



BUSINESS ANALYTICS SKILLS FOR THE FUTURE-PROOF SUPPLY CHAINS

POSLOVNA INTELIGENCA

Avtorji:

Dario Šebalj

Dejan Mirčetić

Michał Adamczak



Dario Šebalj, Dejan Mirčetić, Michał Adamczak

POSLOVNA INTELIGENCA

Poznan 2025



Založba:

Wyższa Szkoła Logistyki

Estkowskiego 6

61-755 Poznan, Poljska

www.wsl.com.pl

Uredniški odbor:

Stanisław Krzyżaniak (predsednik), Ireneusz Fechner, Marek Fertsch, Aleksander Niemczyk, Bogusław Śliwczyński, Ryszard Świekatowski, Kamila Janiszewska

ISBN 978-83-62285-68-6 (na spletu)

Avtorske pravice s strani Wyższa Szkoła Logistyki

Poznan 2025, Issue I

Prevodi:

- prof. Dr. Rebeka Kovačič Lukman, University of Maribor, Faculty of Logistics
- Asist. Kristijan Brglez, University of Maribor, Faculty of Logistics

Recenzenti:

- prof. Ljubica Milanović Glavan, Univerza v Zagrebu, Ekonomsko-poslovna fakulteta, Zagreb, Hrvaška
- prof. Igor Pihir, Univerza v Zagrebu, Fakulteta za organizacijo in informatiko, Varaždin, Hrvaška

Tehnični urednik: Dario Šebalj, Josip Juraj Strossmayer Univerza v Osijeku, Ekonomsko-poslovna fakulteta v Osijeku, Osijek, Hrvaška

Oblikovanje naslovnice: Michał Adamczak, Fakulteta za logistiko v Poznaniu, Poznan, Poljska

Knjiga je bila napisana za projekt BAS4SC (Business Analytics Skills for Future-proof Supply Chains) [2022-1-PL01-KA220-HED-000088856], ki ga je ustanovil program ERASMUS+.

Financirano s strani Evropske unije. Izražena stališča in mnenja so zgolj stališča in mnenja avtorja(-ev) in ni nujno, da odražajo stališča in mnenja Evropske unije ali Evropske izvajalske agencije za izobraževanje in kulturo (EACEA). Zanje ne moreta biti odgovorna niti Evropska unija niti EACEA.



Predgovor

V času, ki ga zaznamuje hitra digitalna preobrazba in odločanje na podlagi podatkov, sposobnost obvladovanja velikih količin podatkov, njihove razlage in uporabe ni več možnost – temveč nujnost. Ta knjiga izstopa kot pravočasen in dragocen vir za študente, predavatelje in strokovnjake, ki želijo razviti ali dodatno poglobiti svoje kompetence na področju poslovne analitike, zlasti v kontekstu upravljanja oskrbovalne verige in logistike.

Knjiga je nastala v okviru projekta Erasmus+ BAS4SC (Business Analytics Skills for Future-proof Supply Chains), sofinanciranega s strani Evropske unije, in je usmerjena v reševanje zaznanega neskladja med akademskimi kurikulumi in potrebami industrije po vsej Evropi. Temelji na temeljitnem raziskovalnem procesu, ki je vključeval analizo mednarodnih študijskih programov ter neposredno sodelovanje z več kot stotimi deležniki iz akademskega in poslovnega okolja. Rezultat je celovit izbor najpomembnejših analitičnih veščin, ki bodo ključne za prihodnje strokovnjake na področju upravljanja oskrbovalnih verig.

Knjiga se začne z osnovami razumevanja in interpretacije podatkov, nato pa sledijo ključne teme, kot so poslovna analitika, podatkovno rudarjenje, strojno učenje, upravljanje poslovnih procesov in informacijskih sistemov. Posebna pozornost je namenjena sodobnim področjem, kot so e-logistika, geografski informacijski sistemi (GIS) in podatkovna etika – temam, ki vse bolj oblikujejo konkurenčno okolje sodobnih oskrbovalnih verig.

Upamo, da bo ta knjiga služila tako kot izobraževalno orodje kot tudi kot strokovno branje. Ne glede na to, ali ste študent, ki se šele pripravlja na vstop na to področje, ali praktik, ki želi prilagoditi svoje znanje in uspeti v dinamičnem okolju, vam bodo spoznanja in veščine, predstavljene v knjigi, pomagale sprejemati pametnejše, hitrejše in odgovornejše odločitve.

