Primjena metoda rudarenja procesa u poslovnim sustavima

Dasko, Nino

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:137:419141

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Image not found or type unknown

Repository / Repozitorij:

Digital Repository Juraj Dobrila University of Pula

zir.nsk.hr

Image not found or type unknown

Sveučilište Jurja Dobrile u Puli
Fakultet informatike u Puli

NINO DASKO

PRIMJENA METODE RUDARENJA PROCESA U POSLOVNIM SUSTAVIMA

Diplomski rad

Pula, 2019.

Sveučilište Jurja Dobrile u Puli
Fakultet informatike u Puli

NINO DASKO

PRIMJENA METODE RUDARENJA PROCESA U POSLOVNIM SUSTAVIMA

Diplomski rad

JMBAG: 0303028589, redoviti student
Studijski smjer: Informatika, diplomski studij

Predmet: Umjetna inteligencija
Znanstveno područje: Društvene znanosti
Znanstveno polje: Informacijske i komunikacijske znanosti
Znanstvena grana: Informacijski sustavi i informatologija

Mentor: doc. dr. sc. Darko Etinger

Pula, rujan 2019.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani Nino Dasko, kandidat za magistra informatike izjavljujem da je ovaj Diplomski rad rezultat isključivo mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Diplomskog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

_____

U Puli, _____, 2019. godine

IZJAVA

o korištenju autorskog djela

Ja, dolje potpisani Nino Dasko, dajem odobrenje Sveučilištu Jurja Dobrile u Puli, kao nositelju prava iskorištavanja, da moj diplomski rad pod nazivom Primjena metode rudarenja procesa u poslovnim sustavima koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama. Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

Student

_____

U Puli, _____ , 2019. godine

Sadržaj:

1. Uvod 1
2. Uvod u poslovne procese 2
2.1 Određivanje poslovnog procesa 2
3. Uvod u procesno rudarenje 7
3.1 Znanost o podacima 9
3.2 Znanost o procesima 11
4. Rudarenje procesima 13
4.2 BPMN dijagram 15
4.2.1 Osnovni elementi i simboli BPMN dijagrama 15
4.3 Definicija procesnog rudarenja 21
4.3.1 Rudarenje podataka i rudarenje procesa – usporedba 22
4.4 Aktivnosti i faze prilikom rudarenja procesa 23
4.5 Prednosti i nedostaci procesnog rudarenja 24
4.6 Zapisnik događaja 25
5. Softverski alati za procesno rudarenje 31
6. Primjer rudarenja u poslovnom sustavu 36
Zaključak 49
Popis Literature 50
Popis slika 53
Popis tablica 54
Sažetak 55
Abstract 56

1. Uvod

Tema ovog diplomskog rada je primjena metode rudarenja procesa u poslovnim sustavima. Cilj rada je čitatelju definirati pojam poslovnih procesa, objasniti što obuhvaća pojam „procesno rudarenje“ te je elaborirano samo značenje rudarenje procesa. Nadalje, u radu je pojašnjen softverski alat ProM kojim je i prikazan primjer rudarenja u jednom poslovnom procesu.

Prvi dio ovog diplomskog rada odnosi se poslovne procese. Opisano je što su to poslovni procesi, kako se poslovni proces određuje te je prikazana hijerarhijska razina poslovnog procesa.

Drugi dio rada fokusira se na uvod u procesno rudarenje. U tom dijelu iznesen je pojam internet događaja i od čega se sastoji. Zatim, opisane su znanosti o podacima i procesima te što ih povezuje.

Četvrto poglavlje definira teorijski dio ovog diplomskog rada. U ovom dijelu definirano je rudarenje procesima te je uspoređeno s rudarenjem podataka, navedene su faze i aktivnosti prilikom procesnog rudarenja te je razrađeno što je to zapisnik događaja i čemu služi.

U petom poglavlju dokumentirani su komercijalni i nekomercijalni alati za procesno rudarenje. Posebna pažnja posvećena na ProM softverski alat i njegovo mjesto u današnjoj upotrebi.

U zadnjem, šestom poglavlju, prikazana je i opisana primjena procesnog rudarenja na jednom poslovnom procesu. Spomenuti su algoritmi koji su se koristili prilikom rudarenja te su rezultati grafički prikazani.

2. Uvod u poslovne procese

Procesi su univerzalni pojam za obavljanje različitih aktivnosti. Riječ *proces* dolazi od latinske riječi *processus* i u prijevodu znači „ići naprijed“.[1] Svaka organizacija, bila ona vladina, ne-vladina, profitabilna ili ne-profitabilna organizacija, svakodnevno prolazi kroz mnogobrojne procese.[2]

Svaka se ljudska aktivnost može nazvati procesom, a među procesima prisutnim u poslovnim okruženju potrebno je razlikovati tri kategorije organizacijskih procesa od kojih svaka kategorija obuhvaća određenu vrstu procesa sa specifičnim karakteristikama i izazovima.

- Radni ili poslovni procesi – predstavljaju slijed aktivnosti koji pretvara inpute u outpute
- Bihevioralni procesi – široko prisutni obrasci ponašanja i načini ponašanja odnosno interakcija
- Procesi promjena – prikazuju slijed događaja tijekom vremena

Razumijevanje gore navedenih procesa od iznimne je važnosti za upravljanje poslovnim procesima jer se na taj način utvrđuju njihove granice.[3]

2.1 Određivanje poslovnog procesa

Popularnost samog izraza rezultirala je brojnim definicijama poslovnih procesa te se većina definicija temelji na literaturi o reinženjeringu poslovnih procesa nastaloj 90-ih godina prošlog stoljeća. Sažimanjem svih bitnijih definicija (Hammer i Champy, 1993.; Davenport, 1993.; Harrington, 1991.; Rentzhog, 1998.; Rummler i Brache, 1995.) Bosilj Vukšić, Hernaus i Kovačić (2008) poslovni proces definiraju kao strukturiran, analitičan međufunkcijski skup aktivnosti koji zahtijeva neprestano unaprjeđivanje.

[1] Bosilj Vukšić, V., Hernaus, T. i A. Kovačić, Upravljanje poslovnim procesima – organizacijski i informacijski pristup, Školska knjiga, Zagreb, 2008., str. 17
[2] Dumas, M., La Rosa, M., Mendling, J., Reijers, H. J., Fundamentals of Business Process Management, str. 1
[3] P. Sikavica, T. Hernanus, Dizajniranje organizacije, Zagreb, 2011., str. 317.

Prilikom definiranja poslovnog procesa, poželjno je istaknuti da poslovni proces nije, kao što se često zna poistovjetiti, isto što i projekt. Između procesa i projekta postoje jasno definirane razlike i to u:

- Vremenskoj dimenziji – Projekt je kratkotrajan, ima točno definiran početak i kraj dok je poslovni proces kontinuiran što znači da se isti proces neprekidno ponavlja ispočetka.
- Prirodi outputa – Projekt uvijek proizvodi jedinstven output dok poslovni proces proizvodi isti output svaki put kad se pokrene proces.
- Načinu podjele zadataka – Kod projekta radni se zadatci ponovno ne utvrđuju u skladu s funkcijskom filozofijom dok se kod poslovnih procesa ponovno utvrđuju u skladu s funkcijskom filozofijom.

Da bi određeno poduzeće bilo uspješno, odnosno kako bi ostvarivalo što više postavljenih poslovnih ciljeva, mora odlično poznavati svoj unutrašnji ustroj i način poslovanja. „Poslovanje organizacije ostvaruje se kroz niz povezanih i cilju usmjerenih poslovnih procesa.“[4]

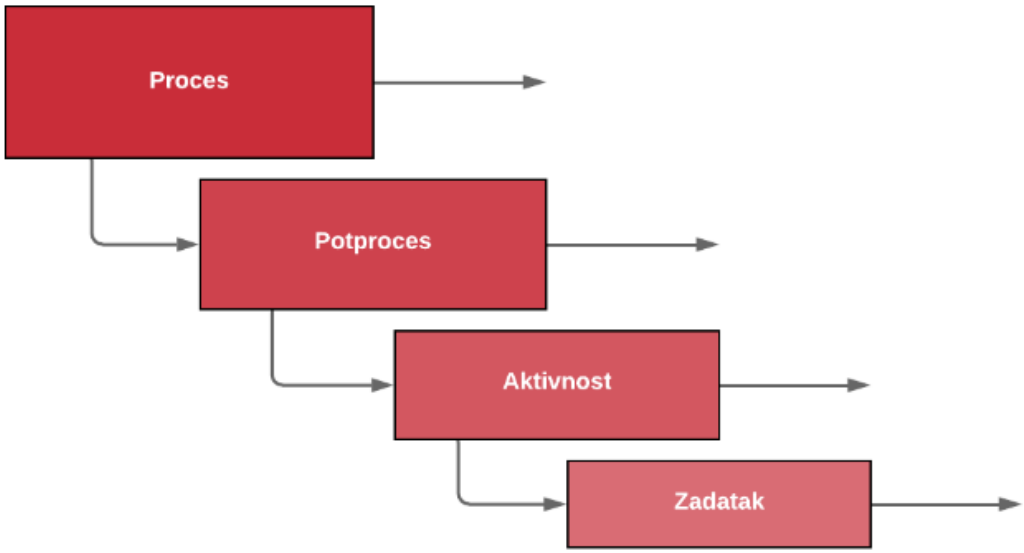
Efikasnost poslovanja određenog poduzeća može se povećati unapređenjem i preustrojem poslovnih procesa. Kako bi se to moglo i dogoditi potrebno je da svi sudionici u potpunosti razumiju poslovne procese, a to će biti moguće jedino ako ih se opiše na nedvosmislen i jasan način. Poslovni procesi i njihova povezanost prilikom izvođenja može se opisati na nekoliko načina. Prvi način na koji se poslovni procesi mogu opisati je – govorno. Ova tehnika je svakako najbrža i najjednostavnija ali nije najpouzdanija iz razloga što ljudi često različito interpretiraju istu stvar koju čuju. Iz tog se razloga, poslovni procesi precizno opisuju pomoću skupa grafičkih simbola s točno definiranom semantikom i čvrstim pravilima njihovog povezivanja.

Poslovni procesi pridaju značenje poslovnim sustavima i organizacijskim strukturama te bi trebali oblikovati njihove operacije i izgled. Također, poslovni procesi oblikuju izgled posla, odgovornosti i potrebne vještine, sve usko vezano za organizacijsku kulturu i kompetencije zaposlenika (Gardner, 2004., str. 27). Poslovne procese treba definirati na način da budu što jasnije razumljivi zaposlenicima na način da svaki zaposlenik jasno razumije svoju ulogu, odgovornost, ovisnost i način na koji

[4] Brumeca, J., Modeliranje poslovnih procesa, KORIS – Konzalting, organizacija, razvoj IS, Varaždin/Zagreb, 2011., str. 2

posao treba biti obavljen. Ibrahim i Hirmanpour (1995., str. 71) navode kako je definicija procesa „omotana“ oko procesnog modela i kako je njezina svrha voditi zaposlenike u obavljanje njihovih zadataka.

Svaka aktivnost koju obavlja pojedini zaposlenik zapravo predstavlja dio jednog šireg procesa. Širi proces se dijeli na brojne manje dijelove koji se međusobno isprepliću prilikom obavljanja određene poslovne aktivnosti te se ne smiju zanemariti. Kako razlikovati te brojne manje dijelove poslovnog procesa objasnio je E. H. Melan (1993.) tako što predlaže hijerarhijsku klasifikaciju procesa s obzirom na razinu detaljnosti do četvrte razine. Njegov model procesne hijerarhije može se nadopuniti zadnjom, petom razinom, tj. koracima. Kako hijerarhijske razine poslovnog procesa u konačnici izgledaju može se vidjeti na sljedećoj slici:



Slika 1. Prikaz hijerarhijskih razina poslovnog procesa.

Izvor: Izrada autora prema Bosilj Vukšić, V., Hernaus, T. i A. *Kovačić, Upravljanje poslovnim procesima – organizacijski i informacijski pristup*, Školska knjiga, Zagreb, 2008., str. 19

U ključnim poslovnim procesima do izražaja dolazi, gore opisana, procesna hijerarhija. Veliki poslovni proces sastavljen je od više potprocesa. Svaki od tih potprocesa djeluje u svom zasebnom području. Potprocesi se dalje mogu dijeliti na aktivnosti koje su, u konačnici, odgovor na pitanje što organizacija radi. Aktivnosti se

dijele na zadatke, a za zadatke su najčešće zaduženi pojedinci. Na posljetku, aktivnosti se dijele na najmanje i najdetaljnije gravidne elemente poslovnog procesa – korake.

Značenje organizacijskim sustavima daju poslovni procesi. Uz značenje, poslovni procesi oblikuju njihov izgled i operacije organizacijskih sustava, odgovornosti i vještine koje utječu na organizacijsku kulturu i kompetencije zaposlenika. Svaka aktivnost koju obavlja zaposlenik je dio nekog šireg procesa. Svaki proces ima nekoliko osnovnih obilježja i to:

- Svaki proces ima svrhu
- Svaki proces ima vlasnika
- Svaki proces ima početak i kraj
- U proces ulaze inputi, a izlaze outputi
- Proces je sastavljen od sekvencijski izvedivih aktivnosti
- Kako bi proces opstao, treba imati poznate unutarnje i/ili vanjske potrošače i dobavljače
- Unaprjeđenje procesa je neizbježno

Važno je napomenuti da ako poslovni proces ispunjava sve gore navedene uvjete ne znači da je poslovni proces uspješan proces. Uspješan proces zadovoljava sljedeće uvjete:

- Usmjeren je na potrošače
- Stalno pruža dodatnu vrijednost
- Ima sposobnog vlasnika proces
- Razumljiv je svima i u odlučivanje su uključeni svi koji sudjeluju u procesu
- Ima zadane mjere uspješnosti i učinkovitosti procesa
- Neprekidno se unaprjeđuje

Profesor Brumec J. u svom radu „Modeliranje poslovnih procesa“ uzimajući u obzir sve gore navedene uvjete iznosi generičku definiciju poslovnog procesa te ona glasi:

„*Poslovni proces je povezani skup aktivnosti i odluka, koji se izvodi na vanjski poticaj radi ostvarenja nekog mjerljivog cilja organizacije, traje određeno vrijeme i troši neke ulazne resurse pretvarajući ih u specifične proizvode ili usluge od značenja za kupca ili korisnika.“*

Prvi dio definicije koji kaže da je poslovni proces povezani skup aktivnosti i odluka podrazumijeva da je to smišljeni skup radnji i odluka koji vode prema definiranom cilju i zadovoljavanju potreba kupca odnosno korisnika. Dio definicije koji kaže da se poslovni proces izvodi na vanjski poticaj odnosi se na to da organizacija ne radi ništa, niti troše neke resurse, ako za to nema određenih zahtjeva ili poticaja treće strane. U proizvodnim organizacijama takav poticaj je narudžba koja dolazi od strane kupaca. U definiciji se spominje da poslovni proces, trošeći ulazne resurse, stvara specifične proizvode ili usluge što bi značilo da svaki izlazni rezultat izvođenja procesa mora biti pojedinačno prepoznatljiv i mjerljiv. Da bi organizacija sama po sebi imala neki smisao mora pružati korisnicima određene proizvode ili usluge i upravo se na to odnosi posljednji dio definicije koji govori da finalni proizvod ili usluga u konačnici moraju biti od značaja za kupca ili korisnika.

Također, važno je naglasiti da se gore navedena generička definicija poslovnog procesa ne smije shvatiti formalno. U praksi se pokazalo beskorisnim ulagati vrijeme i trud oko modeliranja ako na samom početku nisu prepoznati procesi koji odgovaraju samoj definiciji.

