombinaciji sa dobivenim rezultatima istraživanja. Ovo poglavlje također daje uvid u literaturu koja je korištena prilikom izrade diplomskog rada, popis slika, tablica i grafikona, te priloge koji su povezani s istraživačkim dijelom rada. Na samom kraju rada nalazi se sažetak na hrvatskom i engleskom jeziku.

2. RUDARENJE PODATAKA

2.1. POJAM I RAZVOJ RUDARENJA PODATAKA

2.1.1. Što je rudarenje podataka?

Pojam rudarenja podataka je najjednostavnije opisati kao pronalaženje obrazaca i zakonitosti u podacima kako bismo dobili informacije iskoristive za svrhe poslovnog odlučivanja. Naravno da nisu svi podaci dobiveni rudarenjem podataka iskoristivi, ali danas je teško zamisliti uspješno poslovanje poduzeća bez korištenja tehnika rudarenja podataka. Za rudarenje podataka se može reći da je prirodna evolucija tehnologije, a budući da upotrebljava metode, koncepte i tehnike različitih disciplina kao što su statistika, baze podataka, umjetna inteligencija i sl. podrazumjeva se da je pojam rudarenja podataka interdisciplinaran[18].

Rudarenje podataka je podržano uz pomoć skladišta podatka, koje je, prema Inmonu "skup subjektno orjentiranih, integriranih, vremenski ovisnih i nepromjenjivih podataka koji služe kao podrška poslovnom odlučivanju"[19,20]. Baze podataka mogu se pak definirati kao uređen i organiziran skup međusobno povezanih podataka, koji koristi veliki broj korisnika, i koji su pohranjeni na disku, a služe korisnicima za pregledavanje, brisanje, pretraživanje, ispravljanje ili nadopunjavanje[21,22]. Sustav koji upravlja bazom podataka (eng. DBMS - Database Managment system) je programski sustav koji "osigurava osnovne funkcije odabranog modela podataka u postupku kreiranja i korištenja baze podataka"[23]. To je zapravo softver uveden kao sučelje između korisnika (aplikacija, korisničkih programa) i zapisa baze podataka na disku.

---

[18] Karlović, S., Pantelić, A., i Pedić, J., 2017. Rudarenje podataka. *TAOPIS the autopoetic information system.*: Dostupno na: http://autopoiesis.foi.hr/wiki.php?name=KM%20-%20Tim%2062&parent=NULL&page=new [pristupljeno 27.06.2017.]

[19] Inmon, W.H., 1992. Building the Data Warehouse. *John Wiley & Sons, Inc*. New York, NY, USA. str. 31.

[20] Oreščanin, D., 2004. Skladno skladištenje. *skladištenje.com* Dostupno na: http://www.skladistenje.com/skladno-skladistenje/ [pristupljeno 19.03.2017.]

[21] Mandić, S., 2012. Pojam baze podataka. *Računarstvo i informatika.* Dostupno na: https://racunarstvoiinformatika.wordpress.com/2012/01/23/pojam-baze-podataka/ [pristupljeno 21.03.2017.]

[22] Batistić, I., 2004. Što su to baze podataka?. *Grdelin.* Dostupno na: http://grdelin.phy.hr/~ivo/Nastava/Baze_podataka/predavanja-2004/01_pred.pdf [pristupljeno 21.03.2017.]

[23] Tudor, M., Informacijski sustavi.htm. Pomorski Fakultet, Sveučilište u Rijeci. Dostupno na: http://www.pfri.uniri.hr/~tudor/materijali/Informacijski%20sustavi,%20baze%20podataka.htm [pristupljeno 22.03.2017.]

Postoje brojne definicije rudarenja podataka koje su postavili razni autori. Frideman[24] u svojoj knjizi objedinjuje brojne autore i njihove definicije rudarenja podataka, pa je tako prema Fayyadu rudarenje podataka netrivijalni proces idetificiranja potencijalno korisnih, novih i u konačnici razumljivih uzoraka u podacima[25]. Han, Pei i Kamber tvrde da rudarenje podataka pretvara velike količine podataka u znanje[26]. Međutim, ne pružaju nam svi podaci nužno novo znanje. Prema Ziegenbeinu "podaci postaju informacijama ako dobiju neki smisao, te su kao takvi uporabljivi za procese planiranja, odlučivanja, kontrole, operativne procese i procese učenja"[27]. Zekulin kaže da je rudarenje podataka proces ekstrahiranja prethodno nepoznatih, razumljivih i djelotvornih informacija iz velikih baza podataka, te korištenje istih kako bi se donosile ključne poslovne odluke. Prema Ferruzzi rudarenje podataka je set metoda korištenih u procesu otkrivanja znanja kako bi se uvidjeli prethodno nepoznati odnosi i obrasci unutar podataka. John kaže da je rudarenje podataka proces pronalaženja pogodnih obrazaca u podacima, dok Parsaye tvrdi da je rudarenje podataka proces potpore odlučivanja, gdje promatramo velike baze podataka kako bi pronašli nove i neočekivane obrasce informacija. Prema Handu i ostalima rudarenje podataka je analiza (često velikih) promatranih skupova podataka kako bi se pronašle neočekivane veze i sumirali podaci na nove načine koji su istovremeno razumljivi i korisni vlasniku podataka[28]. Može se primjetiti da su sve gore navedene definicije jako slične. U svim područjima gdje se raspolaže velikom masom podataka u kojima se žele otkriti određene pravilnosti, veze i zakonitosti moguće je primjeniti rudarenje podataka, međutim čitav niz faktora može utjecati na ishod nekog događaja, a zadatak je rudarenja podataka otkriti koji su to najznačajniji faktori i koje su njihove karakteristike, s obzirom na ultimativni cilj koji se želi postići[29]. Na slici 2. prikazana je tablica izrađena od strane autorice ovog rada prema Panianu i

[24] Friedman, J.H. *Data mining and statistics: Where`s the connection?* Stanford University.pdf: Dostupno na: http://venus.unive.it/romanaz/edami/letture/jfriedman.pdf [pristupljeno 27.06.2017.] str. 1.

[25] Friedman, J.H.,op.cit.

[26] Han, J., Pei, J. i Kamber, M., 2012. Data Mining: Concepts and Techniques, *Elsevier Inc.,* USA, str. 2.

[27] Ziegenbein, K., 2008. Kontroling, *RRiF plus*, Zagreb, str. 163.

[28] Hand, D., Mannila, H., i Smyth, P., 2001. *Principles of Data Mining.* The MIT Press pdf. Dostupno na: http://box.cs.istu.ru/public/docs/other/_New/Books/Misc/Principles%20of%20Data%20Mining.pdf [pristupljeno 29.06.2017.] str. 6.

[29] Zvorc, N., Stokan, K., Vuković, M., Područja primjene rudarenja podataka. 2017. *TAOPIS the autopoetic information.* Dostupno na: http://autopoiesis.foi.hr/wiki.php?name=KM+-+Tim+20&parent=NULL&page=Podrucja%20primjene%20rudarenja%20podataka [pristupljeno 03.07.2017.]

Klepecu, u kojoj su prikazana 4 razdoblja te njihovi evolucijski koraci koji su u konačnici doveli do rudarenja podataka kakvog danas poznajemo.

Tablica 1: Prikaz četiri revolucionarna koraka koja su pružila mogućnost brzih i preciznih odgovora kakve danas zahtijeva suvremeno poslovanje

RAZDOBLJE	EVOLUCIJSKI KORACI	POSLOVNI UPITI	TEHNOLOGIJA	KARAKTERISTIKE
1960-te	Prikupljanje podataka.	Koliki je ukupni prihod kompanije u posljednjih pet godina?	Kompjutori, trake, diskovi.	Statična isporuka povijesnih podataka.
1980-te	Pristup podacima.	Kolika je bila prodaja po određenim prodajnim jedinicama na području Dalmacije u proteklom mjesecu?	Relacijske baze podataka, SQL, ODBC.	Dinamična isporuka povijesnih podataka jedne razine.
1990-te	Skladištenje podataka i sustavi za potporu odlučivanju.	Kolika je bila prodaja u određenim prodajnim jedinicama na području Dalmacije u proteklom mjesecu? Istraži (drill down) lokalitet Split.	OLAP, multidimenzijske baze podataka, skladište podataka.	Dinamična isporuka povijesnih podataka s više razina.
Danas	Rudarenje podataka.	Što se moe dogoditi s prodajom na lokalitetu Split u sljedećem mjesecu? Zašto?	Napredni algoritmi, multiprocesorski kompjutori, masivne baze podataka.	Predvidiva i proaktivna isporuka informacija.

Prema: Panian, Ž., Klepac, G., 2003. *Poslovna inteligencija,* MASMEDIA, Zagreb. str.78.

Iako su pojedine metode rudarenja podataka u razvijene još u sedamdesetim i osamdesetim godinama dvadesetog stoljeća, u tom periodu nije bilo dogovora što pojam rudarenja podataka zapravo obuhvaća. Sam pojam rudarenja podataka prvi put se počeo koristiti u istraživačkim zajednicama tokom kasnih osamdesetih prošlog stoljeća, međutim, tek je polovica devedesetih godina dvadesetog stoljeća donijela sintagmu rudarenje podataka (eng. data mining) koja objedinjava skup postupaka i metoda koje otkrivaju zakonitosti u masi podataka[30]. Zahvaljujući razvoju tehnologije i in-

[30] Klepac, G. i Mršić, L., op.cit.

terneta u današnje vrijeme je puno lakše organizirati podatke nego što je to bio slučaj u devedesetim godinama dvadesteog stoljeća. Ipak, kako bi ti podaci usitinu mogli poslužiti za donošenje kvalitetnih poslovnih odluka, odnosno da bi oni postali korisni, potrebno je njihovo pretvaranje u informacije i znanje, a to je jedino moguće uz korištenje tehnika rudarenja podataka.

2.1.2. Korištenje rudarenja podataka

U današnjem načinu poslovanja većina klijenata je podijeljena između konkurencije i upravo zbog toga su brojna poduzeća prisiljena promijeniti svoj poslovni odnos prema klijentima. Praksa je pokazala kako proizvodi koji su prilagođeni svima, ustvari odgovaraju jako malom broju klijenata i zbog toga rudarenje podataka igra važnu ulogu kako bi se poduzeća što više orijentirala prema klijentima, odnosno kako bi što bolje zadovoljile njihove želje i potrebe. U skladu s time je nastao pojam "upravljanje odnosom s klijentom", poznatije kao skraćenica CRM (Customer Relationship Management)[31]. Uz pomoć rudarenja podataka lakše je pratiti ponašanje konkurencije, dobavljača, kupaca, pojedinih tržišnih segmenata, te je olakšano operativno planiranje kao i predviđanje budućih pojava[32].

Rudarenje podataka se koristi za: zbrajanje podataka, segmentiranje, klasificiranje, predviđanje, te asocijaciju (prepoznavanje uzoraka)[33]. Pri tome izvori podataka mogu biti različiti, od klasične tradicionalne baze podataka, pa sve do rudarenja teksta, rudarenja Weba, kao i analize vremenskih serija. Rudarenje tradicionalnih baza podataka naziva se tzv. tradicionalno rudarenje podataka, dok je rudarenje Weba, ili teksta nešto složenije, budući da takvi izvori podataka najčešće nisu strukturirani ili su pak strukturirani na temelju nekog specifičnog formata[34].

Primjenom metoda koje svoje korijene vuku iz različitih područja kao što su primjerice matematika, teorija vjerojatnosti, baze podataka, teorija informacija, statistika i umjetna inteligencija pronalazi-

[31] I.V., 2002. Rudarenje poslovno-financijskih podataka. *skladištenje.com*. Dostupno na: http://www.skladistenje.com/rudarenje-poslovno-financijskih-podataka/ [pristupljeno 05.07.2017.]

[32] Klepac, G. i Mršić, L., op.cit.

[33] Karlović, S., Pantelić, A., i Pedić, J., op.cit.

[34] Klepac, G. i Mršić, L., op.cit.

mo zakonitosti u podacima[35]. Imajući na umu da su informacija i znanje dva temeljna resursa za uspješno poslovanje[36], potrebno je znati izvući prave informacije iz mnoštva podataka kako bi se oni mogli uistinu koristiti.

2.1.3. Faze pretraživanja podataka

Prije samog procesa rudarenja podataka potrebno je razmisliti na koji način je moguće prepoznati problem koji je potrebno riješiti analizirajući podatke, kako iz 'hrpe' podataka dobiti željeni odgovor (budući da prikupljanje podataka više nije nikakav problem, već je problem snalaženje u podacima), koji test odnosno metodu upotrijebiti kako bi se riješio određeni problem odnosno dobio odgovor, kako pravilno primijeniti statističke metode, te kako donijeti odluku temeljenu na znanju o podacima.

Sam proces rudarenja podataka sastoji se od više faza koje se mogu promatrati iz tri različite perspektive, a koje jedna osoba ne može samostalno izvršiti[37]. Na samom početku i na kraju procesa rudarenja podataka važna je problemska perspektiva koja se sastoji od odabira problema, definiranja problema, te procjene i primjene znanja. Osoba koja obavlja ove zadatke naziva se korisnik. Druga perspektiva obuhvaća sve zadatke koji su vezani uz pripremu podataka kako bi se mogli rudariti. Ova faza se naziva podaktovna, a obavlja je informatičar. Treća, ujedno i posljednja perspektiva sastoji se od svih zadataka koji su vezani uz analizu podataka, te metode selekcije, implementacije, prezentacije i interpretacije rezultata. Ova faza naziva se metodološka, a obavlja ju osoba koja je stručnjak u rudarenju podataka (eng. data miner)[38]. U sustavima poslovne inteligencije rudarenje podataka može biti podržano skladištima podataka, a ukoliko ne postoji skladište podataka tada se nakon čišćenja podataka ulazi direktno u proces predprocesiranja podataka bez posredovanja skla-

[35] Zvorc, N., Stokan, K., Vuković, M., 2017. Rudarenje podataka (Data Mining) *TAOPIS the autopoetic information system*Dostupno na: http://autopoiesis.foi.hr/wiki.php?name=KM+-+Tim+20&parent=NULL&page=Rudarenje%20podataka [pristupljeno 06.07.2017.]

[36] Čačić, M. Varga, M., 2004 . Informacijska tehnologija u poslovanju. *Element*, Zagreb. str.7.

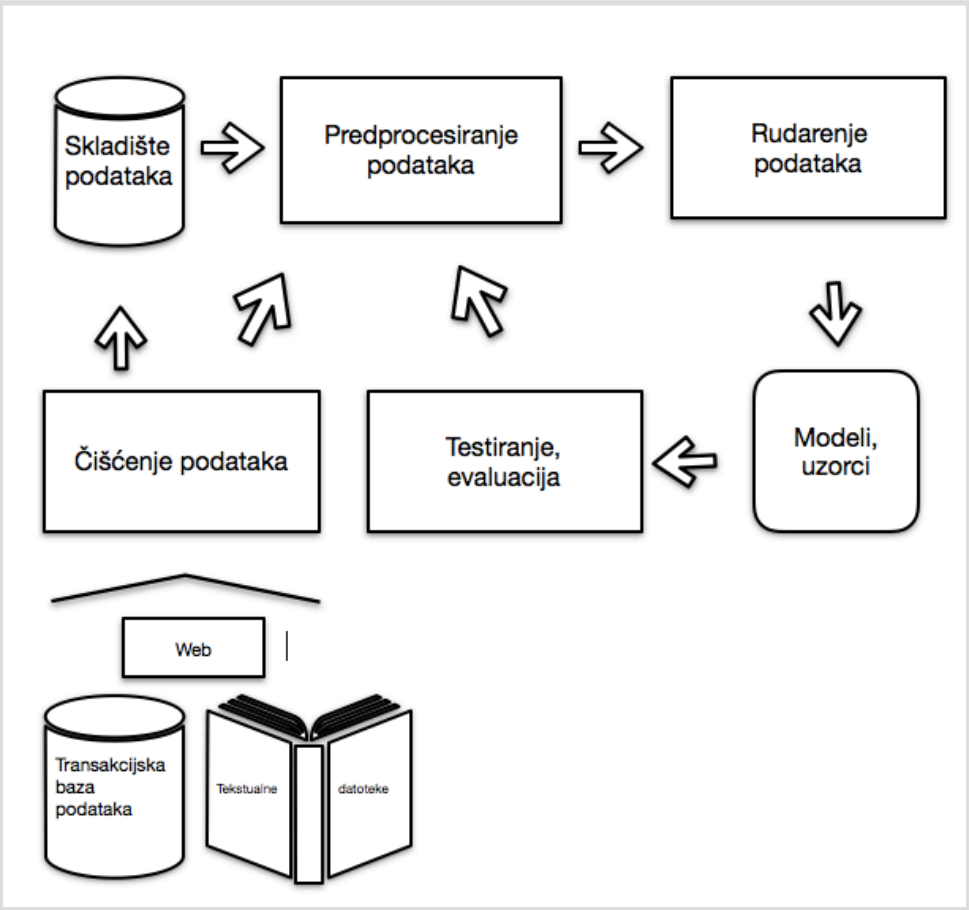
[37] Pejić Bach, M. i Varga, M., 2006. Profil stručnjaka za rudarenje podataka. Ekonomski fakultet, Zagreb. *skladistenje.com* Dostupno na: http://www.skladistenje.com/profil-strucnjaka/ [pristupljeno 04.07.2017.]

[38] Ibid.

dišta podataka[39]. Na slici 3. prikazana je metodologija otkrivanja znanja primjenom metode rudarenja podataka izrađena od strane autorice ovog rada, prema Klepacu i Mršiću.

Važno je napomenuti kako je prije svake analize potrebno napraviti čišćenje podataka, odnosno uklanjanje podataka s greškama, zastarjelih podataka, neupotpunjenih podataka, duplikata i slično. Transformacija podataka je jako važna budući da se tim procesom podiže kvaliteta, odnosno iskoristivost podataka[40].

Slika 2: Metodologija otkrivanja znanja primjenom metoda rudarenja podataka



Izvor: Prema Panian, Ž., Klepac, G., 2003. *Poslovna inteligencija,* MASMEDIA, Zagreb. str.35.

[39] Klepac, G. i Mršić, L., op.cit.

[40] Hammergen, T. C., Simon, A.R. 2009. *Data Warehousing for Dummies.* Willey.

Postoji niz metodoliških pristupa problematici, koji u najvećoj mjeri ovise o preferencijama autora koji obrađuju određenu problematiku, odnosno o ultimativnom cilju koji se želi postići. Najpopularnije metodologije rudarenja podataka su CRISP i SEMMA koje definiraju neke standarde i korake u kojima se provodi rudarenja podataka, odnosno izvlači znanje iz podataka[41]. Iako su navedene metodologije slične, u ovom radu opisati će se CRISP - DM metodologija, iako neće biti detaljno obrazložena. Može se ukratko reći kako je CRISP - DM skraćenica od Cross Industry Standard Process for Data Mining, a sastoji se od šest osnovnih koraka, a to su: 1. Definiranje poslovnog cilja; 2. Razumijevanje podataka; 3. Priprema podataka; 4. Modeliranje; 5. Evaluacija; te 6. Implementacija[42]. Razumijevanje poslovanja je najbitniji dio CRISP-a, stoga je prije početka samog istraživanja podataka važno znati što je zapravo cilj istraživanja. Idući korak je razumjeti podatke koji se žele analizirati i pripremiti ih za daljnju analizu (pročistiti ih), a pri tome treba imati na umu da priprema podataka oduzima oko 70-80% ukupnog vremena projekta. Nakon pripreme podataka pristupa se modeliranju i ukoliko se žele otkriti neka nova znanja tada se koriste algoritmi za klasterizaciju koji od podataka rade određene segmente prema različitim karakteristikama, a najbolji algoritmi za klasterizaciju su k-Means algoritam i Apriori. Ukoliko se pak želi nešto predvidjeti iz postojećih podataka onda će se koristiti algoritmi za klasifikaciju, a to su: algoritam stabla odlučivanja, logističke regresije i neuronskih mreža. Naposljetku se analizira zadovoljstvo rezultatima analize, a ukoliko ono nije zadovoljavajuće tada se potrebno vratiti na početnu fazu revidiranja poslovnog cilja ili baza podataka te primjeniti neke druge algoritme kako bi se dobio bolji rezultat[43].

