



2. ANALITIKA POSLOVNIH PODATKOV

Avtor: Dejan Mirčetić

V dobi digitalizacije zaradi ogromne količine podatkov, ki nastajajo vsakodnevno, tradicionalnih znanj in pristopov ni mogoče uporabiti za upravljanje poslovnih procesov na različnih področjih, torej tudi za upravljanje logistike in oskrbovalnih verig (Nikoličić et al., 2019). Splet 2.0 je skupaj z industrijo 4.0, računalništvom v oblaku, internetom stvari (IoT), RFID in drugimi digitalnimi tehnologijami privedel do ustvarjanja, shranjevanja in prenosa velikih količin podatkov. S povečevanjem količine in kompleksnosti podatkov se povečujeta tudi zahtevnost in čas, ki sta potrebna za analizo teh podatkov in pridobivanje vpogleda vanje.

Koncept velikih podatkov sta prvič predstavila Cox in Ellsworth oktobra 1997 v članku o digitalni knjižnici ACM (Tiwari et al., 2018). Preučevanje velikih podatkov in njihova konceptualizacija sta se nenehno razvijala. Sprva je bil za velike podatke značilen koncept 3Vs, ki je ekonomiziral **količino (volume)**, **hitrost (velocity)** in **raznolikost (variety)**, kot je bilo obravnavano v prejšnjem poglavju. Kasneje se je ta opredelitev razširila na koncept 5Vs, ki vključuje dve dodatni lastnosti: **verodostojnost (veracity)** in **vrednost (value)** (Nguyen et al., 2018; Tiwari et al., 2018). Obseg se nanaša na obseg ustvarjenih podatkov; obseg digitalnih podatkov eksponentno narašča (Arunachalam et al., 2018). Raznolikost se nanaša na dejstvo, da lahko podatki nastajajo iz heterogenih notranjih in zunanjih virov, v strukturiranih, polstrukturiranih in nestrukturiranih oblikah. Hitrost se nanaša na hitrost ustvarjanja in dostave podatkov, ki se lahko obdelujejo paketno, v realnem času, skoraj v realnem času ali pretočno. Verjetnost poudarja pomen kakovosti podatkov, saj številni viri podatkov vsebujejo določeno stopnjo negotovosti in nezanesljivosti. Vrednost se nanaša na iskanje nove vrednosti, vsebovane v podatkih, ki jo je mogoče uporabiti za boljše poslovno načrtovanje (Nguyen et al., 2018).

Analiza velikih količin podatkov (Big Data Analytics - BDA) vključuje dve razsežnosti: (Wang et al., 2016). Analitika velikih količin podatkov (Big Data Analytics - BDA) vključuje uporabo naprednih analitičnih tehnik za pridobivanje dragocenega znanja iz velikih količin podatkov s spremenljivimi vrstami, da bi z odkrivanjem skritih vzorcev in korelacij, trendov ter drugih poslovno dragocenih informacij in znanja prišli do zaključkov, s katerimi bi povečali poslovne koristi, povečali učinkovitost poslovanja ter raziskovali nove trge in priložnosti (Nguyen et al.,



2018; Tiwari et al., 2018). BDA je pritegnila veliko pozornosti na različnih področjih, tako akademskih kot poslovnih, zlasti na področju logistike in upravljanja oskrbovalne verige.

2.1. BDA na področju logistike in upravljanja oskrbovalne verige

Oskrbovalne verige predstavljajo mrežo podjetij in obratov, ki sodelujejo pri preoblikovanju surovin v končne izdelke in distribuciji končnih izdelkov končnim kupcem. V verigah potekajo fizični, finančni in informacijski tokovi med različnimi podjetji. Verige oskrbovalnih sistemov postajajo vsak dan bolj zapletene, razširjene in globalne. Zato sodobni SC za uspešno izvajanje in upravljanje obstoječih procesov v SC ter njihovo stalno prilagajanje tržnim razmeram potrebujejo visoko usposobljene strokovnjake. Da bi lahko odgovorili na te zahtevne naloge, potrebujejo strokovnjaki SC formalno izobraževanje, ki jim bo zagotovilo znanje in veščine z različnih področij, predvsem s področja logistike, informacijske tehnologije in ekonomije.