3. Uvod u procesno rudarenje

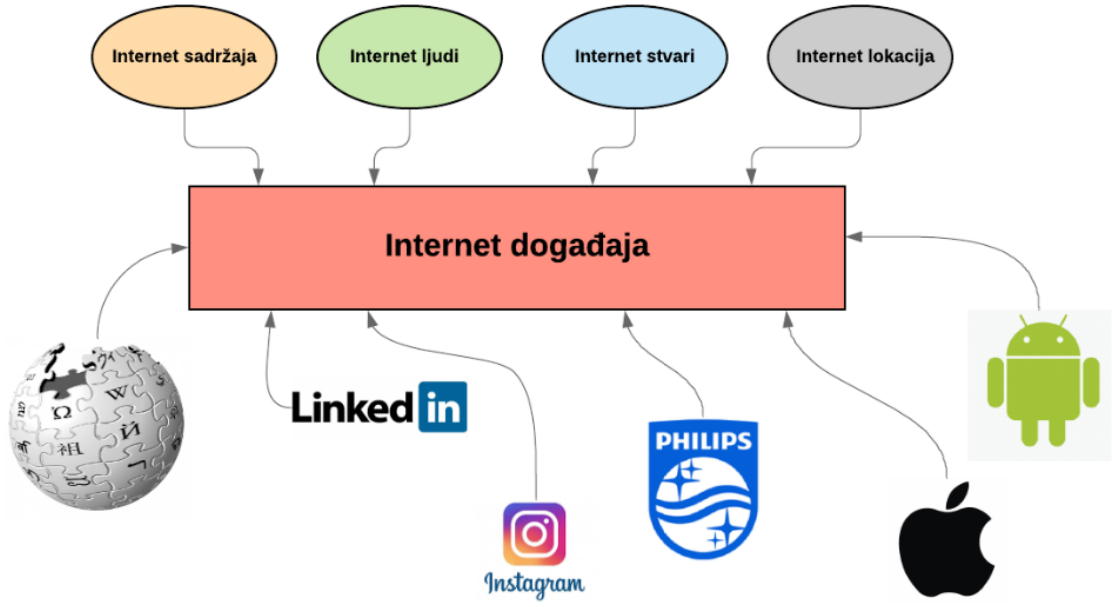
U posljednjih se desetak godina, društvo iz isključivo *analognog* pretvorilo u dominantno *digitalno* društvo. To je dovelo do drastičnih promjena u načinu poslovanja ali i u svakodnevnoj komunikaciji. Zajednica, organizacije i ljudi više „ne spavaju". Organizacije podatke skupljaju o svemu, neovisno o vremenu ili mjestu. Digitalni „svijet" nezaustavljivo raste, a podaci rastu eksponencijalno. Većina prikupljenih podataka, koje jedna poslovna organizacija prikuplja, je nagomilano i nestrukturirano te je kao takvo nepregledno i beskorisno. Da bi ti podaci bili od koristi, organizacija mora pronaći način kako ekstrahirati informaciju i vrijednosti iz podataka koji su spremljeni u njihovim informacijskim sustavima. Iz toga se razloga javila potreba za novom znanstvenom disciplinom – *znanost o podacima*. Novonastala disciplina spoj je klasičnih znanstvenih disciplina kao što su statistika, rudarenje podataka, baze podataka i distribucijski sustavi.

Važnost informacijskih sustava ne odražava se samo u velikom rastu podataka već i ulogom koju ovi sustavi imaju u današnjim poslovnim procesima jer se digitalni i fizički svjetovi sve više usklađuju. Kao primjer jednog takvog usklađivanja možemo uzeti kupnju koncertne ulaznice preko interneta. Korisniku je često u interakciji s više organizacija, a da toga nije ni svjestan. Ako je kupnja uspješna, korisnik dobiva e-kartu koja ustvari predstavlja samo broj.

Rast digitalnog svijeta omogućuje prikupljanje, izvlačenje i analiziranje događaja (engl. *events*). Događaji mogu biti smješteni u strojevima (rendgen, bankomat), u informacijskim sustavima poduzeća (narudžba kupca), unutar bolnica (analiza krvnog uzorka), unutar društvenih mreža (razmijene poruka preko Messenger aplikacije), itd. Događaji mogu biti „životni događaji" (engl. *life events*), „strojni događaji" (engl. *machine events*) ili „organizacijski događaji" (engl. *organization events*). Termin „Internet događaja" (engl. Internet of Events - IoE) se odnosi na sve vrste događaja te se sastoji od:[5]

[5] Van der Aalst, i Wil M.P., Process Mining – Data Science in Action - Second Edition, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., str. 5

- Internet sadržaja (engl. Internet of Content – IoC) – odnosi se na sve podatke koje su stvorili ljudi kako bi povećali znanje o određenoj temi. Tu spadaju internetske stranice, internetske enciklopedije kao što je Wikipedija, YouTube, e-knjige, itd.
- Internet ljudi (engl. Internet of People – IoP) – tu spadaju svi podaci koji se odnose na socijalnu interakciju. Internet ljudi uključuje e-mail, društvene mreže, forume, itd.
- Internet stvari (engl. Internet of Things – IoT) – u ovu vrstu događaja spadaju svi umreženi fizički objekti. Internet stvari uključuje sve objekte koji imaju svoj ID i prisutni su u strukturi poput Interneta.
- Internet lokacija (engl. Internet of Locations – IoL) – u ove događaje spadaju svi podaci koji imaju geografsku ili geoprostornu dimenziju.



Slika 2. Slikovito prikazan „Internet događaja“

Izvor: Izrada autora prema primjeru Van der Aalst, i Wil M.P., Process Mining – Data Science in Action - Second Edition, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., str. 5

3.1 Znanost o podacima

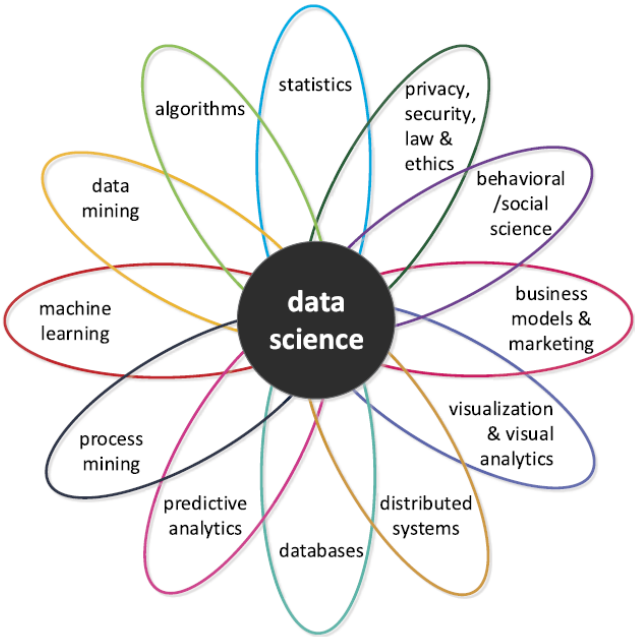
Kao što je već navedeno, znanost o podacima je novija znanstvena disciplina koja se pojavila u zadnjih desetak godina. Autori Van der Aalst, i Wil M.P. u svojoj knjizi *Process Mining – Data Science in Action* iznijeli su sljedeću definiciju znanosti o podacima:

„Znanost o podacima je interdisciplinarno polje koje ima za cilj pretvoriti podatke u stvarnu vrijednost. Podaci mogu biti strukturirani ili nestrukturirani, "big data" ili ne, statički (engl. static) ili prijenosni (engl. streaming). Vrijednost se može pružiti u obliku predviđanja, automatiziranih odluka, modela naučenih iz podataka ili bilo koje vrste vizualizacije podataka koja pruža uvid. Znanost podataka uključuje ekstrakciju podataka, pripremu podataka, istraživanje podataka, transformaciju podataka, pohranu i pronalaženje, računalnu infrastrukturu, razne vrste rudarstva i učenja, prezentaciju objašnjenja i predviđanja i iskorištavanje rezultata uzimajući u obzir etičke, socijalne, pravne aspekte te poslovne aspekte.“

Navedena definicija znanosti o podacima poprilično je široka, a neki znanstvenici smatraju da je znanost o podacima samo drugačije, ljepše ime za statistiku. Nadalje, iz navedene definicije možemo zaključiti da je znanost o podacima širi pojam od statistike i rudarenja podataka. Znanost o podacima pomaže organizacijama u pretvaranju prikupljenih podataka u vrijednosti.

Na slici 3. možemo vidjeti da je znanost o podacima spoj više različitih znanstvenih disciplina i subdisciplina.[6] Znanstvene discipline i subdiscipline razlikuju se po zastupljenosti i preklapanju njihovih granica. Granice nisu jasno vidljive ni definirane, a Van der Aalst i Wil M.P navode kako se one s vremenom i mijenjaju. Kao primjer spajanja na oko nespojivih disciplina možemo uzeti rudarenje podataka i strojno učenje. Korijeni tih dvaju disciplina potpuno su različiti i poprilično odvojeni od statistike ali bez obzira na to možemo vidjeti kako se preklapaju.

[6] Van der Aalst, i Wil M.P., Process Mining – Data Science in Action - Second Edition, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., str. 12



Slika 3. Slikoviti prikaz svih znanstvenih disciplina koje znanost o podacima objedinjuje

Izvor: Van der Aalst, i Wil M.P., Process Mining – Data Science in Action - Second Edition, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., str. 12

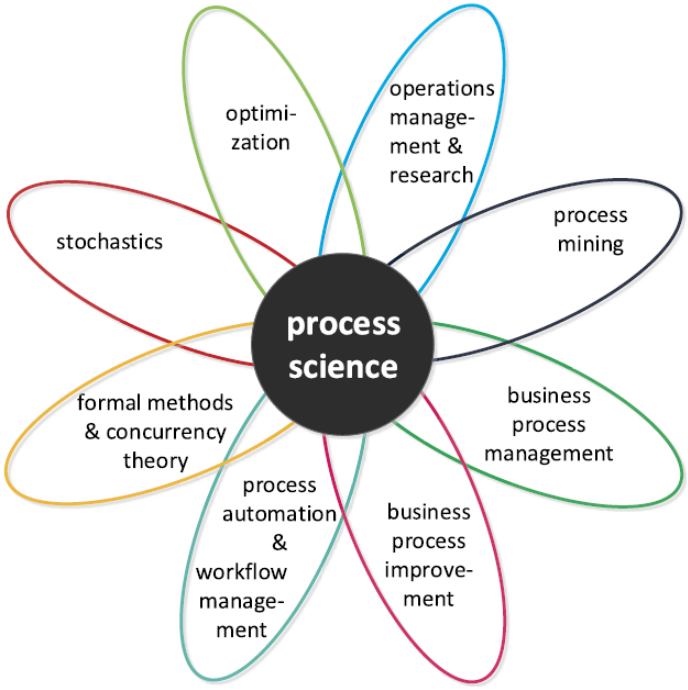
Neke od znanstvenih disciplina ujedinjenih u znanosti o podacima su:

- Statistika (engl. *Statistics*)
- Algoritmi (engl. *Algorithms*)
- Rudarenje podataka (engl. *Data mining*)
- Strojno učenje (engl. *Machine learning*)
- Rudarenje procesa (engl. *Process mining*)
- Baze podataka (engl. *Databases*)
- Distributivni sustavi i dr. (engl. *Distributed systems*)

3.2 Znanost o procesima

Nakon što je u prijašnjem tekstu objašnjeno što je to znanost o podacima u ovom dijelu rada pojasniti će se što je to znanost o procesima (engl. *Process science*).

Pojam „znanost o podacima“ koristi se kako bi se opisala šira disciplina koja kombinira znanje informacijskih tehnologija i menadžersko znanje, a sve to s ciljem razvoja operacijskih procesa. Slika 4. predstavlja slikoviti prikaz procesne znanosti i svih disciplina koje ju čine. Isto kao i kod slike 3., znanstvene discipline i subdiscipline se preklapaju te im granice nisu jasno definirane.



Slika 4. Slikoviti prikaz svih znanstvenih disciplina koje znanost o procesima objedinjuje

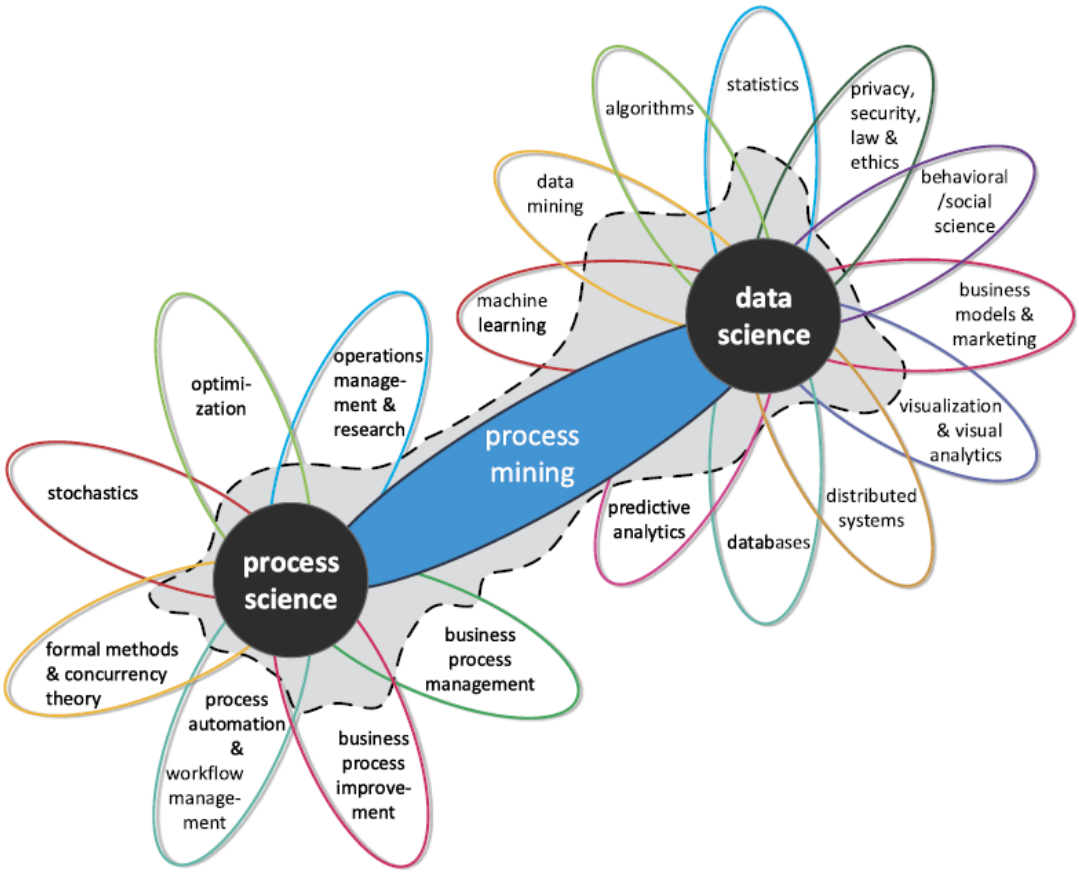
Izvor: Van der Aalst, i Wil M.P., Process Mining – Data Science in Action - Second Edition, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., str. 16

Neke od znanstvenih disciplina ujedinjenih u znanosti o procesima su:

- Optimizacije (engl. *Optimizations*)
- Poslovni procesni menadžment (engl. *Business process management*)

- Operacijski menadžment i istraživanja (engl. *Operations management & research*)
- Rudarenje procesima (engl. *Process mining*)

Ono što možemo primijetiti na slikama 3. i 4. je da obje znanosti objedinjuju veći broj potpuno različitih znanstvenih disciplina koje se međusobno preklapaju u više točaka. Također, možemo primijetiti da obje znanosti imaju jednu zajedničku znanstvenu disciplinu – procesno rudarenje.



Slika 5. Slikoviti prikaz mosta između znanosti o procesima i podacima

Izvor: Van der Aalst, i Wil M.P., Process Mining – Data Science in Action - Second Edition, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., str. 18

Rudarenje procesima povezuje tradicionalne analize procesa i podataka. Kako što je prikazano na slici 5. rudarenje procesima je znanstvena disciplina koja povezuje znanost o podacima i znanost o procesima. Rudarenje procesima predstavlja bitnu vezu između rudarenja podataka i BPM-a (Business Process modeling).

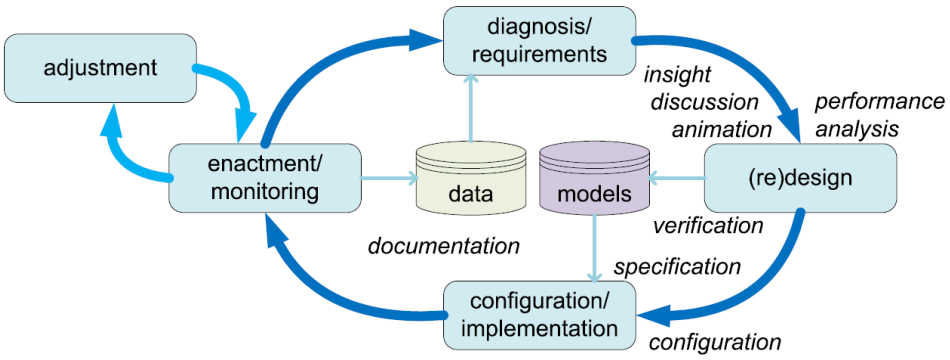
4. Rudarenje procesima

Da bi mogli opisati rudarenje procesima, prvo moramo opisati takozvani BPM (**B**usiness **P**rocess **M**anagement) i njegov životni ciklus (engl. *life-cycle*) te BPMN (**B**usiness **P**rocess **M**odel and **N**otation) dijagram.

4.1 BPM i BPM životni ciklus

„BPM je sistematizirani pristup za zapisivanje, projektiranje, izvođenje, dokumentiranje, mjerenje, praćenje te kontrolu automatiziranih i neautomatiziranih procesa u svrhu postizanja ciljeva i poslovne strategije tvrtke. Kroz sustavno i svjesno upravljanje procesima tvrtke postižu bolje rezultate brže i fleksibilnije. Kroz BPM, procesi se mogu uskladiti s poslovnom strategijom te tako poboljšati performanse zahvaljujući optimizaciji procesa unutar poslovnih odjela ili čak izvan granica tvrtke. Cilj je razumjeti, a time i poboljšati, cijeli proces a ne samo njegove komponente.“[7]

Sljedeća slika opisuje životni krug BPM-a i različite faze upravljanja poslovnim procesom.



