

2. ANALITIKA POSLOVNIH PODATAKA

Autor: Dejan Mirčetić

U eri digitalizacije, zbog ogromne količine podataka koji se svakodnevno generišu, tradicionalna znanja i pristupi ne mogu se koristiti za upravljanje poslovnim procesima u različitim područjima, pa tako ni za upravljanje logistikom i lancima snabdevanja (Nikolić et al., 2019). Web 2.0, zajedno s industrijom 4.0, računarstvom u oblaku, Internetom stvari (IoT), RFID-om i drugim digitalnim tehnologijama doveli su do generisanja, čuvanja i prenosa velikih količina podataka. Kako se obim i složenost podataka povećava, tako raste i složenost i vreme potrebno za analizu tih podataka i izvlačenje zaključaka iz njih.

Koncept Big data prvi su predstavili Cox i Ellsworth u oktobru 1997., u radu objavljenom na ACM Digital Library (Tiwari et al., 2018). Proučavanje velikih podataka i njihova konceptualizacija kontinuirano se razvijaju. U početku je Big data karakterisao koncept 3V, koji je obuhvatao **volumen**, **brzinu** i **raznolikost**, kao što je objašnjeno u prethodnom poglavlju. Kasnije se ovaj koncept proširio na koncept 5V, uključivši dva dodatna atributa: **istinitost** (eng. Veracity) i **vrednost** (eng. Value) (Nguyen et al., 2018; Tiwari et al., 2018). Volumen se odnosi na količinu generisanih podataka budući da količina digitalnih podataka eksponencijalno raste (Arunachalam et al., 2018.). Raznolikost se odnosi na činjenicu da se podaci mogu generisati iz heterogenih unutrašnjih i spoljnih izvora, u strukturiranim, polustrukturiranim i nestrukturiranim formatima. Brzina se odnosi na brzinu generisanja i isporuke podataka, koji se mogu obrađivati u serijama, u realnom vremenu ili gotovo u realnom vremenu. Istinitost naglašava važnost kvaliteta podataka jer mnogi izvori podataka sami po sebi sadrže određeni stepen nesigurnosti i nepouzdanosti. Vrednost se odnosi na pronalaženje nove vrednosti sadržane u podacima koja se može koristiti za bolje poslovno planiranje (Nguyen et al., 2018).

Analitika velikih podataka (Big Data Analytics - BDA) uključuje dve dimenzije: **velike podatke - Big data (BD)** opisan konceptom 5V i **poslovnu analitiku (BA)** koja omogućuje dobijanje informacija iz podataka primenom statistike, matematike, ekonometrije, simulacija, optimizacija ili drugih tehnika koje pomažu da poslovne organizacije donose bolje odluke (Wang et al., 2016). Analitika velikih podataka uključuje korišćenje naprednih analitičkih tehnika za izvlačenje vrednog znanja iz ogromnih količina podataka različitih tipova kako bi se izvukli zaključci otkrivanjem skrivenih obrazaca i korelacija, trendova i drugih

poslovno vrednih informacija i znanja, s ciljem povećanja poslovne koristi, operativne učinkovitosti i istraživanja novih tržišta i prilika (Nguyen et al., 2018; Tiwari et al., 2018). BDA je privukao značajnu pažnju u različitim područjima, kako akademskim tako i poslovnim, posebno u logistici i upravljanju lancima snabdevanja.

2.1. BDA u logistici i upravljanju lancima snabdevanja


Lanci snabdevanja (eng. Supply chains - SC) predstavljaju mrežu kompanija uključenih u transformaciju sirovina u gotove proizvode i distribuciju gotovih proizvoda krajnjim kupcima. U lancima snabdevanja postoje fizički, finansijski i informacioni tokovi među različitim kompanijama. Svakim danom lanci snabdevanja postaju sve složeniji, prošireniji i globalniji. Stoga, za uspješnu implementaciju i upravljanje postojećim procesima u lancima snabdevanja i njihovo kontinuirano usklađivanje s tržišnim uslovima, savremeni lanac snabdevanja treba vešte stručnjake. Kako bi odgovorili na ove izazovne zadatke, stručnjaci iz područja upravljanja lancima snabdevanja trebaju formalno obrazovanje koje će im pružiti znanja i vještine iz različitih područja, prvenstveno iz logistike, informacionih tehnologija i ekonomije.

