



3. RUDARENJE PODATAKA I OTKRIVANJE ZNANJA

Autor: Dejan Mirčetić

Skao što je objašnjeno u 2. poglavlju, koncept izdvajanja podataka i generiranja znanja iz njih usko je povezan s **tehnikama rudarenja podataka (eng. Data Mining)**. U suvremenim preduzećima tehnike rudarenja podataka imaju veliki uticaj na ukupne performanse preduzeća, jer se operativne, taktičke i strateške odluke donose na bazi ulaznih informacija dobijenih procesom rudarenja podataka. U 1. poglavlju navedeno je da je u svetu dosad kreirano više od 97 zetabajta podataka, pri čemu pojedine baze podataka često dosežu veličinu u terabajtima. U većini organizacija podaci se udvostručuju svake dve godine. Podaci se čuvaju na različitim platformama i u različitim formatima, uključujući strukturirane, nestrukturirane i polustrukturirane podatke (vidi Poglavlje 1). Procjenjuje se da do 90% poslovnih podataka postoji u nestrukturiranom formatu. Osim toga, značajan deo ovih podataka može sadržati greške zbog neprikladnog čuvanja ili oblikovanja ili ručnih grešaka tokom prikupljanja podataka. Kao rezultat toga, nisu svi podaci koje organizacije poseduju nužno tačni ili pouzdani. Ipak, ova ogromna količina podataka sadrži vredne strateške informacije za kompanije. Međutim, kada se suočite s tako velikom količinom složenih tipova podataka, postavlja se pitanje kako se oni mogu uspešno 'rudariti' da bi se izvukle značajne poruke koje sadrže? Odgovor leži u rudarenju podataka, koje služi za povećanje prihoda i smanjenje troškova brzim i automatskim izvlačenjem korisnog znanja i poslovnih informacija iz ogromnih skupova podataka.

Rudarenje podataka nastalo je iz potrebe za efikasnim izvlačenjem vrednih informacija, zahtijevajući tehnike koje su usmerene na prepoznavanje razumljivih obrazaca koji se mogu protumačiti kao korisno ili zanimljivo znanje. Dakle, **rudarenje podataka je iterativni i interaktivni proces** usmeren na otkrivanje valjanog, novog, korisnog i razumljivog znanja (obrasci, modeli, pravila itd.) u masivnoj bazi podataka (Behera et al., 2019). Glavni cilj rudarenja podataka je **otkriti kritične uvide** koje **podržavaju donošenje odluka** unutar poslovne organizacije.

U sledećim potpoglavljima govoriće se o tome kako se podaci 'rudare' za poslovnu analitiku i otkrivanje znanja.



3.1. Što je rudarenje podataka?

Pre definisanja rudarenja podataka, važno je smestiti ovaj pojam u kontekst s drugim pojmovima s kojima se obično povezuje i često pogrešno poistovjećuje. Nestručnjaci često mešaju pojmove rudarenje podataka i Big data tehnologija. Međutim, to su dva različita pojma.

Big data opisuje izuzetno velike i složene **skupove podataka** koji zahtevaju specijalizovane softverske aplikacije za obradu. S druge strane, **rudarenje podataka ide korak dalje** jer uključuje analizu tako velikih količina podataka kako bi se otkrila skrivena pravila i obrasci koji možda nisu lako vidljivi.

Data Mining je širok pojam koji obuhvata različite analitičke tehnike, uključujući statistiku, veštačku inteligenciju i mašinsko učenje. Ove se metode koriste za filtriranje velikih količina podataka pohranjenih u bazama podataka ili mrežnim skladištima podataka organizacije. Primarni cilj je otkriti obrasce unutar skupa podataka. **Poslovna analitika (BA)** odnosi se na sveobuhvatan proces korišćenja veština, tehnologija, uspostavljenih praksi i algoritama povezanih s rudarenjem podataka. Stoga **rudarenje podataka obično služi kao pozadina BA funkcije**, dok se interfejs BA funkcije sastoji od metrika izveštavanja i informacija predstavljenih u formatu koji omogućuje menadžerima donošenje informisanih poslovnih odluka. Kada koriste rudarenje podataka, BA stručnjaci ponašaju se kao 'detektivi za podatke' (Lee, 2013), analizirajući podatke kako bi bolje opisali i razumeli sadašnju i prošlu situaciju organizacije (deskriptivna analitika), predvideli buduće ishode (prediktivna analitika) i poduzeli učinkovite radnje (preskriptivna analitika).

