



2. ANALITIKA POSLOVNIH PODATAKA

Autor: Dejan Mirčetić

U eri digitalizacije, zbog ogromne količine podataka koji se svakodnevno generiraju, tradicionalna znanja i pristupi ne mogu se koristiti za upravljanje poslovnim procesima u različitim područjima, pa tako ni za upravljanje logistikom i opskrbnim lancima (Nikoličić et al., 2019). Web 2.0, zajedno s industrijom 4.0, računalstvom u oblaku, Internetom stvari (IoT), RFID-om i drugim digitalnim tehnologijama doveli su do stvaranja, pohrane i prijenosa velikih količina podataka. Kako se obujam i složenost podataka povećava, tako raste i složenost i vrijeme potrebno za analizu tih podataka i izvlačenje uvida iz njih.

Koncept Big data prvi su predstavili Cox i Ellsworth u listopadu 1997., u članku objavljenom na ACM Digital Library (Tiwari et al., 2018). Proučavanje velikih podataka i njihova konceptualizacija kontinuirano se razvijaju. U početku je Big data karakterizirao koncept 3V, koji je obuhvaćao **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 **vrijednost** (eng. Value) (Nguyen et al., 2018; Tiwari et al., 2018). Volumen se odnosi na količinu generiranih podataka budući da količina digitalnih podataka eksponencijalno raste (Arunachalam et al., 2018.). Raznolikost se odnosi na činjenicu da se podaci mogu generirati iz heterogenih unutarnjih i vanjskih izvora, u strukturiranim, polustrukturiranim i nestrukturiranim formatima. Brzina se odnosi na brzinu generiranja i isporuke podataka, koji se mogu obrađivati u serijama, u stvarnom vremenu ili gotovo u stvarnom vremenu. Istinitost naglašava važnost kvalitete podataka jer mnogi izvori podataka sami po sebi sadrže određeni stupanj nesigurnosti i nepouzdanosti. Vrijednost se odnosi na pronalaženje nove vrijednosti sadržane u podacima koja se može koristiti za bolje poslovno planiranje (Nguyen et al., 2018).

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



vrijednih 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 pozornost u različitim područjima, kako akademskim tako i poslovnim, posebice u logistici i upravljanju opskrbnim lancem.

2.1. BDA u logistici i upravljanju opskrbnim lancem

Opskrbni lanci (eng. Supply chains - SC) predstavljaju mrežu tvrtki uključenih u transformaciju sirovina u gotove proizvode i distribuciju gotovih proizvoda krajnjim kupcima. U opskrbnim lancima postoje fizički, financijski i informacijski tokovi među različitim tvrtkama. Svakim danom opskrbni lanci postaju sve složeniji, prošireniji i globalniji. Stoga, za uspješnu implementaciju i upravljanje postojećim procesima u opskrbnim lancima i njihovo kontinuirano usklađivanje s tržišnim uvjetima, suvremeni opskrbni lanac treba vješte stručnjake. Kako bi odgovorili na ove izazovne zadatke, stručnjaci iz područja upravljanja opskrbnim lancima trebaju formalno obrazovanje koje će im pružiti znanja i vještine iz različitih područja, prvenstveno iz logistike, informacijskih tehnologija i ekonomije.


Opskrbni lanac je skup fizičkih elemenata, njihovih aktivnosti i procesa kroz koje se odvija njihova interakcija. Fizički elementi, koji čine lančanu strukturu, predstavljaju fiksni dio opskrbnog lanca. Na strateškoj razini donose se odluke o oblikovanju strukture opskrbnog lanca, a na taktičkoj i operativnoj razini odluke o modalitetima i pravilima realizacije pojedinih logističkih procesa. Oblikovanje fiksnog opskrbnog lanca i upravljanje izvrsnim radom zajedno osiguravaju upravljanje opskrbnim lancem koje definira izvedbu lanca. Sukladno tome, upravljački okvir opskrbnog lanca sastoji se od tri osnovna elementa: (1) strukture opskrbnog lanca; (2) poslovni procesi; (3) i upravljačke komponente. Svaki od ovih elemenata izravno je povezan s ciljevima opskrbnog lanca, odnosno sa stupnjem ispunjenosti zahtjeva krajnjih korisnika, uz uvažavanje kritičnih dimenzija poslovanja o kojima ovisi nastup na tržištu (ključni pokazatelji performansi – KPI). U modernom svijetu ne natječu se više poduzeća, već njihovi opskrbni lanci. Učinkovito upravljanje opskrbnim lancem je stoga postalo potencijalno vrijedan način osiguravanja konkurentске prednosti i poboljšanja organizacijskog učinka.