Slika 6. Životni ciklus BPM-a i prikaz različitih faza upravljanja poslovnog procesa

Izvor: Van der Aalst, i Wil M.P., Process Mining – Data Science in Action - Second Edition, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., str

[7] Martinek, E. Modeliranje poslovnih procesa pomoću grafičkog jezika BPMN, Diplomski rad, str. 5.

Prilikom opisa modela možemo krenuti s fazom dizajna (engl. *design*). U fazi dizajna nastaje sam dizajn procesa. Transformacija modela u aktivni sistem događa se u fazi konfiguracije/implementacije (engl. *configuration/implementation*). U slučaju da je model već u izvršnom obliku i ako je BPM sistem već aktivan, ova faza može trajati jako kratko. Nakon ove faze slijedi faza odluke/praćenja (engl. *enactment/monitoring*). U ovoj fazi, menadžment promatra procese i prati se ako procesu nešto nedostaje. Ako menadžment ustanovi da procesu treba određena promjena, ona se implementira u fazi podešavanja (*engl*. *adjustment*). Dalje slijedi faza dijagnoze/zahtjeva (engl. *diagnosis/requirements*) u kojoj se evaluira proces i testiraju performanse u stvarnom okruženju. Ako performanse nisu zadovoljavajuće ili u slučaju novih zahtjeva okoline, slijedi faza redizajna (engl. *redesign*).[8]

Procesni modeli imaju ključnu ulogu u fazi redizajna i konfiguracije/implementacije, a podaci (engl. *data*) imaju ključnu ulogu u fazama odluke/praćenja i dijagnoze/zahtjeva. Donedavno, nije postojalo previše veza između podataka stvorenih prilikom izvršavanja procesa i stvarnog dizajna procesa. Zapravo, u većini organizacija, faza dijagnoze/zahtjeva nije podržana na sustavan i kontinuiran način. Rudarenje procesima nudi mogućnost stvarnog „zatvaranja“ životnog ciklusa BPM-a. Podaci prikupljeni u informacijskim sustavima mogu se iskoristiti kako bi pružili bolji pregled stvarnih procesa. Razna odstupanja se može lakše uočiti te poboljšati kvalitetu modela.[9]

Radi bolje automatizacije procesa razvio se BPMN koji je trenutno najrašireniji grafički jezik koji služi za modeliranje poslovnih procesa.[10]

[8] Van der Aalst, W., i Van Hee, K., Workflow Management: Models, methods and systems, Eindhoven University of Technology, Faculty of Mathematics and Computing Science, Eindhoven, 2000, .str 7
[9] Ibidem, str 7
[10] Van der Aalst, Wil M.P., Process Mining – Data Science in Action - Second Edition, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., str. 68.

4.2 BPMN dijagram

Predstavlja skup konvencija za modeliranje poslovnog procesa, sastavljen od grafičkih elemenata i formaliziranih zapisa, koji ima status profesionalne norme.[11] BPMN olakšava komunikaciju i bolje razumijevanje poslovnih procesa. Treba naglasiti da svaki poslovni proces možemo opisati na nekoliko načina, a stil modeliranja ovisi o dizajneru i o cilju modela. Osoba koja dizajnira ima odgovornost da njegov model prati željeni cilj koji treba biti u skladu s BPMN standardima.

BPMN dijagrami najviše se koriste radi grafičkog prikaza. Postoje tri različite vrste dijagrama i to:[12]

- Koreografski dijagram (engl. *choreography diagram*) – Predstavlja tip dijagrama koji prikazuje interakciju između dva ili više sudionika. Također, može se proširit sub-koreografskim dijagramima
- Dijagram suradnje (engl. *collaboration diagram*) – U ovom tipu dijagrama može se modelirati procesni tok koji uključuje aktivnosti, razdvajanja i paralelne tokove. Također, moguće je prikazati suradnju dva ili više procesa s njihovim međusobnim porukama
- Razgovorni dijagram (engl. *conversation diagram*) – Predstavlja tip dijagrama koji omogućava pregled nekoliko partnera i njihove međusobne odnose

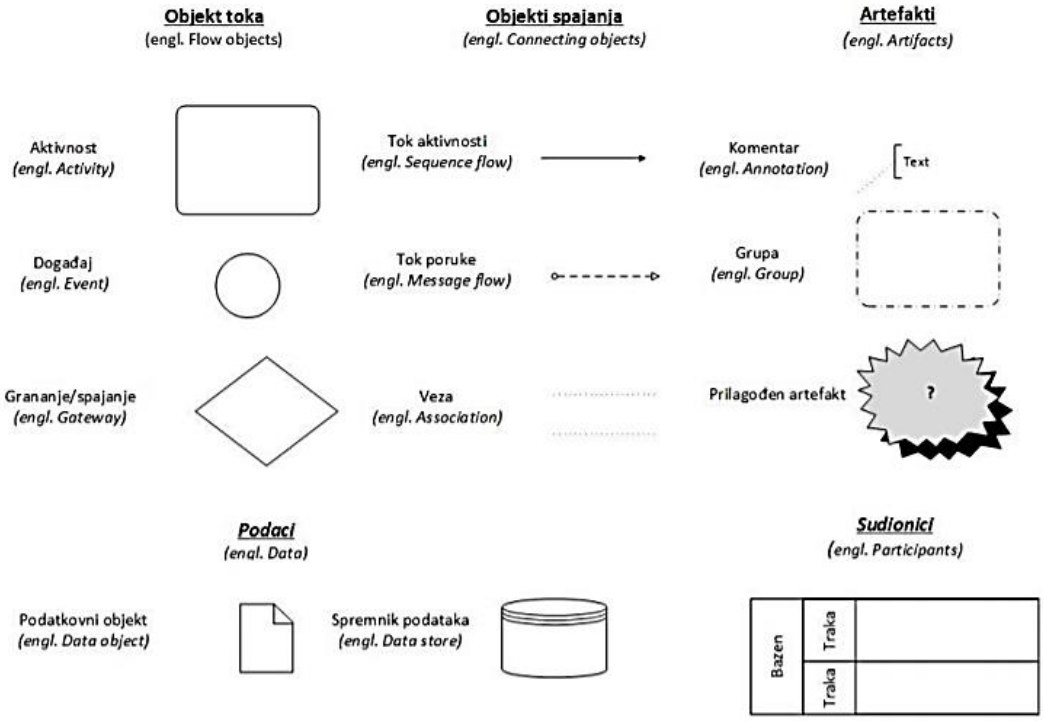
4.2.1 Osnovni elementi i simboli BPMN dijagrama

Prilikom crtanja dijagrama u BPMN-u, koriste se simboli raspoređeni po kategorijama. Te kategorije su temeljni skup BPMN-a i ima pet kategorija:[13]

1) Objekti toka (engl. *flow objects*) – Grafički elementi koji određuju ponašanje procesa
2) Podatkovni objekti (engl. *Data Objects*) – Predstavljaju sadržaje koji se odrađuju tijekom izvršavanja procesa

[11] Brumeca, J., Modeliranje poslovnih procesa, https://www.slideshare.net/Brumiko/modeliranje-poslovnih-procesa-uvod-u-bpmn [Prestupljeno: 24.05.2019.]
[12] What is Business Process Modeling Notation https://www.lucidchart.com/pages/bpmn [Prestupljeno: 24.05.2019.]
[13] Brumeca, J., Modeliranje poslovnih procesa, https://www.slideshare.net/Brumiko/modeliranje-poslovnih-procesa-uvod-u-bpmn [Prestupljeno: 24.05.2019.]

3) Objekti spajanja (engl. *connecting objects*) – Povezuju glavne objekte ili im pridružuju dopunske informacije
4) Polja i staze (engl. *swimlanes*) – definiraju sudionike u procesu ili grupiraju aktivne objekte po nekim zajedničkim karakteristikama
5) Dopunski objekti (engl. *artifacts*) – dopunjuju proces kontekstualnim informacijama



Slika 7. Osnovni elementi BPMN-a

Izvor: Lucid Chart, dostupno na: https://www.lucidchart.com/pages/bpmn#discovery__top

Objekti toka sastoje se od tri elementa:

- Događaj (*engl*. *event*) – predočen je kružnicom, a opisuje nešto što se dogodilo u procesu. On utječe na odvijanje procesa te ima uzrok (engl. *trigger*) i rezultat (*engl*. *result*)



Slika 8. Početni događaj (engl. *Start*), međudogađaj (engl. *Intermediate*) i završni događaj (engl. *End*)

Izvor: Izrada autora koristeći Lucid Chart alat

- Aktivnost (engl. *activity*) – predstavlja generički pojam, a označava rad unutar samog sustava. Tipovi aktivnosti su proces (engl. *process*), podproces (engl. *sub-process*) i radnja (engl. *task*)



Slika 9. Zadatak (*engl. Task*), transakcija (engl. *Transaction*), sub-proces (engl. *Event Sub-Process*), poziv na aktivnost (engl. *Call Activity*)

Izvor: Izrada autora u Lucid Chard alatu

- Skretnica (engl. *gateway*) – koristi se za prikaz grananja (engl. *branching*), razdvajanja (engl. *forking*), spajanja (engl. *merging*) i združivanja (engl. *joining*) tokova. Označava se rombom



Slika 10. Ekskluzivna (engl. *Exclusive*), ekskluzivna vezana na međudogađaj (engl. *Event based*), paralelna (engl. *Parallel*), inkluzivna (engl. *Inclusive*), ekskluzivna vezana na početni događaj (engl. *Exclusive event based*), složena (engl. *Complex*) i paralelna vezana na događaj (engl. *Parallel event based*)

Izvor: Izrada autora u Lucid Chart alatu

Podatkovni objekti sastoje se od četiri elemenata, a to su:

- Podaci (engl. *data objects*)
- Ulazni podaci (engl. *data inputs*)
- Izlazni dodataka (engl. *data outputs*)
- Spremište (engl. *data store*)

U objekte spajanja spadaju:

- Slijedni tok (engl. *sequence flow*) te se on prikazuje punom crtom sa strelicom, a označava slijed u kojem će se izvršiti aktivnost



- Tok obavijesti (engl. *message flow*) koji se prikazuje crtkanom strelicom, a opisuje kretanje obavijesti između dva sudionika.

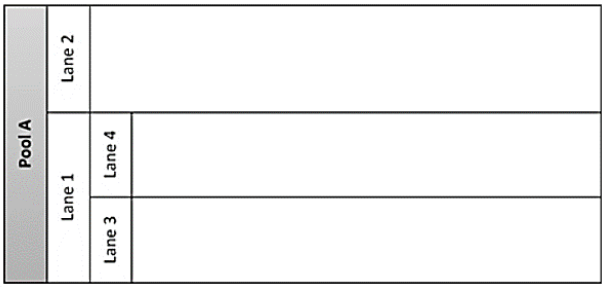


- Pridruženi podaci (engl. *data association*) koji se koriste kako bi se objektima toka produžili podaci, a pridruživanje se koristi općenito za povezivanje objekata toka s komentarima i objašnjenjima.

. . . . . .

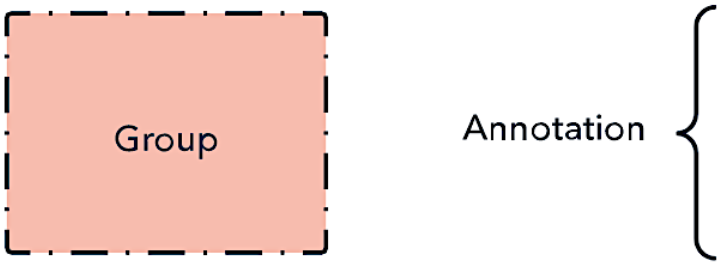
Kategorija pod nazivom polja i staze koristi se za grupiranje aktivnosti po nekim zajedničkim karakteristikama:

- Polja (engl. *pools*) se koristi kao „okvir“ unutar kojeg se odvija jedan poslovni proces unutar kojeg su aktivnosti povezane slijednim vezama. Također, može se koristiti za definiranje sudionika u procesu i za razgraničenje aktivnosti koje propadaju različitim poljima
- Staze (engl. *lanes*) predstavljaju dio polja i protežu se po cijeloj njegovoj duljini. Cilj staze je grupiranje i kategoriziranje aktivnosti unutar jednog procesa

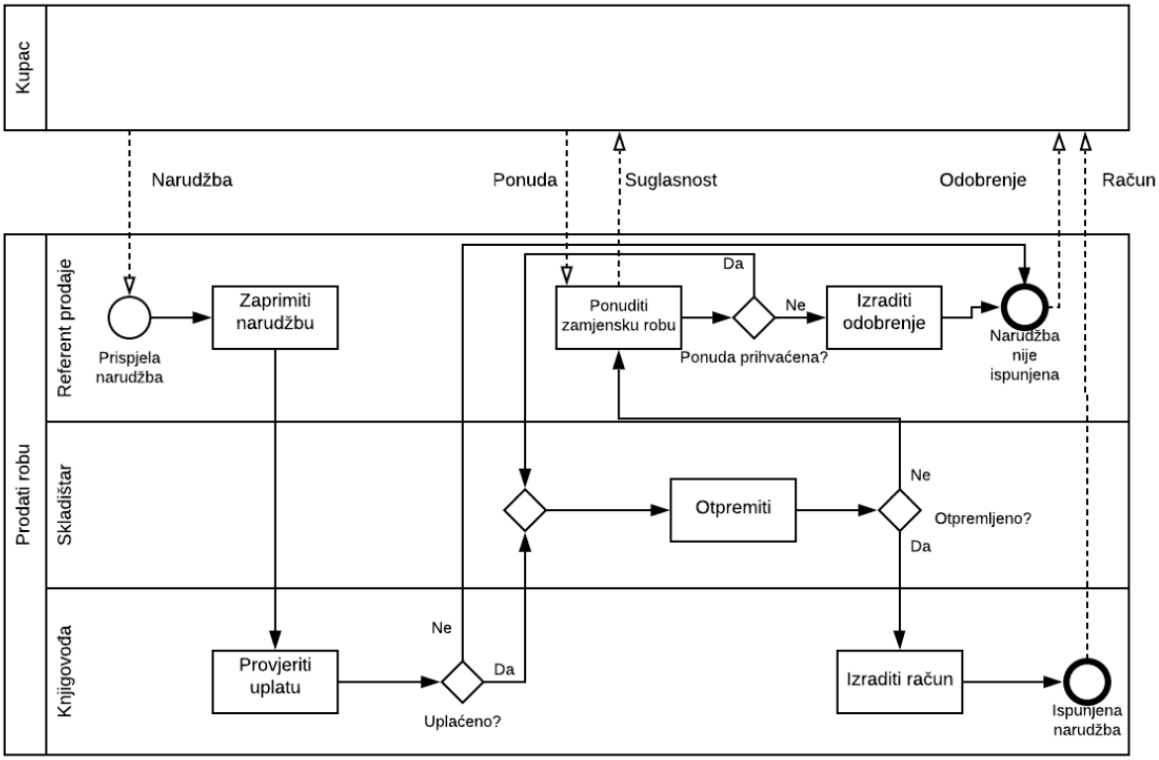


Dopunske objekte može unositi korisnik. Oni služe za objašnjavanje neke specifičnosti u BPM-u. Standardni dopunski objekti jesu:

- Grupe (engl. *groups*) koje se koriste radi analize i dokumentiranja aktivnosti ili za povezivanje aktivnosti koje se odvijaju u različitim spremnicima
- Pribilješke (engl. *annotations*) koje daju dodatne informacije za korisnika modela procesa ili onoga tko čita model



U nastavku rada prikazan je detaljan prikaz procesa PRODATI ROBU koji ima sve navedene elemente BPMN dijagrama te više različitih ishoda.