Data Mining ključna je komponenta procesa **otkrivanja znanja u bazama podataka (KDD)**, ali predstavlja samo jedan korak u celokupnom procesu. Aspekt rudarenja podataka unutar KDD procesa fokusiran je na korišćenje algoritama za izdvajanje i identifikovanje uzoraka iz podataka. U širem KDD procesu, ti izrudareni obrasci se procenjuju i potencijalno tumače kako bi se utvrdilo koji se obrasci mogu smatrati novim "znanjem" (Behera et al., 2019). Definisani na ovaj način, rudarenje podataka kao pozadina i otkrivanjem znanja kao nekom vrstom interfejsa BA, predstavljaju, zajedno s poslovnim podacima, njegove ključne stubove kako je navedeno u poglavlju 2.


Rudarenje podataka koristi razne algoritme za rudarenje ogromnih skupova podataka, identifikujući obrasce koji mogu dati vredne poslovne uvide. Rudarenje podataka je alat, a ne čarobno rešenje. Ne posmatra pasivno vašu bazu podataka i ne upozorava vas na zanimljive obrasce. I dalje je ključno razumijevanje vašeg poslovanja, vaših



podataka i analitičkih metoda. Rudarenje podataka pomaže poslovnim analitičarima otkriti obrasce i odnose u podacima, ali ne određuje vrednost tih obrazaca za organizacije. Stoga rudarenje podataka ne zamenjuje vešte poslovne analitičare, već im pruža snažan novi alat za poboljšanje njihovog rada.

Rudarenje podataka uključuje računarski proces identifikacije trendova, pravila, skrivenih obrazaca i drugih vrednih informacija analizom velikih skupova podataka. Tehnika rudarenja podataka korene ima u mnogim istraživačkim područjima, uključujući statistiku, mašinsko učenje, sisteme baza podataka, vizualizaciju, neuronske mreže itd. To je proces izvlačenja delotvornog znanja iz različitih izvora podataka raspoređenih u različite formate. Rudarenje podataka je poslednjih godina postalo sve relevantnije zbog napretka u tehnologijama čuvanja podataka (Big data), veštačke inteligencije (AI) i robotske automatizacije procesa (RPA).

Proces **otkrivanja znanja u bazama podataka (KDD)** uključuje korišćenje baze podataka, uključujući potrebnu selekciju, prethodnu obradu, poduzorkovanje i transformacije, za primenu algoritama rudarenja podataka za identifikaciju obrazaca (Behera et al., 2019). Takođe uključuje ocenjivanje rezultata rudarenja podataka. Uobičajeni standard za opisivanje koraka procesa otkrivanja znanja je CRISP-DM (eng. Cross-Industry Standard Process for Data Mining), koji je prikazan na slici 3.1.



Slika 3.1 Međustrani standardni proces za rudarenje podataka (CRISP-DM)

Izvor: Rahman et al. (2016).

Na slici 3.1, prva faza je poslovno razumevanje, što uključuje razumevanje ciljeva koji se žele postići i sprovođenje detaljnog utvrđivanja činjenica o resursima i pretpostavkama. Druga faza,




razumevanje podataka, istražuje različite deskriptivne karakteristike podataka. Treća faza, priprema podataka, najzahtjevniji je i najdugotrajniji deo procesa KDD-a, s ciljem izbora relevantnih podataka i njihovog prikladnog oblikovanja za analizu. Ova faza uključuje aktivnosti poput izbora podataka, filtriranja, transformacije i integracije. Četvrta faza, modeliranje, podrazumeva primenu analitičkih metoda i izbor najprikladnijih algoritama. Ova faza takođe uključuje proveru kvaliteta modela kroz testiranje i unakrsnu validaciju. Peta faza, evaluacija, uključuje interpretaciju i procenu otkrivenog znanja (Rahman et al., 2016).

3.2. Otkrivanje znanja u logistici i upravljanju lancem snabdevanja

U kontekstu lanaca snabdevanja i logistike, rudarenje podataka se razlikuje od drugih aplikacija opšte namene. Razlog je vezan uz već spomenutu raznolikost izvora podataka i struktura poslovnih podataka koji predstavljaju značajne izazove za inženjere pri dizajniranju odgovarajućih rešenja za modeliranje. Proces generisanja znanja iz podataka može se sažeti na slici 3.2.