Poduzeća su pod velikim pritiskom da poboljšaju planiranje i performanse opskrbnog lanca zbog sve veća neizvjesnosti i konkurencije. Poboljšanje performansi opskrbnog lanca postalo je kontinuirani proces koji zahtijeva analitički sustav mjerenja performansi. S obzirom na brojnost i raznolikost logističkih procesa i procesa u opskrbnim lancima, resurse koji se koriste za njihovu realizaciju, parametre koji ih karakteriziraju, velik broj podataka koristi se kao temelj



za određivanje performansi opskrbnog lanca. To su podaci o: geografskim, vremenskim i količinskim odrednicama robe, transportna sredstva, transportno - manipulativna sredstva, skladišni kapaciteti, zaposlenici itd. Podaci generirani kroz interno poslovanje, kao i transakcije s dobavljačima i kupcima, mogu se koristiti za otkrivanje malih promjena koje mogu imati veliki utjecaj na organizaciju s obzirom na povećanje učinkovitosti, pa čak i ušteda troškova. Drugim riječima, količina podataka u svakom opskrbnom lancu eksplodira iz različitih izvora podataka, poslovnih procesa i IT sustava. Kako se obujam i složenost podataka povećava, tako raste i složenost i vrijeme potrebno za analizu tih podataka i izvlačenje uvida iz njih. Određivanje, praćenje i poboljšanje logistike i izvedbe opskrbnog lanca postaje složeniji i uključuje mnoge procese kao što su identificiranje mjera, definiranje ciljeva, planiranje, komunikacija, praćenje, izvješćivanje i povratne informacije. Posljedično, konvencionalni pristupi ne mogu se koristiti za donošenje odluka i upravljanje opskrbnim lancem.

U području upravljanja opskrbnim lancem, interes za poslovnu analitiku raste. Ona se naziva još i **analitika opskrbnog lanca (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 korištenje podataka i kvantitativnih alata i tehnika za poboljšanje operativnih performansi, često mjerenih metrikama kao što su ispunjavanje narudžbi i fleksibilnost. Analitika u opskrbnim lancima nije nužno nova ideja jer se različite kvantitativne tehnike i metode modeliranja već dugo koriste u proizvodnim tvrtkama. Nedavni porast interesa za SCA popraćen je novim izazovima i prilikama u poslovnom i informacijskom okruženju. Ti izazovi uključuju probleme koji proizlaze iz upravljanja velikim količinama podataka (npr. dostupnost podataka i kvaliteta podataka) i suočavanje s neizvjesnostima u okruženju. Pravilno primijenjen SCA može utjecati na nekoliko područja u opskrbnom lancu i može generirati značajne prednosti u logističkim performansama: poboljšano planiranje i raspoređivanje; poboljšani odziv; poboljšano planiranje potražnje; optimizacija narudžbi; optimizirano upravljanje zalihama; poboljšano planiranje popunjavanja zaliha. Posljednjih desetljeća, pod utjecajem tehnološkog razvoja, globalizacije i sve zahtjevnijih kupaca, promijenile 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 kategorizirati u tri vrste: deskriptivne, prediktivne i preskriptivne. **Deskriptivna analitika** gleda podatke i analizira prošle događaje radi uvida u to kako pristupiti budućnosti. Traži se odgovor iza prošlih neuspjeha i uspjeha. **Prediktivna analitika** koristi povijesne podatke kako bi odredila vjerojatni budući ishod nekog događaja ili vjerojatnost da se situacija dogodi. Ona iskorištava obrasce pronađene u podacima za prepoznavanje budućih rizika i prilika. **Preskriptivna analitika** automatski sintetizira velike podatke, poslovna pravila i strojno učenje za predviđanje budućnosti. Ona nadilazi predviđanje budućnosti sugerirajući radnje koje je potrebno poduzeti kako bi se postigli željeni ciljevi. Također, njome je moguće pokazati implikacije svake moguće odluke i djelovati kao alat za podršku odlučivanju za stručnjake iz područja SCM-a. U sljedećim potpoglavljima bit će predstavljeni i opisani različiti analitički alati koji se koriste za BDA u SCM-u. Dodatno, fokus će biti na strategijama o tome kako unaprijediti znanje o BDA za stručnjake 21. stoljeća, 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 primjer: srednja vrijednost, mod, medijan, raspon, histogram i standardna devijacija. Deskriptivna analitika opisuje što se dogodilo u prošlosti i izvodi informacije iz značajnih količina podataka kako bi odgovorila na pitanje što se događa. Na temelju informacija u stvarnom vremenu o lokacijama i količinama robe u opskrbnom lancu, menadžeri donose odluke na operativnoj razini (npr. prilagođavaju raspored otpreme, raspoređuju vozila, izdaju naloge za obnavljanje zaliha proizvoda itd.) (Souza, 2014). Deskriptivna analitika pokušava identificirati prilike i probleme korištenjem online sustava analitičke obrade i alata za vizualizaciju podržanih informacijama u stvarnom vremenu i tehnologijom izvješćivanja (npr. GPS, RFID, transakcijski bar-kod). Uobičajeni primjeri deskriptivne analitike su izvješća koja pružaju povijesne uvide u proizvodnju, financije, poslovanje, prodaju, financije, zalihe i kupce tvrtke (Tiwari et al., 2018.).