Dario Šebalj

Dejan Mirčetić

Michał Adamczak



Vsebina

UVOD.....	1
1. RAZUMEVANJE IN INTERPRETACIJA PODATKOV.	4
1.1. Podatki, informacije, znanje, modrost	4
1.2. Viri podatkov in vrste podatkov	6
1.3. Modeliranje in oblikovanje podatkov	10
1.4. Sprejemanje odločitev na podlagi podatkov	13
1.5. Kakovost podatkov	14
VIRI.....	16
2. ANALITIKA POSLOVNIH PODATKOV	19
2.1. BDA na področju logistike in upravljanja oskrbovalne verige	20
2.2. Orodja za analitiko poslovnih podatkov	22
2.2.1. Opisna analitika	23
2.2.2. Prediktivna analitika	23
2.2.3. Predpisovalna analitika	24
2.3. Ekosistem BDA.....	24
2.3.1. Poslovni podatki.....	24
VIRI.....	29
3. PODATKOVNO RUDARJENJE IN ODKRIVANJE ZNANJA	31
3.1. Kaj je podatkovno rudarjenje?.....	32
3.2. Odkrivanje znanja v logistiki in upravljanju oskrbovalne verige.....	34
3.3. Delphihev pristop k sodnemu ustvarjanju znanja	35
3.3.1. Koraki za izvedbo metode Delphi	37
3.4. Kvantitativni pristop podatkovnega rudarjenja za odkrivanje znanja.....	38
VIRI.....	41
4. STROJNO UČENJE.....	43



4.1.	Kaj je strojno učenje?.....	43
4.2.	Osnove in teoretične predpostavke ML.....	45
4.3.	Poslovna inteligenca in ML v SC.....	45
4.3.1.	Poslovni podatki ML in SC.....	51
	VIRI.....	53
5.	UPRAVLJANJE POSLOVNIH PROCESOV IN PROCESOV RUDARJENJA	55
5.1.	Poslovni proces.....	55
5.2.	Upravljanje poslovnih procesov	56
5.3.	Modeliranje poslovnih procesov.....	59
5.3.1.	Dogodki	60
5.3.2.	Naloge (dejavnosti).....	61
5.3.3.	Vrata	61
5.3.4.	Povezovanje predmetov.....	63
5.3.5.	Udeleženci.....	63
5.3.6.	Artefakti.....	64
5.4.	Procesno rudarjenje	65
	VIRI.....	68
6.	INFORMACIJSKI SISTEMI V LOGISTIKI.....	70
6.1.	Sistemi za celovito načrtovanje virov podjetja (ERP).....	70
6.1.1.	Stroški sistemov ERP.....	74
6.1.2.	Trendi sistemov ERP	75
6.2.	Sistemi za upravljanje skladišča.....	77
6.3.	Sistemi za upravljanje prevoza	79
	VIRI.....	81
7.	E-LOGISTIKA.....	84
7.1.	Uvod.....	84
7.2.	E-poslovanje.....	85



7.3.	Opredelitev pojma e-logistika	86
7.4.	Razvoj e-logistike	89
7.5.	Sodobne tehnologije, ki podpirajo e-logistiko	90
7.6.	E-logistika v praksi	92
7.7.	Povzetek	94
VIRI.....		95
8.	GIS V LOGISTIKI	98
8.1.	Geografski informacijski sistemi (GIS)	98
8.2.	GIS v logistiki	102
8.3.	Prihodnji trendi na področju GIS-a	104
VIRI.....		106
9.	METODE VIZUALIZACIJE PODATKOV	108
9.1.	Razumevanje okoliščin.....	108
9.2.	Metode za pritegnitev pozornosti	110
9.3.	Izbira prave metode vizualizacije	114
9.3.1.	Preprosto besedilo	115
9.3.2.	Tabela	116
9.3.3.	Stolpčni diagram.....	116
9.3.4.	Črtni diagram	117
9.3.5.	Diagram razpršitve.....	118
9.3.6.	Choropleth zemljevid.....	119
9.3.7.	Toplotni zemljevid.....	120
9.3.8.	Kazalni stolpčni grafikon	120
9.4.	Smernice za dobro oblikovanje vizualizacije	121
VIRI.....		125
10.	PODATKOVNA ETIKA IN INFORMACIJSKA VARNOST	127
10.1.	Pomen podatkovne etike.....	127