Kao što je već prije spomenuto, vrlo je teško povući jasnu granicu te deklarirati pojedine metode kao isključive metode rudarenja podataka, s obzirom na interdisciplinarnost područja rudarenja podataka, međutim, to nikako nije nedostatak ovog područja već prednost, budući da je iz niza disci-

41 Hampton, J., 2011. SEMMA and CRISP-DM: Data mining methodologies. *jesshampton.com* Dostupno na: http://jesshampton.com/2011/02/16/semma-and-crisp-dm-data-mining-methodologies/ [pristupljeno 22.06.2017.]

42 Gabelica, H. 2013. Rudarenje podataka i CRISP metodologija. *skladištenje.com*. Dostupno na: http://www.skladistenje.com/rudarenje-podataka-i-crisp-metodologija/[pristupljeno 23.06.2017.]

43 Ibid.

plina moguće odabrati one metode i postupke koje u procesu analize mogu lako dovesti do željenog cilja[44].

2.1.4. Uloga rudarenja podataka u svakodnevnom poslovanju

Autori Witten i Frank smatraju da smo u današnjem svijetu pretrpani s podacima. Količina podataka u svijetu i u našim životima, kao da teži ka stalnom povećanju, i čini se da se tome ne nazire kraj. Jeftini diskovi sa mogućnošću spremanja velike količine podataka kao da sugeriraju da spremimo sve, pa čak i kad razmišljamo da li određene stvari na osobnom računalu izbrisati ili zadržati, najčešći je slučaj - jednostavno kupiti još jedan disk i zadržati sve. World Wide Web je preplavljen informacijama, a istovremeno svaka aktivnost na Internetu je zabilježena, svaki izbor se "snima". Svi svjedočimo pristunosti jaza između prikupljanja tih podataka i samom razumijevanju istih[45]. Može se reći kako poslovna inteligencija, odnosno Business Inteligence (BI) sustav omogućava bolje razumijevanje vlastitih klijenata i spoznavanje što ih potiče na određeno ponašanje. Neke od metoda poslovne inteligencije uključuju rudarenje podataka (Data Mining), skladištenje podataka (Data Warehousing) i OLAP mrežnu analitičku obradu podataka, dok se sam pojam poslovne inteligencije *(eng. Business Intelligence, BI)* vezuje uz skup metodologija i koncepata za prikupljanje, analizu i distribuciju informacija uz pomoć različitih softverskih alata[46].

Rudarenje podataka je izrazito multidisciplinarno područje i obuhvaća: baze podataka, ekspertne sustave, teoriju informacija, statistiku, matematiku, logiku, te čitav niz pridruženih područja, dok su područja u kojima se rudarenje podataka može uspješno primjenjivati raznolika, primjerice, poslovanje poduzeća, ekonomija, mehanika, medicina, genetika itd[47]. Rudarenje podataka se koristi još i u politici (rudarenje je metoda kojom je U.S. Army uspjela identificirati vođu napada na Twin

---

[44] Klepac, G. i Mršić, L., op.cit.

[45] Witten, I.H. i Frank, E., 2005. *Data mining: Practical machine learning tools and techniques*. Elsevier : MK [i. e.] Morgan Kaufmann, cop. Amsterdam [etc.] str. 4.

[46] Wikipedia, 2014. Poslovna inteligencija. Dostupno na: https://hr.wikipedia.org/wiki/Poslovna_inteligencija [pristupljeno 28.06.2017.]

[47] Zvorc, N., Stokan, K., Vuković, M., 2017. Područja primjene rudarenja podataka. *TAOPIS*. Dostupno na: http://autopoiesis.foi.hr/wiki.php?name=KM+-+Tim+20&parent=NULL&page=Podrucja%20primjene%20rudarenja%20podataka [pristupljeno 10.07.2017.]

Towers, 11.9.2001.; a tom se metodom također koristi i CIA); igrama (npr.šah); poslovanju (pomaže u bržem donošenju poslovnih odluka)[48].

U današnjem poslovanju razne institucije definiraju segmente u koje svrstavaju svoje klijente kako bi što bolje prepoznale njihove potrebe, ponašanje i profitabilnost, a pri tome koriste složene metode rudarenja podatataka. Također, danas se koriste brojni alati koji omogućuju analizu podadataka na način da se iz velike količine podataka traže uzorci, što je u prošlosti bilo neizvedivo radi predugog vremena potrebnog za takvu vrstu analize. Zahvaljujući povećanju brzine računala to je danas izvedivo, a korisnici su otkrili kako rudarenje podataka pomaže u otkrivanju uzorka određenih pojava kao i boljem razumijevanju ponašanja klijenata[49].

[48] Karlović, S., Pantelić, A., i Pedić, J., op.cit.

[49] I.V., op.cit.

3. PROJEKTNI MENADŽMENT

3.1. POJAM I RAZVOJ PROJEKTNOG MENADŽMENTA

3.1.1. Značenje projektnog menadžmenta

Tržišna situacija u današnjem poslovanju zahtijeva od tvrtke određenu razinu projektnog pristupa kako bi što bolje upravljala sa svim raspoloživim resursima. Zahvaljujući kvalitetnom upravljanju projektima izvršni menadžment ima bolji uvid u troškove te samim time donosi kvalitetnije odluke na razini cijele organizacije, koje su u skladu sa strateškim ciljevima tvrtke, uz istovremeno povećanje produktivnosti te postizanje prednosti u odnosu na konkurenciju[50].

Za projektni menadžment postoje brojne definicije, pa je tako prema Project Management Institutu "projektni menadžment primjena znanja, vještina, alata i tehnika na projektnim aktivnostima kako bi se postigli njegovi zahtjevi"[51], a obuhvaća planiranje, organiziranje, praćenje i kontrolu svih aspekata projekta kao i motiviranje svih uključenih ljudi za postizanje ciljeva projekta[52]. Projektni menadžment se još može definirati i kao primjena menadžerskih tehnika za postizanje unaprijed postavljenih strateških i operativnih ciljeva s obzirom na opseg troškova, kvalitetu i zadovoljavanje potreba te očekivanja sudionika projekta. Ujedno je i vještina vođenja i koordiniranja ljudskih i materijalnih resursa tijekom čitavog životnog ciklusa projekta[53].

Za projekt možemo reći da je to privremeni pothvat koji se poduzima za stvaranje jedinstvenog proizvoda, usluge ili rezultata. Svaki projekt ima svoj početak i kraj, pa tako postoji pet procesa upravljanja projektom, a to su: pokretanje, planiranje, izvršavanje, praćenje i kontrola, te zatvaranje[54].

Parametri koji izravno utječu na uspjeh ili neuspjeh projekta su: doseg, kvaliteta, trošak, vrijeme i resursi, ali ne smije se zanemariti ni rizik koji utječe na svih pet navedenih parametara, iako nije

---

50 Algebra, otvoreno učilište., op.cit.

51 Project Management Institute, 2000. *A Guide to the Project Management Body of Knowledge (PMBOK Guide)* .Dostupno na: https://www.amazon.com/Guide-Project-Management-Knowledge-PMBOK/dp/1880410230 [pristupljeno 09.07.2017.] str. 6

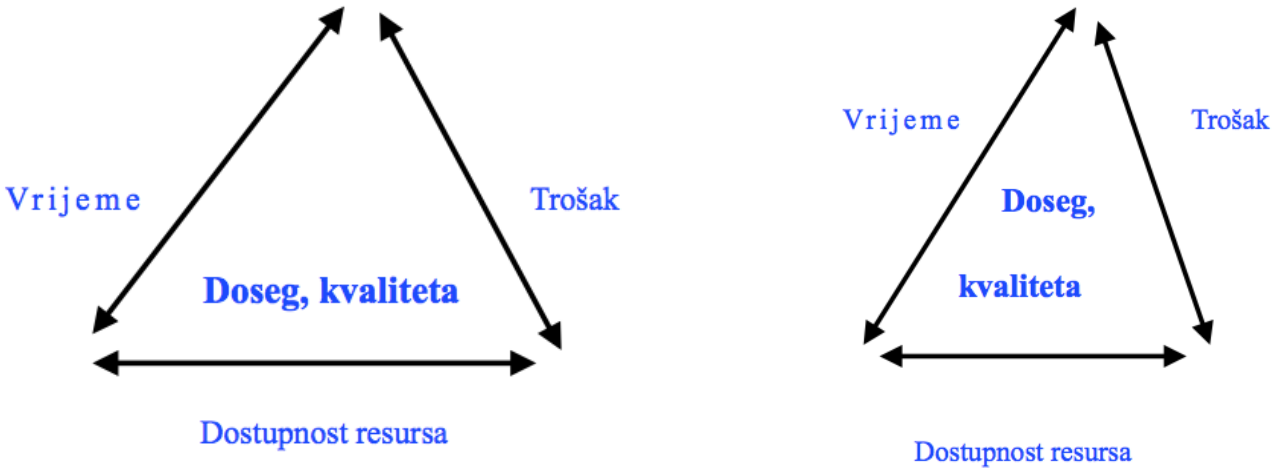
52 Šunjić, D., 2017. Projektni menadžment-Upravljanje projektima. *scribd.com* Dostupno na: https://www.scribd.com/doc/48038724/Projektni-Menadzment-Upravljanje-projektima [pristupljeno 10.07.2017.]

53 Tolić, H. 2016. Upravljanje projektima sportske organizacije primjenom programa ProjectLibre. Završni rad. str. 4.

54 Project Management Institute (PMI) 2000., op.cit.

sastavni dio parametara projekta. Dempsterov trokut ili trokut dosega (scope triangle) prikazuje trostruko ograničenje (triple constraint) odnosa parametara koji trebaju biti u ravnoteži, odnosno treba postojati ravnoteža zahtjeva na trajanje, troškove i resurse uz očuvanje dosega i kvalitete, dok promjena bilo kojeg parametra izbacuje projekt iz ravnoteže, kao što je prikazano na slici 3. prema Fertalju i ostalima, izrađeno od strane autorice ovog rada. Dok površina trokuta predstavlja doseg i kvalitetu projekta, stranice trokuta predstavljaju vrijeme, trošak i dostupnost resursa[55]. Jako je teško postići ravnotežu parametara projekta, te je potrebno dosta znanja i iskustva da se ona postigne.

Slika 3: Trokut dosega (eng. scope triangle)



Izvor: Prema Fertalj, K., Fertalj, Ž., Kosović Nižetić, I., 2016. *Upravljanje projektima.* Fakultet elektronike i računarstva. Sveučilište u Zagrebu. Dostupno na:https://bib.irb.hr/datoteka/807419.Upravljanje_projektima_-_skripta_-FER_2016.pdf Skripta. [pristupljeno 12.07.2017.] str. 6. i 7.

Voditelj projekta je stručnjak u području upravljanja projektima, a ujedno je odgovoran za ostvarivanje navedenih ciljeva projekta, te kao predstavnik klijenta mora odrediti i provesti točne potrebe klijenta. Može imati odgovornost planiranja, izvršavanja, nadzora i zatvaranja bilo kojeg projekta koji se obično odnosi na arhitekturu, građevinsku industriju, računarstvo, inženjering, i telekomuni-

[55] Fertalj, K., Fertalj, Ž., Kosović Nižetić, I., 2016. *Upravljanje projektima.* Fakultet elektronike i računarstva. Sveučilište u Zagrebu. Dostupno na:https://bib.irb.hr/datoteka/807419.Upravljanje_projektima_-_skripta_FER_2016.pdf Skripta. [pristupljeno 12.07.2017.] str. 6. i 7.

kacije[56]. Dakle, ti poslovi mogu biti: analiza rizika, delegiranje zadataka, određivanje vremenskih rokova, raspoređivanje resursa, upravljanje budžetom, komunikacija sa timom i sl.

Razvojem tehnologije u drugoj polovici 20.-tog stoljeća započeo je i razvoj projektnog menadžmenta. Projektni menadžment je prvenstveno razvijen iz proizvodno-procesne industrije, građevinarstva, farmaceutike, vojnih projekata i sl. dok u današnje vrijeme postaje sinonim za moderne, dinamične projektne organizacije[57]. Svrha svakog projekta je postići zadane ciljeve, a da bi se oni ostvarili projektni menadžeri trebaju uložiti dosta truda, te koristiti sve raspoložive resurse.

3.1.2. Faze projektnog menadžmenta

Projektni menadžeri se susreću sa brojnim izazovima kako bi u konačnici uspješno realizirali projekt, te ispunili očekivanja klijenta. Kod vođenja samog projekta posebnu pažnju projektni menadžeri trebaju posvetiti na identifikaciju zahtjeva klijenata, utvrđivanje jasnih i postizljivih ciljeva (koji trebaju biti mjerljivi), uravnoteženje zahtjeva za obujmom, kvalitetom, vremenom i troškovima, te prilagodbu planovima, specifikacijama, te očekivanjima različitih sudionika u projektu.

Postoje različita viđenja različitih autora vezanih uz broj faza koje ima životni ciklus projekta i koje aktivnosti ulaze u koju od faza, a prema Omaziću i Baljkasu postoje tri faze životnog ciklusa projekta i to: faza dizajniranja ili početna faza, faza provedbe ili implementacije, te faza zaključivanja ili završna faza. Svaka od faza projektnog menadžmenta ima svoje ključne zadatke i odluke, te temeljna pitanja na koje je potrebno odgovoriti.

U tablici 2. su prikazane sve tri faze životnog ciklusa projekta sa postavljenim pitanjima, te definiranim zadacima i odlukama izrađene od autorice ovog rada, prema Klepiću.

[56] Wikipedia, 2017. *Project Management.* Dostupno na: https://en.wikipedia.org/wiki/Project_management [pristupljeno 11.07.2017.]

[57] Algebra, otvoreno učilište., op.cit.

Tablica 2: Faze životnog ciklusa projekta

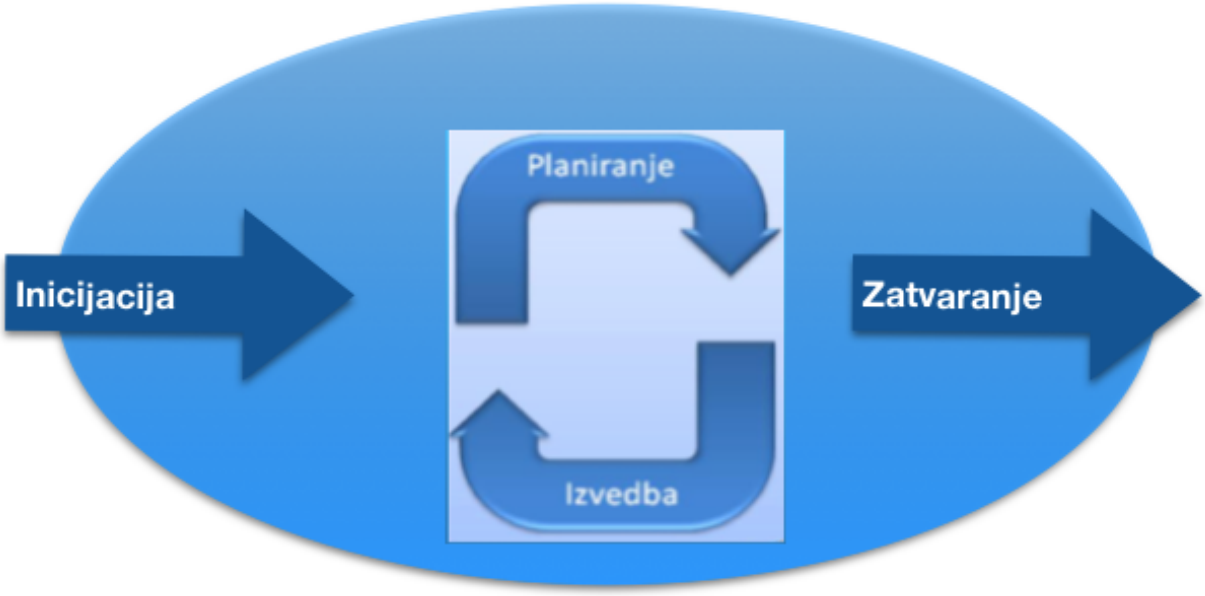
Faza	Ključni zadaci i odluke	Temeljna pitanja
1.Početna faza	Formuliranje vizije i strategije projekta, definiranje ciljeva, modeliranje i planiranje, evaluacija financijskih troškova i koristi, analiza ključnih resursa, budžetiranje.	○Što treba napraviti? ○Zašto to treba napraviti? ○Kako će se to ostvariti? ○Tko će što napraviti i tko će sve biti uključen u projekt? ○Tko će biti sponzor projekta i projektni menadžer? ○Kad je početak, a kad završetak projekta? ○Koliko će to koštati?
2. Faza provedbe	Prikupljanje tima, organizacija, kontrola, vođenje, donošenje odluka i rješavanje problema, rješavanje konflikata, ugovaranje, provedba, prodaja projekta.	○Na koji način će se rukovoditi projektom? ○Tko će obavljati kontrolu nad projektom? ○Hoće li projekt biti završen na vrijeme i u okviru budžeta?
3. Završna faza	Procjena procesa i učinkovitosti projekta, evaluacija, prikupljanje i implementacija znanja u sustav, promjene za budućnost.	○Kakvi su rezultati ostvareni projektom? ○Kako kontinuirano poboljšavati i razvijati projektni menadžment? ○Je li korisnik zadovoljan rezultatom projekta?

Izvor: Prema Klepić, Z., 2016. *Projektni menadžment neprofitnih organizacija.* pdf. Dostupno na: http://ef.sve-mo.ba/sites/default/files/nastavni-materijali/projektni%20menadžment.pdf [pristupljeno 14.07.2017.]

Jedna od temeljnih osobina projekta je da ima ograničeni vijek trajanja, što znači da projekt ima svoj početak i kraj, odnosno životni ciklus. Svaka od faza životnog ciklusa projekta ima svoje specifičnosti, te mora dati odgovore na određena pitanja, kao i definirati ključne zadatke i odluke. Pri tome projektni menadžeri moraju voditi računa da u svim fazama projekta postižu kvalitetu te smanjuju rizike u zadanom vremenskom roku, u okvirima zadanih troškova i resursa[58]. Faze projektnog menadžmenta sastoje se od nekoliko faza, a to su: inicijacija, planiranje, izvedba i zatvaranje kao što je prikazano na slici 4. izrađenoj od strane autorice ovog rada prema Klepiću.

[58] Kraus, C., Starčević Staničić I., 2012. *Metode i alati projektnog menadžmenta u procesu digitalizacije.* Leksikografski zavod Miroslav Krleža. pdf. Dostupno na: http://dfest.nsk.hr/2015/wp-content/themes/boilerplate/2015/prezentacije/Kraus_Starcevic-Stancic.pdf [pristupljeno 12.07.2017.]

Slika 4: Faze projektnog menadžmenta



Izvor: Prema Klepić, Z., 2016. *Projektni menadžment neprofitnih organizacija.* pdf. Dostupno na: http://ef.sve-mo.ba/sites/default/files/nastavni-materijali/projektni%20menadžment.pdf [pristupljeno 14.07.2017.]

Pod inicijacijom projekta podrazumjeva se neka ukazana prilika ili problem koji se treba rješiti putem projekta, a ideja za pokretanje projekta može doći od strane unutarnjih ili vanjskih sudionika. Planiranje projekta podrazumijeva unaprijed definirane ciljeve koji se trebaju ostvariti, odnosno očekivani rezultat definirane razine kvalitete (definirane specifikacijom) unutar zadanih troškova (definiranih budžetom) i unaprijed definiranih rokova (definiranih rasporedom). Sama izvedba projekta se odnosi na korištenje raspoloživih resursa kako bi se postigli ciljevi projekta, a ovo je ujedno i faza životnog ciklusa koja čini središte projekta, gdje je intenzitet aktivnosti najsnažniji. Tijekom same implementacije projekta potrebno je vršiti nadgledanje procesa realizacije kako bi se moglo pratiti da li se odstupa od definiranih ciljeva, a postoje tri uobičejena pravca akcije koja se mogu preporučiti; održavanje statusa quo, korekcija devijacija ili promjena standarda. Posljednja faza je zatvaranje projekta gdje je cilj projektnog menadžmenta da se ispune očekivanja klijenta, a sastoji se od dvije faze; revizija projekta i završetak projekta. Kod revizije projekta promatra se kakav je efekt zapravo postigao projekt i u kojoj mjeri je usitinu bio relevantan za organizaciju i korisnike projekta, dok se sam završetak projekta može napraviti na nekoliko načina, a to su: gašenje, nas-

tavljanje, integracija ili izglađivanje[59]. Funkcije upravljanja projektom (planiranje, organiziranje, vođenje i kontrola) su usko povezane s fazama životnog ciklusa projekta, te omogućuju učinkovitije odvijanje cijelog projektnog zadatka.[60] Odgovor na pitanje da li je određeni projekt bio uspješan ili ne, daju pokazatelji koji mogu biti kvalitativne i kvantitativne prirode, ali je u konačnici najvažnije zadovoljstvo klijenta.