Lanac snabdevanja je skup fizičkih elemenata, njihovih aktivnosti i procesa kroz koje se odvija njihova interakcija. Fizički elementi, koji čine lančanu strukturu, predstavljaju fiksni deo lanca snabdevanja. Na strateškom nivou donose se odluke o oblikovanju strukture lanca snabdevanja, a na taktičkom i operativnom nivou odluke o modalitetima i pravilima realizacije pojedinih logističkih procesa. Oblikovanje fiksnog lanca snabdevanja i upravljanje izvrsnim radom zajedno osiguravaju upravljanje lancem snabdevanja koje definiše učinak lanca. U skladu sa tim, upravljački okvir lanca snabdevanja sastoji se od tri osnovna elementa: (1) struktura lanca snabdevanja; (2) poslovni procesi; (3) i upravljačke komponente. Svaki od ovih elemenata direktno je povezan s ciljevima lanca snabdevanja, odnosno sa stepenom ispunjenosti zahteva krajnjih korisnika, uz uvažavanje kritičnih dimenzija poslovanja od kojih zavisi nastup na tržištu (ključni pokazatelji performansi – KPI). U modernom svetu ne takmiče se više preduzeća, već njihovi lanci snabdevanja. Učinkovito upravljanje lancem snabdevanja je stoga postalo potencijalno vredan način osiguravanja konkurentске prednosti i poboljšanja organizacionog učinka.

Preduzeća su pod velikim pritiskom da poboljšaju planiranje i performanse lanca snabdevanja zbog sve veća neizvesnosti i konkurencije. Poboljšanje performansi lanca snabdevanja postalo je kontinuirani proces koji zahteva analitički sistem merenja performansi. S obzirom na brojnost i raznolikost logističkih procesa i procesa u lancima

snabdevanja, resurse koji se koriste za njihovu realizaciju, parametre koji ih karakterišu, koristi se veliki broj podataka za određivanje performansi lanca snabdevanja. To su podaci o: geografskim, vremenskim i količinskim odrednicama robe, transportna sredstva, transportno - manipulativna sredstva, skladišni kapaciteti, zaposleni itd. Podaci generisani kroz interno poslovanje, kao i transakcije s dobavljačima i kupcima, mogu se koristiti za otkrivanje malih promena koje mogu imati veliki uticaj na organizaciju s obzirom na povećanje učinkovitosti, pa čak i ušteda troškova. Drugim rečima, količina podataka u svakom lancu snabdevanja eksplodira iz različitih izvora podataka, poslovnih procesa i IT sistema. Kako se obim i složenost podataka povećava, tako raste i složenost i vreme potrebno za analizu tih podataka i izvlačenje zaključaka iz njih. Određivanje, praćenje i poboljšanje performansi logistike i lanca snabdevanja postaje složeniji i uključuje mnoge procese kao što su identifikacija mera, definisanje ciljeva, planiranje, komunikacija, praćenje, izveštavanje i povratne informacije. Posledično, konvencionalni pristupi ne mogu se koristiti za donošenje odluka i upravljanje lancem snabdevanja.