SC je skupek fizičnih elementov, njihovih dejavnosti in procesov, prek katerih poteka njihova interakcija. Fizični elementi, ki sestavljajo verižno strukturo, predstavljajo fiksni del SC. Odločitve o oblikovanju strukture KN se sprejemajo na strateški ravni, na taktični in operativni ravni pa se sprejemajo odločitve o načinih in pravilih za izvajanje posameznih logističnih procesov. Načrtovanje fiksne KS in upravljanje izrednega dela skupaj zagotavljata upravljanje KS, ki opredeljuje uspešnost verige. V skladu s tem je okvir upravljanja SC sestavljen iz treh osnovnih elementov: (1) strukture SC; (2) poslovnih procesov; (3) in elementov nadzora. Vsak od teh elementov je neposredno povezan s cilji KN, to je s stopnjo izpolnjevanja zahtev končnih uporabnikov, ob upoštevanju kritičnih razsežnosti poslovanja, ki so odvisne od uspešnosti na trgu (ključni kazalniki uspešnosti - KPI). V sodobnem svetu konkurenca ni več konkurenca med organizacijami, temveč med SC. Učinkovito upravljanje KN je zato postalo potencialno dragocen način zagotavljanja konkurenčne prednosti in izboljšanja uspešnosti organizacije. Upravljanje SC je dejstvo poslovanja, logistika pa je najmočnejše orodje za doseganje končne strateške prednosti.

Podjetja so zaradi dejavnikov, kot sta vse večja negotovost in konkurenca, pod velikim pritiskom, da izboljšajo načrtovanje in uspešnost SC. Izboljšanje uspešnosti SC je postalo neprekinjen proces, ki zahteva analitični sistem merjenja uspešnosti. Glede na število in raznolikost logističnih procesov in procesov SC, virov, ki se uporabljajo za njihovo izvajanje, parametrov, ki jih označujejo, se kot podlaga za določanje uspešnosti SC uporablja veliko



število podatkov o: geografskih, časovnih in količinskih determinantah blaga, prevoznih sredstvih, transportno - manipulativnih sredstvih, skladiščnih zmogljivostih, zaposlenih itd. Podatki, pridobljeni z notranjim poslovanjem ter transakcijami z dobavitelji in strankami, se lahko uporabijo za odkrivanje majhnih sprememb, ki imajo lahko velik vpliv na organizacijo glede povečanja učinkovitosti in celo prihranka stroškov. Z drugimi besedami, količina podatkov v vsaki SC eksplodira iz različnih podatkovnih virov, poslovnih procesov in sistemov IT. S povečevanjem količine in kompleksnosti podatkov se povečujeta tudi zahtevnost in čas, potreben za analizo teh podatkov in pridobivanje vpogleda vanje. Ugotavljanje, spremljanje in izboljševanje logistike in uspešnosti SC postaja vse bolj zapleteno in vključuje številne procese, kot so določanje ukrepov, opredeljevanje ciljev, načrtovanje, komuniciranje, spremljanje, poročanje in povratne informacije. Posledično za sprejemanje odločitev in upravljanje SC ni mogoče uporabiti običajnih pristopov.

Na področju upravljanja oskrbovalne verige je vse večje zanimanje za poslovno analitiko, ki se imenuje tudi **analitika oskrbovalne verige (SCA)**. SCA se v poslovnih in akademskih skupnostih uporablja kot sinonim za izraze, kot sta "analitika velikih količin podatkov" in "poslovna analitika" (Srinivasan in Swink, 2018). SCA se nanaša na uporabo podatkov ter kvantitativnih orodij in tehnik za izboljšanje operativne uspešnosti, ki jo pogosto kažejo kazalniki, kot sta izpolnjevanje naročil in prilagodljivost. Analitika v SCA ni nujno nova zamisel, saj se različne kvantitativne tehnike in metode modeliranja že dolgo uporabljajo v proizvodnih podjetjih. Nedavni porast zanimanja za ZK spremljajo novi izzivi in priložnosti tako v poslovnem okolju kot v okolju informacijske tehnologije. Ti izzivi vključujejo vprašanja, ki izhajajo iz upravljanja velikih količin podatkov (npr. razpoložljivost in kakovost podatkov) in obvladovanja negotovosti okolja. Pravilno uporabljena SCA lahko vpliva na več področij v SC in lahko ustvari pomembne koristi pri logističnih zmogljivostih: izboljšano načrtovanje in razporejanje, izboljšana odzivnost, izboljšano načrtovanje povpraševanja, optimizacija naročil, optimizirano upravljanje zalog, izboljšano načrtovanje dopolnjevanja. V zadnjih desetletjih so se pod vplivom tehnološkega razvoja, globalizacije in vse zahtevnejših kupcev spremenile tudi poslovne paradigme. Na sliki 2.1 so prikazana značilna obdobja (s kratkim opisom) v razvoju logistike, SCM in BDA.