3.1.3. Softveri za projektni menadžment

Upravljanje projektima danas je nezamislivo bez korištenja adekvatnih softverskih rješenja. Korištenje softvera, odnosno alata i tehnika za projektni menadžment, omogućuje voditeljima projekta kao i članovima projektnog tima planiranje, izvršenje i kontrolu projekta unutar zadanog vremenskog okvira uz definiranu kvalitetu i budžet[61].

Softver za projektni menadžment je moguće opisati kao sveukupnost svih alata i tehnika za planiranje, praćenje, procjenu projekta te isporuku projektnih rezultata. Danas postoje brojna softverska rješenja za projektni menadžment, uključujući i aplikacije pomoću kojih je moguće pratiti napredovanje projekta u svim fazama preko pametnih telefona, a sve popularnije postaje upravljanje projektima u oblaku (kao što je to npr. Clarizen, online softver za upravljanje projektom)[62].

Ovisno o sofisticiranosti softvera, mogu upravljati procjenama i planiranjem, kontrolirati troškove, upravljati proračunom i raspodjelom resursa, komunikacijom, pomagati pri donođenju odluka, upravljati kvalitetom i dokumentacijom ili sustavima administracije. Prva povijesno relevantna godina za razvoj softvera za upravljanje projektima je 1896. označena uvođenjem "harmonograma" od strane poljskog ekonomista Karola Adamieckog[63]. On je razvio metodologiju za harmonizaciju rada koja se temeljila na grafičkoj analizi, a postala je popularna tek 1912. kada je Henry Gantt zamjenio harmonogram u napredniji Ganttov dijagram kakav danas poznajemo. Ganttov dijagram ili gan-

[59] Klepić, Z., op.cit.

[60] Kraus, C., Starčević Staničić I., op.cit.

[61] Algebra, otvoreno učilište., op.cit.

[62] Kraus, C., Starčević Staničić I., op.cit.

[63] Wikipedia, 2017. Project management software. Dostupno na: https://en.wikipedia.org/wiki/Project_management_software [pristupljeno 16.07.2017.]

togram je jedan od najčešće korištenih alata za prikaz projektnih aktivnosti. Tip je stupčastog grafikona, koristi se za grafički prikaz rasporeda projekta, te omogućuje prikaz vremenskog rasporeda projekta s aktivnostima na vertikalnoj i vremenom na horizontalnoj osi[64,65].

Prema Capterri[66] top deset najboljih softverskih alata u projektnom menadžmentu trenutno dostupnih na tržištu su: Workfront, dapulse, JIRA, Freshdesk, Wrike, Clarizen, ProWorkflow, Targetprocess, cerri, te ManageEngine ServiceDesk Plus.

64 Project Management History, The Harmonogram. *projectmanagementhistory.com* Dostupno na: http://projectmanagementhistory.com/The_Harmonogram.html# [pristupljeno 16.07.2017.]

65 Kraus, C., Starčević Staničić I., op.cit.

66 Capterra The Smart Way to Find Business Software, 2017. *Top Project Management Tools*. Dostupno na: http://www.capterra.com/project-management-software/ [pristupljeno 16.07.2017.]

4. RAZVOJ SOFTVERA

4.1. METODE RAZVOJA SOFTVERA

4.1.1. Razvoj softvera

Razvoj softvera predstavlja razvoj softverskog proizvoda, a sastoji se od velikog broja koraka koji obuhvaćaju definiranje zahtjeva korisnika, analizu i izgradnju, te implementaciju i korištenje. Metode razvoja softvera također pokrivaju širok spektar aktivnosti, a to su: planiranje i procjenjivanje projekata, analiza sistemskih i softverskih zahtjeva, projektiranje strukture podataka, definiranje arhitekture programa, kodiranje, testiranje i održavanje. Odabrati odgovarajuću metodu koja će se primjeniti u razvoju softvera nije jednostavno, međutim, najvažniji fokus treba biti usmjeren na minimalizaciju troškova razvoja, te osiguranje visoko kvalitetnog proizvoda[67].

Primjeri softvera u svakodnevnom životu su svuda oko nas, od podizanja novca sa bankomata, korištenja mobitela ili pak vožnje automobila. Sam izraz "razvoj softvera" može se koristiti za računalno programiranje, što predstavlja pisanje i održavanja izvornog koda, ali u širem smislu uključuje sve korake u izradi softvera, počevši od dizajna željenog softvera, pa sve do konačnog proizvoda, a može uključivati istraživanje, protutipove, novi razvoj, izmjene, ponovnu upotrebu, održavanje ili bilo koju drugu aktivnost koja dovodi do softverskog proizvoda. Pri razvoju softvera ciljevi mogu biti različiti, međutim, tri su najčešća: ispunjenje uočenih potreba određene grupe potencijalnih korisnika, ispunjenje određenih zahtjeva klijenata, ili osobna upotreba.[68]

Prema Münchu i ostalima, softverski proces je "ciljno orijentirana aktivnost u kontekstu inženjerskog stila razvoja softvera", dok su tipične karakteristike softverskog procesa sljedeće: definirani su u stvarnom svijetu; obično transformiraju jedan ili više ulaznih proizvoda u jedan ili više izlaznih proizvoda; mogu ih izvršavati ljudi (donošenjem) ili strojevi (izvršenjem) ili oboje zajedno[69].

---

[67] D. Čubranić, M. Kaluža, J. Novak, 2013. Standardne metode u funkciji razvoja softvera u Republici Hrvatskoj. pdf. Zbornik Veleučilišta u Rijeci, Vol. 1. str. 239-256. [pristupljeno 19.07.2017.]

[68] Wikipedia, 2013. Razvoj softvera. Dostupno na: https://sr.wikipedia.org/sr-el/Развој_софтвера [pristupljeno 20.07.2017.]

[69] Münch, J., Armbrust, O., Kowalczyk, M., Soto, M., 2012. Software Process Definition and Management. Springer. Dostupno na: https://books.google.se/books?id=S_8Yf1wTKNoC&printsec=frontcover&hl=sv&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false str. 8. [pristupljeno 20.07.2017.]

Pri razvoju softvera izdvajaju se tradicionalne procesno orijentirane i agilne metode. Agilne metode su relativno nove i manje opsežne, s naglaskom na vrijednostima i principima umjesto na procesu, te su usredotočene na manje jedinice posla. Općenito se metodologije razvoja softvera mogu podijeliti na dvije glavne skupine, a to su: 1. Teške i opsežne metodologije razvoja softvera (engl. heavyweight methodologies) koje sadrže mnogo pravila i dokumentacije, te zahtjevaju disciplinu i vrijeme za ispravno slijeđenje, a nazivaju se i „debelim" metodama (engl. thick methods), te 2. Lakše i manje opsežne metodologije razvoja softvera (engl. lightweight methodologies) koje obično sadrže tek nekoliko pravila i načina postupanja koji su lagani za slijeđenje, a nazivaju se i „tankim" metodama (engl. thin methods). Metodologija odabira metode propisuje redoslijed upotrebe metoda od početka do samog kraja životnog ciklusa softvera. Dolje navedene metode pomažu kako bi svaka faza razvoja softvera mogla biti pokrivena sa jednom ili više metoda, ali u daljnjem radu neće biti detaljno obrazložene: IE (information engineering); BSP (engl. *business system planning*); MIRIS (metodika za razvoj informacijskih sustava); OOIE (engl. object oriented information engineering); TAFIM (engl. technical architecture framework for information management); AD/Cycle (engl. application development cycle); SDM (engl. system development methodology); SPIS (engl. strategic planning of information systems)[70].

Cilj razvoja softvera je u konačnici proizvodnja kvalitetnog softvera koji će zadovoljiti potrebe klijenta, a glavna zadaća projektnog menadžmenta jest odabrati najprikladniju metodologiju u okviru razvoja softvera, ovisno o zahtjevima kijenta i raspoloživim resursima u zadanom vremenskom roku.

4.1.2. Osiguranje kvalitete (QA)

Osiguranje kvalitete (eng. Quality Assurance) predstavlja definiranje određenih standarda kako bi se zadovoljila očekivanja klijenata, te istovremeno uklonili nedostaci ili pogreške pri isporuci proizvoda ili usluga klijentima. Iako postoje brojne definicije za pojam kvalitete, u suštini je najvažnije poimanje kvalitete u očima klijenta, budući da su klijenti glavni fokus u poslovanju bilo koje organizacije ili kompanije. Prema ISO 9000 odnosno normi međunarodne organizacije za standardizaciju (eng. International Organization for Standardization) kvaliteta proizvoda ili usluge

[70] D. Čubranić, M. Kaluža, J. Novak., op.cit.

se može definirati kao "stupanj do kojeg skup svojstvenih karakteristika ispunjava zahtjeve"[71]. Ti zahtjevi mogu biti različiti za svakog pojedinca ili klijenta, odnosno svaki klijent može različito percipirati što za njega predstavlja pojam kvalitete. Prema Skoki kvaliteta bi trebala biti prioritet svakoj organizaciji/tvrtki kako bi se ostvarila konkurentska prednost, te bi trebala poticati aktivno sudjelovanje i uključenost svakog zaposlenika, kako bi se zadovoljile izražene ili očekivane potrebe potrošača/klijenta[72].

U uspješnom poslovanju tvrtki nužno je potpuno upravljanje kvalitetom, odnosno TQM (eng. Total quality management). To je filozofija za koju također postoje brojne definicije, a zapravo predstavlja korporativnu filozofiju poslovnog menadžmenta koja prihvaća nedjeljivost potreba kupaca i poslovnih ciljeva. "Ono osigurava maksimalnu efikasnost i efektivnost u poslovanju, kao i vodstvo na tržištu uvodeći procese i sustave kroz koje će promovirati izvrsnost, sprečavati nastajanje pogrešaka i jamčiti da će svaki aspekt poslovanja biti usmjeren na potrebe kupaca i unapređivanje poslovnih ciljeva, bez povećanja ili poduzimanja beskorisnih napora"[73]. Ono što je važno naglasiti jest da se pojam TQM i ISO standarda često povezuju s pojmom kvalitete, ali postoje određene razlike među njima. TQM unapređuje kvalitetu na način da premašuje očekivanja klijenata, te se pogreške uklajnjaju odmah čim se uoče, dok ISO standardi imaju zadatak uklanjati nekvalitetne proizvode. Da bi TQM funkcioniralo u praksi potrebna je puna podrška uprave organizacije na način da se konstantno ulaže u obrazovanje zaposlenika, omogućava dobar timski rad, te neprestalno provode poboljšanja[74].

Proces kontrole kvalitete je univerzalni menadžerski proces za obavljanje poslova kako bi se osigurala stabilnost i spriječile nepovoljne promjene, odnosno "zadržao status quo." Kontrola kvalitete se odvija pomoću povratne petlje, na način da se svaki proces kontrolira od strane zaposlenika. Kriteriji za samokontrolu primjenjuju se na procese u svim funkcijama, a na svim razinama, od generalnog

---

[71] ISO 9000:2015., 2015. *Online Browsing Platform (OBP)*. Dostupno na: https://www.iso.org/obp/ui/#iso:std:iso:9000:ed-4:v1:en [pristupljeno 23.07.2017.]

[72] Skoko, H., 2000. Upravljanje kvalitetom, Sinergija, Zagreb. Dostupno na: https://www.scribd.com/doc/39793919/Upravljanje-Kvalitetom-H-skoko-2000 [pristupljeno 23.07.2017.] str. 12-18

[73] Skoko, H., op.cit. str. 86.

[74] Svijet kvalitete, 2012. Potpuno upravljanje kvalitetom (TQM). *svijet-kvaliete.com* Dostupno na: http://www.svijet-kvalitete.com/index.php/upravljanje-kvalitetom/368-potpuno-upravljanje-kvalitetom-tqm [pristupljeno 26.07.2017.]

direktora do običnog zaposlenika. Samokontrola kvalitete u određenoj organizaciji treba ispunjavati nekoliko bitnih kriterija, a to su: kvaliteta je broj jedan; međusobno povjerenje; samokontrola; obuka i cetifikacija. Planiranje procesa kontrole kvalitete treba osigurati informacijsku mrežu koja može služiti svim donositeljima odluka. Pravilan slijed upravljanja procesom kvalitete jest prvo definirati ciljeve koji se žele postići, zatim planirati kako ostvariti te ciljeve, te odabrati odgovarajuće alate koji će pomoći pri ostvarenju definiranih ciljeva[75].

Osiguranje kvalitete (QA) se u praksi, između ostalog, koristi u okviru razvoja softvera kako bi se klijentima osigurala kvaliteta i uklonile ili spriječile pogreške, a pri tome se koriste razne metode i standardi, od kojih je jedan od njih i prethodno spomentuti ISO 9000. Također pridonosi pri ostvarivanju većih profita u odnosu na konkurenciju, pa je pravilno upravljanje procesom osiguranja kvalitete u današnjem poslovanju esencijalno za uspješno poslovanje određene organizacije ili kompanije.

4.1.3. Procesi u razvoju softvera

U današnjem poslovanju teško je zamisliti razvoj društva bez softvera. Softver predstavlja programsku potporu računalu bez kojeg je računalo zapravo samo hrpa željeza i samo po sebi nije upotrebljivo, odnosno softver "govori" hardveru računala što da radi. Zahvaljujući intelektualnim naporima programera, računalo postaje uporabljivo posredstvom operativnog sustava na koji se “naslanjaju” uporabljivi programski proizvodi kao što su: baze podataka, uređivači teksta, igre, tablični kalkulatori, razni pomoćni programi i ostalo[76].

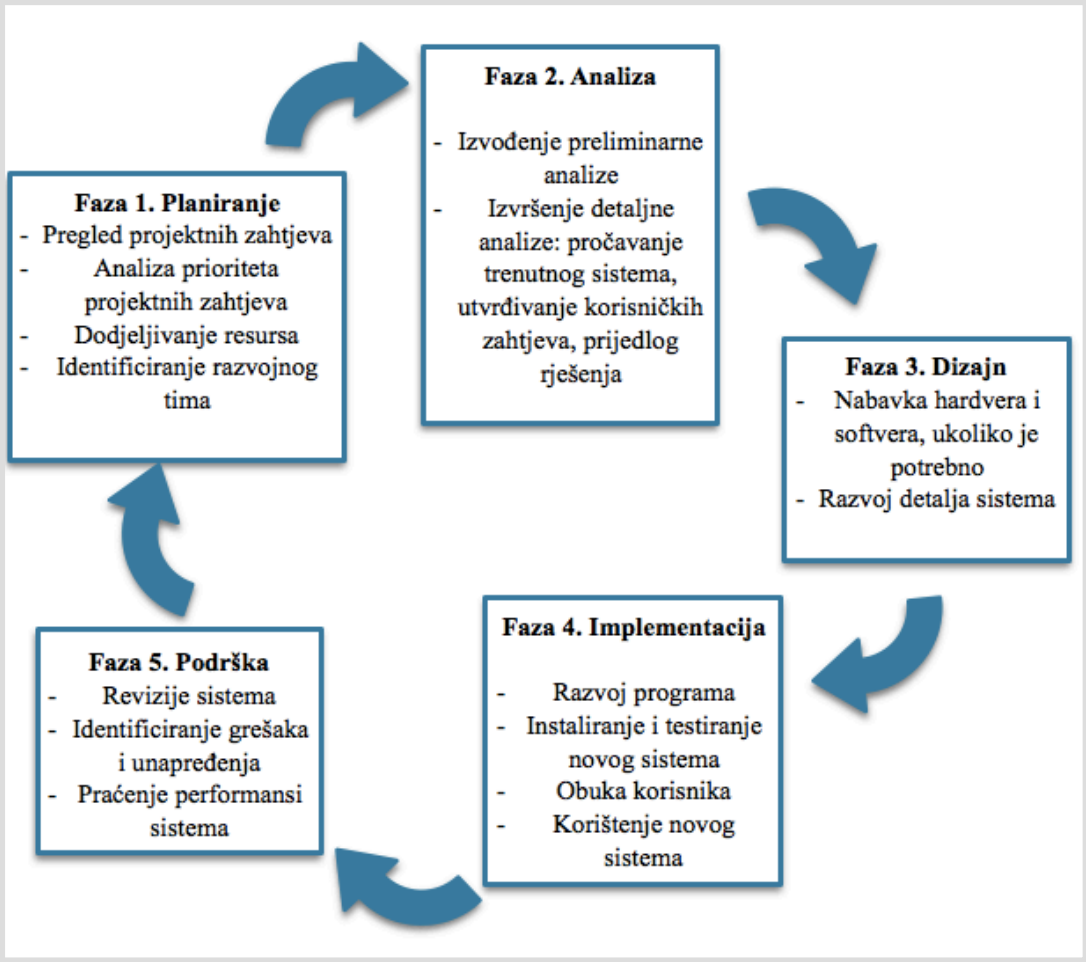
Razvoj softvera podrazumijeva ispunjenje određenih zahtjeva koji su prethodno definirani. U softverskom inžinjerstvu kvaliteta i produktivnost konačnog proizvoda ovise o vještini ljudi koji su uključeni u određeni projekt, procesima koji se koriste za različite zadatake u projektu, te alatima koji se koriste, a pri tome je glavni naglasak na procesima koji se koriste. Softverski proces definira sam način izrade softvera, a obuhvaća: model životnog ciklusa softvera, alate koji se koriste, te po-

[75] Juran, J.M., 1999. *Juran's quality handbook.* Fifth Edition. McGraw-Hill. poglavlje 4. pdf. Dostupno na: http://www.pqm-online.com/assets/files/lib/books/juran.pdf [pristupljeno 26.07.2017.]

[76] Radić, D., Rječnik informatičkih pojmova. Dostupno na: http://www.informatika.buzdo.com/rjecnik/ [pristupljeno 27.07.2017.]

jedince koji sudjeluju u izradi softvera. Model životnog ciklusa softvera definira način na koji se upravlja različitim fazama životnog ciklusa softvera koji se sastoji od nekoliko faza, a to su:planiranje, analiza, dizajn, implementacija i podrška[77]. Faze životnog ciklusa razvoja softvera vidljive su na slici 5. izrađene od strane autorice ovog rada, prema Jeremiću.

Slika 5: Životni ciklus razvoja softvera



Izvor: Prema Jeremić, Z., Softverski proces i životni ciklus softvera. pdf. Dostupno na: http://www.viser.edu.rs/download/uploads/5663.pdf [pristupljeno 27.07.2017.]

Postoji nekoliko načina na koji se softver može razviti, a to je uvjetovano karakteristikama konkretnog modela. Generički modeli procesa razvoja softvera su: vodopadni model, evolucijski model, model formalne transformacije, te model ponovne primjene postojećih resursa koji u ovom radu

[77] Jeremić, Z., Softverski proces i životni ciklus softvera. pdf. Dostupno na: http://www.viser.edu.rs/download/uploads/5663.pdf [pristupljeno 27.07.2017.]

neće biti detaljno pojašnjeni, već samo njihove najznačajnije karakteristike. Najznačajnija karakteristika vodopadnog modela jest ta da se ravija u fazama; kod evolucijskog se inicijalna verzija upućuje korisniku na testiranje; model formalne transformacije temelji se na transformaciji matematičke specifikacije u izvodljiv program; dok se model ponovne primjene postojećih resursa temelji na planiranoj integraciji postojećih komponenti, dijelova sustava ili cjelovitog sustava u novi proizvod. Svaki od navedenih generičkih procesa razvoja softvera ima svoje faze i značajke modela koji se međusobno razlikuju, međutim postoje i određene sličnosti u fazama i modelima.

