



3. PODATKOVNO RUDARJENJE IN ODKRIVANJE ZNANJA

Avtor: Dejan Mirčetić

Kot je opisano v poglavju 2, je koncept pridobivanja podatkov in ustvarjanja znanja iz njih tesno povezan s **tehnikami podatkovnega rudarjenja**. V sodobnih podjetjih imajo tehnike podatkovnega rudarjenja velik vpliv na splošno uspešnost podjetij, saj se operativne, taktične in strateške odločitve sprejemajo na podlagi vhodnih informacij, pridobljenih s postopkom podatkovnega rudarjenja. V poglavju 1 je bilo navedeno, da je na svetu več kot 97 zettabajtov podatkov, pri čemer posamezne podatkovne zbirke pogosto dosegajo velikost terabajtov. V večini organizacij se podatki podvojijo vsaki dve leti. Ti podatki so shranjeni na različnih platformah in v različnih oblikah, vključno s strukturiranimi, nestrukturiranimi in polstrukturiranimi podatki (glej poglavje 1). Ocenjuje se, da je do 90 % poslovnih podatkov v nestrukturirani obliki. Poleg tega lahko precejšen del teh podatkov vsebuje napake zaradi neustreznega shranjevanja ali oblikovanja ali ročnih napak med zbiranjem podatkov. Zato vsi podatki, ki jih imajo organizacije, niso nujno točni ali zanesljivi. Kljub temu ta velika količina podatkov vsebuje dragocene strateške informacije za podjetja. Vendar pa, ko se soočamo s tako veliko količino zapletenih vrst podatkov, kako jih lahko učinkovito "rudarimo", da bi iz njih pridobili pomembne informacije, ki jih vsebujejo? Odgovor je v podatkovnem rudarjenju, ki omogoča povečanje prihodkov in zmanjšanje stroškov s hitrim in samodejnim pridobivanjem uporabnega znanja in poslovnih vpogledov iz obsežnih zbirk podatkov.

Podatkovno rudarjenje je nastalo zaradi potrebe po učinkovitem pridobivanju dragocenih informacij, za kar so potrebne tehnike, ki se osredotočajo na prepoznavanje razumljivih vzorcev, ki jih je mogoče razlagati kot koristno ali zanimivo znanje. Tako **je podatkovno rudarjenje iterativen in interaktiven proces**, katerega cilj je odkrivanje veljavnega, novega, uporabnega in razumljivega znanja (vzorcev, modelov, pravil itd.) v obsežni zbirki podatkov (Behera et al., 2019). Glavni cilj podatkovnega rudarjenja je **odkriti kritična spoznanja**, ki **podpirajo sprejemanje odločitev** v poslovni organizaciji.

Naslednja podpoglavja bodo obravnavala, kako se podatki "rudarijo" za poslovno analitiko in odkrivanje znanja (Knowledge).



3.1. Kaj je podatkovno rudarjenje?

Pred opredelitvijo podatkovnega rudarjenja je treba ta izraz umestiti v kontekst izrazov, s katerimi je običajno povezan, s katerimi je povezan in s katerimi se pogosto napačno enači. Nestrokovnjaki pogosto zamenjujejo izraza podatkovno rudarjenje in tehnologija velikih količin podatkov. Vendar sta to dva ločena pojma. **Veliki podatki opisujejo** izjemno velike in zapletene **podatkovne nize**, ki za obdelavo zahtevajo specializirane programske aplikacije. Po drugi strani pa **je podatkovno rudarjenje še korak dlje**, saj vključuje analizo tako velikih količin podatkov za odkrivanje skritih pravil in vzorcev, ki morda niso takoj vidni.