2.2.2. Predictive analytics

Prediktivna analitika koristi povijesne podatke kako bi odredila vjerojatni budući ishod. Prediktivna analitika u opskrbnim lancima izvodi prognoze potražnje iz prošlih podataka i odgovara na pitanja koja se odnose na ono što će se dogoditi ili što će se vjerojatno dogoditi (Tiwari et al., 2018.). Koristi umjetnu inteligenciju, optimizacijske algoritme i ekspertne sustave za predviđanje budućih ponašanja na temelju obrazaca otkrivenih u prošlosti i pretpostavke da će se povijest ponoviti. Iskorištava obrasce pronađene u podacima za prepoznavanje budućih rizika i prilika te predviđanje budućnosti. Na ovaj način se popunjavaju informacije koje nedostaju i istražuju obrasci podataka pomoću statistike, simulacije i programiranja.



2.2.3. Prescriptive analytics

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 nadilazi predviđanje budućih ishoda tako što također donositelju odluka pokazuju i implikacije svake opcije odluke. Preskriptivna analitika odgovara na pitanje što bi se trebalo događati.


2.3. BDA ekosustav

Glavna svrha BDA ekosustava je isporuka vrijednosti za donositelja odluka. Sukladno tome, BDA ima primarni cilj omogućiti uvid u poslovne procese i odgovoriti kako smanjiti troškove i povećati razinu usluge za krajnje kupce. Kako bi se ispunio cilj, BDA rješenja obično se isporučuju u obliku sustava za podršku odlučivanju (DSS) ili ekspertnog sustava (ES). Stoga će se u ovom i nadolazećim potpoglavljima pojasniti ključni stupovi 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 provođenje bilo kakve analize. **Poslovni podaci** nastaju kao rezultat izvođenja procesa u određenom poslovnom okruženju. U slučaju opskrbnog lanca, postoji mnogo procesa i podprocesa uključenih u isporuku usluge krajnjem korisniku (slika 2.3).

Slika 2.3 predstavlja strukturu opskrbnog lanca gdje se u slučaju SCA-a svaki od navedenih procesa može promatrati kao generator poslovnih podataka. Generirani podaci različiti su po važnosti i utjecaju na krajnje ciljeve poduzeća. Sukladno tome, poslovni podaci mogu se podijeliti na **interno vođene** i **eksterno vođene** podatke. Interno vođeni podaci su podaci koji nastaju kao rezultat strukture tvrtke, hijerarhije i načina na koji je tvrtka odlučila poslovati (na primjer, podaci o proizvodnji, podaci o ljudskim resursima, podaci o isporuci, računovodstveni podaci itd.). Ovi podaci su različiti za svaku tvrtku i služe za izvješćivanje, analiziranje i zakonsko izvješćivanje nadležnih tijela (računovodstveni podaci). Ono što je zanimljivo kod ovih podataka je da tvrtke izravno kontroliraju i utječu na te podatke i oni imaju vrijednost samo za određenu tvrtku.



Slika 2.3 Evolucija logistike i opskrbnog lanca

Izvor: Hesse i Rodrigue (2004).


Vanjski podaci odnose se na podatke generirane izvan organizacije, koji mogu biti javni, nestrukturirani ili prikupljeni od strane trećih organizacija (privatni podaci). Za analitičare opskrbnog lanca posebno su značajni vanjski podaci koji se dijele između tvrtki unutar opskrbnog lanca, uključujući podatke o tržišnoj potražnji. Ova vrsta podataka važna je za tvrtke budući da su rezultat reakcije tržišta na proizvode i usluge tvrtke. Tvrtka nema izravan utjecaj na dane podatke, iako tvrtke pokušavaju putem procesa potražnje i njegovog podprocesa planiranja potražnje neizravno poboljšati tržišni odgovor kupaca. Štoviše, tvrtke pokušavaju oblikovati tržišni angažman za svoje proizvode putem aktivnosti planiranja potražnje kao što su pakiranje, promicanje proizvoda, promicanje prodaje, korištenje nekoliko distribucijskih kanala itd.