Važno je napomenuti kako kod uspješnosti razvoja softvera značajnu ulogu igra prototipiranje, u kojem se stvara inicijalan prototip uvažavajući najvažnije zahtjeve klijenata, kako bi se na temelju njihovih zapažanja i povratnih informacija mogao razviti budući sustav. Ovaj pristup u konačnici smanjuje rizike i povećava uspješnost samog sustava kao i zadovoljstvo klijenata. Evolucijsko prototipiranje je sastavni dio metoda brzog razvoja aplikacije, a dvije najpoznatije metode tog tipa su: Joint Application Development (JAD) ili Zajednički razvoj aplikacije (uključivanje korisnika u razvoj projekta); te Rapid Application Development (RAD) ili Brzi razvoj aplikacije (plasiranje softverskog proizvoda što ranije, dok se naknadno dograđuju zahtjevi koji nisu ključni za njegovu funkcionalnost)[78]. Odluka o tome koju od ovih metoda odabrati pri procesu razvoja softvera ovisi o potrebama klijenata, kao i sposobnostima organizacije da udovolji njihovim zahtjevima. Autori Haapio i Menzies u svojoj studiji slučaja naglašavaju da postoji nedostatak prikupljenih podataka vezanih uz razvoj softvera[79]. Kao glavni razlog navode činjenicu da je u softverskoj industriji prikupljanje podataka više usmjereno prema potrebama kupaca odnosno klijenata, pa je stoga teško genaralizirati, tj. ne moraju nužno podaci iz jednog završenog projekta utjecati na idući.

U projektnom menadžmentu u okviru razvoja softvera mogu se rudariti podaci koji su usko vezani uz razvoj i isporuku softvera. Bitni elementi završenog projekta u koje projektni menadžeri mogu imati uvid zahvaljujući rudarenju podataka su: vrijeme isporuke, visina troška, broj generiranih po-

[78] Požgaj, Ž., Procesi razvoja softvera. EFZG. pdf. Dostupno na: http://web.efzg.hr/dok/inf/pozgaj/pisani%20materijali/T03%20Modeli%20razvoja%20softvera.pdf [pristupljeno 30.07.2017.]

[79] Haapio, T., Menzies, T., 2009. *Data Mining with software industry project data: A case study.* Lane Department of Computer Science, West Virginia University, Morgantown, WV 26506-610, USA. Dostupno na: http://www.academia.edu/2699638/DATA_MINING_WITH_SOFTWARE_INDUSTRY_PROJECT_DATA_A_CASE_STUDY [pristupljeno 25.09.2017.]

grešaka, broj ispravljenih pogrešaka, produktivnost razvoja, prosječno kašnjenje u zapošljavanju, maksimalni postotak kašnjenja dozvoljen u vrijeme isporuke itd. Prema studiji slučaja (case study) autora Mate[80] i ostalih iz 2016. godine, jedan od najvažnijih doprinosa rudarenja podataka jest mogućnost unapređenja samog procesa izgradnje projekta razvoja softvera (eng. Software Development Project; SDP). Autori ističu kako je jedan od glavnih izazova s kojima se susreću projektni menadžeri tijekom procesa izgradnje projekta razvoja softvera (SDP) optimiziranje vrijednosti parametara koji utječu na uspjeh projekta. Znanje stečeno rudarenjem podataka pomaže voditeljima projekta da procijene koje su najprikladnije vrijednosti, u kojima se atributi koji imaju utjecaj na projekt trebaju kretati, kako bi se dobile željene vrijednosti na kraju projekta s obzirom na vrijeme isporuke, cijenu i kvalitetu.

[80] Mata, J., Alvarez, J.L., Riquelme, J.C., Ramos, I. 2016. *Applying Data Mining to Software Development Projects: A case study*. Dostupno na: https://www.researchgate.net/publication/220711344_Applying_Data_Mining_to_Software_Development_Projects_A_Case_Study [pristupljeno 25.09.2017.]

5. REZULTATI ISTRAŽIVANJA I ANALIZA DOBIVENIH REZULTATA

5.1. UZORAK I METODOLOGIJA ISTRAŽIVANJA

Emprijsko istraživanje o učincima rudarenja podataka na uspješnost projekata u okviru razvoja softvera provedeno je putem anketnog upitnika, te metode standardiziranog intervjua. U istraživanju su bili uključeni projektni menadžeri koji se bave razvojem softvera. Istraživanje je provedeno na području grada Stockholma u Švedskoj. Anketni upitnik napisan je na engleskom jeziku, dok se sama distribucija anketnih upitnika vršila elektroničkim putem, te putem društvene mreže LinkedIn. Kao izvor za slanje anketnog upitnika korišteno je nekoliko izvora: popis 500 najuspješnijih tvrtki u Švedskoj u protekloj godini, koja je dostupna na stranicama Veckans Affärer (va.se); društvena mreža LinkedIn, te pretraživanje Interneta. Također su provedena dva osobna intervjua od strane autorice ovog rada sa projektnim menadžerima koji rade za tvrtke koje se bave razvojem softvera u gradu Stockholmu. Intervju je formalno i sadržajno razrađen, a govor ispitanika je vođen unaprijed pripremljenim pitanjima. Primjerak intervuja se nalazi u prilogu ovog rada.

Istraživanje je provedeno u razdoblju od srpnja do sredine rujna 2017.godine. Potrebno je napomenuti da se u ovom slučaju radilo o namjernom uzorku, točnije uzorku poznavatelja, s obzirom na to da postoje određeni kriteriji koje je bilo potrebno ispuniti prije samog slanja anketnog upitnika ili kontaktiranja za osobni intervju, a to su: a) tvrtka se bavi razvojem softvera, b) tvrtka se nalazi na području grada Stockholma u Švedskoj, c) tvrtka koristi projektni menadžment u svom poslovanju, d) ima barem jednog projektnog menadžera u tvrtci. Uzorak poznavatelja po definiciji jest "uzorak koji se ne zasniva na teoriji slučajnosti, nego istraživač bira ispitanika na temelju neke osobine"[81]. Ispitivanje je provedeno putem anketnog upitnika na namjernom uzorku od 42 ispitanika. Svi anketni upitnici su poslani na e-mail adrese koje su odgovarale gore navedenim kriterijima, dok je anketa kreirana uz pomoć servisa Google docs. Pitanja u anketi su konstuirana na način da osiguraju dobivanje informacija kako bi se utvrdila istinitost prethodno postavljene hipoteze. Anketni upitnik sastojao se od 13 pitanja zatvorenog tipa koja su dvojaka. Dakle, to su zatvorena pitanja s po-

[81] Marković, S. 2008. Uzorak i prikupljanje podataka, Sveučilište u Rijeci, Fakultet za menadžment u turizmu i ugostiteljstvu. Dostupno na: http://lumens.fthm.hr/edata/2011/11e0fa5d-6e66-4424-9e1a-7ac9cf5e747b.pdf [pristupljeno 09.09.2017.]

nuđenim odgovorima nabrajanja koja su služila za utvrđivanje objektnih činjenica, te zatvorena pitanja sa ponuđenim odgovorima intenziteta koja su korištena za utvrđivanje stavova ispitanika. Upitnik sadrži 5 pitanja zatvorenog tipa s ponuđenim odgovorima nabrajanja, te mogućnošću odabira "ništa od navedenog" gdje su ispitanici mogli sami napisati odgovor ukoliko se nisu slagali sa niti jednim od ponuđenih odgovora. Za pitanja sa ponuđenim odgovorima intenziteta korištena je diskretna Likertova skala sudova s pet stupnjeva intenziteta[82] gdje se tvrdnji "u potpunosti se ne slažem" može pridružiti ocjena 1 dok se tvrdnji "u potpunosti se slažem" može pridružiti ocjena 5.

Također je važno naglasiti da je ovisno o odgovoru na prvo pitanje postavljen različit set pitanja za ispitanika. Dakle, ukoliko je ispitanik odgovorio na prvo pitanje DA, tada je dobio određeni set pitanja koji ga detaljnije ispituju o rudarenju podataka, a ukoliko je ispitanik na prvo pitanje odgovorio NE, tada je ispitanik odgovarao na potpuno drugi set pitanja (koji se odnosi na alternativne metode donošenja odluka u projektnom menadžmentu u okviru razvoja softvera, te njihovom stavu o mogućem korištenju rudarenja podataka u budućnosti). Popis pitanja, odnosno anketni upitnik nalazi se u prilogu ovog rada.

Pitanja u anketnom upitniku mogu se svrstati u 4 kategorije koje su imale za cilj utvrditi:

- opseg korištenja rudarenja podataka (da li se u određenoj tvrtci koristi ili ne koristi rudarenje podataka);
- ulogu rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera;
- alternativne metode donošenja odluka projektnih menadžera ukoliko ne koriste rudarenje podataka, te njihov stav o rudarenju podataka;
- osnovne podatke o tvrtci za koju ispitanik trenutno radi.

Prvo pitanje se odnosilo na utvrđivanje da li određena tvrtka uopće koristi rudarenje podataka, gdje je ponuđen odgovor isključiv, odnosno odgovor može biti DA ili NE.
Ukoliko je ispitanik na prvo pitanje odgovorio DA (u tvrtci za koju trenutno radi koristi se rudarenje podataka) tada je usmjeren na drugi set pitanja koji ga detaljnije ispituje o rudarenju podataka kao i

[82] Zelenika, R., op. cit., str. 371.

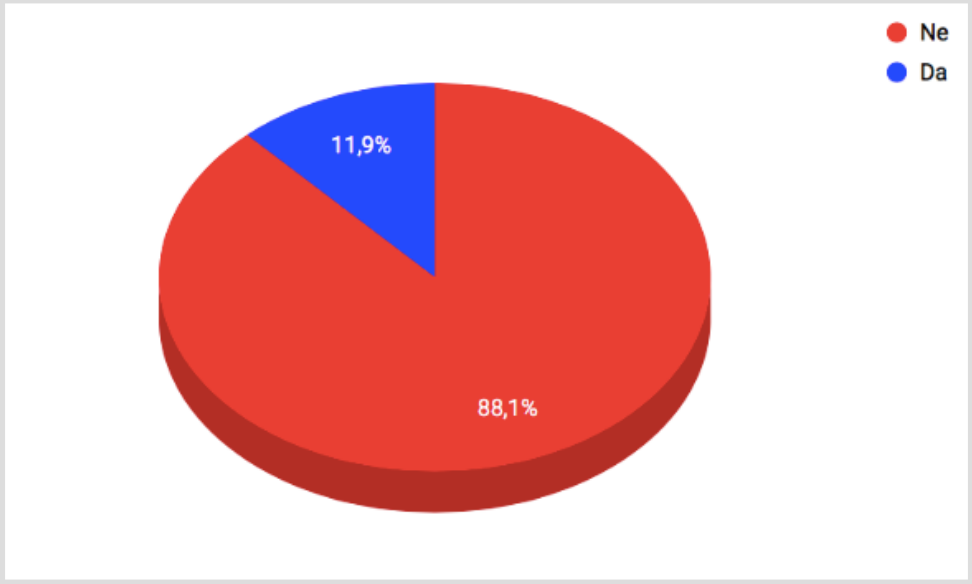
u kojoj mjeri im rudarenje podataka pomaže pri donošenju važnih odluka u procesu razvoja softvera za što je korištena Likertova skala sudova.
Ukoliko je ispitanik na prvo pitanje odgovorio NE (u tvrtci za koju trenutno radi ne koristi se rudarenje podataka) tada se usmjerava na alternativni, treći set pitanja u kojem je također korištena Likertova skala sudova.
U četvrtom, posljednjem dijelu anketnog upitnika ispitani su osnovni podaci o tvrtci za koju ispitanik trenutno radi, a na njih su odgovarali svi ispitanici, neovisno o odgovoru na prvo pitanje (ukoliko je odgovor na prvo pitanje bio DA ili NE).

Podaci prikupljeni anketiranjem obrađeni su uz pomoć Microsoft Excela i SPSS-a. Uz pomoć Google docs i Microsoft Excela napravljena je vizualizacija dobivenih odgovora, te je kroz deskriptivnu statistiku i grafikone prikazano opisno definiranje učinaka rudarenja podataka na uspješnost projekata u budućnosti, odnosno unapređenje faza u projeknom menadžmentu u okviru razvoja softvera. Dublja analiza dobivenih odgovora provedena je uz pomoć statističkog programskog paketa SPSS-a primjenom Cronbach-Alpha koeficijenta, Kolmogorov-Smirnovog testa normaliteta distribucije, te Spearmanovog koeficijenta korelacije ranga.

5.2. ANALIZA PRIKUPLJENIH PODATAKA I INTERPRETACIJA

Analizom prvog pitanja dobiva se odgovor koliko ispitanika koji su sudjelovali u istraživanju koristi rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera, u tvrtci za koju trenutno rade. Budući da je većina ispitanika odgovorila kako ne koristi rudarenje podatka u tvrtki za koju trenutno radi, prvo će se analizirati ona grupu pitanja koja se odnosi na ispitanike koji su na prvo pitanje odgovorili NE (ne koriste rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera u tvrtci za koju trenutno rade), a nakon toga će se obraditi rezultati ispitanika koji su na prvo pitanje odgovorili DA (koriste rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera u tvrtci za koju trenutno rade). Svi dobiveni rezultati se prikazuju grafički, radi što lakše usporedbe i preglednosti.

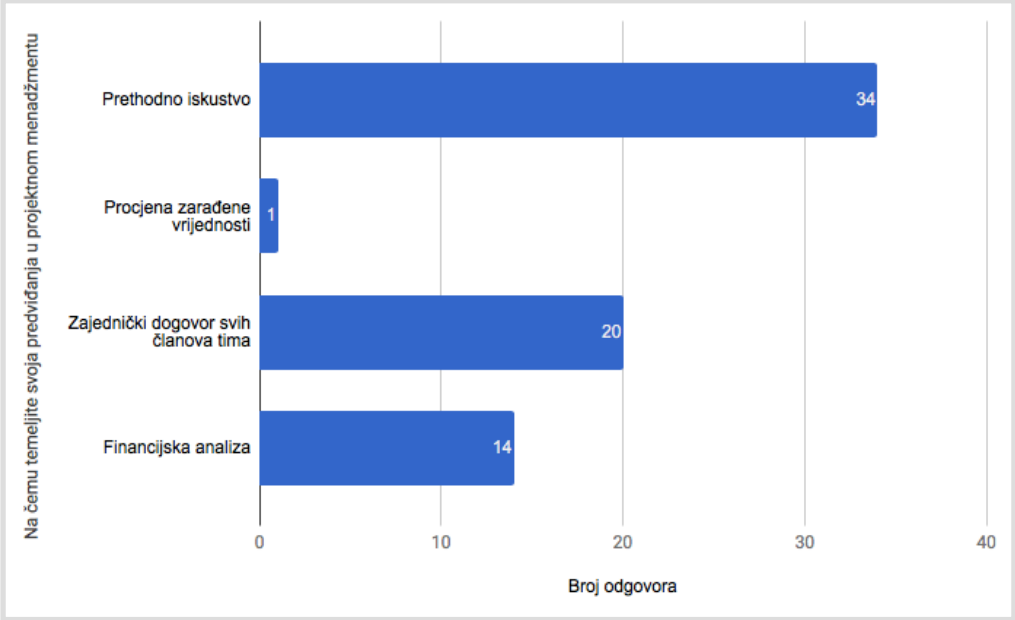
Grafikon 1: Prikaz odgovora na pitanje: "Koristite li rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera?"



Izvor: Istraživanje autorice, N=42

Na grafikonu broj 1. vidljivo je kako je ukupan broj ispitanika je 42, od čega se 5 osoba odnosno 11,9% izjasnilo da koristi rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera u tvrtci za koju trenutno radi, dok se 37 odnosno 88,1% izjasnilo da ne koristi rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera, u tvrtci za koju trenutno radi.

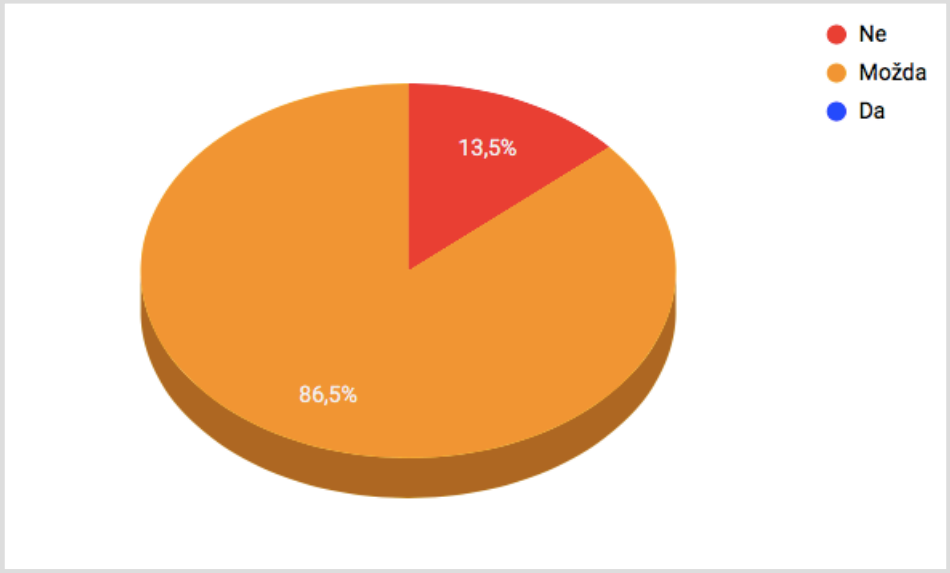
Grafikon 2: Prikaz odgovora na pitanje: "Na čemu temeljite svoja predviđanja u projektnom menadžmentu?"



Izvor: Istraživanje autorice

Na grafikonu 2. je prikazano kako su ispitanici na ovo pitanje imali mogućnost odabrati više odgovora (multiple choice). Najviše ispitanika, njih 91,1% svoja predviđanja, odnosno odluke za buduće projekte u projektnom menadžmentu temelji na prethodnom iskustvu. 54,1% ispitanika svoje odluke donosi zajedničkim dogovorom sa svim članovima tima. Financijske analize za predviđanja koristi 37,8% ispitanika, dok samo 2,7% ispitanika koristi dobivenu procjenu vrijednosti pri donošenju odluka, odnosno za predviđanja u projektnom menadžmentu.

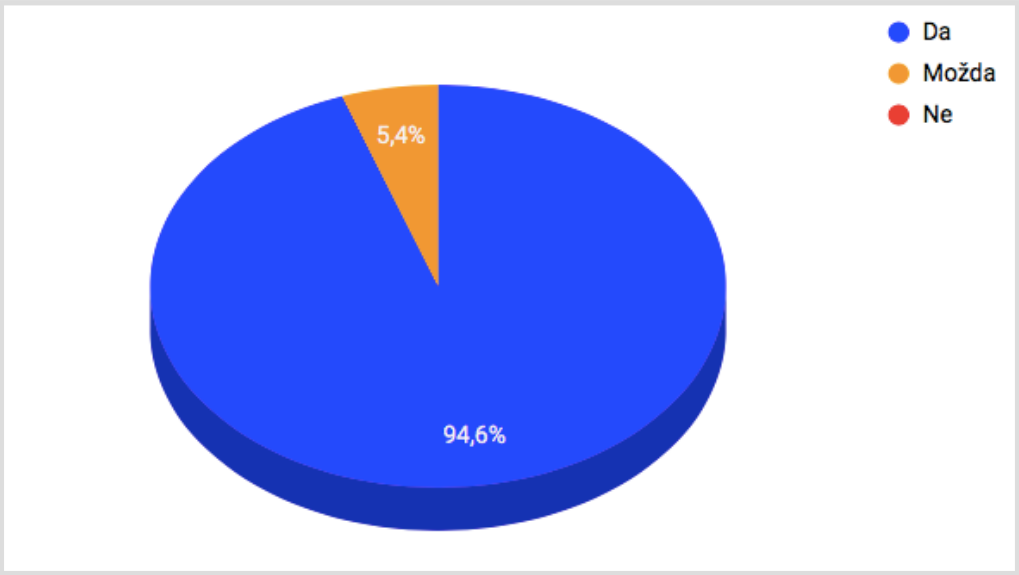
Grafikon 3: Prikaz odgovora na pitanje: "Da li tvrtka za koju trenutno radite namjerava koristiti rudarenje podataka u budućnosti?"