10.2. Osnove informacijske varnosti	131
10.2.1. Kršitve podatkov	133
10.2.2. Grožnje informacijske varnosti	136
10.2.3. Priporočila za informacijsko varnost	139
VIRI	140
SEZNAM TABEL	144
SEZNAM SLIK	144



UVOD

Ta učbenik z naslovom Poslovna inteligenca (po ang. Business Intelligence) je drugi v seriji učbenikov, razvitih v okviru projekta BAS4SC (Business Analytics Skills for Future-proof Supply Chains). Za določitev vsebine tega učbenika je bilo izvedenih več predhodnih raziskovalnih dejavnosti. Najprej je bila izvedena obsežna študija, ki je analizirala predmete poslovne inteligenca v učnih načrtih različnih študijskih programov v Evropski uniji, Združenih državah Amerike in Združenem kraljestvu, ki se ukvarjajo z logistiko in upravljanjem oskrbovalnih verig. Metodologija raziskave vključuje preglede javno dostopnih učnih načrtov in opisov različnih študijskih programov (dodiplomski ali magistrski študij). Raziskava se je osredotočila na študijske programe s področja poslovne ekonomije in uporabnih ved. Ta analiza je razkrila vrzel med znanjem s področja logistike in veščinami poslovne inteligenca, ki se zahtevajo na tem področju, ter tistimi, ki so trenutno na voljo študentom. Z obsežnimi intervjuji in vprašalniki z univerzitetnim pedagoškim osebjem, študenti in strokovnjaki iz panoge je bilo opredeljenih več kot 100 bistvenih veščin poslovne inteligenca. Z uporabo metode razvrščanja ABC je bilo za vključitev v to knjigo izbranih 33 teh veščin, pri čemer je bil velik poudarek na področjih, kot so upravljanje podatkov, analiza poslovnih procesov, strojno učenje, vizualizacija podatkov in poslovni informacijski sistemi. Na podlagi teh izbranih veščin in ugotovljenih potreb je bilo oblikovanih deset vsebinskih poglavij, od katerih vsako obravnava najpomembnejše veščine, ki se zahtevajo na tem področju.

Knjiga se začne s temeljnim poglavjem Razumevanje in razlaga podatkov, v katerem so predstavljeni bistveni podatkovni koncepti, kot so vrste, kakovost in viri podatkov. V njem je pojasnjeno, kako učinkovito odločanje temelji na dobrem razumevanju podatkov, kar strokovnjakom omogoča pridobivanje pomembnih vpogledov in preprečevanje pristranskosti, ki lahko zameglijo poslovno presojo. Teme, kot so piramida podatkov, informacij, znanja in modrosti (DIKW) ter metode za prepoznavanje trendov in korelacij v poslovnih podatkih, ponujajo bralcem trdno podlago za navigacijo po zapletenih podatkovnih pokrajinah.

V drugem poglavju, Analitika poslovnih podatkov, so veliki podatki predstavljeni v poslovnih okoljih, kjer je pojasnjeno, kako lahko organizacije izkoristijo analitiko velikih podatkov za izboljšanje odločanja. To poglavje obravnava "pet V" velikih podatkov - količino, hitrost, raznolikost, resničnost in vrednost - in pomaga bralcem razumeti, kako analitika velikih



podatkov podpira operativne in strateške cilje. Vključuje študije primerov, ki ponazarjajo praktično uporabo in prikazujejo, kako lahko vpogledi v velike podatke vodijo do konkurenčnih prednosti na dinamičnih trgih.

V knjigi Podatkovno rudarjenje in odkrivanje znanja se bralci seznani s temeljnimi tehnikami za pridobivanje dragocenih vzorcev iz velikih zbirk podatkov. To poglavje obravnava koncepte podatkovnega rudarjenja, kot so grozdenje, klasifikacija, rudarjenje asociacijskih pravil in odkrivanje anomalij, ki podjetjem pomagajo odkriti uporabna spoznanja. Poudarja ključne korake v procesu odkrivanja znanja, od čiščenja podatkov do interpretacije vzorcev, kar zagotavlja, da so spoznanja, pridobljena s podatkovnim rudarjenjem, ustrezna in uporabna pri odločanju v resničnem svetu.