Podatkovno rudarjenje je širok pojem, ki zajema različne analitične tehnike, vključno s statistiko, umetno inteligenco in strojnim učenjem. Te metode se uporabljajo za prebiranje velikih količin podatkov, shranjenih v podatkovnih zbirkah ali spletnih skladiščih organizacije. Glavni cilj je odkriti vzorce v naboru podatkov. **Poslovna analitika (BA)** se nanaša na celovit proces uporabe znanj, tehnologij, uveljavljenih praks in algoritmov, povezanih s podatkovnim rudarjenjem. Zato **podatkovno rudarjenje običajno služi kot zaledni del funkcije BA**, medtem ko je sprednji del funkcije BA sestavljen iz metrik za poročanje vodstvu in zbranih informacij, predstavljenih v obliki, ki vodjem omogoča sprejemanje utemeljenih poslovnih odločitev. Pri uporabi podatkovnega rudarjenja strokovnjaki za BA delujejo kot "podatkovni detektivi" (Lee, 2013), ki analizirajo podatke, da bi bolje opisali in razumeli sedanje in pretekle razmere v organizaciji (opisna analitika), napovedali prihodnje rezultate (napovedna analitika) in učinkovito ukrepali (predpisna analitika).


Podatkovno rudarjenje je osrednja sestavina procesa **odkrivanja znanja v podatkovnih zbirkah (KDD)**, vendar je le en korak v celotnem procesu. Vidik podatkovnega rudarjenja v procesu KDD se osredotoča na uporabo algoritmov za pridobivanje in prepoznavanje vzorcev iz podatkov. V širšem procesu KDD se ti izkopani vzorci ovrednotijo in morebiti interpretirajo, da se določi, kateri vzorci se lahko štejejo za novo "znanje" (Behera et al., 2019). Tako opredeljena, s podatkovnim rudarjenjem kot zaledjem in odkrivanjem Knolwedge kot nekakšnim sprednjim delom BA, predstavljata skupaj s poslovnimi podatki njegove ključne stebre, kot je opisano v poglavju 2.

Pri podatkovnem rudarjenju se uporabljajo različni algoritmi za rudarjenje ogromnih zbirk podatkov, pri čemer se ugotavljajo vzorci, ki lahko prinesejo dragocena poslovna spoznanja. Podatkovno rudarjenje je orodje in ne čarobna rešitev. Ne opazuje pasivno vaše zbirke podatkov in vas ne opozarja na zanimive vzorce. Ključnega

pomena ostaja razumevanje vašega poslovanja, vaših podatkov in analitičnih metod. Podatkovno rudarjenje pomaga poslovnim analitikom pri odkrivanju vzorcev in povezav v podatkih, vendar ne določa vrednosti teh vzorcev za organizacije. Zato podatkovno rudarjenje ne nadomešča usposobljenih poslovnih analitikov, temveč jim zagotavlja novo močno orodje za izboljšanje njihovega dela.

Podatkovno rudarjenje vključuje računalniški postopek prepoznavanja trendov, pravil, skritih vzorcev in drugih dragocenih informacij z analizo velikih zbirk podatkov. Podatkovno rudarjenje prevzema svoje tehnike s številnih raziskovalnih področij, vključno s statistiko, strojnim učenjem, sistemi podatkovnih baz, vizualizacijo, nevronske mreže itd. Gre za postopek pridobivanja uporabnega znanja iz različnih virov podatkov, razvrščenih v različnih oblikah. Podatkovno rudarjenje je v zadnjih letih postalo vse pomembnejše zaradi napredka tehnologij za shranjevanje podatkov (Big Data), umetne inteligence (AI) in robotske avtomatizacije procesov (RPA).

Postopek **odkrivanja znanja v podatkovnih zbirkah (KDD)** vključuje uporabo podatkovne zbirke, vključno s potrebno izbiro, predobdelavo, podvzorčenjem in preoblikovanjem, za uporabo algoritmov podatkovnega rudarjenja za prepoznavanje vzorcev (Behera et al., 2019). Vključuje tudi vrednotenje rezultatov podatkovnega rudarjenja. Skupni standard za opis korakov procesa odkrivanja znanja je CRISP-DM (Cross-Industry Standard Process for Data Mining), ki je prikazan na sliki 3.1.



Slika 3.1 Medpanožni standardni postopek za podatkovno rudarjenje (CRISP-DM)

Vir: Rahman et al. (2016).