Kao što je vidljivo na slici 3.2, otkrivanje i generisanje znanja iz podataka uvelike zavisi od izvora znanja i može se podeliti na **procenjeno** i **statističko**. Oba smera imaju svoje prednosti, ali je postupak izvlačenja znanja iz izvora bitno drugačiji. Za primenu formalnijeg pristupa rudarenja podataka, tj. statističkog pristupa, ključni temelj je postojanje kvantitativnih podataka. U lancima snabdevanja postoji veliki broj sektora, lokacija i transakcija koje generišu tokove podataka koji se mogu koristiti za rudarenje podataka i izvlačenje korisnih povratnih informacija. S druge strane, u lancu snabdevanja i logistici takođe postoji puno izvora podataka koji nisu kvantitativni, pa stoga nisu podvrgnuti formalnim kvantitativnim postupcima. Ti su podaci tradicionalno podvrgnuti stručnim procenama (Delphi metoda), a odluke se donose na osnovu iskustva, znanja i autoriteta stručnjaka.



Slika 3.2 Principi izvlačenja znanja iz podataka

Izvor: Autor.

U ovoj knjizi naglasak će biti stavljen na **kvantitativnim/matematičkim tehnikama**, iako će se ukratko spomenuti i neke metodologije za izvlačenje stručnog znanja u strukturiranim okvirima, tj. raspravljaće se o ekspertnom sistemu i njegovim primenama i primerima.

3.3. Delphi pristup prosudbenom stvaranju znanja

Vredna saznanja iskusnih stručnjaka u domenu lanca snabdevanja i logistike često ostaju neprepoznati. Ova saznanja treba podeliti s manje iskusnim stručnjacima u tom području. Delphi metoda je jedan od pristupa za prikupljanje i širenje stručnog znanja. Prema Steureru (2011), metoda Delphi, nazvana po proročištu u Delfima u staroj Grčkoj, koja se u početku koristila za savetovanje o raznim javnim i ličnim pitanjima u staroj Grčkoj, 1950-ih je evoluirala u tehniku u kojoj su stručnjaci zamenili proroke za postizanje konsenzusa među grupom stručnjaka u nekom području. „Projekt Delphi“, osnovan od strane Vazdušnih snaga SAD-a, bio je prvi projekat koji koristi ovu metodu za predviđanje tehnološkog razvoja. Od tada se Delphi metoda razvijala i poboljšavala, pronalazeći primene u raznim naučnim disciplinama. Delphi metoda razvijena je za postizanje pouzdanog stručnog konsenzusa, često služeći kao zamena za empirijske dokaze kada takvi dokazi nedostaju. To jest, Delphi tehnika je iterativni



proces u kojem stručnjaci anonimno daju procene o određenom pitanju, s ciljem prikupljanja konsenzusa i neslaganja zajedno sa svojim opravdanjima. To je visoko strukturirani grupni komunikacioni proces u kojem stručnjaci procenjuju nesigurna i nepotpuna znanja (Naisola-Ruiter, 2022). Prema Paivarinti et al. (2011), Delphi metoda se, među ostalim, intenzivno koristi u istraživanju informacionih sistema. Koristi se za izbor projekata IS-a, određivanje prioriteta za rizike projekta razvoja softvera, definisanje projektnih zahteva IS-a, preciziranje ključnih problema u upravljanju IS-om, stvaranje okvira za aktivnosti manipulacije znanjem, razumevanje uloga i opsega sistema upravljanja znanjem u organizacijama.

Delphi metoda je postala standardna praksa za kvantifikovanje ishoda grupnih procesa izvlačenja informacija. Koristi se u raznim disciplinama za predviđanje trendova, određivanje prioriteta istraživačkih područja, procenu mogućih učinaka izbora različitih politika, utvrđivanje pokazatelja uspešnosti i razvoj kliničkih smernica, među ostalim primenama. **Delphi tehnika se takođe koristi u području lanca snabdevanja i logistike.** Na primer, toplo se preporučuje kao instrument za identifikaciju i procenu rizika snabdevanja, za razne vrste evaluacije u logističkim procesima, za utvrđivanje najboljih logističkih praksi, za strateško odlučivanje i razvoj politike, za mapiranje budućih SCM praksi i za logističko predviđanje. Četiri ključne karakteristike ili osnovna načela Delphi metode su:

- Iterativni i višefazni proces (kao i prikupljanje podataka);
- Povratne informacije učesnika (kontrolisane na nekom nivou) s mogućnošću da učesnici revidiraju svoje odgovore;
- Statističko određivanje grupnog odgovora; i
- Određeni stepen anonimnosti.