Slika 11. Kolaboracijski dijagram pokazuje razmjenu poruka između procesa i okoline

Izvor: Izrada autora koristeći Lucid Chart alat. Izrađeno po primjeru Brumeca, J., Modeliranje poslovnih procesa, dostupno na: https://www.slideshare.net/Brumiko/modeliranje-poslovnih-procesa-uvod-u-bpmn

Slika broj 11. prikazuje kolaboracijski dijagram razmjene poruka između procesa – prodati robu i okoline – kupac. Možemo primijetiti da polje „KUPAC“ nije podijeljeno na staze koje bi se odnosile na radna mjesta kupca. Također, u njemu nije vidljiv niti jedan proces iz razloga što nije poznato kakvom ustroju pripada organizacija kupca. Polje

„PRODAVATI ROBU“ podijeljen je na tri staze: „Knjigovođa“, „Skladištar“ i „Referent prodaje“. Kod procesa prodavati robu bitno je da kupac vrši suradnju tijekom izvođenja procesa prodaje, koji šalje narudžbe i za istu prima račun za naručenu ili za zamjensku robu ukoliko u skladištu nije bilo robe koju je naručio. Za slanje zamjenske robe potrebna je suglasnost kupca. Brumeca, J. u svojoj knjizi navodi kako „Kupac ne može biti povezan slijednim vezama s aktivnostima procesa *Prodati robu*, jer slijedne veze ukazuju na redoslijed izvođenja aktivnosti unutar procesa. Stoga se pretpostavlja da kupac s našim procesom (koji je modeliran u polju *Prodati robu*) surađuje razmjenom poruka (messages). Poruke se prikazuju kao crtkane strelice sa zatvorenim praznim vrhom. One na svom ishodištu imaju kružić, koji je vezan za rub onog simbola iz kojeg poruka dolazi.“

4.3 Definicija procesnog rudarenja

Procesno rudarenje je metoda analize procesa koja za cilj ima otkriti, nadgledat i unaprijediti stvarne procese. Sve potrebne informacije za taj proces analize nalazi u zapisnicima događaja (engl. *event log*) koji su pohranjeni u informacijskim sustavima organizacije. Osim što možemo izvući i prezentirati ključne procese, procesnim rudarenjem možemo spoznati odnose između procesa, analizirati procese te ih grafički prikazati. Na taj način dobivamo širu sliku poslovnog procesa te možemo jasnije vidjeti gdje koji proces trebamo popraviti ili kod kojeg dijela procesa nastaju određeni problemi. Metodom procesnog rudarenja problemi se dijagnosticiraju na temelju činjenica i stvarnih podatak, a ne temelju pretpostavki.[14]

Prema Van der Aalst i Wil M.P. rudarenje procesima je relativno nova znanstvena disciplina koja je pozicionirana između rudarenja podataka (engl. *data mining*) i strojnog učenja (engl. *machine learning*) s jedne strane i procesnog modeliranje i analize (engl. *process modeling and analysis*) s druge strene. Kao što je već navedeno, tako i Van der Aalst i Wil M.P. zaključuju da je sama ideja procesnog rudarenja

[14] Process Mining plays an essential role in Digital Transformation, https://medium.com/@pedrorobledobpm/process-mining-plays-an-essential-role-in-digital-transformation-384839236bbe, [8.8.2019.]

otkrivanje, nadgledanje i unapređenje stvarnih poslovnih procesa na način da se svoj znanje o određenom procesu izvlači iz zapisnika događaja.[15]

4.3.1 Rudarenje podataka i rudarenje procesa – usporedba

Rudarenje podataka je metoda kojom se, u velikim bazama podataka, otkrivaju vrijedni podaci. Metoda se naziva rudarenje podataka, jer se u velikim količinama podataka traže vrijedne informacije.[16]

Rudarenje podataka (engl. *data mining*) i rudarenje procesa (engl. *process mining*) su znanstvene metode koje procesuiraju velike količine podataka i procesa koji se skupljaju informacijskim sustavima. Obje metode imaju puno toga zajedničkog ali i različitog.

Zajedničko im je to što su obje metode dio poslovne inteligencije (engl. *Business Intelligence*) te analiziraju velike količine informacija s ciljem ostvarivanja veće slike. Obje metode se koriste specifičnim algoritmima za otkrivanje skrivenih veza te kao krajnji cilj imaju stvaranje jasnije slike pomoću koje korisnici mogu donositi bolje odluke.

Što se tiče razlika, njih ima više:

- Rudarenje podataka koristimo za analiziranje podatka i predviđanje ili pronalazak određenog uzorka. Kao primjer možemo uzeti pronalaženje grupe ljudi koji kupuju određeni proizvod. S druge strane, rudarenje procesima se fokusira na pronalaženje, nadgledanje i poboljšanje stvarnih poslovnih procesa.
- Rudarenje podataka analizira statičke informacije, odnosno one podatke koji su dostupni u trenutnu same analize. Rudarenje procesima analizira dinamičke informacije, odnosno fokusira se na to kako su određeni podaci nastali.

---

[15] *Van der Aalst, Wil M.P., Process Mining – Data Science in Action - Second Edition, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., 31-32 str.*

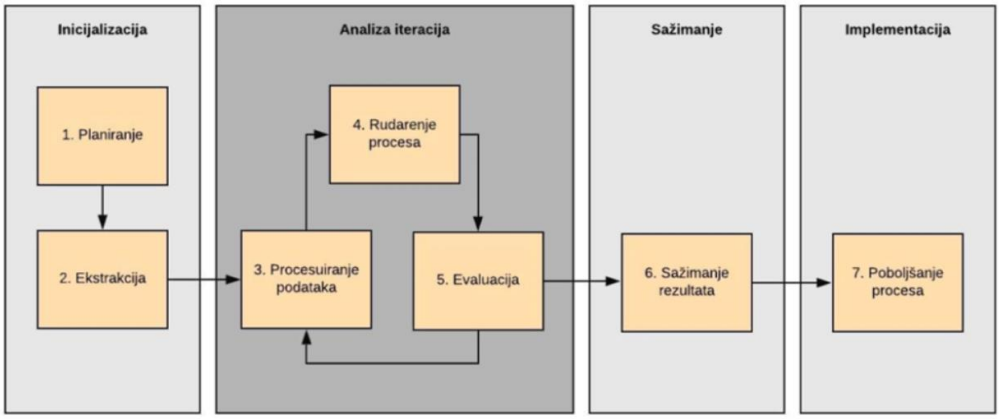
[16] Houthoofd, D.“ Data mining vs. process mining: what’s the difference?“ Dostupno na: *https://www.horsum.be/en/blog/data-process-analytics/data-mining-vs-process-mining-whats-difference [Pristupljeno: 15.08.2019.]*

- Rudarenje podataka služi za pronalazak skrivenih veza i odnosa u prikupljenim podacima, ali ne daje odgovore na specifična pitanja. S druge strane, procesno rudarenje omogućuje dobivanje odgovora na specifična pitanja.
- Rudarenje podataka otkriva određene uzorke ali ne odgovara na pitanje što je dovelo do stvaranja tih uzoraka. Rudarenje procesima ima mogućnost pružanja uvida u to kako se došlo do određenih rezultata.
- Kod rudarenja podataka sav fokus je na glavnom uzorku, a podaci koji iskaču iz uzorka se ne uzimaju u obzir prilikom analiziranja. Kod procesnog rudarenja, ponekad, upravo podaci koji iskaču mogu biti od velikog značenja.

4.4 Aktivnosti i faze prilikom rudarenja procesa

Svaki se proces sastoji od jedne ili više faza i jedne ili više aktivnosti. Proces rudarenja procesima nije izuzetak. Rudarenje procesa sastoji se od ukupno četiri faza i sedam aktivnosti.

- Faze: Inicijalizacija (engl. *initialization*), analiza iteracija (engl. *analysis iterations*), sažimanje (engl. *summarizing*) i implementacija (engl. *implementation*)
- Aktivnosti: Planiranje (engl. *planning*), ekstrakcija (engl. *extraction*), procesiranje podataka (engl. *data processing*), procesno rudarenje (engl. *proces mining*), evaluacija (engl. *evaluation*), sažimanje rezultata (engl. *summarizing result*) i poboljšanje procesa (engl. *process improvement*).



Slika 12. Aktivnosti i faze procesa rudarenja procesima

Izvor: Izrada autora u koristeći Lucid Chart alat

Proces rudarenja procesima obično kreće fazom inicijalizacije (*engl*. *Initialization*), zatim slijedi faza u kojoj se analiziraju iteracije (engl. *Analysis iterations*). Nakon analize iteracije dolaze faze sažimanja (engl. *Summarizing*) i implementacije (engl. *Implementation*). Faza inicijalizacije kreće s planiranjem (engl. *Planning*). To je aktivnost u kojoj određujemo koje procese želimo analizirati odnosno koje odgovore tražimo. Aktivnost planiranja daje nam potrebne informacije za sljedeću aktivnost – ekstrakciju (engl. *Extraction*). Ekstrakcija podataka ovisi o odgovorima na postavljena pitanja prilikom planiranja. Prikupljeni podaci obrađuju se (engl. *Data processing*). Podaci se mogu filtrirati raznim algoritmima, mogu se filtrirati pojedini slučajevi (engl. *cases*) ili događaji (engl. *events*). Tek nakon što se dobiju filtrirani podaci, slijedi rudarenja procesa (engl. *Process mining*). Nakon što završi rudarenje procesa, dolazi jedan bitan korak koji se zove evaluacija (engl. *Evaluation*). Nakon dobivenih rezultata procesnog rudarenja, rezultate se mora moći evaluirati, odnosno procijeniti koliko su dobri ili korisni. Ako rezultati nisu zadovoljavajući, ponovno se vraća korak obrade podataka gdje se ovaj put mijenjaju parametri. Ako nakon procesa rudarenja dobijemo zadovoljavajuće rezultate, slijedi korak sažimanja rezultata (engl. *Summarizing Result*) te završni korak u kojem implementiramo dobivene rezultate i tako poboljšavamo određeni proces (engl. *Process Improvement*).

4.5 Prednosti i nedostaci procesnog rudarenja

Kao i sve metode i procesi, tako i proces rudarenja procesima ima svoje prednosti i nedostatke. Neki od njih navedeni su u nastavku:

- Prednosti procesnog rudarenja – Glavni benefit kod korištenja procesnog rudarenja je objektivnost (korištenje stvarnih podataka osigurava visoki stupanj objektivnosti analize). Drugi benefit je brzina. Jednom prikupljeni podaci brzo se obrađuju, neovisno o kojoj tehnici rudarenja je riječ. Također, rudarenje procesima omogućuje pronalaženje iznimaka i uspoređivanje rezultata. Nadalje, procesno rudarenje ne služi samo za pronalaženje pogrešaka u procesu nego pomaže i u identificiranju čimbenika koji uzrokuju određene

devijacije u procesu. Još jedna od prednosti je ta što procesno rudarenje omogućuje različiti pogled na isti proces ili podatke.[17]

- Nedostaci procesnog rudarenje – Najveći nedostatak kod rudarenja procesa je teško pronalaženje/pristup i priprema podataka. Teško je pronaći odgovarajuće, kvalitetne podatke te prilagoditi ih traženoj strukturi. Također, nedostatak je taj što je većina tehnika procesnog rudarenja kompliciranа. Tehnike su teške za shvatiti ali i za objasniti.[18]

4.6 Zapisnik događaja

U ovom dijelu četvrtog poglavlja biti će riječi o jednom od ključnih elementa procesnog rudarenje – zapisniku događaja (engl. *Event log*).

Rudarenje procesa nije moguće započeti bez zapisnika događaja. Zapisnik događaja sadrži sve potrebne informacije koje određeni događaj sadrži. Slika 16. prikazuje ilustraciju tipičnih informacija koje jedan zapisnik događaja sadrži, a korisne su za procesno rudarenje. Zapisnik događaja mora sadržavati podatke o jednom procesu. Svaka događaj (engl. *event*) u zapisniku mora se odnositi na jednu instancu procesa, odnosno slučaj (engl. *case*). Nadalje, na slici 13. vidimo da se svaki slučaj veže na određenu aktivnost (engl. *activity*).

[17] Claes, J. and Poels, G., Process Mining and the ProM Framework: An Exploratory Survey - Extended report (2012.), str. 5
[18] Ibidem, str. 6

Case id	Event id	Properties				
		Timestamp	Activity	Resource	Cost	...
1	35654423	30-12-2010:11.02	Register request	Pete	50	...
	35654424	31-12-2010:10.06	Examine thoroughly	Sue	400	...
	35654425	05-01-2011:15.12	Check ticket	Mike	100	...
	35654426	06-01-2011:11.18	Decide	Sara	200	...
	35654427	07-01-2011:14.24	Reject request	Pete	200	...
2	35654483	30-12-2010:11.32	Register request	Mike	50	...
	35654485	30-12-2010:12.12	Check ticket	Mike	100	...
	35654487	30-12-2010:14.16	Examine casually	Pete	400	...
	35654488	05-01-2011:11.22	Decide	Sara	200	...
	35654489	08-01-2011:12.05	Pay compensation	Ellen	200	...
3	35654521	30-12-2010:14.32	Register request	Pete	50	...
	35654522	30-12-2010:15.06	Examine casually	Mike	400	...
	35654524	30-12-2010:16.34	Check ticket	Ellen	100	...
	35654525	06-01-2011:09.18	Decide	Sara	200	...
	35654526	06-01-2011:12.18	Reinitiate request	Sara	200	...
	35654527	06-01-2011:13.06	Examine thoroughly	Sean	400	...
	35654530	08-01-2011:11.43	Check ticket	Pete	100	...

Slika 13. Fragment jednog zapisnika događaja

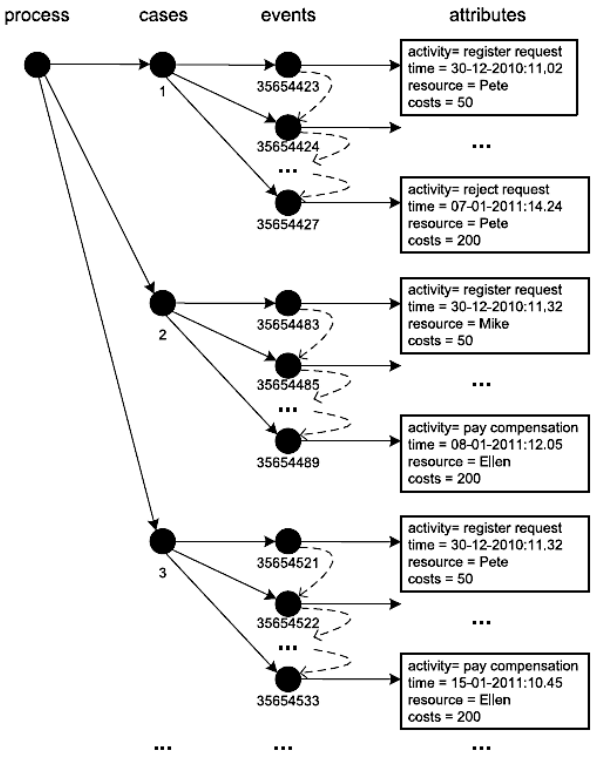
Izvor: Van der Aalst, i Wil M.P., *Process Mining – Data Science in Action - Second Edition,* Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., str. 36

Svaki događaj u zapisniku događaja da bi bio upotrebljiv u procesnom rudarenju mora sadržavati najbitnije informacije, a to su:

- ID događaja
- Vrijeme događaja
- Aktivnost

Ostale informacije koje se mogu nalaziti u zapisniku događaja jesu opis, cijena, korisnik i dr., mogu biti korisne ali nisu ključne.

Sljedeća slika 14. prikazuje stablo strukture zapisnika događaja. Ono što se gore opisalo sada se može vidjeti u obliku stabla. Vidimo da postoji samo jedan proces (engl. *process*) koji ima više nekoliko različitih slučajeva (engl. *cases*). Svaki slučaj ima više poredanih zasebnih događaja (engl. *events*) od kojih svaki može imati više atributa (engl. *attributes*).

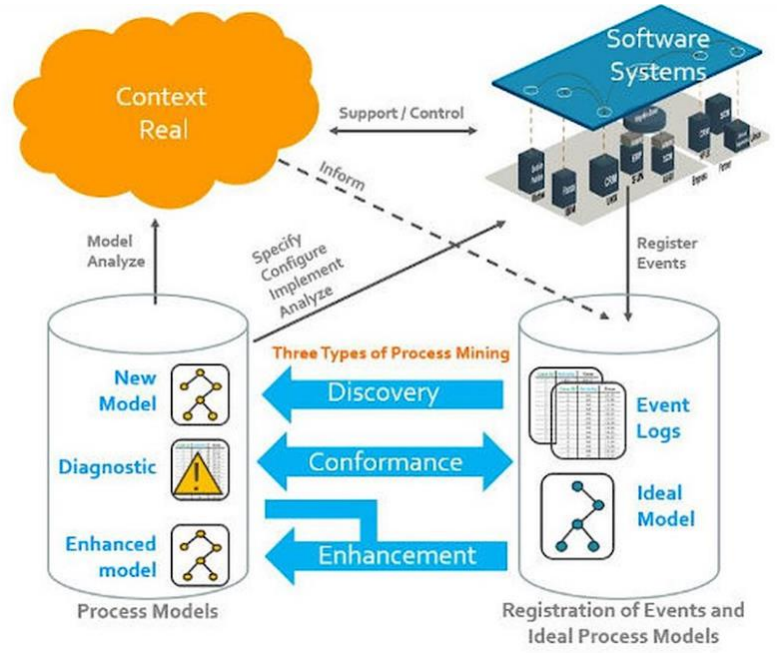


Slika 14. Struktura zapisnika događaja

Izvor: Van der Aalst, i Wil M.P., *Process Mining – Data Science in Action - Second Edition*, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016.. str. 10

Zapisnici događaja mogu služiti u svrhu provedbe tri različite vrste procesnog rudarenja (slika. 15):

- Otkrivanje modela (engl. *Discovery*) – Ovom tehnikom procesnog rudarenja uzima se zapisnik te se kreira model bez korištenja bilo kakvih dodatnih informacija. Primjer za to je α-algoritam koji pomoći zapisnika događaja stvara *Petrijevu mrežu* koja objašnjava ponašanje zabilježe aktivnosti.
- Usporedba modela (engl. *Conformance*) – U ovoj vrsti procesnog rudarenja, postojeći procesni model uspoređuje sa zapisnikom događaja istog procesa.
- Poboljšanja (engl. *Enhancement*) – Ideja treće tehnike procesnog rudarenja je proširiti ili unaprijediti postojeći procesni model tako da se informacije o stvarnom procesnom modelu uzmu iz stvarnog procesa koji je spremljen u zapisniku događaja.