Na sliki 3.1 je prva faza razumevanje poslovanja, ki vključuje razumevanje ciljev, ki jih je treba doseči, ter podrobno ugotavljanje dejstev o virih in predpostavkah. Druga faza, razumevanje podatkov, raziskuje različne opisne značilnosti podatkov. Tretja faza, priprava podatkov, je najzahtevnejši in dolgotrajnejši del postopka KDD, katere cilj je izbrati ustrezne podatke in jih ustrezno oblikovati za analizo. Ta faza vključuje dejavnosti, kot so izbira, filtriranje, preoblikovanje in povezovanje podatkov. Četrta faza, modeliranje, vključuje uporabo analitičnih metod in izbiro najprimernejših algoritmov. Ta faza vključuje tudi preverjanje kakovosti modela s testiranjem in navzkrižnim preverjanjem. Peta faza, vrednotenje, vključuje razlago in oceno odkritega znanja (Rahman et al., 2016).

3.2. Odkrivanje znanja v logistiki in upravljanju oskrbovalne verige

V kontekstu SC in logistike se podatkovno rudarjenje razlikuje od drugih aplikacij za splošne namene. Razlog je povezan z že omenjeno in obravnavano raznolikostjo podatkovnih virov in strukture poslovnih podatkov, ki inženirjem predstavljajo velik izziv pri oblikovanju ustreznih rešitev za modeliranje. Postopek ustvarjanja znanja iz podatkov je mogoče povzeti na sliki 3.2.

Na podlagi slike 3.2 je odkrivanje in ustvarjanje znanja iz podatkov zelo odvisno od vira znanja in ga lahko razdelimo na **presojevalno** in **statistično**. Obe smeri imata svoje prednosti, vendar se postopek pridobivanja znanja iz vira bistveno razlikuje. Za uporabo bolj formalnega pristopa za podatkovno rudarjenje, tj. statističnega pristopa, je ključni temelj obstoj kvantitativnih podatkov. V oskrbovalnih verigah obstaja veliko število sektorjev, lokacij in transakcij, ki ustvarjajo tokove podatkov, ki jih je mogoče uporabiti za podatkovno rudarjenje in pridobivanje koristnih povratnih informacij. Po drugi strani je v SC in logistiki tudi veliko virov podatkov, ki niso kvantitativni in zato niso predmet formalnih kvantitativnih postopkov. Namesto tega so ti podatki tradicionalno podvrženi presoji strokovnih skupin (metoda Delphi), odločitve pa se sprejemajo na podlagi izkušenj, znanja in avtoritete strokovnjakov.



Slika 3.2 Načela pridobivanja znanja iz podatkov

V tej knjigi bo poudarek na **kvantitativnih/matematičnih tehnikah**, čeprav bomo na kratko obravnavali nekatere metodologije za zajemanje strokovnega znanja v strukturirane okvire, tj. obravnavali bomo ES ter njegove aplikacije in primere.

3.3. Delphijev pristop k sodnemu ustvarjanju znanja

Dragoceni vpogledi izkušenih strokovnjakov s področja oskrbne verige in logistike pogosto ostanejo neprepoznani. Ta spoznanja je treba deliti z manj izkušenimi strokovnjaki na tem področju. Metoda Delphi je eden od pristopov za zbiranje in razširjanje strokovnega znanja. Po Steurerju (2011) se je delfska metoda, poimenovana po oraklju iz Delfov v antični Grčiji, ki so ga sprva uporabljali za posvetovanje o različnih javnih in osebnih zadevah v antični Grčiji, v petdesetih letih 20. stoletja razvila v tehniko, pri kateri strokovnjaki nadomestijo orakelj, da bi dosegli soglasje med skupino strokovnjakov na nekem področju. "Projekt Delfi", ki ga je financiralo ameriško letalstvo, je bil prvi projekt, pri katerem je bila ta metoda uporabljena za napovedovanje tehnološkega razvoja. Od takrat se je metoda Delphi razvijala in izpopolnjevala ter se uporabljala na različnih znanstvenih področjih. Metoda Delphi je bila razvita za doseganje zanesljivega soglasja strokovnjakov in pogosto služi kot nadomestek za empirične dokaze, kadar ti manjkajo. To pomeni, da je tehnika Delphi iterativni postopek, v katerem strokovnjaki