Tipičan Delphi proces uključuje predstavljanje niza pitanja u više rundi. Panelisti, odabrani zbog svoje stručnosti i znanja, odgovaraju anonimno. Nakon svakog kruga sledi povratna informacija o agregiranim odgovorima, omogućujući učesnicima da vide kako se njihovi odgovori uspoređuju s odgovorima svih panelista. Panelisti tada mogu prilagoditi svoje odgovore i dati obrazloženja za sve promene u sledećim krugovima. Ovaj iterativni proces se nastavlja dok se ne postigne konsenzus ili dok se ne završi unapred određeni broj krugova.



Koraci u sprovođenju Delphi metode

Delphi metoda je strukturirani pristup koji podrazumeva prikupljanje stručnih uvida i mišljenja kako bi se postigao konsenzus o određenoj temi. Proces obično uključuje četiri glavna koraka (Slika 3.3).



Slika 3.3 Koraci u sprovođenju Delphi metode

Izvor: Steureru (2011).

Korak 1 - Definisanje ciljeva: Početni korak uključuje definisanje ciljeva i opsega Delphi studije. To uključuje identifikovanje specifičnih pitanja ili tema koje zahtevaju mišljenje stručnjaka i navođenje ključnih pitanja o kojima će se raspravljati. Ovaj temeljni korak osigurava fokus i relevantnost studije kroz celo vreme.

Korak 2 – Izbor stručnjaka: Izbor ispravne grupe stručnjaka ključan je za uspjeh i učinkovitost Delphi tehnike. Ti bi stručnjaci trebali imati odgovarajuće znanje, veštine i iskustvo u vezi s temom koja se proučava. Grupa bi trebala biti raznolika kako bi ponudila širok spektar gledišta. Broj učesnika može varirati zavisno od veličine i složenosti studije, ali generalno se savetuje uključivanje najmanje 10-15 stručnjaka.

Korak 3 – Razrada i pokretanje upitnika: Ovaj korak uključuje izradu upitnika za prikupljanje informacija od stručnjaka. Inicijalni upitnik je obično otvorenog tipa kako bi se stručnjacima omogućilo slobodno deljenje mišljenja bez uticaja. U 1. krugu stručnjaci dobijaju upitnik otvorenog tipa i samostalno daju mišljenja, predviđanja ili predloge u vezi s ciljevima studije. U 2. krugu moderator sažima i odgovore iz 1. kruga čini anonimnim kako bi izradio konkretniji upitnik za sledeći krug. Ako je potrebno, mogu se sprovesti dodatni krugovi za pročišćavanje mišljenja na bazi postignutih nivoa konsenzusa, nastavljajući dok se ne postigne unapred definisani konsenzus ili moderator ne odluči prekinuti proces.

Korak 3 – Razrada i pokretanje upitnika: Ovaj korak uključuje izradu upitnika za prikupljanje informacija od stručnjaka. Obično je početni upitnik otvorenog tipa kako bi se stručnjacima omogućilo slobodno deljenje mišljenja bez uticaja. U 1. krugu stručnjaci dobijaju



upitnik otvorenog tipa i samostalno daju mišljenja, predviđanja ili predloge u vezi s ciljevima studije. U 2. krugu voditelj sažima i anonimizuje odgovore iz 1. kruga kako bi izradio usredsređeniji upitnik za sledeći krug. Ako je potrebno, mogu se sprovesti dodatni krugovi za prečišćavanje mišljenja na osnovu postignutih nivoa konsenzusa, nastavljajući dok se ne postigne unapred definisani konsenzus ili moderator ne odluči prekinuti proces.

Korak 4 – Korišćenje rezultata: Nakon dovršetka Delphi procesa i postizanja konsenzusa, rezultati se analiziraju i koriste za donošenje odluka, predviđanje, razvoj politika ili druge svrhe navedene u ciljevima studije. Anonimnost Delphi studija pomaže osigurati da su konačni rezultati nepristrani i odražavaju kombinovanu stručnost uključenih stručnjaka.