U području upravljanja lancem snabdevanja, interes za poslovnu analitiku raste. Ona se naziva još i **analitika lanca snabdevanja (SCA)**. SCA se koristi kao sinonim za pojmove kao što su 'Big Data analitika' i 'poslovna analitika' unutar poslovnih i akademskih zajednica (Srinivasan i Swink, 2018.). SCA se odnosi na korišćenje podataka i kvantitativnih alata i tehnika za poboljšanje operativnih performansi, često merenih metrikama kao što su ispunjavanje narudžbina i fleksibilnost. Analitika u lancima snabdevanja nije nužno nova ideja jer se različite kvantitativne tehnike i metode modeliranja već dugo koriste u proizvodnim kompanijama. Nedavni porast interesa za SCA praćen je novim izazovima i prilikama u poslovnom i informatičkom okruženju. Ti izazovi uključuju probleme koji proizlaze iz upravljanja velikim količinama podataka (npr. dostupnost podataka i kvalitet podataka) i suočavanje s neizvesnostima u okruženju. Pravilno primenjen SCA može uticati na nekoliko područja u lancu snabdevanja i može generisati značajne prednosti u logističkim performansama: poboljšano planiranje i raspoređivanje; poboljšani odziv; poboljšano planiranje potražnje; optimizacija narudžbi; optimizirano upravljanje zalihama; poboljšano planiranje popunjavanja zaliha. Poslednjih decenija, pod uticajem tehnološkog razvoja, globalizacije i sve zahtjevnijih kupaca, promenile su se i poslovne paradigme. Slika 2.1 prikazuje tipična razdoblja (s kratkim opisom) u evoluciji logistike, SCM i BDA.




Slika 2.1 Evolucija logistike, SCM-a i BDA

Izvor: Prilagođeno prema Arunachalam et al. (2018).

2.2. Alati u analitici poslovnih podataka

Slika 2.2 prikazuje različite trendove, alate i prednosti koje se koriste u BDA ili SCA. Sve predstavljene analitičke tehnike mogu se kategorizovati u tri vrste: deskriptivne, prediktivne i preskriptivne. **Deskriptivna analitika** posmatra podatke i analizira prošle događaje radi uvida u to kako pristupiti budućnosti. Traži se odgovor iz prošlih neuspeha i uspeha. **Prediktivna analitika** koristi istorijske podatke kako bi odredila verovatni budući ishod nekog događaja ili verovatnost da se situacija dogodi. Ona iskorišćava obrasce pronađene u podacima za prepoznavanje budućih rizika i prilika. **Preskriptivna analitika** automatski sintetizuje velike podatke, poslovna pravila i mašinsko učenje za predviđanje budućnosti. Ona prevazilazi predviđanje budućnosti sugerišući radnje koje je potrebno poduzeti kako bi se postigli željeni ciljevi. Takođe, njome je moguće pokazati implikacije svake moguće odluke i delovati kao alat za podršku odlučivanju za stručnjake iz područja SCM-a. U sledećim potpoglavljima biće predstavljeni i opisani različiti analitički alati koji se koriste za BDA u SCM-u. Dodatno, fokus će biti na strategijama o tome kako unaprediti znanje o BDA za stručnjake 21. veka, putem nekoliko studija slučaja.



Slika 2.2 Trendovi, alati i koristi SCA

Izvor: Autor.

2.2.1. Deskriptivna analitika

Deskriptivna analitika daje sažetak deskriptivne statistike za određeni uzorak podataka, na primer: srednja vrednost, mod, medijana, raspon, histogram i standardna devijacija. Deskriptivna analitika opisuje šta se dogodilo u prošlosti i izvodi informacije iz značajnih količina podataka kako bi odgovorila na pitanje šta se događa. Na osnovu informacija u stvarnom vremenu o lokacijama i količinama robe u lancu snabdevanja, menadžeri donose odluke na operativnom nivou (npr. prilagođavaju raspored otpreme, raspoređuju vozila, izdaju naloge za obnavljanje zaliha proizvoda itd.) (Souza, 2014). Deskriptivna analitika pokušava identifikovati prilike i probleme korišćenjem online sistema analitičke obrade i alata za vizualizaciju podržanih informacijama u stvarnom vremenu i tehnologijom izveštavanja (npr. GPS, RFID, transakcijski bar-kod). Uobičajeni primeri deskriptivne analitike su izveštaji koji pružaju istorijske uvide u proizvodnju, finansije, poslovanje, prodaju, zalihe i kupce kompanije (Tiwari et al., 2018.).