Slika 15. Prikaz tri glavna tipa procesnog rudarenja: otkrivanje modela (*engl*. *Discovery*), usporedba modela (engl. *Conformance*), poboljšanja (engl. *Enhancement*)

Izvor: Medium, dostupno na https://medium.com/@pedrorobledobpm/process-mining-plays-an-essential-role-in-digital-transformation-384839236bbe

4.7 XES – eXtensible Event Stream

Moglo bi se reći da je u procesnom rudarenju jedna od najvažnijih stvari koje treba standardizirati format podataka za zapisnike događaja. Sve do 2010. godine standardni jezik pomoću kojeg su se spremali i izmjenjivali zapisnici događaja bio je MXML (**M**ining e**X**tensible **M**arkup **L**anguage). MXML nastao je 2003. godine te je vrlo brzo nakon toga postao sastavni dio softverskog alata za procesno rudarenje – ProM. Alat pod nazivom ProMimport omogućuje konverziju podataka iz različitih izvora u MXML.

XES (eXtensible Event Stream) je poboljšana verzija MXML-a te se temelji na XML jeziku. Prilikom samog dizajniranja XES standarda po sljedeća četiri principa koji su ujedno i prednosti XES-a:[19]

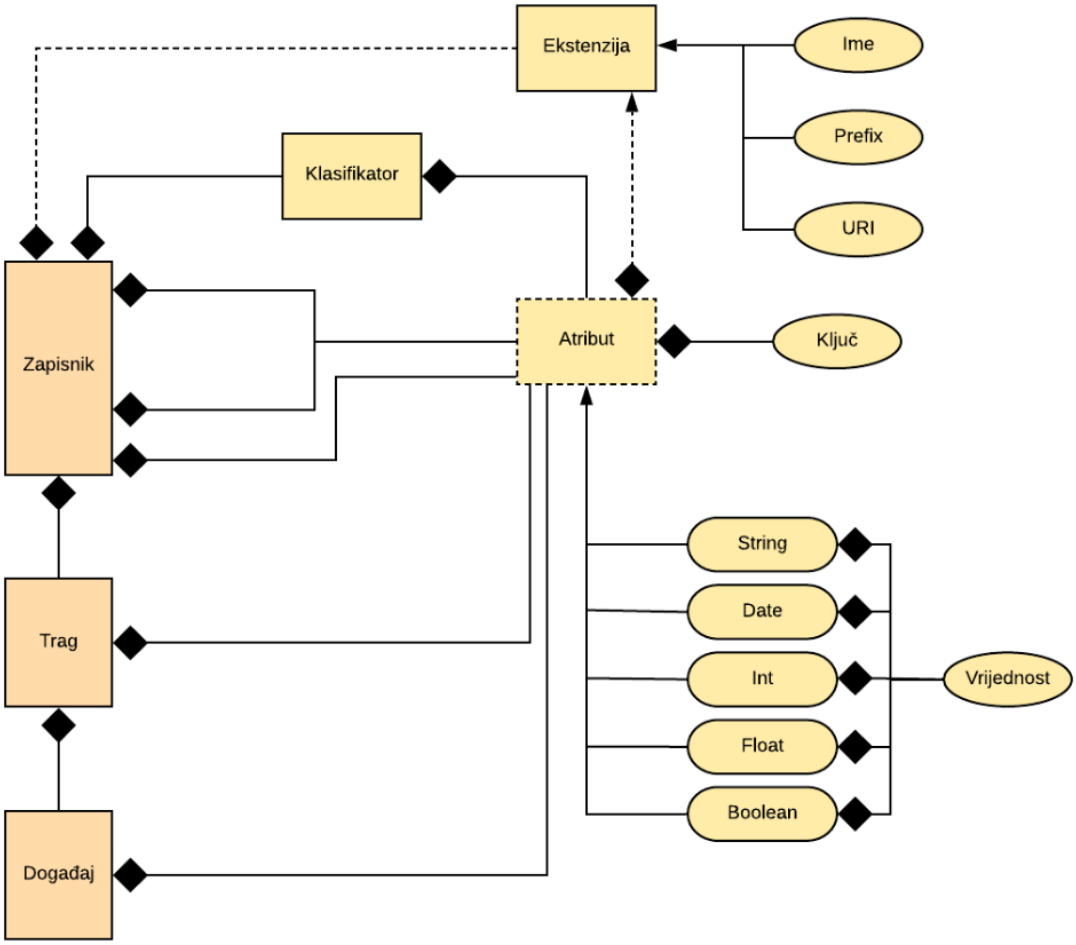
[19] An Introduction to the XES Standard - https://fluxicon.com/blog/2010/09/intro-to-xes/ [Pristupljeno: 10.08.2019.]

- Jednostavnost – koristi se najjednostavniji način za prikazivanje informacije. XES treba moći jednostavno analizirati i generirati. Trebali bi biti jednako dobro razumljivi strojevima i ljudima.
- Fleksibilnost – XES standard trebao bi biti u mogućnosti snimiti zapisnike događaja neovisno o informacijskom sustavu, pozadini ili aplikacijskoj domeni promatranog procesa. XES standards cilja dalje od samo procesnog rudarenja te želi biti glavni standard za zapisnike podataka.
- Proširivost – XES standard treba biti lako nadograditi (engl. *update*) i prilagoditi drugim standardima u budućnosti.
- Ekspresivnost – Prilikom standardizacije podataka, XES bi trebao omogućiti gubitak što je manje što manjeg broja podataka.

XES meta model može se prikazati pomoću UML dijagrama. Na slici 15. prikazan je meta model XES-a. Iz dijagrama se može vidjeti kako XES dokument sadrži jedan zapisnik (engl. *log*) koji se sastoji od neodređenog broja tragova (engl. *traces*). Svaki pojedini trag opisuje redoslijed događaja (engl. *events*) koji odgovaraju određenom slučaju (engl. *case*). Broj atributa (engl. *atributes*) koji zapisnik, tragovi i događaj mogu imati nije definiran, a osnovni atributi jesu: *String*, *Date*, *Int*, *Float* i *Boolean*. Također, atributi imaju i proširenje (engl. *Extension*) koje sadrži *name*, *prefix* i *URI (Uniform Resource Identifier)*. Svako proširenje može definirati atribute koji će se uzeti u obzir prilikom korištenja proširenja.

XES može odrediti hoće li neki atributi biti obavezni ili neće. Primjerice, može odrediti da svaki trag (engl. *trace*) treba imati atribut ime (engl. *name*) ili da svaki događaj (engl. *event*) mora imati oznaku vremena. Iz tog razloga, dnevnik (engl. *log*) ima dva popisa glavnih atributa. Jedan je za tragove, a drugi za događaje.

XES podržava koncept klasifikatora (engl. *classifier*). Klasifikator je funkcija koja preslikava atribute određenog događaja na oznaku koja se koristi u procesnom modelu. XES zapisnik definira proizvoljan broj klasifikatora, a svaki klasifikator određen je listom atributa. Bilo koja dva događaja koja imaju identične vrijednosti u odnosnu na atribute, klasifikator ih smatra jednakim te postaju obavezni atributi događaja. Pretpostavimo da je klasifikator određen atributom imena i atributom resursa. U tom slučaju će se dva događaja, koja imaju isti atribut imena i resursa, svrstati u istu klasu.



Slika 16. XES meta model

Izvor: XES meta model napravljen u Lucid Chart alatu prema „*An Introduction to the XES Standard*“ https://fluxicon.com/blog/2010/09/intro-to-xes/ [Pristupljeno: 10.08.2019.]

Pored nekomercijalnih softverskih alata za procesno rudarenje, kao što su ProM, RapidProM, PMLAB i CoBeFra, koji već sada podržavaju XES standard, sve veći broj komercijalnih softverskih alata krenuo je istim tim putem. Trenutno XES podržavaju Disco, Celonis, Mint, Rialto i SNP dok Fujitsu, PPM i EDS još uvijek ne podržavaju.

5. Softverski alati za procesno rudarenje

U ovom poglavlju obrađena je tema softverskih alata za procesno rudarenje. Navedeni su neki alati ali posebna pažnja pridodala se softverskom alatu ProM. Opisan je njegov razvoj te gdje je pozicioniran u današnjoj uporabi.

Prije navođenja softverskih alata i opisivanja glavnog alata ovog diplomskog rada, opisane su dvije različite klasifikacije koje softverski alat za procesno rudarenje može imati.

Softvere možemo klasificirati pomoću korisnika softvera za procesno rudarenje. Korisnike možemo najčešće podijelite u dvije skupine: [20]

- Eksperti – Grupa ljudi kojima alat služi da odgovore na neka jedinstvena pitanja. Odgovore na ta pitanja mogu pronaći samo određenim sofisticiranim analizama i složenim algoritmima.
- Krajnji korisnici – Grupa ljudi koja jednostavno želi imati uvid u standardne poslovne procese.

Sljedeći način na koji se alati za procesno rudarenje mogu klasificirati je temeljeno na njihovoj dostupnosti:

- Softver za procesno rudarenje otvorenog kôda (engl. *open source*) – ovisno o licenci kôd softvera je javno dostupan te se može dijeliti, izmjenjivati ili proširivati.
- Softver za procesno rudarenje zatvorenog kôda (engl. *closed cource*) – kôd softvera nije javno dostupan i ne smije se dijeliti, izmjenjivati ili proširivati.

Danas postoje na desetke komercijalnih i nekomercijalnih alata za softversko rudarenje, a neki od tih alata jesu:

- Komercijalni – Celonis Process Mining, Disco, Enterprise Discovery Suite, Interstage Business Process Manager Analytics, Minit, myInvenio, Perceptive

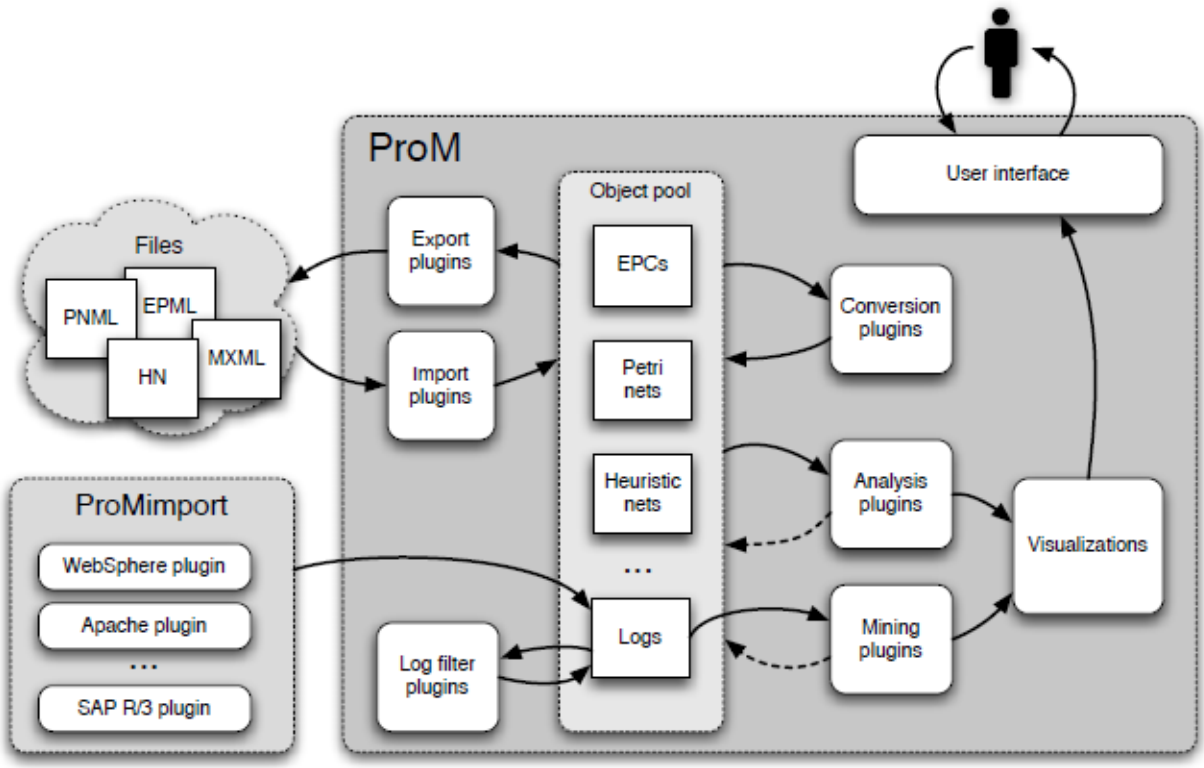
[20] Van der Aalst, Wil M.P., Process Mining – Data Science in Action - Second Edition, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016., 328 str.

Process Mining, QPR ProcessAnalyzer, Rialto Process, SNP Business Process Analysis, webMethods Process Performance Manager

- Nekomercijalni – ProM, PMLAB, CoBeFra, RapidProM

Softverski alat koji se koristio u ovom radu zove se ProM (engl. ***Pro**cess **M**ining framework*). ProM je besplatni softverski alat otvorenog koda ima dostupne instalacijske pakete za sve operacijske sustave. ProM ne ovisi o platformama iz razloga što je implementiran u programskom jeziku Java. ProM softverski alat razvio je profesor Wil van der Aalst, zajedno sa svojim stručnim timom, na sveučilištu *Eindhoven University of Technology*. ProM danas ima preko 100 različitih dodataka (engl. *plug-in*) te se koristi raznim algoritmima za procesno rudarenje.

Na sljedećoj slici 17. prikazan je *framework* softverskog alata ProM.



Slika 17. Framework softverskog alata ProM

Izvor: Preuzeto iz Christian Walter Gunther, Process Mining in Flexible Environments, str. 15

U sredini slike možemo vidjeti *Object pool* koji može sadržavati bilo koji broj objekata različitih tipova. U ovom slučaju *object pool* sadrži EPC, Petrijeve mreže,

Heurističke mreže i zapisnike. Dodaci (engl. *plug-in*) u ProM-u mogu pripadati jednom od sljedeće navedenih šest tipova:[21]

- Ulazni dodaci (engl. *Import plugins)*
- Izlazni dodaci (engl. *Export plugins*)
- Dodaci za konverziju (engl. *Conversion plugins*)
- Dodaci za filter zapisnika (engl. *Log filter plugins*)
- Dodaci za rudarenje (engl. *Mining plugins*)
- Dodaci za analizu (engl. *Analysis plugins*)

Prema istraživanju Cleas J. i Poels G. (2012.) u radu *„Process Mining and the ProM Framework: An Exploratory Survey - Extended report“*, ProM je najpopularniji i najčešće korišten alat za procesno rudarenje. Tablica 1 i Slika 18. preuzete su iz gore spomenutog rada te jasno prikazuju kako je alat ProM najpoznatiji i najčešće korišteni alat za procesno rudarenje.

U istraživanju je sudjelovalo 131 ispitanika. Cilj istraživanja bio je pronaći najpopularniji i najkorišteniji alat za softversko rudarenje. Svi ispitanici su trebali svaki softverski alat, ukupno 10 komercijalnih i nekomercijalnih alata za softversko rudarenje, svrstati u sljedeće kategorije: često korišten (engl. *Frequent use*), ponekad korišten (engl. *Occasional use*), jednom korišten (engl. *Tried it once*), nikad korišten ali čuo/čula sam za njega (engl. *Didn't use but heard about it*) i nikad nisam čuo/čula za njega (engl. *Never heard about it*).

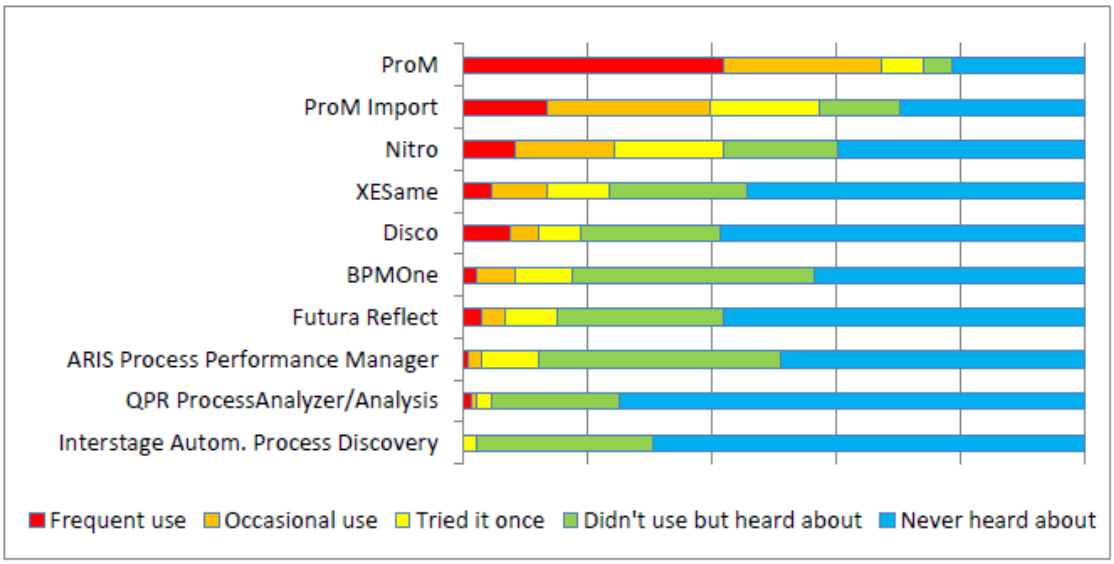
Rezultat istraživanja je da je ProM softverski alat za procesno rudarenje koje ispitanici najčešće koriste. Čak 55 od 131 ispitanika redovito koristi taj alat, a još 33 ga koriste povremeno. Dok s druge strane imamo Interstage Automated Process Discovery, kojeg nitko od ispitanika ne koristi povremeno ni često, i ARIS Process Performance Manager, kojeg jedan ispitanik koristi često, a troje povremeno.