anonimno podajajo ocene o določenem vprašanju, da bi zbrali soglasje in nestrinjanje skupaj z njihovimi utemeljitvami. Gre za visoko strukturiran proces skupinske komunikacije, v katerem strokovnjaki ocenjujejo negotovo in nepopolno znanje (Naisola-Ruiter, 2022). Po navedbah Paivarinta et al. (2011) se metoda Delphi med drugim pogosto uporablja v raziskavah informacijskih sistemov. Uporablja se pri izbiri projektov IS, določanju prioritet tveganj projektov razvoja programske opreme, opredelitvi zahtev projektov IS, določanju ključnih vprašanj pri upravljanju IS, oblikovanju okvira za dejavnosti ravnanja z znanjem, razumevanju vlog in obsega sistemov za upravljanje znanja v organizacijah ter preučevanju raziskav IS na področju offshoringa.

Metoda Delphi je postala standardna praksa za kvantifikacijo rezultatov skupinskih postopkov pridobivanja informacij. Uporablja se na različnih področjih, med drugim za napovedovanje trendov, določanje prednostnih raziskovalnih področij, ocenjevanje morebitnih učinkov različnih političnih odločitev, določanje kazalnikov uspešnosti in razvijanje kliničnih smernic.

Tehnika Delphi se uporablja tudi na področju nadzora in logistike. Zelo priporočljiva je na primer kot instrument za ugotavljanje in ocenjevanje tveganj pri oskrbi, za različne vrste vrednotenja v logističnih procesih, za določitev najboljših logističnih praks, za strateško odločanje in razvoj politik, za kartiranje prihodnjih praks SCM in za logistično napovedovanje. Štiri ključne značilnosti ali osnovna načela metode Delphi so:

- Iterativni in večstopenjski postopek (in tudi zbiranje podatkov);
- Povratne informacije za udeležence (v določeni meri nadzorovane) z možnostjo, da udeleženci popravijo svoje odgovore;
- Statistično določanje odziva skupine in
- Določena stopnja anonimnosti.

Tipičen postopek Delphi vključuje predstavitev vrste vprašanj v več krogih. Člani panela, izbrani zaradi svojega strokovnega znanja in izkušenj, odgovarjajo anonimno. Vsakemu krogu sledijo povratne informacije o zbranih odgovorih, kar udeležencem omogoča, da vidijo, kako so njihovi odgovori primerljivi z odgovori celotne skupine. Udeleženci panela lahko nato prilagodijo svoje odgovore in v naslednjih krogih utemeljijo morebitne spremembe. Ta ponavljajoči se postopek se nadaljuje, dokler ni doseženo soglasje ali dokler se ne zaključi vnaprej določeno število krogov.

Koraki za izvedbo metode Delphi

Metoda Delphi je strukturiran pristop, ki vključuje zbiranje strokovnih spoznanj in mnenj za doseg soglasja o določeni temi. Postopek običajno vključuje štiri glavne korake (slika 3.3).



Slika 3.3 Koraki za izvedbo metode Delphi

Korak 1 - Opredelitev ciljev: Prvi korak vključuje opredelitev ciljev in obsega delfske študije. To vključuje opredelitev posebnih vprašanj ali tem, ki zahtevajo prispevek strokovnjakov, in oris ključnih vprašanj, o katerih je treba razpravljati. Ta temeljni korak zagotavlja, da študija ves čas ohranja osredotočenost in ustreznost.

Korak 2 - Izbira strokovnjakov: Izbira prave skupine strokovnjakov je bistvenega pomena za uspeh in učinkovitost tehnike Delphi. Ti strokovnjaki morajo imeti ustrezno znanje, spretnosti in izkušnje v zvezi s preučevanim predmetom. Skupina mora biti raznolika, da ponudi širok spekter stališč. Število udeležencev se lahko razlikuje glede na velikost in zapletenost študije, vendar je na splošno priporočljivo vključiti vsaj 10-15 strokovnjakov.