2.2.2. Prediktivna analitika

Prediktivna analitika koristi istorijske podatke kako bi odredila verovatni budući ishod. Prediktivna analitika u lancima snabdevanja izvodi prognoze potražnje iz prošlih podataka i odgovara na pitanja koja se odnose na ono što će se dogoditi ili što će se verovatno dogoditi (Tiwari et al., 2018.). Koristi veštačku inteligenciju, optimizacione algoritme i ekspertske sistema za predviđanje budućih ponašanja na bazi obrazaca otkrivenih u prošlosti i pretpostavke da će se istorija ponoviti. Iskorišćava obrasce pronađene u podacima za prepoznavanje budućih rizika i prilika kao i predviđanje budućnosti. Na ovaj način se popunjavaju informacije koje nedostaju i istražuju obrasci podataka pomoću statistike, simulacije i programiranja.

2.2.3. Preskriptivna analitika

Preskriptivna analitika izvodi preporuke za donošenje odluka na temelju deskriptivnih i prediktivnih analitičkih modela kao i na temelju matematičke optimizacije, simulacija ili višekriterijskih tehnika odlučivanja. Preskriptivna analitika prevazilazi predviđanje budućih ishoda tako što takođe donosiocu odluka pokazuju i implikacije svake opcije odluke. Preskriptivna analitika odgovara na pitanje šta bi se trebalo događati.


2.3. BDA ekosistem

Glavna svrha BDA ekosistema je isporuka vrednosti za donosiocima odluka. S tim u skladu, BDA ima primarni cilj omogućiti uvid u poslovne procese i odgovoriti kako smanjiti troškove i povećati nivo usluge za krajnje kupce. Kako bi se ispunio cilj, BDA rešenja obično se isporučuju u obliku sistema za podršku odlučivanju (DSS) ili ekspertnog sistema (ES). Stoga će se u ovom i narednim potpoglavljima pojasniti ključni stubovi BDA: **poslovni podaci**, **rudarenje podataka** i **otkrivanje znanja** (analiza podataka, DSS, ES platforme itd.).

2.3.1. Poslovni podaci

Pojam podatka detaljno je objašnjen u prvom poglavlju ove knjige. Podaci su ključni faktor za sprovođenje bilo kakve analize. **Poslovni podaci** nastaju kao rezultat izvođenja procesa u određenom poslovnom okruženju. U slučaju lanca snabdevanja, postoji mnogo procesa i podprocesa uključenih u isporuku usluge krajnjem korisniku (slika 2.3).

Slika 2.3 predstavlja strukturu lanca snabdevanja gde se u slučaju SCA-a svaki od navedenih procesa može posmatrati kao generator poslovnih podataka. Generisani podaci različiti su po važnosti i uticaju na krajnje ciljeve preduzeća. Shodno tome, poslovni podaci mogu se podeliti na **interno vođene** i **eksterno vođene** podatke. Interno vođeni podaci su podaci koji nastaju kao rezultat strukture kompanije, hijerarhije i načina na koji je kompanija odlučila poslovati (na primer, podaci o proizvodnji, podaci o ljudskim resursima, podaci o isporuci, računovodstveni podaci itd.). Ovi podaci su različiti za svaku kompaniju i služe za izveštavanje, analiziranje i zakonsko izveštavanje nadležnih tela (računovodstveni podaci). Ono što je zanimljivo kod ovih podataka je da kompanije direktno kontrolišu i utiču na te podatke i oni imaju vrednost samo za određenu kompaniju.



Slika 2.3 Evolucija logistike i lanca snabdevanja


Izvor: Hesse i Rodrigue (2004).

Spoljni podaci odnose se na podatke generisane izvan organizacije, koji mogu biti javni, nestrukturirani ili prikupljeni od strane trećih organizacija (privatni podaci). Za analitičare lanca snabdevanja posebno su značajni spoljni podaci koji se dele između kompanija unutar lanca snabdevanja, uključujući podatke o tržišnoj potražnji. Ova vrsta podataka važna je za kompanije budući da su rezultat reakcije tržišta na proizvode i usluge kompanije. Kompanija nema direktan uticaj na date podatke, iako kompanije pokušavaju putem procesa potražnje i njegovog podprocesa planiranja potražnje indirektno poboljšati tržišni odgovor kupaca. Štaviše, kompanije pokušavaju oblikovati tržišni angažman za svoje proizvode putem aktivnosti planiranja potražnje kao što su pakovanje, promovisanje proizvoda, promovisanje prodaje, korišćenje više distributivnih kanala itd.

