



3. RUDARENJE PODATAKA I OTKRIVANJE ZNANJA

Autor: Dejan Mirčetić

Kao 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 poduzećima tehnike rudarenja podataka imaju veliki utjecaj na ukupne performanse poduzeća, jer se operativne, taktičke i strateške odluke donose na temelju ulaznih informacija dobivenih procesom rudarenja podataka. U 1. poglavlju navedeno je da je u svijetu dosad kreirano više od 97 zetabajta podataka, pri čemu pojedine baze podataka često dosežu veličinu u terabajtima. U većini organizacija podaci se udvostručuju svake dvije godine. Podaci pohranjuju 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 dio ovih podataka može sadržavati pogreške zbog neprikladne pohrane ili oblikovanja ili ručnih pogrešaka tijekom prikupljanja podataka. Kao rezultat toga, nisu svi podaci koje organizacije posjeduju nužno točni ili pouzdani. Ipak, ova golema količina podataka sadrži vrijedne strateške informacije za tvrtke. Međutim, kada se suočite s tako velikom količinom složenih tipova podataka, kako se oni mogu učinkovito 'rudariti' da bi se izvukli značajni uvidi koje sadrže? Odgovor leži u rudarenju podataka, koje služi za povećanje prihoda i smanjenje troškova brzim i automatskim izvlačenjem korisnog znanja i poslovnih uvida iz ogromnih skupova podataka.

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

U sljedećim potpoglavljima govorit će se o tome kako se podaci 'rudare' za poslovnu analitiku i otkrivanje znanja.



3.1. Što je rudarenje podataka?

Prije definiranja rudarenja podataka, važno je smjestiti ovaj pojam u kontekst s drugim pojmovima s kojima se obično povezuje i često pogrešno poistovjećuje. Nestručnjaci često miješaju pojmove rudarenje podataka i Big data tehnologija. Međutim, to su dva različita pojma. **Big data opisuje** iznimno velike i složene **skupove podataka** koji zahtijevaju specijalizirane softverske aplikacije za obradu. S druge strane, **rudarenje podataka ide korak dalje** jer uključuje analizu tako golemih količina podataka kako bi se otkrila skrivena pravila i obrasci koji možda nisu lako vidljivi.

Rudarenje podataka je širok pojam koji obuhvaća različite analitičke tehnike, uključujući statistiku, umjetnu inteligenciju i strojno učenje. Ove se metode koriste za filtriranje golemih količina podataka pohranjenih u bazama podataka ili mrežnim spremištima organizacije. Primarni cilj je otkriti obrasce unutar skupa podataka. **Poslovna analitika (BA)** odnosi se na sveobuhvatan proces korištenja vještina, tehnologija, uspostavljenih praksi i algoritama povezanih s rudarenjem podataka. Stoga **rudarenje podataka obično služi kao pozadina BA funkcije**, dok se sučelje BA funkcije sastoji od metrika izvješćivanja i informacija predstavljenih u formatu koji omogućuje menadžerima donošenje informiranih poslovnih odluka. Kada koriste rudarenje podataka, BA stručnjaci ponašaju se kao 'podatkovni detektiv' (Lee, 2013), analizirajući podatke kako bi bolje opisali i razumjeli sadašnju i prošlu situaciju organizacije (deskriptivna analitika), predvidjeli buduće ishode (prediktivna analitika) i poduzeli učinkovite radnje (preskriptivna analitika).


Rudarenje podataka ključna je komponenta procesa **otkrivanja znanja u bazama podataka (KDD)**, ali predstavlja samo jedan korak u cjelokupnom procesu. Aspekt rudarenja podataka unutar KDD procesa usredotočen je na korištenje algoritama za izdvajanje i identificiranje uzoraka iz podataka. U širem KDD procesu, ti izrudareni obrasci se procjenjuju i potencijalno tumače kako bi se utvrdilo koji se obrasci mogu smatrati novim "znanjem" (Behera et al., 2019). Definirani na ovaj način, rudarenje podataka kao pozadina i otkrivanjem znanja kao nekom vrstom sučelja BA, predstavljaju, zajedno s poslovnim podacima, njegove ključne stupove kako je navedeno u poglavlju 2.

Rudarenje podataka koristi razne algoritme za rudarenje ogromnih skupova podataka, identificirajući obrasce koji mogu dati vrijedne poslovne uvide. Rudarenje podataka je alat, a ne čarobno rješenje. Ne promatra 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 vrijednost tih obrazaca za organizacije. Stoga rudarenje podataka ne zamjenjuje vješte poslovne analitičare, već im pruža snažan novi alat za poboljšanje njihovog rada.