Poglavje Strojno učenje obravnava vlogo strojnega učenja pri napovedni analitiki in poslovni inteligenci. Razloži osnove strojnega učenja, vključno z nadzorovanim in nenadzorovanim učenjem, in kako te tehnike omogočajo računalnikom prepoznavanje vzorcev, napovedovanje in prilagajanje na podlagi novih podatkov. Poglavje zajema aplikacije strojnega učenja, kot so priporočilni sistemi, napovedovanje povpraševanja in odkrivanje anomalij, ter prikazuje, kako algoritmi strojnega učenja organizacijam omogočajo avtomatizacijo odločanja, izboljšanje izkušenj strank in optimizacijo poslovanja.

V poglavju Upravljanje poslovnih procesov (BPM) in rudarjenje procesov so obravnavane strukture in strategije za učinkovite poslovne procese. To poglavje opisuje, kako lahko organizacije analizirajo in izpopolnjujejo svoje procese ter s pomočjo BPM in procesnega rudarjenja uskladijo poslovanje s strateškimi cilji. Poglavje vključuje orodja in okvire za ocenjevanje poslovnih procesov ter pojasnjuje, kako lahko procesno rudarjenje odkrije ozka grla in neučinkovitosti, ki ovirajo uspešnost.

Informacijski sistemi v logistiki ponujajo pregled ključnih informacijskih sistemov, kot so ERP (Enterprise Resource Planning), WMS (Warehouse Management Systems) in TMS (Transportation Management Systems). V tem poglavju je obravnavano, kako ti sistemi povezujejo različne logistične funkcije, racionalizirajo pretok podatkov in izboljšujejo učinkovitost upravljanja virov v oskrbovalnih verigah. Poudarja pomen teh sistemov pri zagotavljanju podatkov v realnem času in omogočanju odzivnega, na podatkih temelječega upravljanja logistike.

Poglavje o e-logistiki obravnava transformativni vpliv digitalnih tehnologij na logistične procese, pri čemer je poudarjeno nemoteno povezovanje materialnih in digitalnih tokov. Začne



z opredelitvijo e-logistike in jo umesti v širši koncept e-poslovanja ter poudari, kako digitalni procesi podpirajo funkcije, kot so nabava materiala, skladiščenje in prevoz, zlasti v okviru e-poslovanja. V poglavju je opisan razvoj e-logistike na spletni strani od zgodnjih sistemov za načrtovanje materiala do sodobnih rešitev ERP, WMS in TMS, ki omogočajo izmenjavo podatkov v realnem času v oskrbovalnih verigah. S hitro rastjo digitalnega gospodarstva je e-logistika postala bistvena za organizacije, ki si prizadevajo izboljšati konkurenčni položaj in racionalizirati svoje logistične dejavnosti.

Geografski informacijski sistemi (GIS) v logistiki omogočajo vpogled v prostorsko analizo in njeno vlogo pri optimizaciji logističnih omrežij. Poglavje obravnava, kako aplikacije GIS podjetjem omogočajo vizualizacijo, analizo in upravljanje geografskih podatkov ter podpirajo naloge, kot so optimizacija poti, izbira lokacij in ocena tveganja. Z uporabo GIS lahko podjetja sprejemajo bolj utemeljene odločitve, ki upoštevajo geografske in okoljske dejavnike, kar na koncu izboljša učinkovitost in storitve za stranke.

Poglavje o metodah vizualizacije podatkov poudarja pomen pretvorbe kompleksnih podatkov v vizualne oblike, ki olajšajo razumevanje in odločanje. To poglavje bralce popelje skozi učinkovite tehnike vizualizacije, od preprostih preglednic in grafov do naprednih interaktivnih nadzornih plošč. Obravnava orodja in najboljše prakse, s katerimi so podatki dostopni zainteresiranim stranem, kar podjetjem omogoča, da jasno sporočajo spoznanja in spodbujajo premišljeno ukrepanje.