Slika 2.1 Razvoj logistike, SCM in BDA

Vir: Prirejeno po Arunachalam et al. (2018).

2.2. Orodja za analitiko poslovnih podatkov

Na sliki 2.2 so predstavljeni različni trendi, orodja in prednosti, ki se uporabljajo pri BDA ali SCA. Vse predstavljene analitične tehnike lahko razvrstimo v tri vrste: opisne, napovedne in preskriptivne. **Opisna analitika** obravnava podatke in analizira pretekle dogodke, da bi dobila vpogled v to, kako pristopiti k prihodnosti. Iščejo se odzivi v ozadju preteklih neuspehov in uspehov. **Prediktivna analitika** uporablja pretekle podatke za določitev verjetnega prihodnjega izida dogodka ali verjetnosti nastanka situacije. Izkorišča vzorce, ki jih najde v podatkih, da bi prepoznala prihodnja tveganja in priložnosti. **Predpisovalna analitika** samodejno sintetizira velike količine podatkov, poslovna pravila in strojno učenje za napovedovanje prihodnosti. Presegajo napovedovanje prihodnosti, saj predlagajo ukrepe, ki jih je treba izvesti za doseg želenih ciljev. Prav tako lahko prikaže posledice vsake možne odločitve in deluje kot orodje za podporo odločanju strokovnjakov SC. V naslednjih podpoglavjih bomo predstavili in opisali različna analitična orodja, ki se uporabljajo za BDA v SCM. Poleg tega se bomo s pomočjo več študij primerov osredotočili na strategije, kako izboljšati znanje na področju BDA za strokovnjake SC 21. stoletja.



Slika 2.2 Trendi, orodja in prednosti SCA

Vir: Avtor: Avtor.

2.2.1. Opisna analitika

Opisna analitika zagotavlja povzetek opisne statistike za določen vzorec podatkov, na primer: povprečje, način, mediana, razpon, histogram in standardni odklon. Opisna analitika opisuje, kaj se je zgodilo v preteklosti, in iz velike količine podatkov pridobiva informacije, da bi odgovorila na vprašanje, kaj se dogaja. Na podlagi informacij v realnem času o lokacijah in količinah blaga v oskrbovalni verigi vodje sprejemajo odločitve na operativni ravni (npr. prilagodijo urnik pošiljk, razporedijo vozila, izdajo naročila za dopolnitev zalog izdelkov itd) (Souza, 2014). Priložnosti in težave poskuša prepoznati z uporabo spletnega sistema za analitično obdelavo in orodij za vizualizacijo, ki jih podpira tehnologija za informacije in poročanje v realnem času (npr. GPS, RFID, transakcijska črtna koda). Pogosti primeri opisne analitike so poročila, ki zagotavljajo zgodovinski vpogled v proizvodnjo, finance, poslovanje, prodajo, finance, zaloge in stranke podjetja (Tiwari et al., 2018).

2.2.2. Prediktivna analitika

Prediktivna analitika uporablja pretekle podatke za določanje verjetnega izida v prihodnosti. Prediktivna analitika v oskrbovalnih verigah iz preteklih podatkov izpeljuje napovedi povpraševanja in odgovarja na vprašanja, povezana s tem, kaj se bo zgodilo ali kaj se bo verjetno zgodilo (Tiwari et al., 2018). Uporablja umetno inteligenco, optimizacijske algoritme in ekspertne sisteme za napovedovanje prihodnjega vedenja na podlagi vzorcev, odkritih v preteklosti, in predpostavke, da se bo zgodovina ponovila. Izkorišča vzorce, najdene v podatkih, za prepoznavanje prihodnjih tveganj in priložnosti ter napovedovanje prihodnosti. Z njim se dopolnjujejo manjkajoče informacije in raziskujejo podatkovni vzorci z uporabo statistike, simulacije in programiranja.



2.2.3. Predpisovalna analitika

Preskriptivna analitika pripravlja priporočila za odločanje na podlagi opisnih in napovednih analitičnih modelov ter matematične optimizacije, simulacije ali večkriterijskih tehnik odločanja. Presegajo napovedovanje prihodnjih izidov, saj predlagajo tudi ukrepe, ki bodo koristili napovedim, in odločevalcu prikažejo posledice posameznih možnosti odločanja. Predpisovalna analitika odgovarja na vprašanje, kaj bi se moralo zgoditi.