[21] Christian Walter Gunther, *Process Mining in Flexible Environments*, str. 15-16

	Frequent use	*Occasional use*	*Tried it once*	*Didn't use but heard about it*	*Never heard about it*
ARIS Process Performance Manager (Software AG)	1	3	12	51	64
BPMOne (Pallas Athena)	3	8	12	51	57
Disco (Fluxicon)	10	6	9	29	77
Futura Reflect (Futura Technology)	4	5	11	35	76
Interstage Automated Process Discovery (Fujitsu)	0	0	3	37	91
Nitro (Fluxicon)	11	21	23	24	52
ProM (Academic)	55	33	9	6	28
ProM Import (Academic)	18	34	23	17	39
QPR ProcessAnalyzer/Analysis (QPR Software)	2	1	3	27	98
XESame (Academic)	6	12	13	29	71

Tablica 1. Alati za rudarenje procesima

Izvor: Claes, J. i G. Poels, „Process Mining and the ProM Framework: An Exploratory Survey - Extended report“, Ghent University, Belgium (2012.), str. 5



Slika 18. Alati za rudarenje procesima

Izvor: Claes, J. i G. Poels, „Process Mining and the ProM Framework: An Exploratory Survey - Extended report“, Ghent University, Belgium (2012.), str. 6

ProM se može koristiti kako bi odgovorio na neka od najčešćih pitanja koja si menadžeri u organizacijama postavljaju:[22]

- Koja je prosječna/minimalna/maksimalna propusnost instanci kroz određeno vrijeme?
- Koji put (engl. *path*) prosječno troši najviše vremena? Koliko instanci prati te puteve?
- Koliko je prosječno vrijeme usluga za svaku aktivnost?
- Koliko vremena je utrošeno između dvije aktivnosti u procesnom modelu?
- Na koji način se aktivnosti izvode?
- Da li se poštuju pravila?
- Koliko ljudi je uključeno u određeni proces?
- Koja je komunikacijska struktura i ovisnost među ljudima?
- Tko radi na istom zadatku?

[22] ProM 6 Tutorial http://www.promtools.org/prom6/downloads/prom-6.0-tutorial.pdf (05.06.2019.)

6. Primjer rudarenja u poslovnom sustavu

U ovom dijelu rada prikazat će se postupak unošenja podataka u softverski alat ProM, obrada unesenih podataka korištenjem raznih algoritama, grafički i animirani prikaz te analiza dobivenih rezultata.

Podaci korišteni za ovaj primjer preuzeti su s internetske stranice Future Learn (www.futurelearn.com). U ovom primjeru obrađen je proces popravka uređaja u kojem se analizom pokušalo ustanoviti koji je *bottleneck*. Bottleneck predstavlja određeno zagušenje ili zaostatak u samom procesu. Zagušenje dovodi do povećanja vremena čekanja. Detekcijom zagušenja, problem se može lakše identificirati, a proces time i optimizirati.

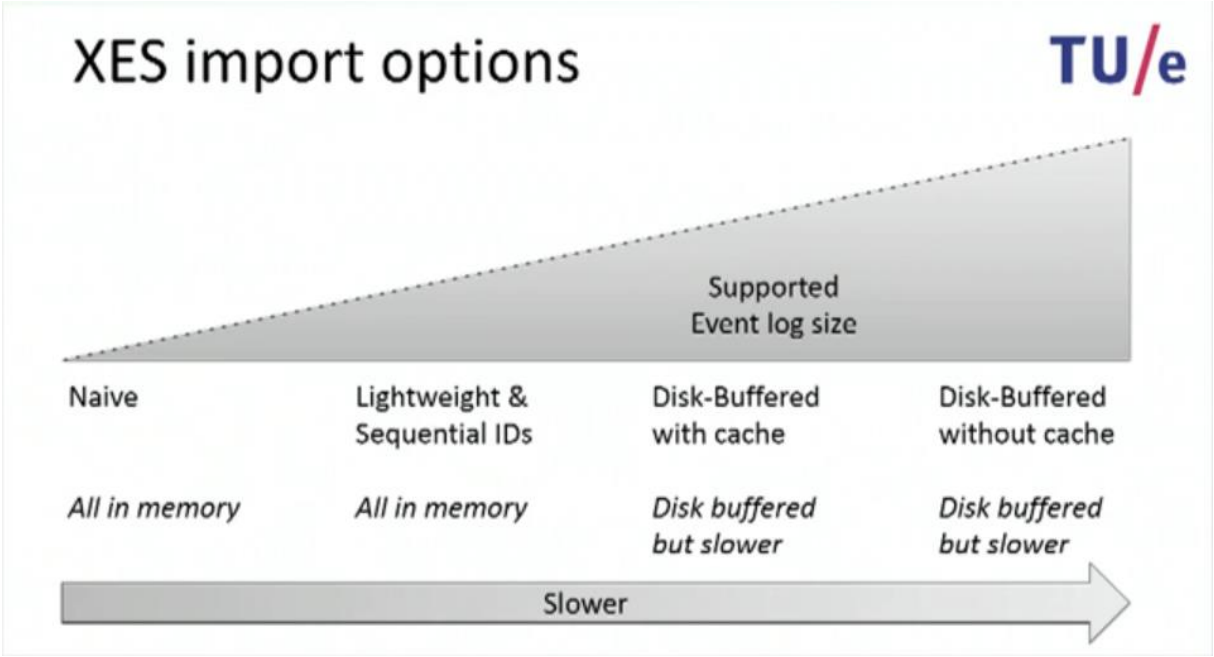
Nakon preuzimanja podataka, otvaramo softverski alat ProM. Preuzeti podaci uvoze se naredbom „import“ koja se nalazi u gornjem desnom uglu zaslona. Na Slici 19. prikazan je početni zaslon programa.



Slika 19. Prikaz početnog zaslona programa ProM

Izvor: Izrada autora u ProM softverskom alatu

Nakon odabira i prije unosa zapisnika događaja (engl. *event log)* u ProM, moramo odabrati opciju načina na koji želimo podatke uvesti (engl. *import*). Imamo četiri opcije za uvoz podataka: *Naive, Lightweight & Sequential IDs, Disk-Buffered with cache, Disk-Buffered without cache*. Naive opcija je najbrža i koristi se najčešće kod manjeg broja podataka gdje se memorija računala neće previše opteretiti. Sljedeća Slika 20. grafički prikazuje opcije za uvoz podataka u ProM.

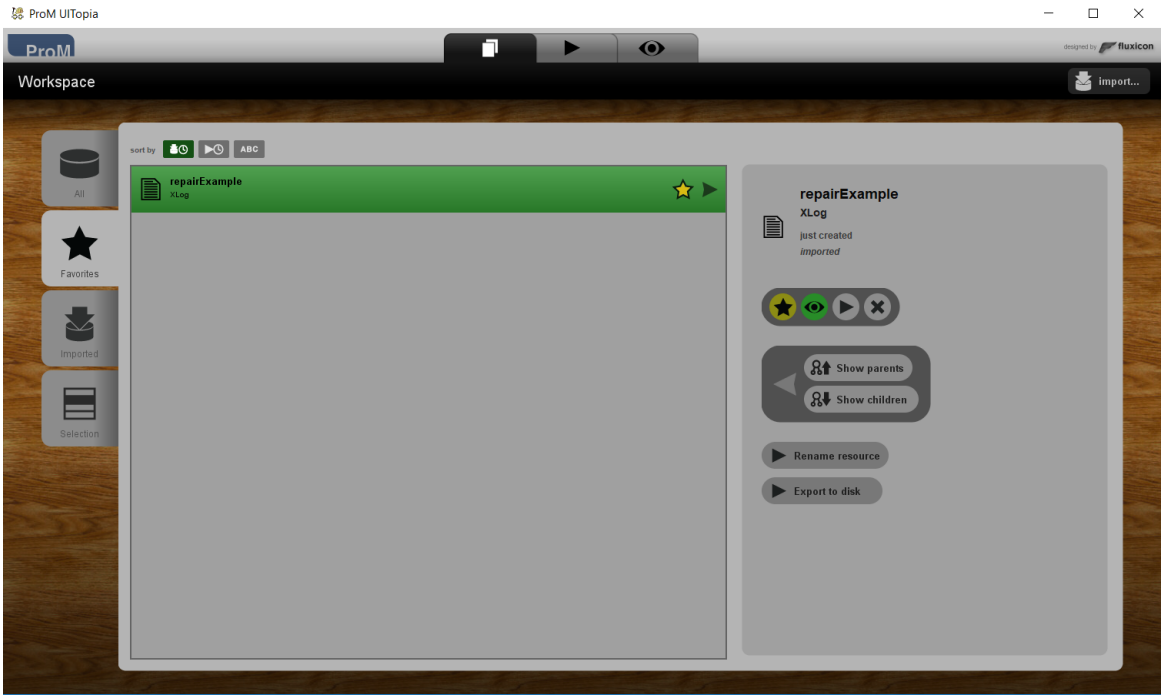


Slika 20. Prikaz četiri opcije za unos podataka u ProM.

Izvor: Future Learn, dostupno na: https://www.futurelearn.com/courses/process-mining/10/steps/494775

Kako se krećemo u desno tako su metode sporije, ali omogućuju unošenje većeg broja podataka. Za naš primjer nismo koristili veliki broj podataka te se iz tog razloga koristila „Naive“ opcija za unos podataka.

Kako će zaslon izgledati nakon odabira opcije za unos podatka i učitavanja samih podataka, prikazano je na Slici 21.



Slika 21. Prikaz zaslona programa ProM nakon unosa podataka

Izvor: Izrada autora u ProM softverskom alatu

Sljedeći korak koji se mora napraviti je odabrati „*View Resources*“ ikonu koja je na Slici 21. označena zelenom bojom. Na taj ćemo način biti u mogućnosti vizualizirati i istražiti uneseni zapisnik podataka. Nakon odabira opcije „*View Resources*“, zaslon će automatski prikazati *Dashboard* koji se sastoji od dva glavna dijagrama:

- Događaj po slučaju (engl. *Events per case*) - prikazuje koliko je događaja zabilježeno po jednom slučaju i koja je njihova distribucija.
- Događaj klase po slučaju (engl. *Event classes per case*) - prikazuje broj aktivnosti

Osim dva glavna dijagrama, lijevo na sučelju prikazani su ključni podaci (engl. *Key Data*), a desno informacije o zapisniku (engl. *Log info*). Ključni podaci nam prikazuju od čega se sve uvezeni zapisnik događaja sastoji. U ovom primjeru možemo vidjeti da se zapisnik događaja sastoji od:

- 1 proces (engl. *processes*),
- 1104 procesnih instanci (engl. *cases*),
- 11855 događaja (engl. *events*),

- 12 klasa (engl. *event classes*),
- 2 tipa evenata (engl. *event types*) te
- 13 pokretača događaja (engl. *originators*).

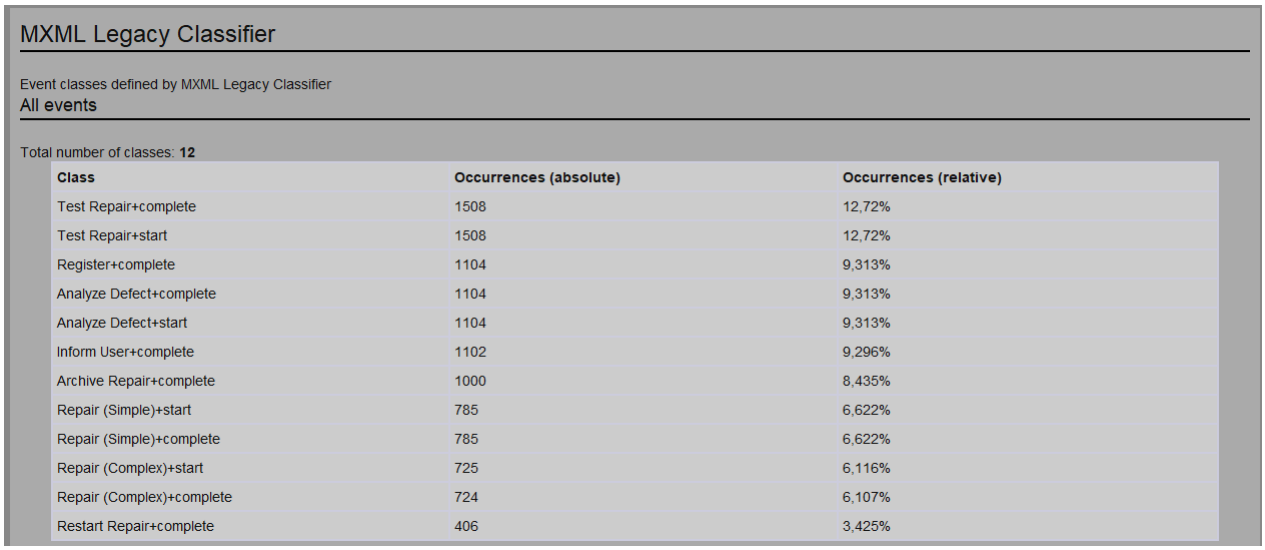
Informacije o zapisniku prikazuju vrijeme prvog i zadnjeg zapisnika događaja te na taj način imamo predodžbu o vremenskoj duljini promatranog procesa.



Slika 22. Zaslon kad se klikne na „View Sources“

Izvor: Izrada autora u ProM softverskom alatu

Sažetak svih uvezenih podataka možemo pronaći na jednom mjestu i to odabirom opcije „*Summary*“. U sažetku, zapravo, možemo dobiti detaljniji uvid u podatke odnosno možemo vidjeti one događaje koji se češće pojavljuju. Na sljedećoj Slici 23. prikazan je sažetak primjera korištenom u radu.



MXML Legacy Classifier

Event classes defined by MXML Legacy Classifier
All events

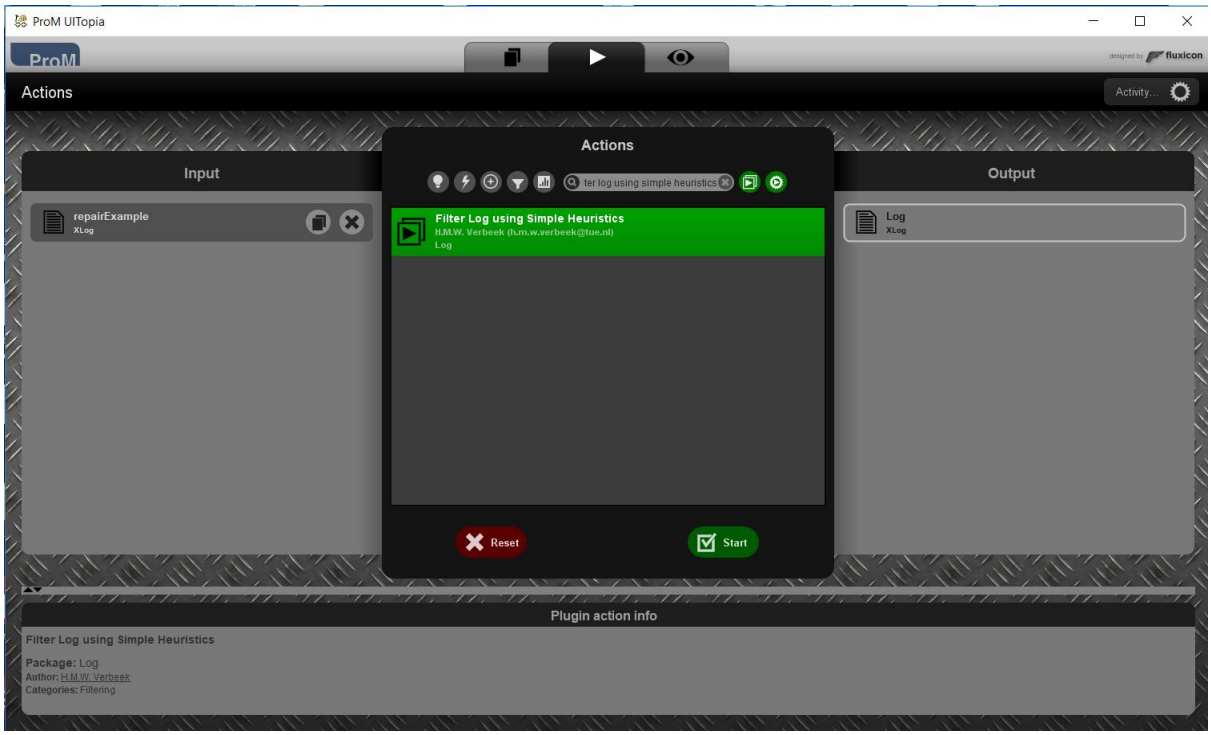
Total number of classes: **12**

Class	Occurrences (absolute)	Occurrences (relative)
Test Repair+complete	1508	12,72%
Test Repair+start	1508	12,72%
Register+complete	1104	9,313%
Analyze Defect+complete	1104	9,313%
Analyze Defect+start	1104	9,313%
Inform User+complete	1102	9,296%
Archive Repair+complete	1000	8,435%
Repair (Simple)+start	785	6,622%
Repair (Simple)+complete	785	6,622%
Repair (Complex)+start	725	6,116%
Repair (Complex)+complete	724	6,107%
Restart Repair+complete	406	3,425%

Slika 23. Prikaz sadržaja klasa

Izvor: Izrada autora u ProM softverskom alatu

Svi zapisnici događaja imaju određene smetnje (engl. *noise*) ili sadrže određenu pogrešku te ih je iz tog razloga prije procesa analize, potrebno filtrirati. Za filtriranje podataka odabire se opcija „*Use resource*“. Prvo što treba provjeriti je da su svi uneseni zapisnici događaja označeni ispod kategorije „*Input*“. ProM ima više algoritama za filtriranje podataka, a za ovaj primjer korišten je „*Filter Log using Simple Heuristics*“ algoritam. Nakon odabira filtere, klikne se na „*Start*“ nakon čega se otvori nekoliko novih prozora. Prvi prozor koji se otvori daje opciju tipova događaja koje želimo uključiti. U ovom primjeru odabrani su događaji „*start*“ i „*complete*“. U drugom prozoru odabran je početni događaj, nakon kojeg slijedi prozor s ponuđenim događajem s kojim završavamo. U ovom primjeru početni događaj je „*Register+complete*“, a završni je „*Archive repair+complete*“. Zadnji zaslon koji se pojavljuje nudi mogućnost odabira svih događaja koje želimo uključiti u filtriranje. U ovom slučaju odabrani su svi ponuđeni događaji te je za kraj potrebno kliknuti na „*Finish*“.