Etika podatkov in informacijska varnost obravnava etične vidike uporabe podatkov v poslovnem okolju. V tem poglavju so obravnavani zakoni o zasebnosti, prakse varstva podatkov in etične posledice ravnanja z osebnimi podatki, zlasti na področju analitike oskrbovalne verige. Z obravnavo tem, kot so protokoli za varnost podatkov in etični okviri, poglavje opremi bralce za ohranjanje standardov integritete in zaupanja v okoljih, ki temeljijo na podatkih.



1. RAZUMEVANJE IN INTERPRETACIJA PODATKOV.

Avtor: Dario Šebalj

V tem poglavju so pojasnjeni temeljni koncepti razumevanja in razlage podatkov. Podatki so temelj učinkovitega odločanja in imajo ključno vlogo pri doseganju organizacijskega uspeha. S pridobivanjem znanja na področju analize in razlage podatkov lahko posamezniki (podatkovni analitiki, vodje, poslovni strokovnjaki, navdušenci nad podatki itd.) pridobijo veščine, potrebne za pridobivanje dragocenih spoznanj iz velikega oceana razpoložljivih informacij. Podatki analizi zagotavljajo dejansko podlago. Organizacijam omogočajo sprejemanje bolj objektivnih in na dejstvih utemeljenih odločitev, saj jim omogočajo, da presežejo domneve in intuicijo. Organizacije lahko s pomočjo podatkov najdejo korelacije, trende in vzorce, ki bi jih sicer morda spregledale.

Druga prednost analize podatkov je iskanje organizacijskih neučinkovitosti in področij za izboljšave. Organizacije lahko z ocenjevanjem operativnih podatkov najdejo ozka grla, skrajšajo delovne postopke in izboljšajo splošno učinkovitost poslovnih procesov. Poleg tega analiza podatkov olajša ocenjevanje uspešnosti projektov ali strategij, ki so se začeli izvajati, kar pospeši sprejemanje odločitev in izboljša načrtovanje.


Pred postopkom analize podatkov je treba opisati različne vrste in vire podatkov, razpravljati o modeliranju podatkov in poudariti pomen kakovosti podatkov. To poglavje bo postavilo trdne temelje poslovnega obveščanja in uporabnikom zagotovilo orodja za sprostitve moči podatkov in sprejemanje informiranih odločitev.

1.1. Podatki, informacije, znanje, modrost

Pri opredelitvi pojma podatki se kot izhodišče pogosto uporablja znana piramida podatkov, informacij, znanja in modrosti (DIKW) ali hierarhija DIKW. Rowley (2007) navaja, da hierarhija služi opredelitvi in opisu procesov, ki so vključeni v preoblikovanje entitete na nižji ravni v hierarhiji (kot so podatki) v entiteto na višji ravni v hierarhiji (kot so informacije), ter kontekstualizaciji podatkov, informacij, znanja in občasno modrosti v medsebojnem razmerju.



Vsaka raven piramide temelji na ravni pod njo, za učinkovito odločanje na podlagi podatkov pa so potrebne vse štiri ravni (Cotton, 2023). Slika 1.1 prikazuje piramido DIKW.



Slika 1.1 Piramida DIKW (Data, Information, Knowledge, Wisdom)

Vir: Rowley (2007).

Podatki so surovina, ki nima pomena. Gre za vsebino, ki jo je mogoče neposredno opazovati ali preverjati, za neorganizirano dejstvo, ki je izvzeto iz konteksta in ga je težko razumeti (Brackett, 2015; Dalkir, 2023). Podatki so lahko v obliki števil, besedila, slik itd. Brez razlage bodo podatki ostali brez pomena. Primer podatkov: nabor podatkov, ki vsebuje odčitke temperature, zbrane na vremenskih postajah.

Zbirka podatkov v kontekstu, ki so pomembni za eno ali več oseb ob določenem času ali za določen čas, se imenuje **informacija**. Gre za obdelane, organizirane, strukturirane in kontekstualizirane podatke. Odgovore na pogosta vprašanja, kot so "kdo", "kaj", "kje" in "kdaj", je mogoče najti s pomočjo informacij. (Brackett, 2015; Cotton, 2023). Primer informacij: Z analizo podatkov o temperaturi lahko ugotovimo, da je povprečna temperatura v zadnjem mesecu višja kot v enakem obdobju lani.