2.3. Ekosistem BDA

Glavni namen ekosistema BDA je zagotoviti vrednost za odločevalca. V skladu s tem je glavni cilj sistema BDA zagotoviti vpogled v poslovne procese in priti do možnega odgovora, kako zmanjšati stroške in povečati raven storitev za končne stranke. Da bi izpolnili svoj cilj, so rešitve BDA običajno dobavljene v obliki sistema za podporo odločanju (DSS) ali ekspertnega sistema (ES). Zato se bomo v tem in naslednjih poglavjih poglobili v ključne stebre BDA: **poslovne podatke**, **podatkovno rudarjenje** in **odkrivanje znanja** (podatkovna analitika, DSS, platforme ES itd.).

2.3.1. Poslovni podatki

Pojem podatkov je podrobno razložen v prvem poglavju te knjige. Podatki so ključni dejavnik za izvedbo kakršne koli analize. **Poslovni podatki** nastajajo kot rezultat izvajanja procesov v določenem poslovnem okolju. V primeru SC je pri zagotavljanju storitve končnemu kupcu vključenih veliko procesov in podprocesov (slika 2.3).

Na sliki 2.3 je prikazana struktura SC, kjer je v primeru SCA vsak od danih procesov mogoče opazovati kot generator poslovnih podatkov. Ustvarjeni podatki se razlikujejo po pomembnosti in vplivu na končne cilje podjetja. V skladu s tem lahko poslovne podatke razdelimo na podatke, ki jih **poganjajo notranji viri**, in podatke, ki jih **poganjajo zunanji viri**. Notranje gnani podatki so podatki, ki nastanejo kot posledica strukture podjetja, hierarhije in načina, na katerega se je podjetje odločilo delovati (na primer podatki o proizvodnji, podatki o človeških virih, podatki o dostavi, računovodski podatki itd.) Ti podatki so za vsako podjetje drugačni in služijo za poročanje, analiziranje in pravno poročanje organom (računovodski podatki). Zanimivo pri teh podatkih je, da jih podjetja neposredno nadzorujejo in nanje vplivajo, vrednost pa imajo le za posamezno podjetje.



Slika 2.3 Razvoj logistike in SC


Vir: Hesse in Rodrigue (2004).

Zunanji podatki se nanašajo na podatke, ustvarjene zunaj organizacije, ki so lahko javni, nestrukturirani ali jih zbirajo organizacije tretjih oseb (zasebni podatki). Za analitike SC so zlasti pomembni zunanji podatki, ki si jih izmenjujejo podjetja znotraj oskrbovalnih verig, vključno s podatki o povpraševanju na trgu. Tovrstni zunanji podatki so pomembni za podjetja, saj so rezultat odziva trga na izdelke in storitve podjetja. Podjetje nima neposrednega vpliva na dani podatek, čeprav si podjetja prek procesa povpraševanja in njegovega podprocesa načrtovanja povpraševanja prizadevajo posredno izboljšati odziv kupcev na trgu. Poleg tega poskušajo podjetja z dejavnostmi načrtovanja povpraševanja, kot so pakiranje, promocija izdelka, pospeševanje prodaje, uporaba več distribucijskih kanalov itd.

Podjetja vlagajo veliko časa, denarja in truda, da bi bolje razumela in modelirala svoje procese glede na podatke o povpraševanju na trgu. To je zelo zahtevna naloga iz več razlogov. Najprej morajo podjetja vzpostaviti infrastrukturo, postopke in pogodbe s trgovci na drobno za spremljanje in beleženje podatkov o povpraševanju. Običajno podjetja kot približek podatkov o povpraševanju uporabljajo podatke o prodaji od partnerja na nižji stopnji v SC. V resnici to niso podatki o povpraševanju, temveč podatki o nabavi, ki lahko bistveno popačijo podatke o povpraševanju. To je zelo pogosta praksa, saj podjetja ne želijo deliti svojih podatkov, velik delež podjetij pa ne ve, da je to slaba praksa. Ena od slabosti tega pristopa, saj povzroča bullwhip učinek med partnerji v SC. Drug pristop je, da podjetja uporabljajo podatke o

prodajnih mestih (POS) trgovcev na drobno kot približek podatkov o povpraševanju (Syntetos et al., 2016). Tudi to ima svoje prednosti in slabosti, saj ne upošteva razmer, ko na maloprodajnih policah zmanjka zalog. Ta pristop potrebuje tudi močno infrastrukturo IT in pogodbe s trgovci na drobno.