Izvor: Istraživanje autorice

Kako što je vidljivo na grafikonu 3. većina ispitanika odnosno 86,5% tvrdi da će tvrtka za koju trenutno rade možda koristiti rudarenje podataka u budućnosti, dok ih 13,5% tvrdi da tvrtka za koju trenutno rade neće u budućnosti koristiti rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera. Nitko od ispitanika nije odgovorio potvrdno na ovo pitanje, odnosno da će tvrtka za koju trenutno rade sigurno koristiti rudarenje podataka u budućnosti.

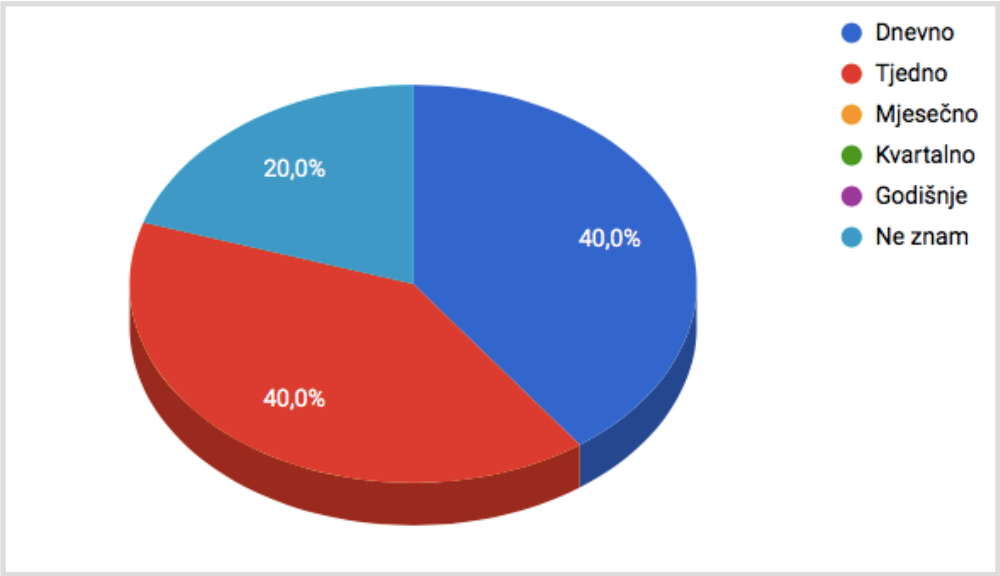
Grafikon 4: Prikaz odgovora na pitanje: "Da li bi koristili rudarenje podataka u projektnom menadžmentu ako bi znali da bi imali direktnu korist od toga?"



Izvor: Istraživanje autorice

Grafikon 4. prikazuje kako na pitanje da li bi koristili rudarenje podataka u projektnom menadžmentu ako bi znali da bi imali direkntnu korist od toga, nitko od ispitanika nije odgovorio negativno. Dakle, većina ispitanika je dala potvrdan odgovor, odnosno njih 94,6%, dok se 5,4% ispitanika izjasnilo da bi možda koristili rudarenje podataka u budućnosti ako bi imali direktnu korist od toga. U nastavku rada analizirati će se grupa pitanja koja se odnosi na one ispitanike koji su na prvo pitanje odgovorili DA (koriste rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera u tvrtci za koju trenutno rade).

Grafikon 5: Prikaz odgovora na pitanje: "Koliko često koristite rudarenje podataka u projektnom menadžmentu?"

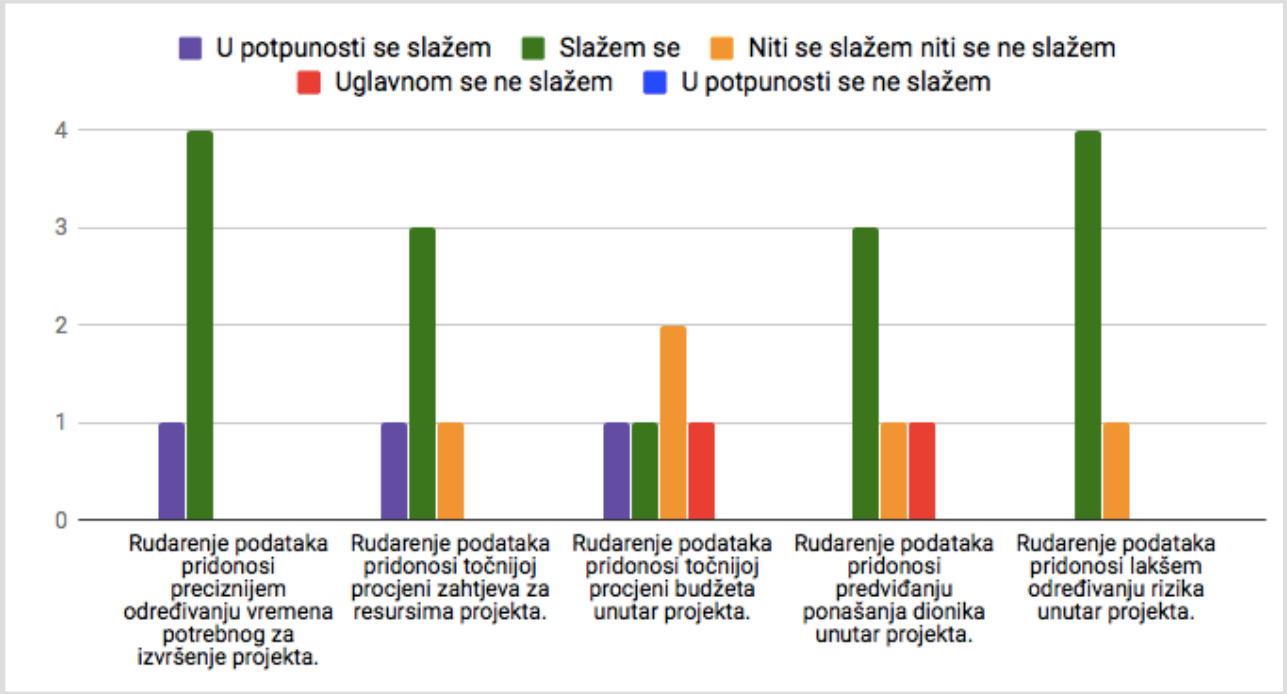


Izvor: Istraživanje autorice

Na grafikonu 5. rezultati pokazuju kako ispitanici koji koriste rudarenje podataka u projektnom menadžmentu najčeše koriste rudarenje podataka na dnevnoj bazi, odnosno njih 40%. Isti postotak, odnosno 40% ispitanika koristi rudarenje podataka na tjednoj bazi, dok 20% ispitanika ne zna odgovor na ovo pitanje. Nitko od ispitanika nije odgovorio da koristi rudarenje podataka na mjesečnoj, kvartalnoj ili godišnjoj razini.

U nastavku analize dobivenih podataka, ispitanici su trebali ocijeniti stupanj slaganja sa navedenim tvrdnjama. Radi lakše analize, svakoj od ponuđenih tvrdnji možemo pridružiti ocjene od 1 do 5, gdje bi ocjena 1 označavala najmanji stupanj slaganja s navedenom tvrdnjom, dok bi ocjena 5 označavala najveći stupanj slaganja s navedenom tvrdnjom.

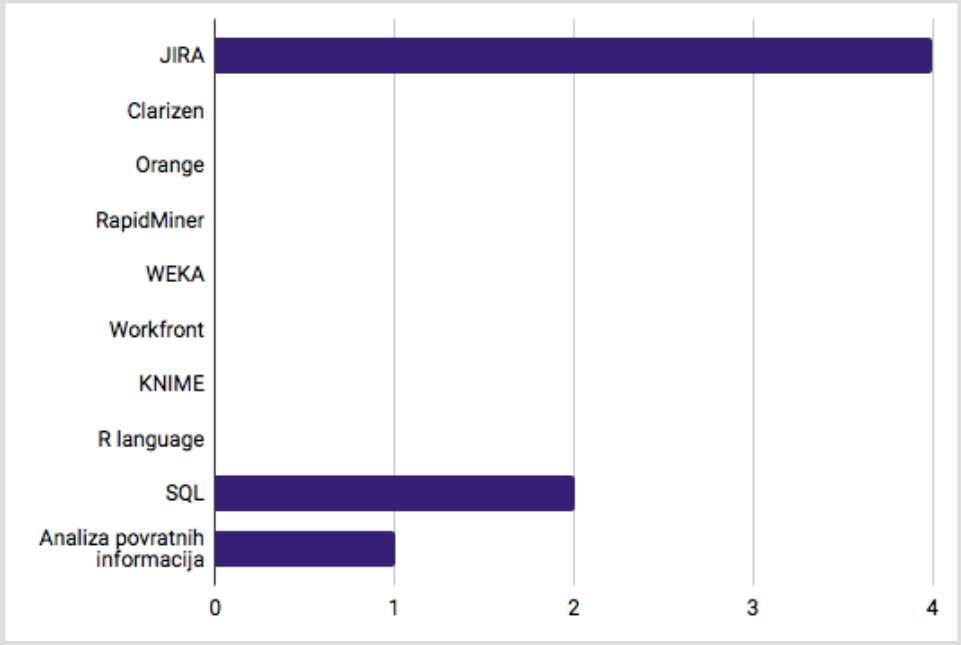
Grafikon 6: Prikaz odgovora na pitanje: "Ocijenite tvrdnje koje se odnose na rudarenje podatka u projektnom menadžmentu u okviru razvoja softvera."



Izvor: Istraživanje autorice

Grafikon 6. prikazuje da se najveći broj ispitanika (80%) uglavnom složio kako rudarenje podataka pridonosi preciznijem određivanju vremena potrebnog za izvršenje projekta, kao i tvrdnji da rudarenje podatka pridonosi lakšem određivanju rizika unutar projekta. 40% ispitanika se niti slaže niti ne slaže sa tvrdnjom kako rudarenje podataka podataka pridonosi točnijoj procjeni budžeta unutar projekta, dok se 60% ispitanika uglavnom slaže sa tvrdnjom kako rudarenje podataka pridonosi točnijoj procjeni zahtjeva za resursima projekta, te kako rudarenje podataka pridonosi predviđanju ponašanja dionika unutar projekta.

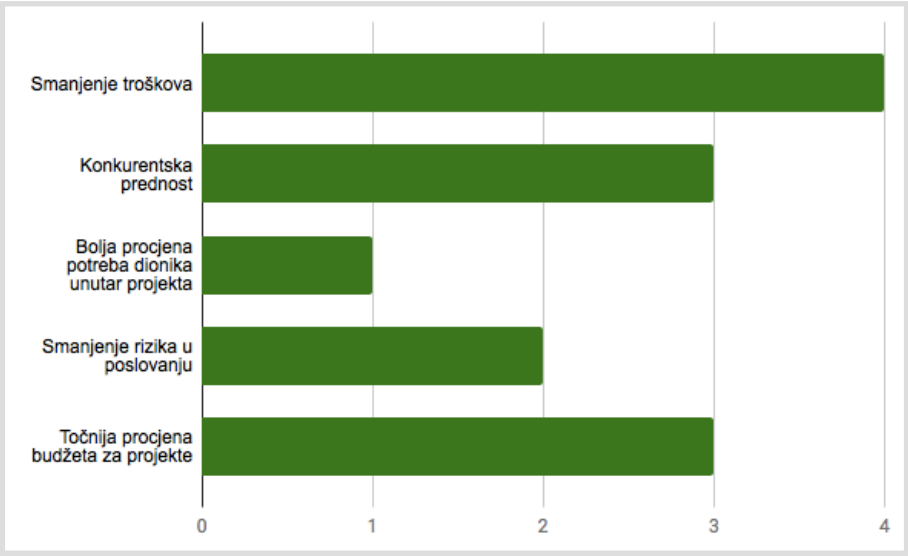
Grafikon 7: Prikaz odgovora na pitanje: "Koji su najčešće korišteni alati pri rudarenju podataka?"



Izvor: Istraživanje autorice

Na grafikonu 7. vidljivo je kako ispitanici najčešće koriste JIRU kao alat pri rudarenju podataka, njih 80% te SQL (40%). Među navedenim alatima pri rudarenju podataka ispitanici najmanje koriste analizu povratnih informacija (20%), dok nitko od ispitanika nije odabrao Clarizen, Orange, RapidMiner, WEK-u, Workfront, KNIME i R language kao alat koji najčešće koristi pri rudarenju podataka. Na ovo pitanje ispitanici su također imali mogućnost odabrati više odgovora (multiple choice).

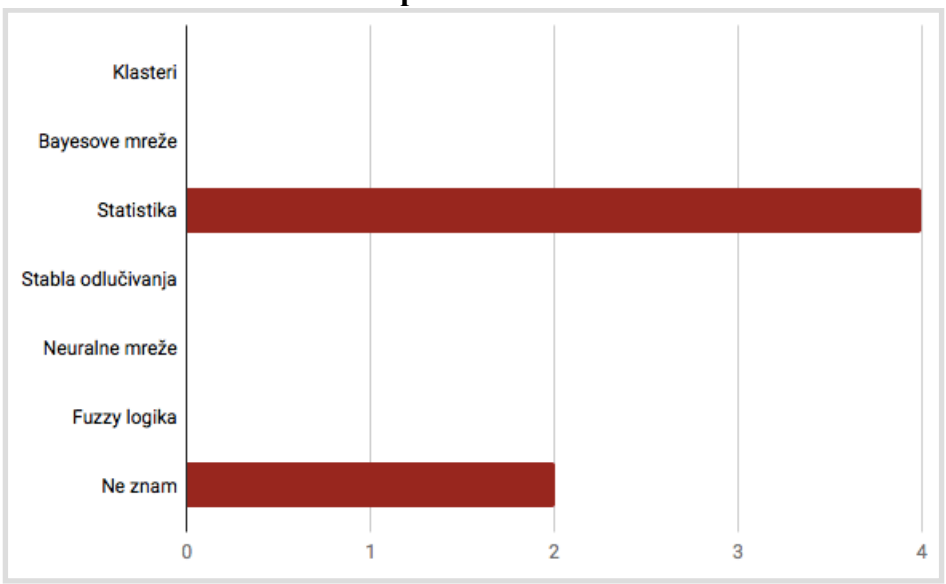
Grafikon 8: Prikaz odgovora na pitanje: "Koji od sljedećih razloga najviše pridonose porastu popularnosti rudarenja podataka?"



Izvor: Istraživanje autorice

Grafikon 8. prikazuje kako smanjenje troškova 80% ispitanika smatra kao najvažniji razlog za rast popularnosti rudarenja podataka, potom slijede konkurentska prednost i točnija procjena budžeta za projekte za koje 60% ispitanika smatra da su najviše pridonijeli porastu popularnosti rudarenja podataka. 40% ispitanika smatra da je to smanjenje rizika, dok 20% smatra da je bolja procjena potreba dionika unutar projekta jedan od razloga porasta popularnosti rudarenja podataka.

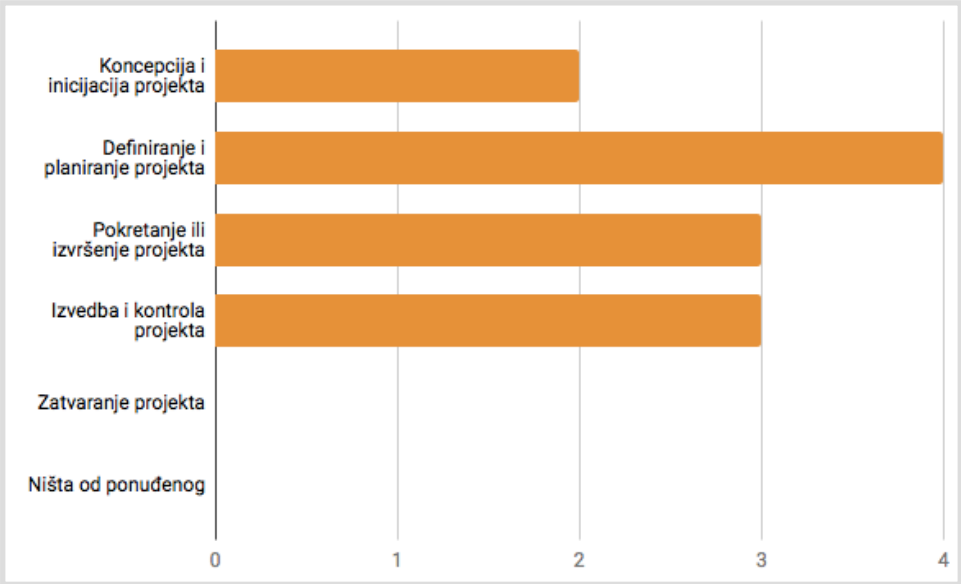
Grafikon 9: Prikaz odgovora na pitanje: "Koje su najčešće korištene tehnike pri rudarenju podatka?"



Izvor: Istraživanje autorice

Kao što je vidljivo na grafikonu 9. statistika je vidljivo najkorištenija tehnika pri rudarenju podatka koju koristi 80% ispitanika. Nitko od ispitanika nije naveo da koristi klastere, Bayesove mreže, stabla odlučivanja, neuralne mreže ili fuzzy logiku, dok se 20% ispitanika izjasnilo da ne zna odgovor na ovo pitanje.

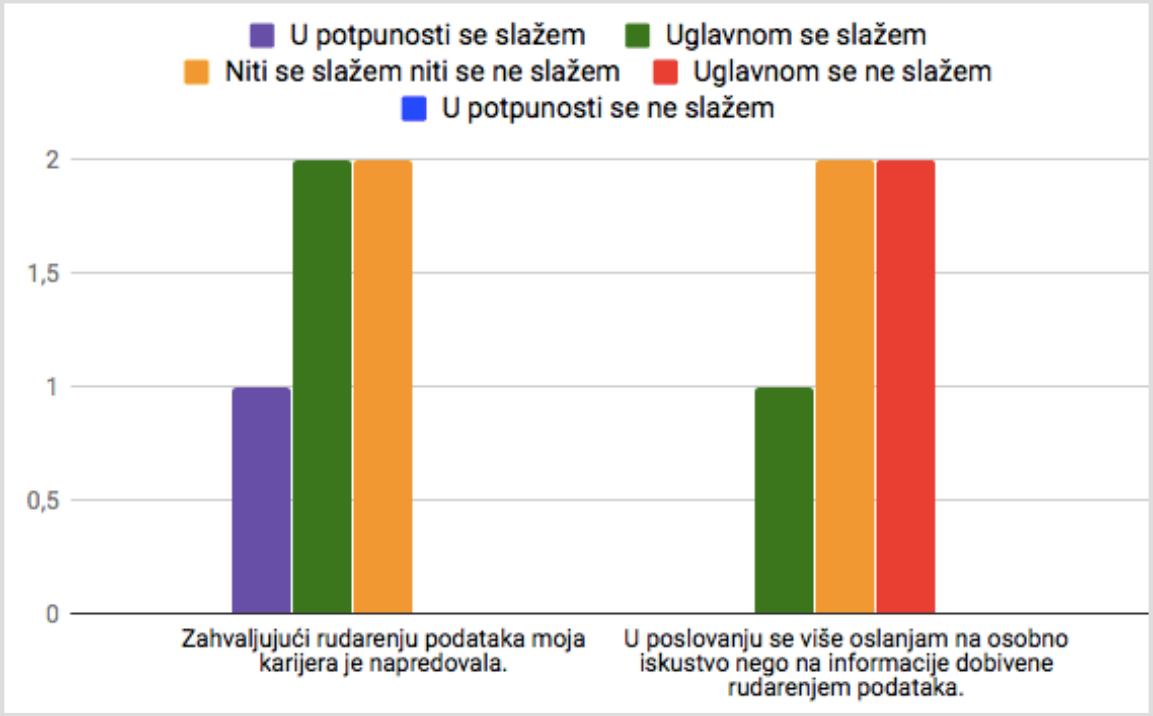
Grafikon 10: Prikaz odgovora na pitanje: "Koje faze poboljšava rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera?"