Kompanije ulažu puno vremena, novca i truda kako bi bolje razumele i modelirale svoje procese prema podacima o potražnji na tržištu. Ovo je vrlo zahtevan zadatak iz nekoliko razloga. Pre svega, kompanije moraju uspostaviti infrastrukturu, procedure i ugovore s trgovcima za praćenje i beleženje podataka o potražnji. Kompanije obično koriste podatke o prodaji od nizvodnog partnera u lancu snabdevanja kao zamenu za podatke o potražnji. U stvarnosti, to nisu podaci o potražnji, već podaci o nabavci koji mogu značajno iskriviti podatke o potražnji. Ovo je uobičajena praksa budući da kompanije ne žele da dele svoje podatke i veliki deo kompanija ne zna da je to loša praksa. Jedna od loših strana ovog pristupa je što uzrokuje efekt biča među partnerima u lancu snabdevanja. Drugi pristup je da kompanije koriste podatke prodajnih mesta trgovaca (POS) kao zamenu za podatke o

potražnji (Syntetos et al., 2016.). Ovo takođe ima svoje prednosti i nedostatke, budući da ne uzima u obzir situaciju sa zalihama na policama u maloprodaji. Ovaj pristup takođe zahteva jaku IT infrastrukturu i ugovore s trgovcima.


Drugi „problem” s tržišno generisanim podacima je taj što ne slede uobičajene statističke procese. To je problem jer većina matematičkih i statističkih metoda pretpostavlja da podaci slede neki statistički proces. Ovo je vrlo vidljivo u lancu snabdevanja, gde modeli zaliha pretpostavljaju da potražnja tokom vremena isporuke sledi normalnu distribuciju i razvijaju jednačine za izračunavanje sigurnosnih zaliha na osnovu te pretpostavke. Prema Mirčetiću et al. (2017), Mirčetiću et al. (2022) i Mirčetiću et al. (2018.), 90% podataka iz skupa od 97 serija u empirijskoj studiji industrije piva ne sledi normalnu distribuciju. Takođe, modeli zaliha pretpostavljaju da je potražnja deterministička i ravnomerno raspoređena kroz sve periode, što u stvarnosti nije baš tako. Na primer, na slici 2.4 prikazana je potražnja za unapred narezanim salamama u razdoblju od 2015. do 2022. za italijanskog proizvođača. Potražnja pokazuje jasno nedeterminističko, tj. stohastičko ponašanje (sa nasumičnim fluktuacijama i trendom).



Slika 2.4 Potražnja za unapred narezanim salamama u razdoblju od 2015.-2022.

Izvor: Autor.

Dodatno, dnevna potražnja pokazuje vrlo nestabilno ponašanje, stoga agregacija potražnje kroz različita vremenske periode (nedeljno, mesečno itd.) pokazuje jasan galopirajući trend potražnje (slika 2.5).




Slika 2.5 Agregacija potražnje kroz različite vremenske periode

Izvor: Autor.

Agregacija potražnje pokazuje jasnu novu stvarnost od početka COVID-19 (uzlazni trend u procesu praćenja potrošnje)! Ovo su nepobitni dokazi da potražnja nije deterministička. Što se tiče pretpostavke o normalnosti, slika 2.6 pokazuje značajno odstupanje od normalne distribucije, imajući na umu da je to ekstremno desno usmerena distribucija.

Slika 2.6 pokazuje da je došlo do značajne promene u potražnji salame od početka pandemije COVID-19. Prvi lockdown u Italiji bio je 21. februara 2020. (vertikalna crvena linija na slici 2.4), nakon čega je potražnja za narezanim salamama eruptirala i dosegla istorijski maksimum. Potražnja je bila u stalnom trendu, dosegnuvši vrhunac 20. decembra 2021., s 21.280 narezanih komada prodatih u jednom danu.



Slika 2.6 Empirijska distribucija potražnje

Izvor: Autor.