Rudarenje podataka uključuje računalni proces identificiranja trendova, pravila, skrivenih obrazaca i drugih vrijednih informacija analizom velikih skupova podataka. Tehnika rudarenja podataka korijene ima u mnogim istraživačkim područjima, uključujući statistiku, strojno učenje, sustave baza podataka, vizualizaciju, neuronske mreže itd. To je proces izvlačenja djelotvornog znanja iz različitih izvora podataka raspoređenih u različite formate. Rudarenje podataka je posljednjih godina postalo sve relevantnije zbog napretka u tehnologijama pohrane podataka (Big data), umjetne inteligencije (AI) i robotske automatizacije procesa (RPA).

Proces **otkrivanja znanja u bazama podataka (KDD)** uključuje korištenje baze podataka, uključujući potrebnu selekciju, prethodnu obradu, poduzorkovanje i transformacije, za primjenu algoritama rudarenja podataka za identifikaciju obrazaca (Behera et al., 2019). Također uključuje ocjenjivanje 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 Međuindustrijski standardni proces za rudarenje podataka (CRISP-DM)

Izvor: Rahman et al. (2016)




Na slici 3.1, prva faza je poslovno razumijevanje, što uključuje razumijevanje ciljeva koji se žele postići i provođenje detaljnog utvrđivanja činjenica o resursima i pretpostavkama. Druga faza, razumijevanje podataka, istražuje različite deskriptivne karakteristike podataka. Treća faza, priprema podataka, najzahtjevniji je i najdugotrajniji dio procesa KDD-a, s ciljem odabira relevantnih podataka i njihovog prikladnog oblikovanja za analizu. Ova faza uključuje aktivnosti poput odabira podataka, filtriranja, transformacije i integracije. Četvrta faza, modeliranje, podrazumijeva primjenu analitičkih metoda i odabir najprikladnijih algoritama. Ova faza također uključuje provjeru kvalitete modela kroz testiranje i unakrsnu validaciju. Peta faza, evaluacija, uključuje interpretaciju i procjenu otkrivenog znanja (Rahman et al., 2016).

3.2. Otkrivanje znanja u logistici i upravljanju opskrbnim lancem

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

Kao što je vidljivo na slici 3.2, otkrivanje i generiranje znanja iz podataka uvelike ovisi o izvoru znanja i može se podijeliti na **prosudbeno** i **statističko**. Oba smjera imaju svoje prednosti, ali je postupak izvlačenja znanja iz izvora bitno drugačiji. Za primjenu formalnijeg pristupa rudarenja podataka, tj. statističkog pristupa, ključni temelj je postojanje kvantitativnih podataka. U opskrbnim lancima postoji velik broj sektora, lokacija i transakcija koje generiraju tokove podataka koji se mogu koristiti za rudarenje podataka i izvlačenje korisnih povratnih informacija. S druge strane, u opskrbnom lancu i logistici također postoji puno izvora podataka koji nisu kvantitativni, pa stoga nisu podvrgnuti formalnim kvantitativnim postupcima. Ti su podaci tradicionalno podvrgnuti stručnim procjenama (Delphi metoda), a odluke se donose na temelju iskustva, znanja i autoriteta stručnjaka.



Slika 3.2 Principi izvlačenja znanja iz podataka

Izvor: Armstrong (2001)

U ovoj knjizi naglasak će biti stavljen na **kvantitativnim/matematičkim tehnikama**, iako će se ukratko spomenuti i neke metodologije za dohvaćanje stručnog znanja u strukturiranim okvirima, tj. raspravljat će se o ekspertnom sustavu i njegovim primjenama i primjerima.

3.3. Delphi pristup prosudbenom stvaranju znanja

Vrijedni uvidi iskusnih stručnjaka u domeni opskrbnog lanca i logistike često ostaju neprepoznati. Ove uvide treba podijeliti 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 savjetovanje o raznim javnim i osobnim pitanjima u staroj Grčkoj, 1950-ih je evoluirala u tehniku u kojoj su stručnjaci zamijenili proroke za postizanje konsenzusa među grupom stručnjaka u nekom području. „Projekt Delphi“, osnovan od strane Zračnih snaga SAD-a, bio je prvi projekt koji koristi ovu metodu za predviđanje tehnološkog razvoja. Od tada se Delphi metoda razvijala i poboljšavala, pronalazeći primjene u raznim znanstvenim disciplinama. Delphi metoda razvijena je za postizanje pouzdanog stručnog konsenzusa, često služeći kao zamjena za empirijske dokaze kada takvi dokazi nedostaju. To jest, Delphi tehnika je iterativni