Korak 3 - Priprava in uvedba vprašalnikov: Ta korak vključuje pripravo vprašalnikov za zbiranje podatkov od strokovnjakov. Običajno je začetni vprašalnik odprtega tipa, da lahko strokovnjaki svobodno in brez vpliva delijo svoja mnenja. V prvem krogu strokovnjaki prejmejo vprašalnik odprtega tipa in neodvisno posredujejo vpoglede, napovedi ali predloge, povezane s cilji študije. V 2. krogu moderator povzame in anonimizira odgovore iz 1. kroga, da oblikuje bolj osredotočen vprašalnik za naslednji krog. Če je potrebno, se lahko izvedejo dodatni krogi za izpopolnitev mnenj na podlagi doseženih ravni soglasja, kar se nadaljuje, dokler ni doseženo vnaprej določeno soglasje ali dokler se moderator ne odloči za zaključek postopka.


Korak 4 - Uporaba rezultatov: Po končanem postopku Delphi in doseženem soglasju se rezultati analizirajo in uporabijo za odločanje, napovedovanje, razvoj politike ali druge namene, opredeljene v ciljih študije. Anonimnost študij Delphi pomaga zagotoviti, da so končni rezultati nepristranski in odražajo skupno strokovno znanje vključenih strokovnjakov.



3.4. Kvantitativni pristop podatkovnega rudarjenja za odkrivanje znanja

Kot je prikazano na sliki 3.2, se kvantitativno **podatkovno rudarjenje močno opira na formalna matematična orodja, bolj neposredno na statistična**. Lahko trdimo, da lahko vsako statistično operacijo na podatkih obravnavamo kot kvantitativno analizo. Glavni namen teh operacij je iz podatkov izluščiti prave vzorce in ustvariti koristne vpogleds v opazovani proces (če gre za analizo v poslovnih ali oskrbovalnih verigah). To ni enostavna naloga, saj obstaja precejšnje neskladje med predpostavkami statistične/matematične teorije ter porazdelitvami in vzorci, ki so prisotni v dejanskih poslovnih podatkih. Večina poslovnih analiz v praksi ima glavni tok, ki temelji na tem neskladju. Pri uporabi kvantitativnih metod je bistvenega pomena, da podatki izpolnjujejo teoretične matematične predpostavke, ki jih omejuje opazovani model, da bi lahko rezultate modela obravnavali kot veljavne in na njihovi podlagi sprejemali odločitve.


Kot je opisano v prejšnjem razdelku, so metode podatkovnega rudarjenja osrednja sestavina postopka KDD in se v njem večkrat uporabljajo. Podatkovno rudarjenje je multidisciplinarna tehnika, katere končne analitične metode temeljijo na matematiki. Zlasti statistika ima ključno vlogo pri analizi podatkov v fazi priprave podatkov in je temelj več metod podatkovnega rudarjenja. Podatkovno rudarjenje vključuje uporabo učinkovitih algoritmov za odkrivanje pričakovanih ali verjetnih vzorcev. Kot je prikazano na sliki 3.4, lahko **naloge podatkovnega rudarjenja** razvrstimo v pet kategorij: grozdenje, klasifikacija, regresija, asociacijska pravila in posploševanje. Cilj **grozdenja** je združiti predmete podatkovne zbirke tako, da so si predmeti v grozdu podobni, predmeti v različnih grozdih pa so si različni. **Klasifikacija** vključuje učenje funkcije, ki dodeljuje vrednosti atributov vnaprej določenim razredom. **Regresija**, statistična metoda, ocenjuje odnose med spremenljivkami in se pogosto uporablja za napovedovanje in napovedovanje ter se precej prekriva s strojnimi učenjem. **Asociacijska pravila** se uporabljajo za opis močnih povezav znotraj transakcijskih procesov, kot je "ko A in B, potem C". Namen **posploševanja** je čim bolj kompaktno izraziti veliko količino podatkov (Su, 2016). Glavne tehnike, ki se uporabljajo pri podatkovnem rudarjenju, so: klasifikacijska pravila ali odločitvena drevesa, regresija, grozdenje, genetski algoritmi, agentno modeliranje itd.



Slika 34 Naloge podatkovnega rudarjenja

Vir: Su (2016).