3.4. Kvantitativni pristup rudarenju podataka za otkrivanje znanja

Kao što je prikazano na slici 3.2, **kvantitativno rudarenje podataka uveliko se oslanja na formalne matematičke alate, tačnije one statističke**. Može se tvrditi da se svaka statistička operacija nad podacima može smatrati kvantitativnom analizom. Glavna svrha ovih operacija je izvući stvarne obrasce iz podataka i dobiti korisne informacije u posmatranom procesu (u slučaju analize u preduzeću ili lancu snabdevanja). Ovo nije jednostavan zadatak budući da postoji značajna neusklađenost između pretpostavki statističke/matematičke teorije i distribucija i obrazaca koji su prisutni u stvarnim poslovnim podacima. Većina poslovnih analiza u praksi bazirana je na toj neusklađenosti. Kod primene kvantitativnih metoda od vitalne je važnosti da podaci ispunjavaju teorijske matematičke pretpostavke ograničene promatranim modelom, kako bi se rezultati modela tretirali kao valjani i potencijalno na bazi njih donosile odluke.

Kao što je objašnjeno u prethodnom poglavlju, metode rudarenja podataka čine baznu komponentu KDD procesa i stalno se koriste u njemu. Rudarenje podataka je multidisciplinarna tehnika, sa svojim analitičkim metodama baziranim na matematici. Statistika posebno igra vitalnu ulogu u analizi podataka tokom faze pripreme podataka, čineći temelj za nekoliko metoda rudarenja podataka. Rudarenje podataka uključuje korišćenje učinkovitih algoritama za otkrivanje očekivanih ili pretpostavljenih obrazaca. Kao što je prikazano na slici 3.4, **zadaci rudarenja podataka** mogu se klasifikovati u pet kategorija: grupisanje, klasifikacija, regresija, asocijacijska pravila i generalizacija. **Klasteriranje** ima za cilj grupisati objekte baze podataka tako da su objekti unutar klastera slični, dok su oni u drugim klasterima različiti.




Klasifikacija uključuje učenje funkcije koja dodeljuje vrednosti atributa unapred definiranim klasama. **Regresija**, statistička metoda, procenjuje odnose među varijablama i obično se koristi za predviđanje i predviđanje, a značajno se preklapa sa mašinskim učenjem. **Asocijacijska pravila** koriste se za opisivanje jakih odnosa unutar transakcijskih procesa, kao što je "ako A i B tada C". **Generalizacija** nastoji izraziti veliku količinu podataka što kompaktnije (Su, 2016). Glavne tehnike koje se koriste u rudarenju podataka su: pravila klasifikacije ili stabla odlučivanja, regresija, klasteriranje, genetski algoritmi, modeliranje bazirano na agentima itd.



Slika 3.4 Zadaci rudarenja podataka

Izvor: Su (2016).

Znanje se može izvući iz obrađenih kvantitativnih podataka. **KDD proces sastoji se od devet koraka** kao što je prikazano na slici 3.5. Važno je napomenuti da se rudarenje podataka sprovodi nad transformiranim podacima, pri čemu su nerelevantne informacije već isključene iz izvornog skupa podataka. Obrasci otkriveni kroz ovaj proces zatim se tumače i procenjuju unutar specifičnog konteksta kako bi se steklo znanje koje može pomoći u donošenju odluka.



Slika 3.5 Koraci koji čine KDD proces

Izvor: Fayyad et al. (1996).

Kao što je prethodno navedeno, zajednički standard za opisivanje koraka KDD procesa je CRISP-DM, koji predstavlja vodeći industrijski model. S obzirom na trenutne publikacije i studije koje je istražio Su (2016), tipične tehnike rudarenja podataka i primene u lancima snabdevanja uključuju:

- **Stabla odlučivanja:** Rešavanje problema dobavljača koji se mogu svesti npr. za svaku odluku, skup mogućih ishoda, zajedno s procenom verovatnosti da će se svaki ishod dogoditi;
- **Regresija:** Predviđanje i procena potražnje kupaca za novim proizvodom;
- **Asocijacijska pravila:** Identifikacija ključnog uzroka kvara proizvoda, optimiziranje proizvodnog kapaciteta i omogućavanje održavanja baziranog na stanju;
- **Genetski algoritam:** Evaluacija poboljšane hipoteze rada VMI-a u neizvesnom okruženju potražnje;
- **Algoritmi klasterisanja:** S k-Mean algoritmom za kategorizaciju vraćene robe kako bi se poboljšao kvalitet proizvodnih procesa ili raspoređivanje kupaca u različite segmente na osnovu njihove demografije i kupovnog ponašanja;
- **Sistem rudarenja podataka s više agenata:** podrška odlukama o planiranju proizvodnje na osnovu analize istorije potražnje za proizvodima.