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

Delphi metoda je postala standardna praksa za kvantificiranje ishoda grupnih procesa izvlačenja informacija. Koristi se u raznim disciplinama za predviđanje trendova, određivanje prioriteta istraživačkih područja, procjenu mogućih učinaka izbora različitih politika, utvrđivanje pokazatelja uspješnosti i razvoj kliničkih smjernica, među ostalim primjenama. **Delphi tehnika se također koristi u području opskrbnog lanca i logistike.** Na primjer, toplo se preporučuje kao instrument za identifikaciju i procjenu rizika opskrbe, 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 sudionika (kontrolirane na nekoj razini) s mogućnošću da sudionici revidiraju svoje odgovore,
- Statističko određivanje grupnog odgovora, i
- Određeni stupanj anonimnosti.

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

3.3.1. Koraci u provođenju Delphi metode

Delphi metoda je strukturirani pristup koji podrazumijeva 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 provođenju Delphi metode

Izvor: Steurer (2011)

Korak 1 - Definiranje ciljeva: Početni korak uključuje definiranje ciljeva i opsega Delphi studije. To uključuje identificiranje specifičnih pitanja ili tema koje zahtijevaju mišljenje stručnjaka i navođenje ključnih pitanja o kojima će se raspravljati. Ovaj temeljni korak osigurava fokus i relevantnost studije kroz cijelo vrijeme.

Korak 2 – Odabir stručnjaka: Odabir ispravne grupe stručnjaka ključan je za uspjeh i učinkovitost Delphi tehnike. Ti bi stručnjaci trebali imati odgovarajuće znanje, vještine i iskustvo u vezi s temom koja se proučava. Grupa bi trebala biti raznolika kako bi ponudila širok spektar gledišta. Broj sudionika može varirati ovisno o veličini i složenosti studije, ali općenito se savjetuje 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 dijeljenje mišljenja bez utjecaja. U 1. krugu stručnjaci dobivaju upitnik otvorenog tipa i samostalno daju uvide, predviđanja ili prijedloge u vezi s ciljevima studije. U 2. krugu moderator sažima i anonimizira odgovore iz 1. kruga kako bi izradio konkretniji upitnik za sljedeći krug. Ako je potrebno, mogu se provesti dodatni krugovi za pročišćavanje mišljenja na temelju postignutih razina konsenzusa, nastavljajući dok se ne postigne unaprijed definirani 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 dijeljenje mišljenja bez utjecaja. U 1. krugu stručnjaci dobivaju upitnik otvorenog tipa i samostalno daju uvide, predviđanja ili prijedloge u vezi s ciljevima studije. U 2. krugu voditelj sažima i anonimizira odgovore iz 1. kruga kako bi izradio usredotočeniji upitnik za sljedeći krug. Ako je potrebno, mogu se provesti dodatni krugovi za pročišćavanje mišljenja na temelju postignutih razina konsenzusa, nastavljajući dok se ne postigne unaprijed definirani konsenzus ili moderator ne odluči prekinuti proces.




Korak 4 – Korištenje 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 kombiniranu stručnost uključenih stručnjaka.

3.4. Kvantitativni pristup rudarenju podataka za otkrivanje znanja

Kao što je prikazano na slici 3.2, **kvantitativno rudarenje podataka uvelike se oslanja na formalne matematičke alate, točnije one statističke**. Mogli bismo 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 uvide u promatranom procesu (u slučaju analize u poduzeću ili opskrbnom lancu). 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 temeljena je na toj neusklađenosti. Kod primjene 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 donosile odluke na temelju njih.

Kao što je objašnjeno u prethodnom poglavlju, metode rudarenja podataka čine temeljnu komponentu KDD procesa i stalno se koriste u njemu. Rudarenje podataka je multidisciplinarna tehnika, sa svojim analitičkim metodama utemeljenim na matematici. Statistika posebno igra vitalnu ulogu u analizi podataka tijekom faze pripreme podataka, čineći temelj za nekoliko metoda rudarenja podataka. Rudarenje podataka uključuje korištenje učinkovitih algoritama za otkrivanje očekivanih ili pretpostavljenih obrazaca. Kao što je prikazano na slici 3.4, **zadaci rudarenja podataka** mogu se klasificirati u pet kategorija: grupiranje, klasifikacija, regresija, asocijacijska pravila i generalizacija. **Klasteriranje** ima za cilj grupirati objekte baze podataka tako da su objekti unutar klastera slični, dok su oni u drugim klasterima različiti. **Klasifikacija** uključuje učenje funkcije koja dodjeljuje vrijednosti atributa unaprijed definiranim klasama. **Regresija**, statistička metoda, procjenjuje odnose među varijablama i obično se koristi za predviđanje i predviđanje, a značajno se preklapa sa strojnim 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 temeljeno 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 provodi nad transformiranim podacima, pri čemu su nerelevantne informacije već isključene iz izvornog skupa podataka. Obrasci otkriveni kroz ovaj proces zatim se tumače i procjenjuju 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 primjene u opskrbnim lancima uključuju:

- **Stabla odlučivanja:** Rješavanje problema dobavljača koji se mogu svesti npr. za svaku odluku, skup mogućih ishoda, zajedno s procjenom vjerojatnosti da će se svaki ishod dogoditi
- **Regresija:** Predviđanje i procjena potražnje kupaca za novim proizvodom
- **Asocijacijska pravila:** Identificiranje ključnog uzroka kvara proizvoda, optimiziranje proizvodnog kapaciteta i omogućavanje održavanja temeljenog na stanju
- **Genetski algoritam:** Evaluacija poboljšane hipoteze rada VMI-a u neizvjesnom okruženju potražnje
- **Algoritmi klasteriranja:** S k-Mean algoritmom za kategoriziranje vraćene robe kako bi se poboljšala kvaliteta proizvodnih procesa ili raspoređivanje kupaca u različite segmente na temelju njihove demografije i kupovnog ponašanja.
- **Sustav rudarenja podataka s više agenata:** podrška odlukama o planiranju proizvodnje na temelju analize povijesne potražnje za proizvodima

Znanje izvučeno rudarenjem podataka obično se pohranjuje i prezentira korištenjem **ekspertnih sustava (ES)**. ES je sofisticirani sustav znanja dizajniran da oponaša ljudsku stručnost u različitim područjima primjene. Olson i Courtney (1992) definiraju ES kao „računalni program unutar određene domene, koji uključuje određenu količinu umjetne 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 donositelju odluka u području gdje je potrebna stručnost (Turban, 1995). U osnovi, ES prenosi stručnost od stručnjaka (ili drugog izvora) na računalo. Može podržati donositelje odluka ili ih u potpunosti zamijeniti, a najprimjenjiva je i komercijalno najuspješnija tehnologija umjetne 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 dijelom sustava za potporu odlučivanju (eng. *Decision Support Systems* - DSS), koji bi se mogao okarakterizirati kao informacijski sustav temeljen na računalo koji kombinira modele i podatke u pokušaju rješavanja polustrukturiranih i nestrukturiranih problema uz opsežno sudjelovanje korisnika (Turban et al., 2007; Mirčetić et al., 2016). Sljedeće poglavlje odnosi se na strojno učenje (ML), koje se odnosi na sposobnost računala da uče i predstavljaju znanje iz ulaznih podataka. ML se može



promatrati kao most između rezultata dobivenih rudarenjem podataka i alata poslovne inteligencije koji se koriste za predstavljanje metrike izvješćivanja u formatu koji omogućuje menadžerima donošenje informiranih poslovnih odluka.

REFERENCE

1. Armstrong, J. S. (2001). Introduction. In Armstrong, J. S. (Ed.), *Principles of Forecasting: A Handbook for Researchers and Practitioners* (pp. 1-12), Springer Nature.
2. 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.
3. 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.
4. 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>
5. 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.
6. 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.
7. Naisola-Ruiter, V. (2022). The Delphi technique: a tutorial. *Research in Hospitality Management*, 12(1), pp. 91-97.
8. Olson, D. L., Courtney, J. F. & Courtney, J. F. (1992). *Decision support models and expert systems*. New York: Macmillan, USA.
9. 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.



10. 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.
11. Steurer, J. (2011). The Delphi method: an efficient procedure to generate knowledge. *Skeletal Radiol*, 40, pp. 959-961.
12. Su, W. (2016). Knowledge Discovery in Supply Chain Transaction Data by Applying Data Farming (Master thesis). Technical University of Dortmund, Dortmund, DE.
13. Turban, E. (1995). Decision support and expert systems Management support systems. Prentice-Hall, Inc. New York, USA.
14. Turban, E., Rainer, R. K. & Potter, R. E. (2007). Introduction to Information Systems: Supporting and Transforming Business. John Wiley & Sons, Inc. USA.