Tvrtke ulažu puno vremena, novca i truda kako bi bolje razumjele i modelirale svoje procese prema podacima o potražnji na tržištu. Ovo je vrlo zahtjevan zadatak iz nekoliko razloga. Prije svega, tvrtke moraju uspostaviti infrastrukturu, procedure i ugovore s trgovcima za praćenje i bilježenje podataka o potražnji. Obično tvrtke koriste podatke o prodaji od nizvodnog partnera u opskrbnom lancu kao zamjenu za podatke o potražnji. U stvarnosti, to nisu podaci o potražnji, već podaci o nabavi koji mogu značajno iskriviti podatke o potražnji. Ovo je vrlo uobičajena praksa budući da tvrtke ne žele dijeliti svoje podatke i velik dio tvrtki ne zna da je to loša praksa. Jedna od loših strana ovog pristupa jer uzrokuje efekt biča među partnerima u



opskrbnom lancu. Drugi pristup je da tvrtke koriste podatke prodajnih mjesta trgovaca (POS) kao zamjenu za podatke o potražnji (Syntetos et al., 2016.). Ovo također ima svoje prednosti i nedostatke, budući da ne uzima u obzir situaciju sa zalihama na policama u maloprodaji. Ovaj pristup također zahtijeva jaku IT infrastrukturu i ugovore s trgovcima.


Drugi „problem” s tržišno generiranim podacima je taj što ne slijede uobičajene statističke procese. To je problem jer većina matematičkih i statističkih metoda pretpostavlja da podaci slijede neki statistički proces. Ovo je vrlo vidljivo u opskrbnom lancu, gdje modeli zaliha pretpostavljaju da potražnja tijekom vremena isporuke slijedi normalnu distribuciju i razvijaju jednadžbe za izračun sigurnosnih zaliha na temelju 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 slijedi normalnu distribuciju. Također, modeli zaliha pretpostavljaju da je potražnja deterministička i ravnomjerno raspoređena kroz sva razdoblja, što u stvarnosti nije baš tako. Na primjer, na slici 2.4 prikazana je potražnja za unaprijed narezanim salamama u razdoblju od 2015. do 2022. za talijanskog proizvođača. Potražnja pokazuje jasno nedeterminističko, tj. stohastičko ponašanje (sa nasumičnim fluktuacijama i trendom).



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

Izvor: Autor.

Dodatno, dnevna potražnja pokazuje vrlo nestabilno ponašanje, stoga agregacija potražnje kroz različita vremenska razdoblja (tjedno, mjesečno 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 neprobojni 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 usmjerena distribucija.

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



Slika 2.6 Empirijska distribucija potražnje

Izvor: Autor.

Osim problema s gore navedenim teorijskim pretpostavkama o podacima, trenutna situacija u svjetskom gospodarstvu i posljedično opskrbnim lancima postavlja još jedno pitanje pred poslovne analitičare. Ova se pitanja pojavljuju kao rezultat pandemija, ratnih kriza, nedostatka resursa, rastuće inflacije, slomljenog svjetskog opskrbnog lanca, itd. Pitanje koje suvremeni poslovni analitičari trebaju riješiti kada se bave podacima nakon početka COVID-19. koliko dugo razdoblje je sada potrebno uzeti za promatranje i modeliranje? To se jasno vidi na slici 2.4. Ako pomnije pogledamo brojku, primijetiti ćemo da prije pandemije COVID-19 i lockdowna, potrošači nikada nisu konzumirali prethodno narezanu salamu u količinama kao iz prvog lockdowna. Primjetno je da je došlo do naglog rasta potrošnje određenog proizvoda. Sada se nameće nekoliko pitanja:

- Je li to samo hype u potrošnji zbog specifičnih uvjeta tijekom pandemije;
- Hoće li se ovaj trend nastaviti i u budućnosti i treba li tvrtka povećati svoju proizvodnju;
- Imaju li podaci prije COVID-19 (od 2015. do 2020.) ikakvu vrijednost danas i treba li ih odbaciti pri modeliranju podataka o potražnji za prethodno narezanom salamom?

Na sva ova pitanja teško je odgovoriti bez odgovarajućeg postupka analize podataka koji će biti predstavljen u sljedećim 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.