Cotton (2023) trdi, da je **znanje** rezultat analize in interpretacije informacij, ki razkriva vzorce, trende in povezave. Ponuja vpogled v to, "kako" in "zakaj" se določeni dogodki dogajajo. Vključuje boljše razumevanje temeljnih idej. Chaffey in Wood (2005, povzeto po Rowley, 2007) opredeljujeta znanje kot "kombinacijo podatkov in informacij, ki jim je dodano strokovno mnenje, veščine in izkušnje, da nastane dragoceno sredstvo, ki se lahko uporabi za pomoč pri odločanju". Primer znanja: Meteorolog lahko z znanjem, pridobljenim z analizo preteklih podatkov o temperaturi, predvidi vremenske razmere za prihodnji teden.

Sposobnost razumevanja dejstev, na katerih temeljijo, ter sprejemanja dobro informiranih odločitev in učinkovitih ukrepov je znana kot **modrost** (Cotton, 2023). Primer modrosti: Na



podlagi vremenskih napovedi in razumevanja lokalnih podnebnih razmer lahko kmet sprejme odločitve o sajenju določene vrste pridelka.

Razumevanje medsebojnega vpliva med podatki, informacijami, znanjem in modrostjo je temeljna podlaga za izkoriščanje potenciala poslovne inteligence. V nadaljevanju te knjige bo to razumevanje služilo kot osnova, na kateri je mogoče izkoristiti moč podatkov in jih preoblikovati v uporabna spoznanja, kar bo organizacije vodilo k uspehu v nenehno razvijajočem se okolju informacijske dobe.

1.2. Viri podatkov in vrste podatkov

V sodobnem času se podatki pogosto imenujejo "nova nafta" - dragocen vir, ki spodbuja inovacije in odločanje. V središču vsakega prizadevanja, ki temelji na podatkih, je spekter vrst podatkov, od katerih ima vsak svoje edinstvene značilnosti in pomen. Vsak dan nastane ogromna količina podatkov. Po trenutnih napovedih je na svetu 97 zettabajtov podatkov, vsak dan pa se ustvari več kot 2,5 kvintilijonov bajtov podatkov. 90 % podatkov na svetu je bilo ustvarjenih v zadnjih dveh letih (Marr, n.d.).

Kenett in Shmueli (2016) pravita, da "podatki lahko izhajajo iz različnih instrumentov zbiranja: anket, laboratorijskih testov, terenskih poskusov, računalniških poskusov, simulacij, spletnih iskanj, mobilnih posnetkov itd. Podatki so lahko primarni, zbrani za namen študije, ali sekundarni, zbrani iz drugega razloga. Podatki so lahko univariatni ali multivariatni, diskretni, zvezni ali mešani. Podatki lahko vsebujejo semantične nestrukturirane informacije v obliki besedila, slik, zvoka in videa. Podatki imajo lahko različne strukture, vključno s presečnimi podatki, časovnimi vrstami, panelnimi podatki, omrežnimi podatki, geografskimi podatki itd. Podatki lahko vključujejo informacije iz enega samega vira ali iz več virov. Podatki so lahko poljubne velikosti in razsežnosti.

Podatki se ustvarjajo hitreje in neprekinjeno. Vsi ti podatki in še več ustvarjajo nove podatke, ki jih je iz nekega razloga treba nekje hraniti. Družabna omrežja, pametni telefoni in slikovna tehnologija, ki se uporablja v medicinski diagnostiki, so le nekateri primeri. Naprave in senzorji samodejno ustvarjajo diagnostične podatke, ki jih je treba takoj analizirati in shraniti. Ohranjanje te ogromne količine podatkov je dovolj težavno, vendar je njihovo analiziranje za prepoznavanje trendov in pridobivanje dragocenih informacij še veliko težje, zlasti če podatki ne ustrezajo tradicionalnim predstavam o strukturi podatkov (EMC Education Services, 2015).