Izvor: Istraživanje autorice

Na prikazanom grafikonu 10. najviše ispitanika (80%) smatra kako rudarenje podataka poboljšava fazu definiranja i planiranja projekta u projektnom menadžmentu u okviru razvoja softvera. 60% ispitanika se izjasnilo da rudarenje podataka poboljšava fazu pokretanja ili izvršenja projekta, te fazu izvedbe i kontrole projekta. Da fazu koncepcije i inicijacije projekta poboljšava rudarenje podatka u projektnom menadžmentu u okviru razvoja softvera smatra 40% ispitanika, dok nitko od ispitanika nije odabrao da rudarenje podataka poboljšava fazu završetka projekta. Također, nitko od ispitanika nije odgovorio potvrdno da rudarenje podataka ne pomaže u nijednoj fazi u projektnom menadžmentu u okviru razvoja softvera, odnosno svi ispitanici koji su odgovorili na ovo pitanje smatraju kako rudarenje podataka poboljšava barem jednu od faza u projektnom menadžmentu u okviru razvoja softvera.

Grafikon 11: Prikaz odgovora na pitanje: "Ocijenite tvrdnje koje se odnose na projektni menadžment u okviru razvoja softvera."

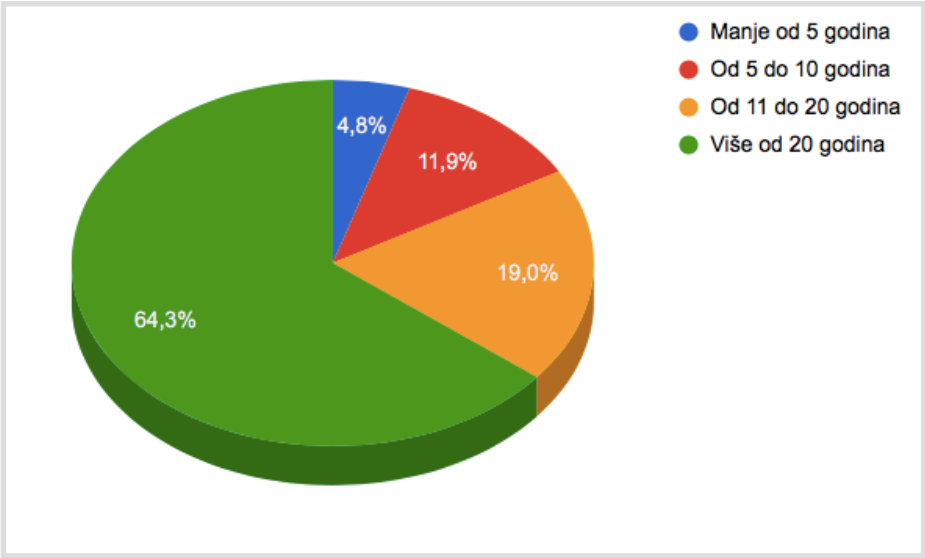


Izvor: Istraživanje autorice

Na grafikonu 11. promatrajući ocjenjene tvrdnje vidljivo je kako mišljenja ispitanika poprilično variraju. Da im je zahvaljujući rudarenju podataka karijera napredovala uglavnom se slaže 40% ispitanika, dok isti postotak ispitanika niti se slaže niti se ne slaže s navedenom tvrdnjom. Na tvrdnju da se u poslovanju više oslanjaju na osobno iskustvo nego na informacije dobivene rudarenjem podataka uglavnom se ne slaže 40% ispitanika, dok se također 40% ispitanika niti slaže niti ne slaže sa navedenom tvrdnjom.

Na iduća dva pitanja koja će se u daljnjem radu analizirati odgovarali su svi ispitanici koji su sudjelovali u ovom istraživanju, nevisno o odgovoru na prvo pitanje, odnosno ukoliko su odgovorili DA (koriste rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera u tvrtci za koju trenutno rade) ili NE (ne koriste rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera u tvrtci za koju trenutno rade).

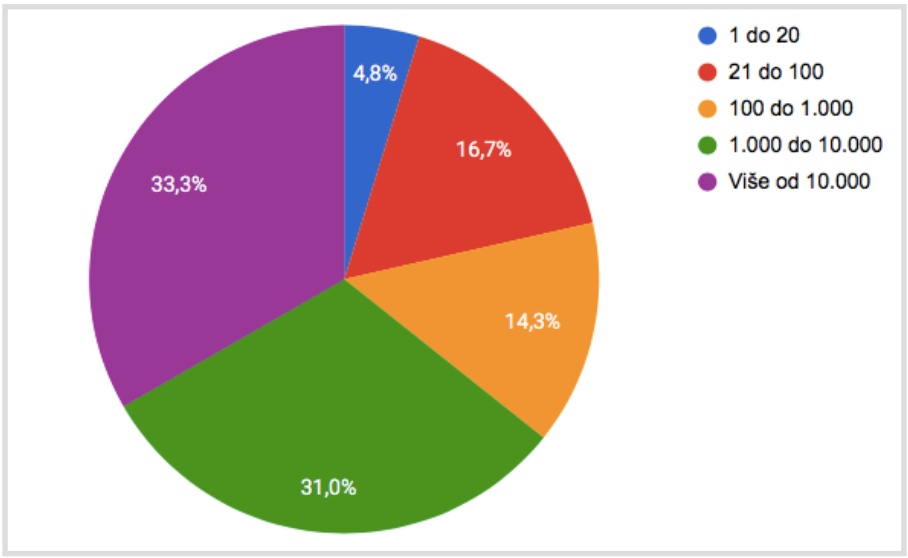
Grafikon 12: Prikaz odgovora na pitanje: "Kada je osnovana tvrtka za koju trenutno radite?"



Izvor: Istraživanje autorice

Grafikon 12. prikazuje da svi ispitanici rade za tvrtke koje se bave razvojem softvera, a najviše ispitanika, njih 64,3% radi za tvrtke koje su osnovane prije više od 20 godina. 19% ispitanika radi za tvrtke koje su osnovane prije 11 do 20 godina, dok 11,9% ispitanika radi za tvrtke koje su osnovane prije 5 do 10 godina. Najmanji postotak ispitanika (4,8%) radi za tvrtke koje su osnovane prije manje od 5 godina.

Grafikon 13: Prikaz odgovora na pitanje: "Koliko zaposlenika ima tvrtka za koju trenutno radite?"



Izvor: Istraživanje autorice

Na grafikonu 13. rezultati pokazuju kako najviše (33,3%) ispitanika radi za tvrtke koje imaju preko 10 000 zaposlenika. U tvrtkama koje imaju 1 000 do 10 000 zaposlenika radi 31% ispitanika, dok 16,7% ispitanika radi u tvrtkama koje imaju od 21 do 100 zaposlenika. U tvrtkama koje imaju od 100 do 1000 zaposlenika radi 14,3% ispitanika, dok najmanji postotak ispitanika (4,8%) radi za tvrtke koje imaju od 1 do 20 zaposlenika.

5.3. TESTIRANJE ISTRAŽIVAČKE HIPOTEZE

Kako bi se ostvario temeljni istraživački cilj, odnosno analizirao utjecaj rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera u gradu Stockholmu, u empirijskom istraživanju postavljena je jedna hipoteza koja će se kroz istraživanje potvrditi ili opovrgnuti. Postavljena hipoteza se sastoji od nekoliko elemanata, a glasi:

H 1*: Rudarenje podataka unapređuje faze projektnog menadžmenta u okviru razvoja softvera*

Jedan od testova pozdanosti koji se najčešće koristi za provjeru pozdanosti pitanja u upitniku sa višestrukom Likertovom skalom sudova jest Cronbach - Alpha koeficijent. U svrhu procjene pouzdanosti odnosno interne konzistencije skupa mjerila za određivanje učinaka rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera koristi se Cronbach - Alpha koeficijent koji predstavlja prosječnu korelaciju (povezanost) pitanja koja mjere istu osobinu. Koeficijent pouzdanosti se kreće od 0 do 1 u procjeni pouzdanosti mjere. Mnogi metodolozi preporučuju da se minimalni Cronbach - Alpha koeficijent kreće između 0,65 i 0,8 (ili više), a koeficijenti koji su manji od 0,5 obično su neprihvatljivi[83]. Izračunava se korelacijom rezultata za svaku stavku skale s ukupnim rezultatom za svako promatranje. U ovom radu to su pojedinačni odgovori svakog ispitanika koji su potom uspoređivani.

U tablici 3. prikazani su rezultati pozdanosti testa preciznijeg određivanja vremena potrebnog za izvršenje projekta, točnije procjene zahtjeva za resursima projekta, točnije procjene budžeta unutar projekta, predviđanja ponašanja dionika unutar projekta, te lakšeg određivanja rizika unutar projek-

[83] Goforth, C., 2015. Using and Interpreting Cronbach's Alpha. University of Virginia Library. Dostupno na: http://data.library.virginia.edu/using-and-interpreting-cronbachs-alpha/ [pristupljeno 16.09.2017.].

ta. Stupac N of Items prikazuje broj tvrdnji u anketnom upitniku pomoću kojeg se utvrđuje sama konzistentnost datih odgovora uz pomoć Cronbach - Alpha koeficijenta. U tablici je vidljivo kako najvišu vrijednost Cronbach - Alpha (0,868 > 0,8) ima test predviđanja ponašanja dionika unutar projekta. Zatim slijedi test lakšeg određivanja rizika unutar projekta (0,759 < 0,8) koji je nešto niži od koeficijenta 0,8, ali je i dalje preporučena razina Cronbach - Alpha koeficijenta.

Tablica 3: Cronbach-Alpha koeficijenti

Scale	Cronbach's Alpha	N of Items
Preciznije određivanje vremena potrebnog za izvršenje projekta.	0,690	5
Točnija procjena zahtjeva za resursima projekta.	0,624	5
Točnija procjena budžeta unutar projekta.	0,524	5
Predviđanje ponašanja dionika unutar projekta.	0,868	5
Lakše utvrđivanje rizika unutar projekta.	0,759	5

Izvor: Istraživanje autorice

Najneosjetljiviji test iz ove grupe testova je test točnije procjene budžeta unutar projekta gdje je Cronbach - Alpha najniža (0, 524) što je ujedno i minimalni Cronbach - Alpha koeficijent, ali i dalje prihvatljiv za analizu.

Budući da su svi koeficijenti Cronbach-Alpha na poželjnoj razini, izračunate su nove varijable kao aritmetička sredina ocjena po grupi tvrdnji.

Tablica 4: One-Sample Kolmogorov-Smirnov Test

	Kolmogorov-Smirnov Z	Asymp.Sig.(2-tailed)	N
Preciznije određivanje vremena potrebnog za izvršenje projekta.	1,789	0,001	5
Točnija procjena zahtjeva za resursima projekta.	0,671	0,161	5
Točnija procjena budžeta unutar projekta.	0,596	0,200	5
Predviđanje ponašanja dionika unutar projekta.	1,342	0,046	5
Lakše utvrđivanje rizika unutar projekta.	1,789	0,001	5
a Test distribution is Normal. b Calculated from data.			

Izvor: Istraživanje autorice

U tablici 4. provedeno je testiranje normalnosti distribucije frekvencija, odnosno izvršio se Kolmogorov - Smirnov test kako bi se ispitalo ima li neka promatrana distribucija oblik po nekom teorijskom zakonu. Kolmogorov - Smirnov test se temelji na najvećoj apsolutnoj razlici (ili diferenciji) D između empirijskih (iz uzorka) kumulativnih frekvencija i očekivanih kumulativnih frekvencija, dok se kao rezultat ovog testiranja dobije empirijska signifikantnost.

Ako je $\alpha^* > 5\% \Longrightarrow H_0$, tj. prihvaća se pretpostavka da zadana empirijska distribucija ima teorijski oblik koji se testira. Da bi se donio zaključak o prihvaćanju hipoteze da varijable iz prikazane tablice imaju oblik normalne distribucije uz graničnu signifikantnost od 5% pomoću Kolmogorov-Smirnov testa, potrebno je postaviti hipoteze[84]:

$$H0:.....X \sim N(\mu,\sigma)$$

$$H1:.....X \neq N(\mu,\sigma)$$

Ukupna površina normalne distribucije bilježi sa 1,0 ili 100 %, a normalna distribucija je jedan od osnovnih pojmova statističkog promatranja budući da je osnova za razumijevanje glavnih statističkih pojmova vjerojatnosti[85]. Na temelju dobivenih rezultata iz tablice 4. može se zaključiti da je empirijska signifikantnost: $\alpha^* = 0{,}001 = 1\% \Longrightarrow \alpha^* < 5\%$, tj. odbacuje se početna (nulta) hipoteza da distribucija preciznije određivanje vremena potrebnog za izvršenje projekta ima normalan oblik. Distribucija točnija procjena zahtjeva za resursima projekta ima normalnu distribuciju, budući da je $\alpha^* = 0{,}161 \Longrightarrow \alpha^* > 5\%$, također i distribucija točnija procjena budžeta unutar projekta, jer je $\alpha^* = 0{,}200 \Longrightarrow \alpha^* > 5\%$, odnosno prihvaća se početna (nulta) hipoteza da varijable iz prikazane tablice imaju oblik normalne distribucije uz graničnu signifikantnost od 5%. Ostale distribucije nemaju oblik normalne distribucije budući da je $\alpha^* < 5\%$. Ovakav tip testa je manje osjetljiv na pojavu

[84] Pivac, S., 2010. Statističke metode. Split: Ekonomski fakultet u Splitu, str. 166-171.

[85] Unizd, Distribucije. *unizd.hr* Dostupno na: www.unizd.hr/Portals/13/NASTAVNI_MATERIJALI/04%20-%20Distribucije.pdf. [pristupljeno 20.09.2017.].

netipičnih vrijednosti i može se primijeniti ako distribucija varijabli nije normalnog oblika[86]. Provedeni Kolmogorov-Smirnov test je pokazao da su dvije promatrane varijable normalno distribuirane, dok ostale varijable nisu normalno distribuirane, stoga su provedene neparametrijske metode.

Budući da se istražuje međuovisnost pojava koje su izražene modalitetima redoslijednog obilježja, što znači da su im modaliteti pridruženi na temelju ordinarne skale računa se korelacija ranga. Najpoznatija mjera korelacije ranga između dvije varijable je Spearmanov koeficijent korelacije ranga (r_S). Spearmanov koeficijent korelacije ranga može poprimiti vrijednosti u intervalu: $-1 \leq r_S \geq 1$. Koeficijent bliži rubovima ovog intervala, tj. -1 i 1 upućuje na veću korelaciju ranga promatranih dviju varijabli. Da bi se testirala značajnost Spearmanovog koeficijenta korelacije postavljene su hipoteze[87]:

$$H_0 \ldots\ldots r = 0$$

$$H_1 \ldots\ldots r \neq 0$$

U tablici 5. N je 42, budući da su odgovori svih ispitanika grupirani u 0 (ne koriste rudarenje podataka u okviru razvoja softvera u tvrtci za koju trenutno rade) i 1 (koriste rudarenje podataka u okviru razvoja softvera u tvrtci za koju trenutno rade), te je promatrana povezanost svih koji koriste rudarenje podataka, sa tvrdnjama vezanim uz primjenu rudarenja podataka. Prikazan je Spearmanov koeficijent korelacije ranga između učestalosti korištenja rudarenja podataka i tvrdnji vezanih uz primjenu rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera.

[86] Efzg, Regresijska i korelacijska analiza. *efzg.hr* Dostupno na: http://web.efzg.hr/dok/STA/mcizmesija/Regresijska%20i%20korelacijska.pdf [pristupljeno 20.09.2017.].

[87] Pivac, S. op.cit. , str. 242-245.

Tablica 5: Spearmanov koeficijent korelacije ranga između učestalosti korištenja rudarenja podataka i tvrdnji vezanih uz primjenu rudarenja podataka

Spearman's Rho		Povjerenje
Preciznije određivanje vremena potrebnog za izvršenje projekta.	Correlation Coefficient	0.998(**)
	Sig. (2-tailed)	0,000
	N	42
Točnija procjena zahtjeva za resursima projekta.	Correlation Coefficient	0.997(**)
	Sig. (2-tailed)	0,000
	N	42
Točnija procjena budžeta unutar projekta.	Correlation Coefficient	0,997(**)
	Sig. (2-tailed)	0,000
	N	42
Predviđanje ponašanja dionika unutar projekta.	Correlation Coefficient	0,997(**)
	Sig. (2-tailed)	0,000
	N	42
Lakše određivanje rizika unutar projekta.	Correlation Coefficient	0.998(**)
	Sig. (2-tailed)	0,000
	N	42
** Correlation is significant at the 0.01 level (2-tailed).		

Izvor: Istraživanje autorice

Analizom podataka iz tablice 5. vidljivo je kako su svi koeficijenti korelacije ranga statistički značajni pri signifikantnosti od 1% ($p<0,01$) i pozitivni, što ukazuje da postoji statistički značajna jaka pozitivna ($r_S>0,8$) povezanost između uporabe rudarenja podataka s jedne strane i korisnosti primjene rudarenja podataka: rudarenje podataka pomaže pri preciznijem određivanju vremena potrebnog za izvršenje projekta, točnijoj procjeni zahtjeva za resursima projekta, točnijoj procjeni budžeta unutar projekta, predviđanju ponašanja dionika unutar projekta, te lakšem utvrđivanju rizika unutar projekta, s druge strane čime je potvrđena hipoteza H1. To znači da rudarenje podataka može poslužiti kao alat koji može pomoći kod povećanja uspješnosti projekata, odnosno rudarenje podataka unapređuje faze projektnog menadžmenta u okviru razvoja softvera.

5.4. OGRANIČENJA ISTRAŽIVANJA

U ovom radu postoje određena ograničenja koja treba uzeti u obzir za eventualna buduća istraživanja vezana uz rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera. Prvenstveno, ograničenje se odnosi na sam uzorak istraživanja. Za potrebe istraživanja u ovom radu korišten je relevantan uzorak u kojem istraživač bira one jedinice promatranja za koje smatra da reprezentiraju osnovni skup. Odnosno, "namjerni uzorci biraju se tehnikom u kojoj su jedinice uzorka izabrane na osnovi osobne odluke ili pogodnosti, a nije poznata vjerojatnost da će jedinica osnovnog skupa biti izabrana u uzorak"[88]. Reprezetativnost ovog uzorka bi se tako mogla povećati kada bi istraživanje bilo provedeno na većem broju ispitanika, odnosno ukoliko bi se uzorak povećao. Preporuka je da budući istraživači nastoje kontaktirati što više tvrtki koje se bave razvojem softvera ukoliko žele što relevantnije rezultate.

Kao još jedno ograničenje može se spomenuti vremensko kao i proračunsko ograničenje koji ograničavaju granice istraživanja, u smislu metoda istraživanja te uzorkovanja. Dodatne sugestije su dogovaranje sastanaka, odnosno provođenje što više intervjua sa projektnim menadžerima koji se bave razvojem softvera, što može donijeti značajan doprinos kod budućih istraživanja. U ovom radu su provedena dva standardizirana intervjua, te je važno napomenuti da takva metoda istraživanja iziskuje dosta vremena, te zahtjeva određene resurse.

Također je važno spomenuti i ograničenje polja i mjesta istraživanja. Istraživanje je provedeno na području grada Stockholma, odnosno bilo bi poželjno provesti istraživanje na uzorku projektnih menadžera koji se bave razvojem softvera na razini cijele Švedske, budući da nisu obuhvaćene sve tvrtke koje se bave razvojem softvera u Švedskoj. Na taj način bi se mogli uspoređivati dobiveni rezultati sa rezultatima u nekim drugim zemljama. Najčešći razlozi zbog kojih ispitanici nisu željeli sudjelovati u istraživanju su: nedostatak vremena, previše upita od strane studenata, prioritet imaju studenti koji stažiraju u određenih tvrtkama i sl. Preporuka je u budućim istraživanjima uključiti i neke druge metode prikupljanja podataka, kao npr. telefonski pozivi, budući da se radi o vrlo specifičnoj grupi ispitanika (projektni menadžeri u okviru ravoja softvera na području Stockholma) koje ponekad nije lako naogovoriti da sudjeluju u istraživanju, što je ujedno bio jedan od najvećih izazova pri izradi ovog rada.