Druga težava podatkov, pridobljenih na trgu, je, da ne sledijo običajnim statističnim postopkom zbiranja. To predstavlja izziv, saj večina matematičnih in statističnih metod predpostavlja, da podatki izhajajo iz določenega statističnega procesa generiranja. Ta problem je posebej izrazit na področju oskrbovalnih verig, kjer modeli zalog predpostavljajo, da povpraševanje v pripravljalnem obdobju sledi normalni porazdelitvi. Na podlagi te predpostavke se oblikujejo enačbe za izračun varnostne zaloge. Vendar pa podatki iz empirične študije pivovarske industrije, ki so jih predstavili Mirčetić idr. (2017, 2018, 2022), kažejo, da kar 90 % izmed 97 analiziranih časovnih vrst ne sledi normalni porazdelitvi. Poleg tega modeli pogosto domnevajo, da je povpraševanje deterministično in enakomerno porazdeljeno skozi vsa obdobja, kar v praksi redko drži. Na sliki 2.4 je denimo prikazano povpraševanje po predrezani salami v obdobju 2015–2022 pri italijanskem proizvajalcu. Podatki jasno kažejo nedeterministično, tj. stohastično obnašanje, zaznamovano z naključnimi nihanji in trendom.



Slika 2.4 Povpraševanje po predhodno narezani salami v obdobju 2015-2022

Vir: Avtor: Avtor.

Poleg tega je dnevno povpraševanje zelo nestanovitno, zato se pri zbiranju povpraševanja v različnih časovnih obdobjih (tedensko, mesečno itd.) pokaže jasen trend naraščanja povpraševanja (slika 2.5).




Slika 2.5 Združevanje povpraševanja v različnih časovnih obdobjih

Vir: Avtor: Avtor.

Agregacija povpraševanja kaže jasno novo realnost od začetka COVID-19 (trend naraščanja v procesu porabe povpraševanja)! To so nepremagljivi dokazi, da povpraševanje ni deterministično. Kar zadeva predpostavko normalnosti, slika 2.6 prikazuje precejšnje odstopanje od normalne porazdelitve, pri čemer je treba upoštevati, da gre za izjemno desno nagnjeno porazdelitev.

Slika 2.6 prikazuje, da se je povpraševanje po salamah od začetka pandemije COVID-19 opazno spremenilo. Prva zapora v Italiji je bila 21. 2. 2020 (navpična rdeča črta na sliki 2.4), po kateri je povpraševanje po predrezani salami izbruhnilo in doseglo zgodovinski maksimum. Povpraševanje se je nenehno gibalo in doseglo najvišjo vrednost 2021-12-20, ko je bilo v enem dnevu prodanih 21280 narezanih kosov.



Slika 2.6 Empirična porazdelitev povpraševanja

Vir: Avtor: Avtor.

Poleg težav z zgoraj navedenimi teoretičnimi predpostavkami o podatkih sedanje razmere v svetovnem gospodarstvu in posledično v podjetjih postavljajo pred poslovne analitike še eno vprašanje. Ta vprašanja se pojavljajo zaradi pandemij, vojnih kriz, pomanjkanja virov, naraščajoče inflacije, zlomljenih svetovnih trgov itd. Vprašanje, ki ga morajo sodobni poslovni analitiki rešiti pri obravnavi podatkov po začetku COVID-19, je, kako dolgo obdobje in obzorje podatkov sta zdaj veljavna za opazovanje in modeliranje? To je jasno razvidno iz slike 2.4. Če podrobneje pregledamo sliko, bomo opazili, da potrošniki pred pandemijo COVID-19 in zaporo nikoli niso uživali vnaprej narezane salame v takšnih količinah kot od prve zapore. Opazno je, da je poraba določenega izdelka izbruhnila. Zdaj se pojavlja več vprašanj:

- Ali gre le za povečano porabo zaradi posebnih razmer med pandemijo;
- Ali se bo ta trend nadaljeval tudi v prihodnosti in ali bo podjetje moralo povečati svojo proizvodnjo;
- Ali imajo podatki iz obdobja pred COVID-19 (2015-2020) danes kakršno koli vrednost in jih je treba pri modeliranju podatkov o povpraševanju po predrezani salami zavreči?

Na vsa ta vprašanja je zelo težko odgovoriti brez ustreznega postopka analize podatkov, ki bo predstavljen v naslednjih poglavjih.



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.