Blazquez in Domenech (2018) pravita, da se tehnologije, povezane z internetom, pametnimi telefoni in pametnimi senzorji, vse bolj vključujejo v večino poslovnih in osebnih vsakodnevnih dejavnosti. Veliko podjetij na primer uporablja družbene medije za promocijo svojih blagovnih znamk, ponuja izdelke prek spleta, s pametnimi telefoni spremlja poti, ki jih opravijo prodajalci, ali uporablja specializirane senzorje za beleženje delovanja strojev. Po drugi strani pa ljudje uporabljajo računalnike, pametne telefone in tablične računalnike za brskanje po spletu za izdelke, komuniciranje s prijatelji, izmenjavo mnenj in iskanje poti. Poleg tega senzorji, nameščeni po mestih, na avtocestah in na javnih površinah, kot so supermarketi, beležijo vsakodnevno gibanje in dejavnosti državljanov. Zaradi tega vse te tehnologije ustvarjajo ogromno količino na novo digitaliziranih in svežih podatkov o dejavnostih ljudi in podjetij. Če so ti podatki ustrezno analizirani, lahko pomagajo prepoznati trende in slediti gospodarskemu, industrijskemu in družbenemu obnašanju.


Sherman (2015) poudarja, da je lahko težava, če ima podjetje več podatkov, kot jih lahko upravlja. Z vsakodnevnimi stiki s strankami, partnerji in dobavitelji zbirajo ogromne količine notranjih in zunanjih podatkov. Izvajajo tržne raziskave in spremljajo informacije o svojih tekmecih. Spletna mesta s kodami za sledenje jim omogočajo, da sledijo natančnemu številu obiskovalcev in njihovem izvoru. Hranijo in upravljajo podatke, potrebne za industrijske pobude in vladne zahteve. Danes obstaja internet stvari (IoT), ki zbira podatke iz senzorjev, vgrajenih v predmete iz resničnega sveta, kot so pasje ovratnice, srčni spodbujevalniki in termostati. Gre za poplavo podatkov. Po podatkih podjetja EMC Education Services (2015) sta med viri velikih podatkov z najhitrejšo stopnjo rasti družbeni mediji in genetsko sekvenciranje, ki sta primera netradicionalnih virov podatkov, ki se uporabljajo za analizo.

Howson (2014) meni, da je uspeh pobude za poslovno obveščanje (BI) odvisen od razpoložljivosti visokokakovostnih in ustreznih podatkov, ki vključujejo širok nabor podatkovnih virov, potrebnih za informiranje procesov odločanja.

Podatki so na voljo v različnih oblikah. Glavne vrste podatkov so (slika 1.2):

1. **Kvantitativni (numerični) podatki** - podatki, ki so izraženi v številkah. Nadalje jih lahko delimo na diskretne in zvezne podatke. Diskretni podatki so podatki, ki imajo lahko samo določeno vrednost (npr. število zaposlenih). Neprekinjeni podatki imajo lahko neskončno število možnih vrednosti (npr. cena izdelka).
2. **Kvalitativni podatki** - to vrsto podatkov lahko razdelimo na kategorične in ordinalne podatke. Kategorični podatki predstavljajo besedilne podatke, ki jih je mogoče razvrstiti

v posamezne kategorije (npr. kraj rojstva, regija, kategorija izdelka), ordinalne podatke pa je mogoče razvrstiti ali urediti (npr. zadovoljstvo strank - zelo nezadovoljen, nezadovoljen, nevtralen, zadovoljen, zelo zadovoljen; stopnja izobrazbe - osnovna, srednja šola, dodiplomski študij, magisterij, doktorat).



Slika 1.2 Glavne vrste podatkov

Vir: Avtor: Avtor.

Podatki se delijo na strukturirane, polstrukturirane in nestrukturirane.

Strukturirane podatke je mogoče shranjevati, obdelovati in obdelovati v tradicionalnem sistemu za upravljanje relacijskih podatkovnih zbirk. Ti podatki prihajajo iz različnih virov, vključno s tokovi klikov, spletnimi obrazci, transakcijami na prodajnih mestih, senzorji in stroji. Ustvarjajo jih lahko ljudje ali stroji. Ti podatki imajo vnaprej določeno obliko, vrsto in organizacijo (EMC Education Services, 2015; Person & Porway, 2015).


Polstrukturirani podatki so organizirani z oznakami, ki pomagajo podatkom dati hierarhijo in red, čeprav ne ustrezajo strukturiranemu sistemu podatkovne zbirke. Podatkovne zbirke in datotečni sistemi pogosto vsebujejo polstrukturirane podatke. Datoteke dnevnikov, besedilo z oznakami HTML, datoteke XML in podatkovne datoteke JSON so nekateri od možnih formatov za shranjevanje. (McKinsey Global Institute, 2011; Person & Porway, 2015).