Znanje je mogoče pridobiti iz obdelanih kvantitativnih podatkov. **Postopek KDD obsega devet korakov**, kot je prikazano na sliki 3.5. Pomembno je poudariti, da se podatkovno rudarjenje izvaja na preoblikovanih podatkih, pri čemer so nepomembne informacije že izključene iz prvotnega nabora podatkov. Vzorci, odkriti v tem postopku, se nato interpretirajo in ovrednotijo v določenem kontekstu, da se pridobi znanje, ki je lahko v pomoč pri sprejemanju odločitev.



Slika 35 Koraki, ki sestavljajo postopek KDD

Vir: Fayyad et al. (1996).

Kot je bilo že navedeno, je skupni standard za opis korakov procesa KDD CRISP-DM, ki predstavlja vodilni industrijski model. Glede na trenutne objave in raziskave na, ki jih je



pregledal Su (2016), tipične tehnike in aplikacije podatkovnega rudarjenja v oskrbovalnih verigah vključujejo:

- **Odločitvena drevesa:** Za vsako odločitev je na primer treba navesti niz možnih izidov, skupaj z oceno verjetnosti, da se bo vsak izid zgodil.
- **Regresija:** Napovedovanje in ocenjevanje povpraševanja kupcev po novem izdelku
- **Pravilo asociacije:** ugotavljanje vzrokov za okvare izdelkov, optimizacija proizvodnih zmogljivosti in omogočanje vzdrževanja na podlagi stanja.
- **Genetski algoritem:** Vrednotenje izboljšane hipoteze delovanja VMI v okolju z negotovim povpraševanjem
- **Algoritmi za grozdenje:** Z algoritmom k-Mean kategoriziramo vrnjeno blago, da bi izboljšali kakovost proizvodnih procesov ali razporedili stranke v različne segmente na podlagi njihovih demografskih podatkov in nakupnega vedenja.
- **Sistem podatkovnega rudarjenja z več agenti:** Podpora odločitvam pri načrtovanju proizvodnje na podlagi analize preteklega povpraševanja po izdelkih

Znanje, pridobljeno s podatkovnim rudarjenjem, je običajno shranjeno in predstavljeno s pomočjo **ekspertnih sistemov (ES)**. ES je izpopolnjen sistem znanja, zasnovan za posnemanje človeškega strokovnega znanja na različnih področjih uporabe. Olson in Courtney (1992) sta ES opredelila kot "računalniški program na določenem področju, ki vključuje določeno količino umetne inteligence za posnemanje človeškega razmišljanja, da bi prišel do enakih zaključkov, kot bi jih prišel človeški strokovnjak". Komponenta ES je idealna za pomoč odločevalcu na področju, kjer je potrebno strokovno znanje (Turban, 1995). V bistvu ES prenaša strokovno znanje od strokovnjaka (ali drugega vira) na računalnik. Lahko pomaga odločevalcem ali pa jih popolnoma nadomesti in je najbolj razširjena in komercialno uspešna tehnologija umetne inteligence (Turban et al., 2007). Ena od utemeljitev za izgradnjo ES je zagotavljanje strokovnega znanja velikemu številu uporabnikov (Kock, 2005). Po Turbanu in drugih (2007) se ES obravnavajo kot del sistema za podporo odločanju (DSS), ki bi ga lahko opredelili kot računalniško podprt informacijski sistem, ki združuje modele in podatke v poskusu reševanja polstrukturiranih in nestrukturiranih problemov z obsežno udeležbo uporabnikov (Turban in drugi, 2007; Mirčetić in drugi, 2016). V naslednjem poglavju je obravnavano strojno učenje (angl. Machine Learning, ML), ki se nanaša na sposobnost računalnikov, da se učijo in predstavljajo znanje iz vhodnih podatkov. ML je mogoče obravnavati kot most med rezultati, ki jih ustvari podatkovno rudarjenje, in orodji za poslovno



obveščanje, ki se uporabljajo za predstavitev metrik za vodstveno poročanje v obliki, ki vodjem omogoča sprejemanje utemeljenih poslovnih odločitev.

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.