Slika 24. Prikaz odabira algoritma za filtriranje podataka

Izvor: Izrada autora u ProM softverskom alatu

Nakon filtriranja podataka iz zapisnika, na zaslon se otvara „*View resource*“ koji prikazuje sve filtrirane podatke. Možemo vidjeti kako i dalje imamo 1 proces, ali nam se broj slučajeva (engl. *cases*) i događaja (engl. *events*) znatno smanjio. Tako sada imamo:

- 1000 slučaja (početno ih je bilo 1104)
- 10845 događaja (početno ih je bilo 11855)



Slika 25. Grafički prikaz filtriranih podataka

Izvor: Izrada autora u ProM softverskom alatu

Također, filtrirani podaci mogu se pogledati preko „*Summary*“ opcije te tako usporediti filtrirane i ne filtrirane podatke.

MXML Legacy Classifier

Event classes defined by MXML Legacy Classifier
All events

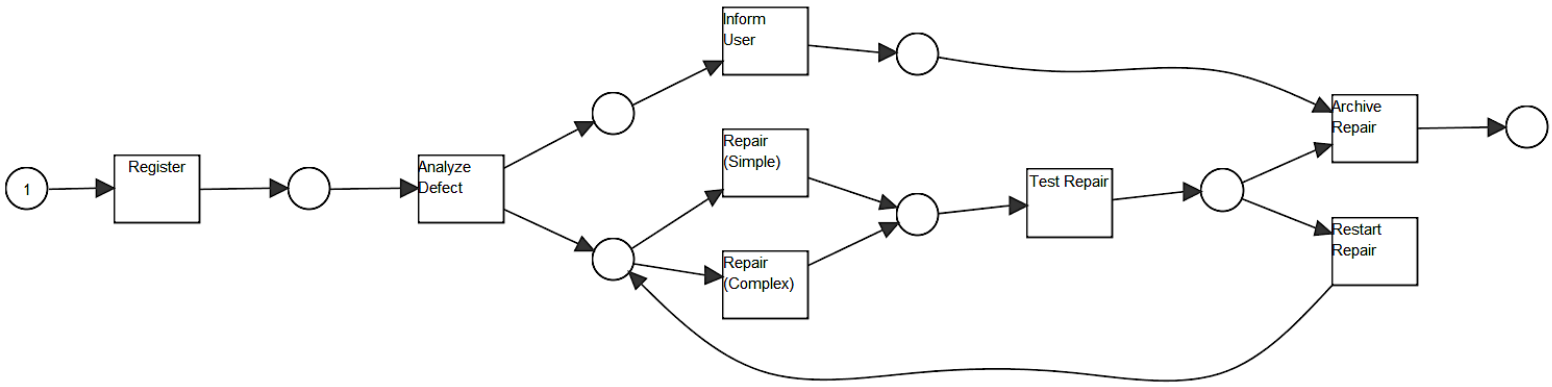
Total number of classes: **12**

Class	Occurrences (absolute)	Occurrences (relative)
Test Repair+complete	1369	12,623%
Test Repair+start	1369	12,623%
Register+complete	1000	9,221%
Archive Repair+complete	1000	9,221%
Analyze Defect+complete	1000	9,221%
Inform User+complete	1000	9,221%
Analyze Defect+start	1000	9,221%
Repair (Simple)+start	697	6,427%
Repair (Simple)+complete	697	6,427%
Repair (Complex)+complete	672	6,196%
Repair (Complex)+start	672	6,196%
Restart Repair+complete	369	3,402%

Slika 26. Summary filtriranih podataka

Izvor: Izrada autora u ProM softverskom alatu

Sljedeće što želimo napraviti je filtrirane podatke prikazati u dijagramu, a to ćemo napraviti koristeći se opcijom „*Mine Petri net with Inductive Miner*“ algoritam. Kao i u slučaju filtriranja, postoje različiti algoritmi za dijagramni prikaz event logova, a za ovaj primjer „*Mine Petri net with Inductive Miner“* algoritam ispostavio se najjednostavnijim i najboljim za prikaz. U „*Use resource*“ prozoru otvorimo filtrirane podatke i te odaberemo „*Mine Petri Net with Inductive Miner*“ algoritam te kliknemo „Start“. Slika 27. prikazan je dijagram koji se dobije nakon izvršavanja algoritma.



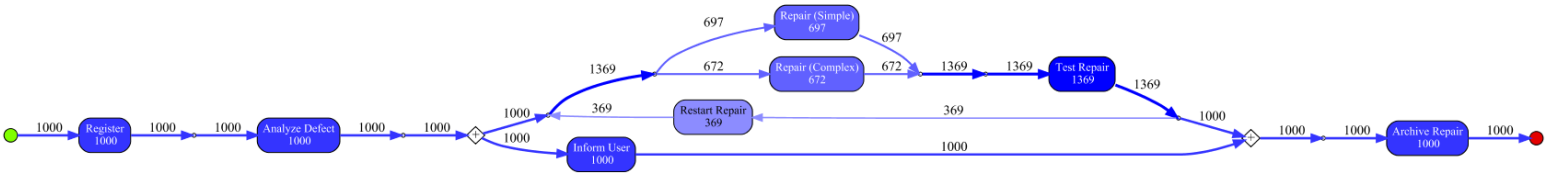
Slika 27. Dijagram dobiven korištenjem „Mine Petri Net with Inductive Miner“ algoritma

Izvor: Izrada autora u ProM softverskom alatu

Po prvi put možemo vizualizirati kako naš poslovni proces „Popravak uređaja“ izgleda. Možemo vidjeti kako model započinje registracijom (engl. *Register*) te nastavlja s analiziranjem prijavljenog problema (engl. *Analyze defect*). Nakon što se analizira prijavljeni problem, slijedi paralelna aktivnost popravaka uređaja (engl. *Repair*). Popravak uređaja može biti jednostavan (engl. *Simple*) ili složen (engl. *Complex*). Nakon popravka, uređaj se testira (engl. *Test Repair*) te nakon testiranja slijede dvije moguće aktivnosti. U slučaju da uređaj prođe testiranje uređaj se arhivira (engl. *Archive Repair*) te proces završava, a u slučaju da uređaj ne prođe testiranje uređaj se šalje na ponovni popravak (engl. *Restart Repair*) te ponovno prolazi kroz fazu popravka (engl. *Repair*).

Na slici 27. privi put je vizualiziran naš primjer ali i dalje ne možemo vidjeti sve detalje. Kako bi poslovni proces popravka uređaja mogli bolje analizirati ali i razumjeti, potrebno je napraviti animaciju cijelog poslovnog sustava.

Za animaciju, u ovom primjeru, korišten je algoritam „*Mine with Inductive Visual Miner*“. Algoritam za vizualizaciju pokreće se na isti način kao i ostali algoritmi. Slika 28. prikazuje kadar animacije našeg poslovnog procesa.

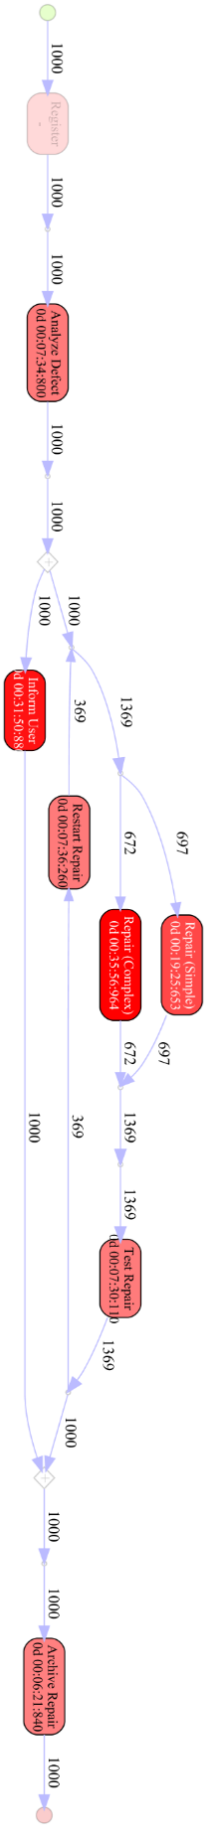


Slika 28. Kadar animacije poslovnog procesa koristeći „Mine with Inductive Visual Miner“ algoritam.

Izvor: Izrada autora u ProM softverskom alatu

Pomoću animacije možemo jasno vidjeti broj instanci koji je prošao kroz svaku pojedinu aktivnost. Tako vidimo da poslovni proces započinje i završava s 1000 procesnih instanci. Svih 1000 instanci prolazi kroz analizu (engl. *Analize Defect*) te nakon toga dolazi do prve skretnice nakon koje svaka pojedina instanca prolazi kroz proces popravka (engl. *Repair*) i proces informiranja korisnika (engl. *Inform User*). Možemo primijetiti da kod analiziranog poslovnog procesa od 1000 početnih instanci (uređaji s kvarom) njih 369 uređaja nije iz prve prošlo testiranje te se vratilo na ponovni popravak (engl. *Restart Repair*). Samim ponovnim popravkom, proces se odužuje. Ova animacija je korisna jer točno prikazuje kroz koje aktivnosti je prošla svaka pojedina instanca te možemo vidjeti koja je aktivnost najopterećenija.

Sada kad znamo koliko instanci prolazi kroz koju aktivnost, nameće nam se pitanje koliko se u stvari vremena troši u svakoj aktivnosti? Odgovor na to pitanje možemo vidjeti na Slici 29. koja prikazuje prosječno vrijeme boravka svake instance u određenoj aktivnosti. Dijagram koji smo dobiti vrlo je sličan prethodnoj animaciji, a dobijemo ga na način da odabiremo „Paths and sojourn times“ u padajućem izborniku pod nazivom „*Show*“.

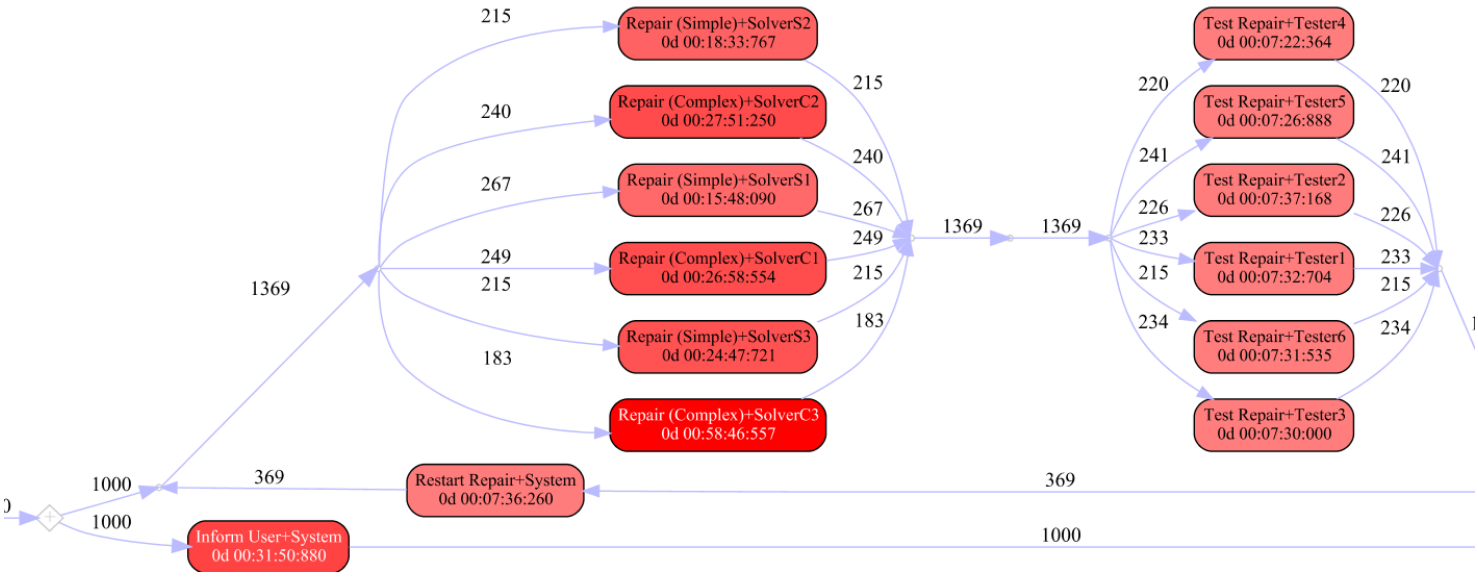


Slika 29. Kadar animacije poslovnog procesa s prikazom puteva i vremena boravka svake pojedine instance.

Izvor: Izrada autora u ProM softverskom alatu

Sa Slike 29. možemo lako vidjeti koliko se prosječno instanca zadržava u pojedinoj aktivnosti. Možemo vidjeti da aktivnosti analiza, testiranje, ponovno testiranje i arhiviranje traju relativno kratko, oko 7 minuta. Očekivano, aktivnosti koje troše najviše vremena jesu popravci uređaja. Aktivnost informiranja korisnika također traje duže, ali nju ne uzimamo u obzir iz razloga što u potpunosti ovisi o uspješnom popravku uređaja, odnosno pozitivnom rezultatu testiranja uređaja.

Nakon što smo pomoću dijagrama mogli zaključiti da se instance najviše zadržavaju u aktivnosti popravka, možemo ići u daljnju analizu procesa. Aktivnosti popravka možemo razgranati te vidjeti kod kojeg se radnika (engl. *Solver*) instance najduže prosječno zadržavaju. Odabirom klasifikatora „*Event Name AND Resource*“ aktivnosti „*Repair*“ razgranat će se, a kako će dijagram izgledati vidljivo je na Slici 30.

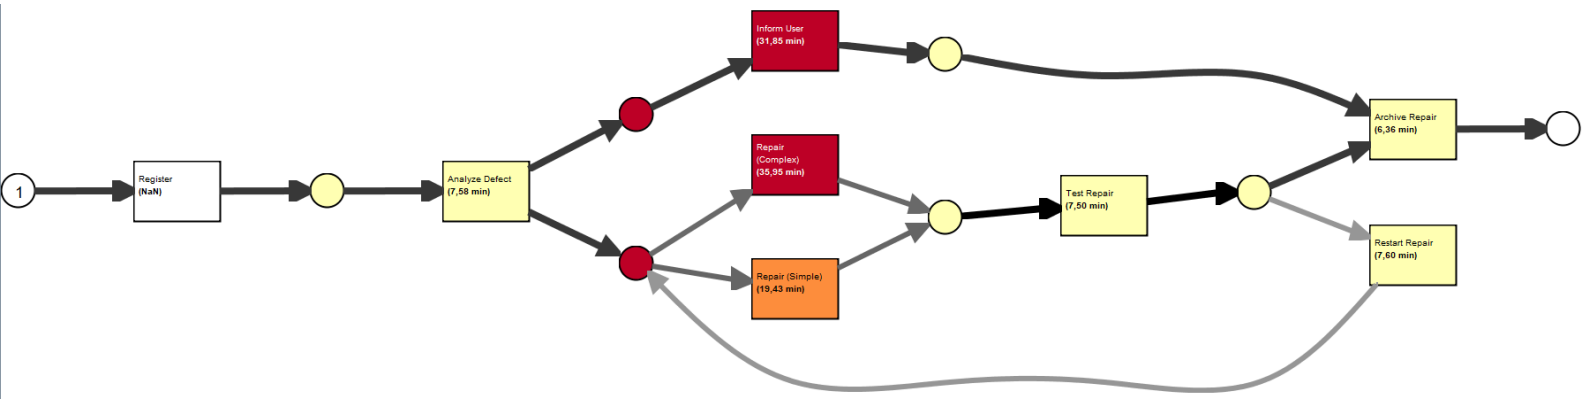


Slika 30. Isječak dijagrama koji prikazuje prosječno vrijeme zadržavanje instance kod svakog radnika (engl. *Solver*)

Izvor: Izrada autora u ProM softverskom alatu

Analizirajući dijagram poboljšani dijagram možemo zaključiti da se kod radnika broj 3 koji radi na složenim popravcima (*Repair (Complex)+SolverC3*) instance najdulje zadržavaju, odnosno da se kod tog radnika pojavljuje najveće zagušenje.