Osim problema s gore navedenim teorijskim pretpostavkama o podacima, trenutna situacija u svetskoj privredi i posledično lancima snabdevanja postavlja još jedno pitanje pred poslovne analitičare. Ova se pitanja pojavljuju kao rezultat pandemija, ratnih kriza, nedostatka resursa, rastuće inflacije, prekinutog svetskog lanca snabdevanja, itd. Pitanje koje savremeni poslovni analitičari trebaju riješiti kada se bave podacima nakon početka COVID-19 je: koliko dugi period je sada potrebno uzeti za posmatranje i modeliranje? To se jasno vidi na slici 2.4. Ako se pažljivije pogledaju cifre, primeti će se da pre pandemije COVID-19 i lockdowna, potrošači nikada nisu konzumirali prethodno narezanu salamu u količinama kao iz prvog lockdowna. Primetno je da je došlo do naglog rasta potrošnje određenog proizvoda. Sada se nameće nekoliko pitanja:

- Da li je li to samo pik u potrošnji zbog specifičnih uslova tokom pandemije;
- Hoće li se ovaj trend nastaviti i u budućnosti i treba li kompanija povećati svoju proizvodnju;
- Imaju li podaci pre COVID-19 (od 2015. do 2020.) ikakvu vrednost danas i treba li ih odbaciti pri modeliranju podataka o potražnji za prethodno narezanom salamom?

Na sva ova pitanja teško je odgovoriti bez odgovarajućih postupaka analize podataka koji će biti predstavljeni u sledećim poglavljima.

REFERENCE

1. Arunachalam, D., Kumar, N. & Kawalek, J. P. (2018). Understanding big data analytics capabilities in supply chain management: Unravelling the issues, challenges and implications for practice. *Transportation Research Part E*, 114, pp. 416-436.
2. Hesse, M. & Rodrigue, J.-P. (2004). The transport geography of logistics and freight distribution. *Journal of Transport Geography*, 12(3), pp. 171–184.
3. Mircetic, D., Rostami-Tabar, B., Nikolicic, S. & Maslaric, M. (2022). Forecasting hierarchical time series in supply chains: an empirical investigation. *International Journal of Production Research*, 60(8), pp. 2514-2533.

4. Mirčetić, D. (2018). Unapređenje top-down metodologije za hijerarhijsko prognoziranje logističkih zahteva u lancima snabdevanja (Doctoral dissertation), University of Novi Sad, Serbia.
5. Mirčetić, D., Nikoličić, S., Stojanović, Đ. & Maslarić, M. (2017). Modified top-down approach for hierarchical forecasting in a beverage supply chain. *Transportation Research Procedia*, 22, pp. 193-202.
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. Nikoličić, S., Maslarić, M., Mirčetić, D. & Artene, A. (2019). Towards more efficient logistic solutions: Supply chain analytics. In *Proceedings of the 4th Logistics International Conference*, Belgrade, Serbia (pp. 23-25).
8. Souza, G. C. (2014). Supply chain analytics. *Business Horizons*, 57, pp. 595-605.
9. Srinivasan, R. & Swink, M. (2018). An investigation of visibility and flexibility as complements to supply chain analytics: an organizational information processing theory perspective. *Prod. Oper. Manag.* 27(10), pp. 1849–1867.
10. Syntetos, A. A., Babai, Z., Boylan, J. E., Kolassa, S. & Nikolopoulos, K. (2016). Supply chain forecasting: Theory, practice, their gap and the future. *European Journal of Operational Research*, 252(1), pp. 1-26.
11. Tiwari, S., Wee, H. M. & Daryanto, Y. (2018). Big data analytics in supply chain management between 2010 and 2016: Insights to industries. *Computers & Industrial Engineering*, 115, pp. 319-330.
12. Wang, G., Gunasekaran, A., Ngai, E. W. T. Papadopoulos Th. (2016). Big data analytics in logistics and supply chain management: Certain investigations for research and applications. *Int. J. Production Economics*, 176, pp. 98-110.
13. Zhu, S., Song, J., Hazen, B. T., Lee, K. & Cegielski, C. (2018). How supply chain analytics enables operational supply chain transparency: An organizational information processing theory perspective. *International Journal of Physical Distribution & Logistics Management*, 48(1), pp. 47-68.