88 Marković, S. 2008., op.cit.

6. ZAKLJUČAK

Zahvaljujući rudarenju podataka moguće je pronaći skriveno znanje iz velike količine podataka. Rudarenje podataka omogućuje lakše donošenje odluka na različitim razinama upravljanja, unaprijeđuje postojeće znanje, te pomaže pri predviđanju određenih trendova i ponašanja. Može se reći kako postaje jedan od alata koji služi za povećanje konkurentnosti na tržištu, budući da omogućuje bolje poznavanje vlastitih ili potencijalnih korisnika, te njihovih želja, potreba i navika. Razvoj softvera je neophodan za svakodnevno poslovanje i samo funkcioniranje današnjeg društva, pa se koriste razne metode kako bi se pospješio razvoj kao i isporuka softvera. Pri tome se između ostaloga koristi i rudarenje podataka u kojem leži veliki potencijal za bolje planiranje, razvoj i isporuku softvera u budućnosti. Imajući na umu sve navedeno provedeno je istraživanje o učinku rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera. Istraživanje je provedeno u gradu Stockholmu u Švedskoj od strane autorice ovog rada, te obuhvaća uspješne firme koje se bave razvojem softvera.

Rezultati istraživanja potvrdili su kako rudarenje podataka unapređuje faze projektnog menadžmenta u okviru razvoja softvera. Prema Rošiću sam termin rudarenja se često poistovjećuje sa 2 različita procesa, a to su: otkrivanje i predviđanje znanja, gdje se proces otkrivanja znanja odnosi na korisnikovo razumijevanje eksplicitnih informacija za koje je bitno da su u čitljivom obliku, dok se predviđanje odnosi na buduće događaje. U provedenom istraživanju potvrđen je pozitivan utjecaj rudarenja podataka u projektnom menadžmentu na razvoj softvera u budućim projektima, što potvrđuje teorijske postavke koje je Rošić postavio. Samim uvidom u projekte koji su završili moguće je otkrivanje znanja zahvaljujući rudarenju podataka, dok se istovremeno ta stečena znanja mogu iskoristiti za određena predviđanja koja mogu biti korisna za buduće projekte u okviru razvoja softvera. Pozitivni učinci korištenja rudarenja podataka u projektnom menadžmentu na uspješnost budućih projekata vide se u provedenom istraživanju, odnosno prikazani su pozitivni učinci rudarenja podataka na preciznije određivanje vremena potrebnog na izvršenje projekta, lakše određivanje rizika unutar projekta, točniju procjenu zahtjeva za resursima projekta, točnijoj procjeni budžeta unutar projekta, te predviđanje ponašanja dionika unutar projekta. Ovakvi nalazi su također u skladu sa teorijskim postavkama vezanim uz projektni menadžment, gdje informacije iz prethodno završenih projekata služe za bolje, odnosno uspješnije poslovanje, te uspješniju izvedbu projeka-

ta u budućnosti. Zahvaljujući informacijama koje pružaju završeni projekti moguć je uvid u detalje, kako bi se napravila analiza uspjeha, te stečeno znanje iskoristilo za buduće projekte. Implikacije ovog istraživanja su da je uloga rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera jedan od alata koji će biti neophodan za poslovanje tvrtki u budućnosti, ukoliko tvrtka namjerava ostati konkurentna na tržištu.

Također, rezultati provedenog istraživanja ukazuju na nedovoljnu zastupljenost rudarenja podataka kao alata u projektnom menadžmentu, u tvrtkama koje se bave razvojem softvera u Stockholmu. Od 42 ispitanika samo 5 projeknih menadžera je odgovorilo kako u tvrtci u kojoj trenutno radi u okviru razvoja softvera, koristi rudarenje podataka. Osim toga, rezultati pokazuju kako projektni menadžeri u okviru razvoja softvera pri donošenju odluka, u svim fazama razvoja projekta, svoje odluke većinom temelje na prethodnom iskustvu, zajedničkom dogovoru sa svim članovima tima, te financijskim analizama. Iz toga se može zaključiti kako je rudarenje podataka kao alat za donošenje odluka u projektnom menadžmentu u okviru razvoja softvera još uvijek nedovoljno zastupljen. Može se reći kako je potencijal nedovoljno iskorišten, što rezultira manjkom korisnih informacija za poslovanje u okviru razvoja softvera. Rudarenje podataka može pomoći projektnom menadžmentu kako bi bolje razumjeli želje klijenata i njihovo ponašanje, te predvidjeli njihovo buduće ponašanje. Stav projektnih menadžera koji trenutno ne koriste rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera u tvrtci za koju trenutno rade je pozitivan, odnosno koristili bi rudarenje podataka kada bi imali prilike i znali da im može pomoći za povećanje uspješnosti projekata. Kako bi se projekt izvršio što preciznije (bolja procjena budžeta, resursa, vremena potrebnog za izvedbu i sl.) potrebne su određene informacije koje ponekad mogu biti skrivene u mnoštvu podataka, a uvid u njih može pružiti rudarenje podataka.

Autori Omazić i Baljkas navode kako postoje tri faze životnog ciklusa projekta i to: faza dizajniranja ili početna faza, faza provedbe ili implementacije, te faza zaključivanja ili završna faza. Svaka od faza projektnog menadžmenta ima svoje ključne zadatke i odluke, te temeljna pitanja na koje je potrebno odgovoriti. Rezultati istraživanja su pokazali kako rudarenje podataka pospješuje faze u projektnom menadžmentu u okviru razvoja softvera. Pri tome, najveći postotak ispitanika smatra kako rudarenje podataka poboljšava fazu definiranja i planiranja projekta. Razvoj softvera podrazumijeva

ispunjenje određenih zahtjeva koji su prethodno definirani, stoga projektni menadžeri moraju voditi računa da u svim fazama projekta postižu kvalitetu, te smanjuju rizike u okvirima zadanih troškova i resursa.

Rudarenje podataka je najveći učinak imalo na točniju procjenu zahtjeva za resursima projekta, te lakše određivanje rizika unutar projekta, prema rezultatima istraživanja. Također, osim definiranog glavnog cilja postavljeni su i sekundarni ciljevi unutar istraživanja, a to su: otkrivanje najpopularnijih metoda rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera; definiranje uloge i značaja rudarenja podataka u današnjem poslovanju; utvrđivanje utjecaja rudarenja podatka u projektnom menadžmentu na zadovoljstvo i uspješnost projektnih menadžera; otkrivanje najpopularnijih standarda kod pretraživanja podataka, te utvrđivanje razloga za rast popularnosti rudarenja podataka u današnjem poslovanju. Kao najpopularniji alati za rudranje podataka u projektnom menadžmentu u okviru razvoja softvera pokazali su se JIRA i SQL. Uloga i značaj rudarenja podataka u današnjem poslovanju sve više raste, te ispitanici (koji već koriste rudarenje podataka u projektnom menadžmenu u okviru razvoja softvera), koriste rudarenje podataka učestalo, odnosno na dnevnoj i tjednoj bazi. Također, prevladava mišljenje ispitanika kako im je karijera napredovala zahvaljujući rudarenju podataka, pa se može zaključiti kako rudarenje podataka ima utjecaj na zadovoljstvo i uspješnost projektnih menadžera. Kao najvažniji razlog za rast popularnosti rudarenja podataka ispitanici navode smanjenje troškova, a potom slijede konkurentska prednost i točnija procjena budžeta za projekte.

Unaprijediti poslovanje i ostati konkurentan je izazov u današnjem poslovnom okruženju, stoga tvrtke moraju biti u koraku s promjenama koje se dešavaju. Postoji dosta prostora za napredak po pitanju povećanja uspješnosti projekata u okviru razvoja softvera, ali rudarenje podataka može biti jedan od alata koji će se koristiti kako bi se još više povećala uspješnost projekata u budućnosti.

Doneseni zaključci mogu poslužiti tvrtkama koje se bave razvojem softvera kao smjernice za poboljšanje projekata u budućnosti, te kako zahvaljujući rudarenju podataka mogu imati bolji uvid u sve aspekte koji su važni u projektnom menadžmentu u okviru razvoja softvera (od određivanja resursa do detekcije potencijalnih rizika unutar projekta). Istraživanje je kombiniralo nekoliko

apekata koji su važni pri razvoju projekta u okviru razvoja softvera i primjenilo ih u jedan model kako bi se razumijela važnost rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera. Provedeno istraživanje može pomoći projektnim menadžerima koji još uvijek nisu upoznati sa tematikom i uporabom rudarenja podataka kako bi razvili puni potencijal uspješnosti projekata u okviru razvoja softvera.

LITERATURA

1. A Guide to the Project Management Body of Knowledge (PMBOK® Guide)—Fifth Edition, 2013. *Project Management Institute.* Dostupno na: http://epm.bpharmed.com/pmo/PMBOK/PMBOK2012-5rd%20Edition.pdf?Mobile=1&Source=%2Fpmo%2F_layouts%2Fmobile%2Fview.aspx%3FList%3D473cddfb%252D7264%252D45bd%252Da478%252Dec282a672ead%26View%3D4739149c%252Dc28d%252D4758%252Da547%252D19f2a323efbd%26CurrentPage%3D1 [pristupljeno 23.03.2017.] str.5.

2. Algebra, otvoreno učilište., 2017. Zašto Projektni Management? Dostupno na: http://www.algebra.hr/edukacija/project-management-akademija/ [pristupljeno 03.04.2017].

3. Batistić, I., 2004. Što su to baze podataka?. *Grdelin.* Dostupno na: http://grdelin.phy.hr/~ivo/Nastava/Baze_podataka/predavanja-2004/01_pred.pdf [pristupljeno 21.03.2017.]

4. Capterra The Smart Way to Find Business Software, 2017. *Top Project Management Tools*. Dostupno na: http://www.capterra.com/project-management-software/ [pristupljeno 16.07.2017.]

5. Čačić, M. Varga, M., 2004 . Informacijska tehnologija u poslovanju. *Element*, Zagreb. str.7.

6. Čerić, V., element.hr. Informacijska tehnologija i poslovanje. Dostupno na: https://element.hr/artikli/file/1377 [pristupljeno 03.03.2017.] str. 10.

7. Čubranić, D., Kaluža, M., Novak, J. 2013. Standardne metode u funkciji razvoja softvera u Republici Hrvatskoj. pdf. Zbornik Veleučilišta u Rijeci, Vol. 1. str. 239-256. [pristupljeno 19.07.2017.]

8. EEE Software Engineering Standard 792-1983.,1990. IEEE Standard Glossary of Software Engineering Terminology. *The Institute of Electrical and Electronics Engineers.* 345 East 47th Street, New York, NY 10017, USA. [pdf] Dostupno na: http://www.mit.jyu.fi/ope/kurssit/TIES462/Materiaalit/IEEE_SoftwareEngGlossary.pdf [pristupljeno 23.03.2017.] str. 66.

9. Ekonomski Fakultet Zagreb, Regresijska i korelacijska analiza. *efzg.hr*. [pdf] Dostupno na: http://web.efzg.hr/dok/STA/mcizmesija/Regresijska%20i%20korelacijska.pdf Nastavni materijali. [pristupljeno 20.09.2017.].

10. Fayyad et al.1996. From data Mining to Knowledge Discovery in Database, Al Magazine Vol. 17, No.3, dostupno na: http://www.aaai.org/ojs/index.php/aimagazine/article/viewFile/1230/1131 [pristupljeno 09.03.2017.]

11. Fertalj, K., Fertalj, Ž., Kosović Nižetić, I., 2016. *Upravljanje projektima.* Fakultet elektronike i računarstva. Sveučilište u Zagrebu. Dostupno na: https://bib.irb.hr/datoteka/807419.Upravljanje_projektima_-_skripta_FER_2016.pdf Skripta. [pristupljeno 12.07.2017.] str. 6. i 7.

12. Friedman, J.H. *Data mining and statistics: Where`s the connection?* Stanford University.pdf: Dostupno na: http://venus.unive.it/romanaz/edami/letture/jfriedman.pdf [pristupljeno 27.06.2017.] str. 1.

13. Gabelica, H. 2013. Rudarenje podataka i CRISP metodologija. *skladištenje.com*. Dostupno na: http://www.skladistenje.com/rudarenje-podataka-i-crisp-metodologija/ [pristupljeno 23.06.2017.]
10. Hammergen, T. C., Simon, A.R. 2009. *Data Warehousing for Dummies.* Willey.

14. Goforth, C., 2015. Using and Interpreting Cronbach's Alpha. University of Virginia Library. Dostupno na: http://data.library.virginia.edu/using-and-interpreting-cronbachs-alpha/ [pristupljeno 16.09.2017.].

15. Haapio, T., Menzies, T., 2009. *Data Mining with software industry project data: A case study.* Lane Department of Computer Science, West Virginia University, Morgantown, WV 26506-610, USA. Dostupno na: http://www.academia.edu/2699638/DATA_MINING_WITH_SOFTWARE_INDUSTRY_PROJECT_DATA_A_CASE_STUDY [pristupljeno 25.09.2017.]

16. Hampton, J., 2011. SEMMA and CRISP-DM: Data mining methodologies. *jesshampton.com* Dostupno na: http://jesshampton.com/2011/02/16/semma-and-crisp-dm-data-mining-methodologies/ [pristupljeno 22.06.2017.]

17. Han, J., Pei, J. i Kamber, M., 2012. Data Mining: Concepts and Techniques, *Elsevier Inc.,* USA, str. 2.

18. Hand, D., Mannila, H., i Smyth, P., 2001. *Principles of Data Mining.* The MIT Press pdf. Dostupno na: http://box.cs.istu.ru/public/docs/other/_New/Books/Misc/Principles%20of%20Data%20Mining.pdf [pristupljeno 29.06.2017.] str. 6.

19. Inmon, W.H., 1992. Building the Data Warehouse. *John Wiley & Sons, Inc*. New York, NY, USA. str. 31.

20. ISO 9000:2015., 2015. *Online Browsing Platform (OBP)*. Dostupno na: https://www.iso.org/obp/ui/#iso:std:iso:9000:ed-4:v1:en [pristupljeno 23.07.2017.]

21. I.V., 2002. Rudarenje poslovno-financijskih podataka. *skladištenje.com* Dostupno na: http://www.skladistenje.com/rudarenje-poslovno-financijskih-podataka/ [pristupljeno 05.07.2017.]

22. Jeremić, Z., Softverski proces i životni ciklus softvera. pdf. Dostupno na: http://www.viser.edu.rs/download/uploads/5663.pdf [pristupljeno 27.07.2017.]

23. Juran, J.M., 1999. *Juran's quality handbook.* Fifth Edition. McGraw-Hill. poglavlje 4. pdf. Dostupno na: http://www.pqm-online.com/assets/files/lib/books/juran.pdf [pristupljeno 26.07.2017.]

24. Karlović, S., Pantelić, A., i Pedić, J., 2017. Rudarenje podataka. *TAOPIS the autopoetic information system.*: Dostupno na: http://autopoiesis.foi.hr/wiki.php?name=KM%20-%20Tim%2062&parent=NULL&page=new [pristupljeno 27.06.2017.]

25. Klepac, G. i Mršić, L., 2006. Poslovna inteligencija kroz poslovne slučajeve. *TIM press i Lider press*; Zagreb.Dostupno na: http://www.goranklepac.com/index.asp?j=HR&iz=1&sa=1&vi=1&hi=1 eno [pristupljeno 01.03.2017.]

26. Klepić, Z., 2016. *Projektni menadžment neprofitnih organizacija.* pdf. Dostupno na: http:// ef.sve-mo.ba/sites/default/files/nastavni-materijali/projektni%20menadžment.pdf [pristupljeno 14.07.2017.]

27. Kraus, C., Starčević Staničić I., 2012. Metode i alati projektnog menadžmenta u procesu digitalizacije. Leksikografski zavod Miroslav Krleža. pdf. Dostupno na: http://dfest.nsk.hr/2015/wp-content/themes/boilerplate/2015/prezentacije/Kraus_Starcevic-Stancic.pdf [pristupljeno 12.07.2017.]

28. Krneta, P., Upravljanje projektima razvoja softvera za potporu poslovnim procesima tvrtke. [pdf] Dostupno na: http://www.inf.uniri.hr/files/datoteke/majam/upravljanje_projektima_razvoja_-softvera_za_ppp_tvrtke_v1.pdf [pristupljeno 24.03.2017.] str.1.

29. Mandić, S., 2012. Pojam baze podataka. *Računarstvo i informatika.* Dostupno na: https://racunarstvoiinformatika.wordpress.com/2012/01/23/pojam-baze-podataka/ [pristupljeno 21.03.2017.]

30. Marković, S. 2008. Uzorak i prikupljanje podataka, Sveučilište u Rijeci, Fakultet za menadžment u turizmu i ugostiteljstvu. Dostupno na: http://lumens.fthm.hr/edata/ 2011/11e0fa5d-6e66-4424-9e1a-7ac9cf5e747b.pdf [pristupljeno 09.09.2017.]

31. Mata, J., Alvarez, J.L., Riquelme, J.C., Ramos, I. 2016. *Applying Data Mining to Software Development Projects: A case study*. Dostupno na: https://www.researchgate.net/publication/ 220711344_Applying_Data_Mining_to_Software_Development_Projects_A_Case_Study [pristupljeno 25.09.2017.]

32. Münch, J., Armbrust, O., Kowalczyk, M., Soto, M., 2012. Software Process Definition and Management. Springer. Dostupno na: https://books.google.se/books? id=S_8Yf1wTKNoC&printsec=frontcover&hl=sv&source=gbs_ge_summary_r&cad=0#v=onepage &q&f=false str. 8. [pristupljeno 20.07.2017.]

33. Oreščanin, D., 2004. Skladno skladištenje. *skladištenje.com* Dostupno na: http://www.skladistenje.com/skladno-skladistenje/ [pristupljeno 19.03.2017.]

34. Panian, Ž., Klepac, G., 2003. *Poslovna inteligencija,* MASMEDIA, Zagreb. str. 247.

35. Pejić-Bach, M., Varga, M., 2006. Profil stručnjaka za rudarenje podataka. Ekonomski fakultet Zagreb, Katedra za informatiku. *skladištenje.com* Dostupno na: http://www.skladistenje.com/profil-strucnjaka/ [pristupljeno 10.04.2017.]

36. Pivac, S., 2010. Statističke metode. Split: Ekonomski fakultet u Splitu, str. 166-171.

37. Požgaj, Ž., Procesi razvoja softvera. Ekonomski Fakultet Zagreb, Zagreb. [pdf] Dostupno na: http://web.efzg.hr/dok/inf/pozgaj/pisani%20materijali/T03%20Modeli%20razvoja%20softvera.pdf [pristupljeno 05.04.2017].

38. Project Management Institute, 2000. *A Guide to the Project Management Body of Knowledge (PMBOK Guide)* .Dostupno na: https://www.amazon.com/Guide-Project-Management-Knowledge-PMBOK/dp/1880410230 [pristupljeno 09.07.2017.] str. 6

39. Project Management Institute (PMI). 2017. What is Project Management? Dostupno na: https://www.pmi.org/about/learn-about-pmi/what-is-project-management [pristupljeno 01.04.2017].

40. Project Management History, The Harmonogram. *projectmanagementhistory.com* Dostupno na: http://projectmanagementhistory.com/The_Harmonogram.html# [pristupljeno 16.07.2017.]

41. Quinion, M., 2005. Garbage in, garbage out. *World Wide Words.* Dostupno na: http://www.-worldwidewords.org/qa/qa-gar1.htm [pristupljeno 19.03.2017.]

42. Radić, D., Rječnik informatičkih pojmova. Dostupno na: http://www.informatika.buzdo.com/rjecnik/ [pristupljeno 27.07.2017.]

43. Rošić, S., 2017. Taopis the autopoetic information system. Fakultet organizacije i informatike. Dostupno na: http://www.autopoiesis.foi.hr/wiki.php?edit=yes&name=Skladišta+podataka&page=rudarenje+podataka&lang=de&lang=hr [pristupljeno 05.03.2017.]

44. Skoko, H., 2000. Upravljanje kvalitetom, Sinergija, Zagreb. Dostupno na: https://www.scribd.-com/doc/39793919/Upravljanje-Kvalitetom-H-skoko-2000 [pristupljeno 23.07.2017.] str. 12-18

45. Svijet kvalitete, 2012. Potpuno upravljanje kvalitetom (TQM). *svijet-kvaliete.com* Dostupno na: http://www.svijet-kvalitete.com/index.php/upravljanje-kvalitetom/368-potpuno-upravljanje-kvalitetom-tqm [pristupljeno 26.07.2017.]

46. Šunjić, D., 2017. Projektni menadžment-Upravljanje projektima. *scribd.com* Dostupno na: https://www.scribd.com/doc/48038724/Projektni-Menadzment-Upravljanje-projektima [pristupljeno 07.07.2017.]