Osim *„Mine with Inductive Visual Miner“* algoritma postoje i drugi algoritmi pomoću kojih možemo vizualizirati trajanje cijelog procesa. Kao primjer, možemo koristiti „*Replay a log on petri net for performance/Conformance Analysis*“ algoritam.



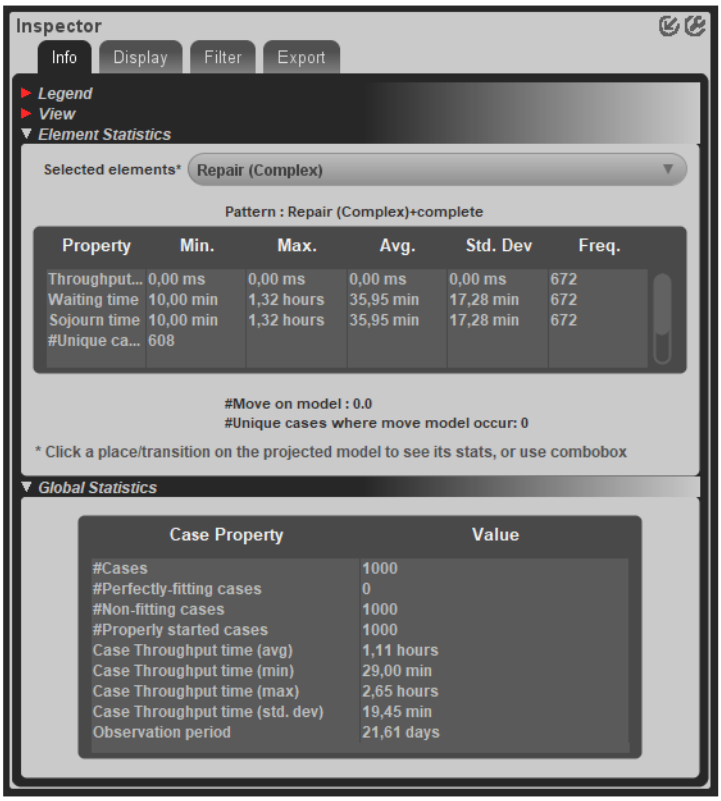
Slika 31. Prikaz grafa upotrebom „Replay a log on petri net for performance/Conformance Analysis“ algoritama.

Izvor: Izvor: Izrada autora u ProM softverskom alatu

Na grafu sa slike 31. odmah možemo uočiti da su aktivnosti koje traju duže, crvenije od ostalih, te da su putevi koji su češće korišteni, tamniji. Pomoću ovog algoritma imamo pregledniji uvid u statističke podatke. Tako s desne strane imamo prozor „*Inspector*“ kod kojeg možemo pogledati osnovne informacije o:

- Procesu
- Displeju
- Filterima
- Eksportu

Za ovaj poslovni proces mogu biti zanimljive opće informacije o procesu i pojedine informacije o određenom elementu procesa, točnije o aktivnosti popravka. Kao što je prikazano na slici 32., obje opcije možemo istovremeno otvoriti i usporediti.



Slika 32. Prikaz informacija o aktivnosti popravka i općim informacija promatranog procesa

Izvor: Izvor: Izrada autora u ProM softverskom alatu

U općim informacija možemo vidjeti da podaci za naš cijeli proces skupljali kroz period od 21 dan. Prosječno trajanje cijelog procesa, od trenutka analize do arhiviranja, je približno 1 sat i 10 minuta. Maksimalno vrijeme koja je jedna instanca provela u procesu popravka je približno 2 sata i 40 minuta, dok je najkraće vrijeme „boravka“ u procesu točno 29 minuta.

Što se tiče složenih popravaka, prosječno vrijeme popravka uređaja iznosi 35,95 minuta. Maksimalno vrijeme koje je trebalo da se jedan uređaj popravio iznosi malo više od 1 sata i 30 minuta, a minimalno vrijeme koje je uređaj proveo kod radnika iznosi točno 10 minuta.

Zaključak

U diplomskom radu „*Primjena metode rudarenja procesa u poslovnim sustavima*“ definiran je i objašnjen pojam poslovnih procesa, definirane su znanost o podacima i znanost o procesima te koja je poveznica među njima. Pojašnjeno je i definirano rudarenje procesima, što je to zapisnik događaja i zašto je bitan. Također, opisani su softverski alati za procesno rudarenje te je posebna pažnja posvećena ProM softverskom alatu. U zadnjem dijelu rada prikazana je i prezentirana primjena procesno rudarenja na primjeru jednog poslovnog procesa.

Procesi su univerzalni pojam za obavljanje različitih aktivnosti. Svaka se ljudska aktivnost može nazvati procesom, a među procesima prisutnim u poslovnim okruženju potrebno je razlikovati tri kategorije organizacijskih procesa (radni ili poslovni, bihevioralni i procesi promjena) od kojih svaka kategorija obuhvaća određenu vrstu procesa sa specifičnim karakteristikama i izazovima.

Kako je cijela civilizacija, u vrlo kratkom roku, prešla iz analognog u digitalno doba, tako se i broj podataka i procesa višestruko povećao te se iz tog razloga razvila potreba za novom znanstvenom disciplinom koja se bavi procesima. Možemo reći da je to spoj disciplina kao što su statistika, rudarenje podacima, baze podataka i distributivni sustavi. Nadalje, rudarenje procesima je znanstvena disciplina koja ispunjava prazninu između strojnog učenja i rudarenja podacima s jedne strane i procesnog modeliranja i analize s druge strane. Ideja rudarenja procesa je otkriti, motriti i poboljšati stvarne procese izdvajajući informacije iz zapisnika događaja koja su mogu prikupiti pomoću današnjim sustavima.

Kao i sve metode, tako i metoda rudarenja procesa ima svoje pozitivne strane ali i izazove. Pozitivne strane s kojima sam se susreo i koje smatram da trebaju biti istaknute su sljedeće: objektivnost rezultata, brzina simulacije i prikazivanje rezultata. Izazovi s kojim sam se susreo prilikom izrade primjera jesu: prikupljanje podataka; od nijednog poduzeća nisam uspio dobiti zapisnike događaja stvarnog procesa koje bih mogao analizirati, odabir algoritama koji će najbolje odgovarati za željenu analizu.

Popis Literature

Knjige:

1. Andersen, B., *Business Process Improvement Toolbox*, ASQ Quality Press, Milwaukee, Wisconsin, 2007.
2. Bosilj Vukšić, V., Hernaus, T. i A. Kovačić, *Upravljanje poslovnim procesima – organizacijski i informacijski pristup*, Školska knjiga, Zagreb, 2008.
3. Gunther Christian W., *Process Mining in Flexible Environments*, Technische Universiteit Eindhoven, The Netherlands, 2009.
4. Van der Aalst, i Wil M.P., *Process Mining – Data Science in Action - Second Edition*, Springer, Eindhoven University of Technology, Department of Mathematics and Computing Science, Eindhoven, The Netherlands 2016.
5. Van der Aalst, W., i Van Hee, K., *Workflow Management: Models, methods and systems*, Eindhoven University of Technology, Faculty of Mathematics and Computing Science, Eindhoven, 2000.

Članci:

1. Brumeca, J., *Modeliranje poslovnih procesa*, KORIS - Konzalting, organizacija, razvoj IS, Varaždin/Zagreb, 2011., dostupno na: http://koris.hr/preuzmi/koris-uvod-u-modeliranje-poslovnih-procesa.pdf (24.06.2019.)
2. Claes, J. i G. Poels, „Process Mining and the ProM Framework: An Exploratory Survey - Extended report“, Ghent University, Belgium (2012.)
3. Rančić, M. i D. Rančić, „*Petrijeve mreže i simulacije proizvodnih sistema procesa*“, Visoka poslovna škola, Prof. Dr. Radomir Bojković (2013.)

Ostali radovi:

1. Bašić, M., *Primjena modeliranja poslovnih procesa u izradi poslovnog softvera*, Završni rad, Sveučilište u Splitu, Split, 2010.
2. Martinek, E*. Modeliranje poslovnih procesa pomoću grafičkog jezika BPMN*, Diplomski rad, Sveučilište u Zagrebu, Zagreb, 2018.
3. Pejić B, Mirjana, *Rudarenje podataka u bankarstvu*, Stručni rad, Zbornik Ekonomskog fakulteta u Zagrebu, godina 3, 2005.
4. Vincek, I., *Definiranje poslovnih procesa I modeliranje procesa prodaje u poduzeću mikronis*, Diplomski rad, Sveučilište Sjever, Varaždin, 2017.

Internetski izvori:

1. An Introduction to the XES Standard - https://fluxicon.com/blog/2010/09/intro-to-xes/ [Pristupljeno: 10.08.2019.]
2. Brumeca, J., Modeliranje poslovnih procesa, dostupno na: https://www.slideshare.net/Brumiko/modeliranje-poslovnih-procesa-uvod-u-bpmn [Prestupljeno: 24.05.2019.]
3. Cambridge dictionary, dostupno na: https://dictionary.cambridge.org/dictionary/english/sub-optimization [Prestupljeno: 20.05.2019]
4. D. Čičin-Šain, viši pred., *Poslovne i procesne funkcije u poduzeću* - http://www.unizd.hr/portals/4/nastavni_mat/2_godina/menadzment/menadzment_12.pdf [20.05.2019.]
5. Future Learn, dostupno na: https://www.futurelearn.com/courses/process-mining/0/steps/15626 [Pristupljeno: 24.05.2019.]
6. Houthoofd, D.“ Data mining vs. process mining: what’s the difference?“ Dostupno na: *https://www.horsum.be/en/blog/data-process-analytics/data-mining-vs-process-mining-whats-difference [Pristupljeno: 15.08.2019.]*
7. Medium, dostupno na: https://medium.com/@pedrorobledobpm/process-mining-plays-an-essential-role-in-digital-transformation-384839236bbe [Prestupljeno: 24.05.2019.]
8. Petri Nets, dostupno na: https://www.techfak.uni-bielefeld.de/~mchen/BioPNML/Intro/pnfaq.html [Prestupljeno: 24.05.2019.]
9. Petrijeve mreže, dostupno na: http://www.cs.tau.ac.il/~nachumd/models/Nets.pdf [Prestupljeno: 24.05.2019.]
10. Process Mining plays an essential role in Digital Transformation, https://medium.com/@pedrorobledobpm/process-mining-plays-an-essential-role-in-digital-transformation-384839236bbe, [Pristuljeno: 8.8.2019.]
11. Process mining, dostupno na: http://www.processmining.org/ [Prestupljeno: 24.05.2019.]
12. Prof.dr.sc. Sanja Pfeifer INTERNA SKRIPTA ZA KOLEGIJ „MENADŽMENT“ - http://www.efos.unios.hr/menadzment/wp-content/uploads/sites/205/2013/04/Interna_skripta_Menadzment_1.pdf [22.05.2019.]

13. ProM 6 Tutorial, dostupno na: http://www.promtools.org/prom6/downloads/prom-6.0-tutorial.pdf [Prestupljeno: 24.05.2019.]
14. Prom Tools, dostupno na: http://www.promtools.org [Prestupljeno: 24.05.2019.]
15. ResearshGate, dostupno na: https://www.researchgate.net/figure/An-Example-of-Petri-Nets-Graph_fig4_228713375 [Prestupljeno: 24.05.2019.]
16. What is Business Process Modeling Notation, dostupno na: https://www.lucidchart.com/pages/bpmn [Prestupljeno: 24.05.2019.]

Popis slika

Slika 1. Prikaz hijerarhijskih razina poslovnog procesa. 4
Slika 2. Slikovito prikazan „Internet događaja“....8
Slika 3. Slikoviti prikaz svih znanstvenih disciplina koje znanost o podacima objedinjuje 10
Slika 4. Slikoviti prikaz svih znanstvenih disciplina koje znanost o procesima objedinjuje 11
Slika 5. Slikoviti prikaz mosta mosta između znanosti o procesima i podacima 12
Slika 6. Životni ciklus BPM-a i prikaz različitih faza upravljanja poslovnog procesa...13
Slika 7. Osnovni elementi BPMN-a....16
Slika 8. Početni događaj (engl. Start), međudogađaj (engl. Intermediate) i završni događaj (engl. End) 17
Slika 9. Zadatak (engl. Task), transakcija (engl. Transaction), sub-proces (engl. Event Sub-Process), poziv na aktivnost (engl. Call Activity)....17
Slika 10. Ekskluzivna (engl. Exclusive), ekskluzivna vezana na međudogađaj (engl. Event based), Paralelna (engl. Parallel), Inkluzivna (engl. Inclusive), ekskluzivna vezana na početni događaj (engl. Exclusive event based), složena (engl. Complex) i paralelna vezana na događaj (engl. Parallel event based)....18
Slika 11. Kolaboracijski dijagram pokazuje razmjenu poruka između procesa i okoline 20
Slika 12. Aktivnosti i faze procesa rudarenja procesima 23
Slika 13. Fragment jednog zapisnika događaja....26
Slika 14. Struktura zapisnika događaja 27
Slika 15. Prikaz tri glavna tipa procesnog rudarenja: otkrivanje modela (engl. Discovery), usporedba modela (engl. Conformance), poboljšanja (engl. Enhancement)....28
Slika 16. XES meta model 30
Slika 17 Framework softverskog alata ProM 32
Slika 18. Alati za rudarenje procesima 34
Slika 19. Prikaz početnog zaslona programa ProM Izvor: Izrada autora u ProM softverskom alatu....36

Slika 20. Prikaz četiri opcije za unos podataka u ProM. 37
Slika 21. Prikaz zaslona programa ProM nakon unosa podataka 38
Slika 22. Zaslon kad se klikne na „View Sources“ 39
Slika 23. Prikaz sadržaja klasa 40
Slika 24. Prikaz odabira algoritma za filtriranje podataka 41
Slika 25. Grafički prikaz filtriranih podataka 42
Slika 26. Summary filtriranih podataka 42
Slika 27. Dijagram dobiven korištenjem „Mine Petri Net with Inductive Miner“ algoritma 43
Slika 28. Kadar animacije poslovnog procesa koristeći „Mine with Inductive Visual Miner“ algoritam. 44
Slika 29. Kadar animacije poslovnog procesa s prikazom puteva i vremena boravka svake pojedineinstance. 45
Slika 30. Isječak dijagrama koji prikazuje prosjećno vrijeme zadržavanje instance kod svakog radnika (engl. Solver) 46
Slika 31. Prikaz grafa upotrebom „Replay a log on petri net for performance/Conformance Analysis“ algoritama. 47
Slika 32. Prikaz informacija o altivnosti popravka i općim informacija promatranog procesa 48

Popis tablica

Tablica 1. Alati za rudarenje procesima 34

Sažetak

U ovom radu definirani su poslovni procesi te je opisana hijerarhijska struktura poslovnih procesa. Ukratko su opisane znanosti o podacima i procesima te što ih povezuje. Prije same definicije procesnog rudarenja, opisan je BPM životni ciklus i BPMN dijagram. Definiran je pojam zapisnika događaja i opisano je čemu služi. Nadalje, opisani su softverski alati za procesno rudarenje, a posebna se pažnja posvetila softverskom alatu za procesno rudarenje – ProM. U zadnjem dijelu rada, prikazano je procesno rudarenje na primjeru poslovnog procesa „popravak uređaja“ prilikom kojeg su korišteni razni algoritmi te dobiveni različiti grafovi.

Ključne riječi: procesno rudarenje, poslovni procesi, ProM

Abstract

This paper defines business processes and describes its hierarchical structure. Data and process sciences and what connects them are briefly described. The BPM life cycle and BPMN diagram are presented followed by a chapter explaining and defining process mining. The term event log is specified and defined for what purpose. Furthermore, software tools for process mining are interpreted, and particular attention is paid to the software tool for process mining - ProM. In the last part of the paper, process mining is presented on the example of a business process "repair of a device", where different algorithms were used and different graphs were obtained.

Keywords: Process mining, business process, ProM