Znanje izvučeno rudarenjem podataka obično se pohranjuje i prezentuje korišćenjem **ekspertskih sistema (ES)**. ES je sofisticirani sistem znanja dizajniran da oponaša ljudsku



stručnost u različitim područjima primene. Olson i Courtney (1992) definišu ES kao „računarski program unutar određenog domena, koji uključuje određenu količinu veštačke inteligencije za oponašanje ljudskog razmišljanja kako bi se došlo do istih zaključaka kao što bi to učinio ljudski stručnjak”. ES komponenta je idealna za pomoć donosiocu odluka u području gdje je potrebna stručnost (Turban, 1995). U osnovi, ES prenosi stručnost od stručnjaka (ili drugog izvora) na računar. Može podržati donosiocje odluka ili ih u potpunosti zameniti, a najprimenljivija je i komercijalno najuspešnija tehnologija veštačke inteligencije (Turban i dr., 2007.). Jedno od opravdanja za izgradnju ES-a je pružanje stručnog znanja velikom broju korisnika (Kock, 2005). Prema Turbanu et al. (2007), ES-ovi se smatraju delom sistema za podršku odlučivanju (eng. Decision Support Systems - DSS), koji bi se mogao okarakterisati kao informacioni sistem baziran na računaru koji kombinuje modele i podatke u pokušaju rešavanja polustrukturiranih i nestrukturiranih problema uz opsežno učestvovanje korisnika (Turban et al., 2007; Mirčetić et al., 2016). Sledeće poglavlje odnosi se na mašinsko učenje (ML), odnosno na sposobnost računara da uče i predstavljaju znanje iz ulaznih podataka. ML se može promatrati kao most između rezultata dobijenih rudarenjem podataka i alata poslovne inteligencije koji se koriste za predstavljanje metrike izveštavanja u formatu koji omogućuje menadžerima donošenje informisanih poslovnih odluka.

LITERATURA

1. Behera, P. C., Dash, C. & Mohapatra, S. (2019). Data Mining and Knowledge Discovery (KDD). International Journal of Research and Analytical Reviews, 6(1), pp. 101-106.
2. Fayyad, U. M., Patetsky-Shapiro, G. & Smith, P. (1996). From Data Mining to Knowledge Discovery in Databases. American Association for Artificial Intelligence, 17, pp. 37-34.
3. Kock, E. D. (2005) Decentralising the Codification of Rules in a Decision Support Expert Knowledge Base (MSc thesis). University of Pretoria; 2005. Available from: <http://repository.up.ac.za/handle/2263/22959>
4. Lee, P. M. (2013). Use of Data Mining in Business Analytics to Support Business Competitiveness. Review of Business Information Systems, 17(2), pp. 53-58.



5. Mirčetić, D., Ralević, N., Nikoličić, S., Maslarić, M. & Stojanović, Đ. (2016). Expert system models for forecasting forklifts engagement in a warehouse loading operation: A case study. *Promet-Traffic&Transportation*, 28(4), pp. 393-401.
6. Naisola-Ruiter, V. (2022). The Delphi technique: a tutorial. *Research in Hospitality Management*, 12(1), pp. 91-97.
7. Olson, D. L., Courtney, J. F. & Courtney, J. F. (1992). *Decision support models and expert systems*. New York: Macmillan, USA.
8. Paivarinta, T., Pekkola, S. & Moe, C. E. (2011). Grounding Theory from Delphi Studies. In: *Proceedings of the 32nd International Conference on Information Systems (ICIS 2011): Research Methods and Philosophy*, 4-7 December 2011, Shanghai, China.
9. Rahman, F. A., Shamsuddin, S. M., Hassan, S. & Haris, N. A. (2016). A Review of KDD-Data Mining Framework and Its Application in Logistics and Transportation. *International Journal of Supply Chain Management*, 2(1), pp. 1-9.
10. Steurer, J. (2011). The Delphi method: an efficient procedure to generate knowledge. *Skeletal Radiol*, 40, pp. 959-961.
11. Su, W. (2016). *Knowledge Discovery in Supply Chain Transaction Data by Applying Data Farming (Master thesis)*. Technical University of Dortmund, Dortmund, DE.
12. Turban, E. (1995). *Decision support and expert systems Management support systems*. Prentice-Hall, Inc. New York, USA.
13. Turban, E., Rainer, R. K. & Potter, R. E. (2007). *Introduction to Information Systems: Supporting and Transforming Business*. John Wiley & Sons, Inc. USA.