47. Tolić, H. 2016. Upravljanje projektima sportske organizacije primjenom programa ProjectLibre. Završni rad. str. 4.

48. Tudor, M., Informacijski sustavi.htm. Pomorski Fakultet, Sveučilište u Rijeci. Dostupno na: http://www.pfri.uniri.hr/~tudor/materijali/Informacijski%20sustavi,%20baze%20podataka.htm [pristupljeno 22.03.2017.]

49. Unizd, Distribucije. *unizd.hr* [pdf] Dostupno na: www.unizd.hr/Portals/13/NASTAVNI_MA-TERIJALI/04%20-%20Distribucije.pdf. Nastavni materijali [pristupljeno 20.09.2017.].

50. Wikipedia, 2014. *Poslovna inteligencija*. Dostupno na: https://hr.wikipedia.org/wiki/Poslov-na_inteligencija [pristupljeno 28.06.2017.]

51. Wikipedia, 2017. *Project Management.* Dostupno na: https://en.wikipedia.org/wiki/Project_-management [pristupljeno 11.07.2017.]

52. Wikipedia, 2017. *Project management software*. Dostupno na: https://en.wikipedia.org/wiki/Project_management_software [pristupljeno 17.07.2017.]

53. Wikipedia, 2013. *Razvoj softvera*. Dostupno na: https://sr.wikipedia.org/sr-el/Развој_софтвера [pristupljeno 20.07.2017.]

54. Wikipedia, *Software*. Dostupno na: https://en.wikipedia.org/wiki/Software [pristupljeno 25.03.2017.]

55. Witten, I.H. i Frank, E., 2005. Data mining: Practical machine learning tools and techniques. *Elsevier : MK [i. e.] Morgan Kaufmann, cop.* Amsterdam [etc.] str. 4.

56. Zelenika, R., 2000. *Metodologija i tehnologija izrade znanstvenog i stručnog djela.* 4. izd. Rijeka: Ekonomski fakultet u Rijeci, str. 323-381.

57. Ziegenbein, K., 2008. Kontroling, *RRiF plus*, Zagreb, str. 163.

58. Zvorc, N., Stokan, K., Vuković, M., 2017. Područja primjene rudarenja podataka. *TAOPIS the autopoetic information system*. Dostupno na: http://autopoiesis.foi.hr/wiki.php?name=KM+-+Tim+20&parent=NULL&page=Podrucja%20primjene%20rudarenja%20podataka [pristupljeno 29.06.2017.]

59. Zvorc, N., Stokan, K., Vuković, M., 2017. Rudarenje podataka (Data Mining) *TAOPIS the autopoetic information system*. Dostupno na: http://autopoiesis.foi.hr/wiki.php?name=KM+-+Tim+20&parent=NULL&page=Rudarenje%20podataka [pristupljeno 06.07.2017.]

POPIS SLIKA

Slika 1: Rudarenje podataka kao samo jedan korak u procesu otkrivanja znanja.....5

Slika 2: Metodologija otkrivanja znanja primjenom metoda rudarenja podataka.....20

Slika 3: Trokut dosega (eng. scope triangle).....25

Slika 4: Faze projektnog menadžmenta.....28

Slika 5: Životni ciklus razvoja softvera.....35

POPIS TABLICA

Tablica 1: Prikaz četiri revolucionarna koraka koja su pružila mogućnost brzih i preciznih odgovora kakve danas zahtijeva suvremeno poslovanje 17

Tablica 2: Faze životnog ciklusa projekta 27

Tablica 3: Cronbach-Alpha koeficijenti 52

Tablica 4: One-Sample Kolmogorov-Smirnov Test 52

Tablica 5: Spearmanov koeficijent korelacije ranga između učestalosti korištenja rudarenja podataka i tvrdnji vezanih uz primjenu rudarenja podataka 55

POPIS GRAFIKONA

Grafikon 1: Prikaz odgovora na pitanje: “Koristite li rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera?” 41

Grafikon 2: Prikaz odgovora na pitanje: “Na čemu temeljite svoja predviđanja u projektnom ..41

menadžmentu?” 41

Grafikon 3: Prikaz odgovora na pitanje: “Da li tvrtka za koju trenutno radite namjerava koristiti rudarenje podataka u budućnosti?” 42

Grafikon 4: Prikaz odgovora na pitanje: “Da li bi koristili rudarenje podataka u projektnom menadžmentu ako bi znali da bi imali direktnu korist od toga?” 43

Grafikon 5: Prikaz odgovora na pitanje: “Koliko često koristite rudarenje podataka u projektnom menadžmentu?” 44

Grafikon 6: Prikaz odgovora na pitanje: “Ocijenite tvrdnje koje se odnose na rudarenje podatka u projektnom menadžmentu u okviru razvoja softvera.” 45

Grafikon 7: Prikaz odgovora na pitanje: “Koji su najčešće korišteni alati pri rudarenju podataka?” 46

Grafikon 8: Prikaz odgovora na pitanje: “Koji od sljedećih razloga najviše pridonose porastu popularnosti rudarenja podataka?” 47

Grafikon 9: Prikaz odgovora na pitanje: “Koje su najčešće korištene tehnike pri rudarenju podatka?” 47

Grafikon 10: Prikaz odgovora na pitanje: “Koje faze poboljšava rudarenje podataka u projektnom menadžmentu u okviru razvoja softvera?” 48

Grafikon 11: Prikaz odgovora na pitanje: “Ocijenite tvrdnje koje se odnose na projektni menadžment u okviru razvoja softvera.” 49

Grafikon 12: Prikaz odgovora na pitanje: “Kada je osnovana tvrtka za koju trenutno radite?” ..50

Grafikon 13: Prikaz odgovora na pitanje: “Koliko zaposlenika ima tvrtka za koju trenutno radite?” 50

PRILOZI

Anketa o rudarenju podataka u projektnom menadžmentu u okviru razvoja softvera

Survey of Data Mining in Project Management within the Software Development

Respected,

This survey is a part of Master's thesis research related to the impact of Data Mining in Project Management within the Software Development.

It will take only 3 to 5 minutes to complete this survey. It is completely anonymous and voluntary. The results obtained by the survey will be used only for the purpose of graduation and it is intended to Project Managers and Analysts. Please answer on the following questions honestly.

Thank you for your time and participation! :)

Explanation relevant to the survey:
DATA MINING - is a set of methodologies used in analyzing data from various dimensions and perspectives, finding previously unknown hidden patterns, classifying and grouping the data and summarizing the identified relationships.
PROJECT - in this survey relates to Software Development.

* Required

Do you agree with the following statement: "We use Data Mining in Project Management in our company". *

- ◯ Yes
- ◯ No

NEXT

Page 1 of 7

Set pitanja ukoliko je ispitanik na prvo pitanje odgovorio NE

Data Mining

On what do you base your predictions in Project Management? *
Multiple choices available.

- [ ] Previous experience
- [ ] Common agreement of all project members
- [ ] Financial analysis
- [ ] Other: _____

Is your company planning to use Data Mining within the Project Management in the future? *

- ○ Yes
- ○ No
- ○ Maybe

Would you use Data Mining in Project Management if you knew that you could have a direct benefit from it? *

- ○ Yes
- ○ No
- ○ Maybe

BACK NEXT Page 2 of 7

Set pitanja ukoliko je ispitanik na prvo pitanje odgovorio DA

Data Mining in Project Management within Software Development

How often do you use Data Mining within Project Management in your company? *

- ◯ Daily
- ◯ Weekly
- ◯ Monthly
- ◯ Quarterly
- ◯ Yearly
- ◯ I don't know

How do you agree with the following statements? *

	Strongly Disagree	Disagree	Neither Agree or Disagree	Agree	Strongly Agree
Data Mining contributes to more precise determination of project execution time.	◯	◯	◯	◯	◯
Data Mining contributes to a more accurate assessment of project resource requirements.	◯	◯	◯	◯	◯
Data Mining contributes to a more accurate budget estimation within project.	◯	◯	◯	◯	◯
Data Mining contributes to predict the behavior of stakeholders within project.	◯	◯	◯	◯	◯
Data Mining contributes in easier risk determination within project.	◯	◯	◯	◯	◯

BACK NEXT Page 3 of 7

Data Mining in Project Management within Software Development

Which of the following Data Mining tools is commonly used in your company? *

Multiple choices available.

- [ ] JIRA
- [ ] Clarizen
- [ ] Orange
- [ ] RapidMiner
- [ ] WEKA
- [ ] Workfront
- [ ] KNIME
- [ ] R language
- [ ] SQL
- [ ] Other: _____

Which of the following reasons you find most accurate in raising popularity of Data Mining. *

Multiple choices available.

- [ ] Lowering costs
- [ ] Competitive advantage
- [ ] Better recognising the needs of stakeholders
- [ ] Risk reduction in business
- [ ] More accurate budget estimation for projects
- [ ] Other: _____

BACK NEXT

Page 4 of 7

Data Mining in Project Management within Software Development

Multiple choices available.

Which of the following Data Mining techniques is most commonly used in your company? *

Multiple choices available.

- [ ] Clustering
- [ ] Bayesian network
- [ ] Statistics
- [ ] Decision Trees
- [ ] Neural Networks
- [ ] Fuzzy logic
- [ ] I don't know
- [ ] Other: _____

BACK NEXT

Page 5 of 7

Project Management within Software Development

In your opinion, which phases in Project Management within Software Development does Data Mining improve? *

Multiple choices available.

- [ ] Project conception and initiation
- [ ] Project definition and planning
- [ ] Project launch or execution
- [ ] Project performance and control
- [ ] Project close
- [ ] None of them

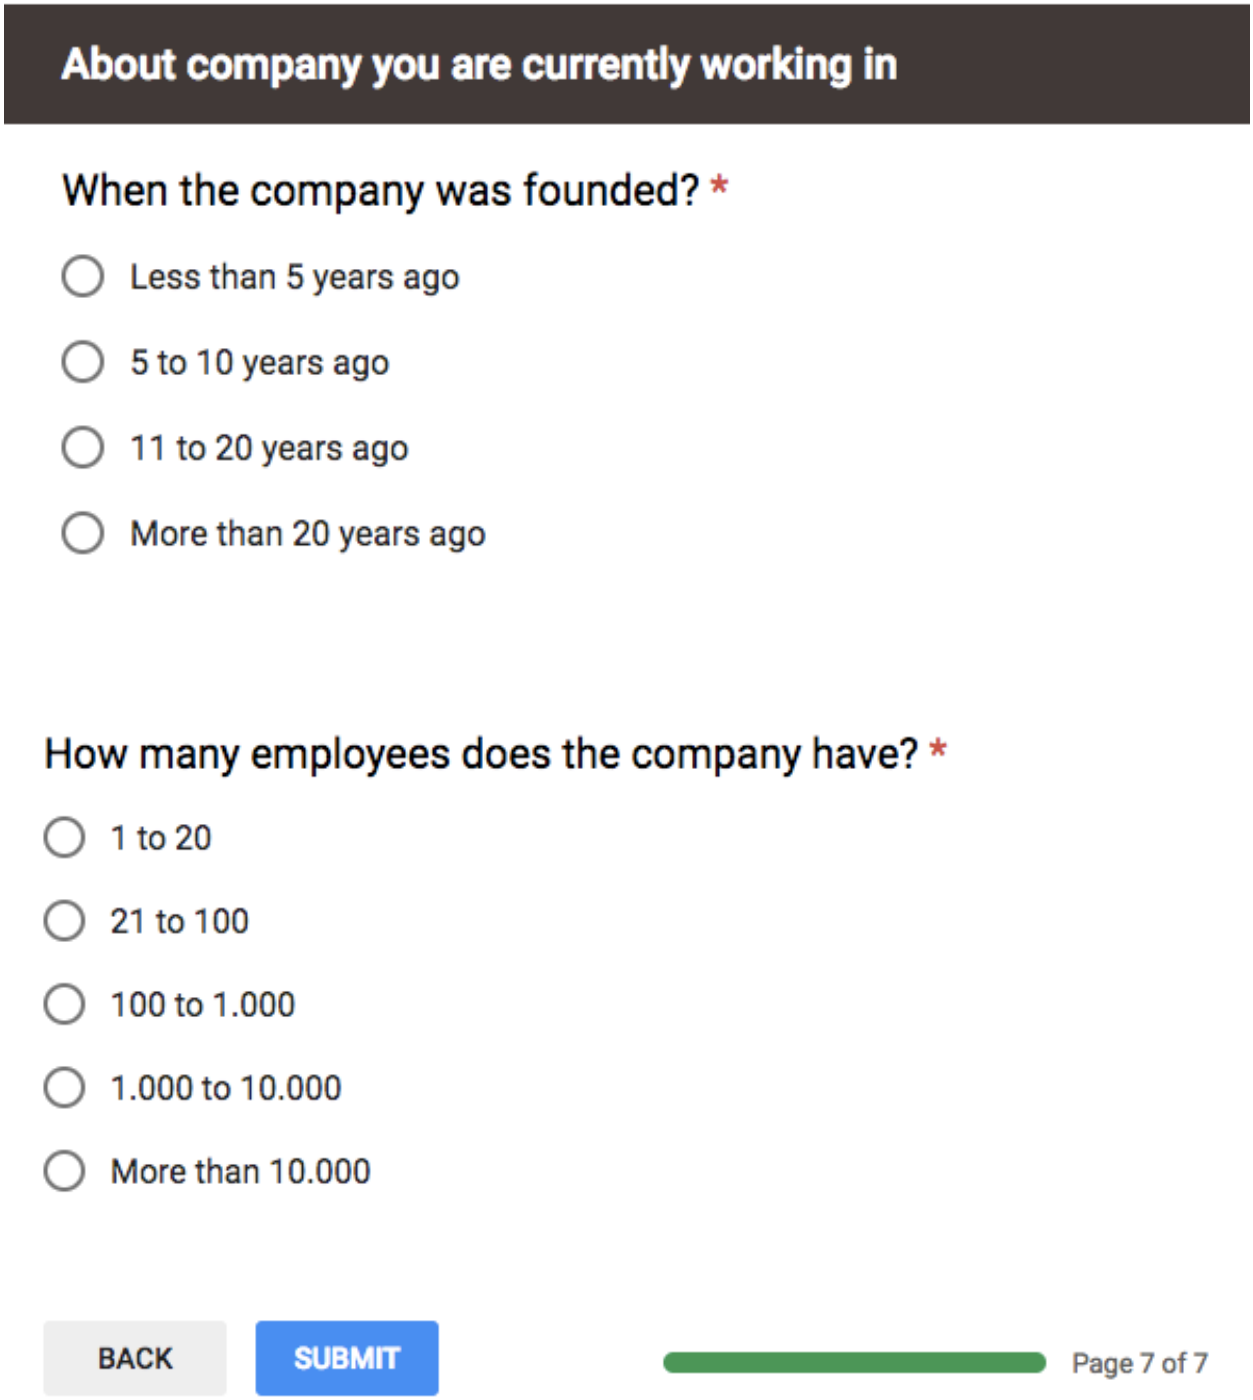
How do you agree with the following statements? *

	Strongly Disagree	Disagree	Neither Agree or Disagree	Agree	Strongly Agree
Thanks to the Data Mining my career has progressed.	○	○	○	○	○
In business I rely more on my personal experience than on information obtained by Data Mining.	○	○	○	○	○

BACK NEXT

Page 6 of 7

Set pitanja neovisno da li je ispitanik na prvo pitanje odgovorio DA ili NE



Intervju

Pitanja za intervju:

1. Za koju tvrtku trenutno radite i gdje?

2. Da li se u tvrtci za koju radite koristi rudarenje podataka? DA/NE

3. Smatrate li da bi korištenje rudarenja podataka moglo biti korisno za projekte u budućnosti?

4. Koji su najčešći problemi s kojima se susrećete u projektnom menadžmentu pri razvoju softvera?

5. Tko radi na rudarenju podataka, odnosno kako se dobiju podaci iz prethodnih projekata, i kome su dostupni ti podaci?

6. Da li biste dali prijedlog za korištenje rudarenja podataka u Vašoj tvrtci ako bi znali da donosi određene prednosti u odnosu na konkurenciju?

Odgovori:

Projektni menadžer u tvrtci Ericsson, Stockholm.

1. Trenutno radim u tvrtci Ericsson koja se nalazi u Stockholmu.

2. Da, postoje određene metode rudarenja podataka koje se koriste u tvrtci u kojoj trenutno radim.

3. Apsolutno, rudarenje podataka nam omogućuje uvid u završene projekte, te je na taj način moguće saznati koje faze pri razvoju softvera nailaze na poteškoće, kako se pristupa pri rješavanju tih poteškoća i koliko uspješno je projekt završen. Također je moguće i smanjenje troškova te povećanje zadovoljstva klijenta.

4. Najčešći problemi s kojima se susrećemo u projektnom menadžmentu pri razvoju softvera su kriva procjena rizika, te kriva procjena vremena potrebnog za razvoj softvera.

5. Na rudarenju podataka rade "rudari podataka" (eng.data mineri), određeni podaci iz završenih projekata se dobiju rudarenjem, a dostupni su projektnim menadžerima, odnosno voditeljima projekta.

6. Da, svakako bih predložila da se upotrebljava rudarenje podataka, pogotovo što se u praksi pokazalo da je ta metoda korisna.

Projektni menadžer u tvrtci Infinera, Stockholm

1. Trenutno radim u tvrtci Infinera u Stockholmu.

2. U tvrtci u kojoj radim trenutno se ne koriste metode rudarenja podataka, ali sam radio u tvrtci u kojoj se koristilo rudarenje podataka.

3. Da, smatram da bi rudarenje podataka moglo biti korisno za projekte u budućnosti jer je na taj način moguće imati uvid u detalje projekta koji je završen.

4. Pa, postoje razni problemi s kojima se moguće susresti pri razvoju softvera. Najčešće su: pogrešna procjena vremena potrebnog za razvoj softvera, pogrešna procjena budžeta ili pogrešna raspodjela ljudskih resursa.

5. Budući da se u tvrtci za koju trenutno radim ne koristi rudarenje podataka ne mogu dati odgovor na to pitanje. Ono što mogu reći jest da mi projektni menadžeri po završetku projeketa imamo uvid

u projekt koji je završen, te na temelju toga pokušavamo stečena znanja primjeniti na iduće projekte.

6. Naravno, smatram da je rudarenje podataka iznimno korisna metoda koja daje detaljnije informacije o projektu i razvojnim fazama projekta, te ju svakako pozdravljam.

SAŽETAK

U ovom radu je provedeno istraživanje o utjecaju rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera, na uspješnost projekata u budućnosti. Istraživanje je provedeno u gradu Stockholmu u Švedskoj, te obuhvaća nasumično odabrane najuspješnije tvrtke koje se bave razvojem softvera. Istraživanje je provedeno putem anketnog upitnika, te su provedeni intervjui sa projektnim menadžerima koji se bave razvojem softvera. Provedeno istraživanje obuhvaća i otkrivanje najpopularnijih metoda rudarenja podataka u projektnom menadžmentu u okviru razvoja softvera; definiranje uloge i značaja rudarenja podataka u današnjem poslovanju; utvrđivanje utjecaja rudarenja podatka u projektnom menadžmentu na zadovoljstvo i uspješnost projektnih menadžera, te utvrđivanje razloga za rast popularnosti rudarenja podataka u današnjem poslovanju. Dobiveni razultati pokazuju zastupljenost rudarenja podataka u projektnom managementu, te u kolikoj mjeri projektni menadžeri u okviru razvoja softvera, svoje odluke temelje na rudarenju podataka.

Ključne riječi: Rudarenje podataka, projektni menadžment, Stockholm, projekt, razvoj softvera.

SUMMARY

This study explores the impact of Data Mining in Project Management within the Software Development, on the success of projects in the future. The research was taken in Stockholm, Sweden, and includes randomly selected most successful Software Development companies. The research was conducted through a survey questionnaire and interviews, which were taken with Project Managers who are working within the Software Development. This research also covers the discovery of the most popular Data Mining techniques in Project Management within Software Development; defining the role and significance of Data Mining in today's business; determining the impact of Data Mining on the satisfaction and success of Project Managers and finding reasons for increasing the popularity of Data Mining in today's business.The results obtained by this research show the presence of Data Mining in Project Management and to what extent Project Managers in Software Development rely on Data Mining while taking their decisions.

Key words: Data Mining, Project Management, Stockholm, Project, Software Development.