Ker **nestrukturirani podatki** običajno nastanejo zaradi človeške dejavnosti in ne ustrezajo strukturirani obliki podatkovne zbirke, so v celoti nestrukturirani. Primeri te vrste podatkov so besedilni dokumenti, datoteke PDF, zapisi na spletnih dnevnikih, elektronska sporočila, slike in videoposnetki. (EMC Education Services, 2015; Person & Porway, 2015). Po mnenju Shermana (2015) je treba nestrukturirane in polstrukturirane podatke obravnavati drugače kot tradicionalne strukturirane podatke.

Tej veliki količini strukturiranih in zlasti nestrukturiranih podatkov, ki se ustvarjajo, zbirajo in obdelujejo z veliko hitrostjo in kompleksnostjo, pravimo veliki podatki. McKinsey Global Institute (2011) opredeljuje velike podatke kot "podatke, katerih obseg, porazdelitev, raznolikost in/ali pravočasnost zahtevajo uporabo novih tehničnih arhitektur in analitike za omogočanje vpogledov, ki odpirajo nove vire poslovne vrednosti". Kitchen in McArdle (2016) navajata, da je Doug Laney leta 2001 podrobno opisal, da so za velike podatke značilne tri lastnosti (Three V's):

- **obseg** (sestavljen iz ogromnih količin podatkov),
- **hitrost** (ustvarjena v realnem času),
- **tipi** (strukturirani, polstrukturirani in nestrukturirani).

Po Howsonu (2014) je temelj uspešnega poslovnega obveščanja podatkovna arhitektura (glej sliko 1.3), ki jo sestavlja šest pomembnih vidikov v zvezi s podatki: širina, pravočasnost, kakovost, ustreznost in zrnatost. Kakovost podatkov je osrednji steber, saj je veliko truda vloženega v zagotavljanje in izboljševanje kakovosti podatkov.



Slika 1.3 Podatkovna arhitektura kot temelj za uspešno BI

Vir: Avtor, prirejeno po Howson (2014).

Kot smo že omenili, se lahko podatki zbirajo iz različnih virov. To je povezano s širino podatkov kot enim od stebrov podatkovne arhitekture. Nanaša se na možnost pridobivanja več virov podatkov, kar je danes, v dobi velikih podatkov, običajen način zbiranja podatkov. Po drugi strani pa združevanje podatkov iz več različnih izvornih sistemov prav tako prispeva k težavam s kakovostjo podatkov (Howson, 2014).


V naslednjem podpoglavju se bomo osredotočili na razumevanje podatkov in izkoriščanje njihovega potenciala. Raziskani bodo sistemi za upravljanje relacijskih podatkovnih zbirk

(RDBMS) za shranjevanje in iskanje podatkov ter vizualna predstavitev struktur podatkovnih zbirk z diagrami Entity- Relationship (ER). S povezovanjem razumevanja podatkovnih virov in podatkovnih vrst z modeliranjem in oblikovanjem podatkov bo narejen pomemben korak k praktični uporabi poslovne inteligence.

1.3. Modeliranje in oblikovanje podatkov

Podatkovni model je formalna predstavitev podatkov, ki jih poslovni sistem uporablja in ustvarja. (Dennis et al., 2018). Kot že omenjeno, so strukturirani podatki običajno shranjeni v sistemu za upravljanje relacijskih podatkovnih zbirk (RDBMS). Po Tilleyju (2020) je "sistem za upravljanje podatkovnih zbirk zbirka orodij, funkcij in vmesnikov, ki uporabnikom omogoča dodajanje, posodabljanje, upravljanje, dostop in analizo podatkov". Nekateri priljubljeni RDBMS so Oracle (Oracle), DB2 (IBM) in SQL Server (Microsoft).

V RDBMS so podatki organizirani v tabele, ki vsebujejo zbirko zapisov, v katerih so shranjene informacije o določeni entiteti. Tabele so predstavljene kot dvodimenzionalne strukture z navpičnimi stolpci in vodoravnimi vrsticami. Vsak stolpec predstavlja polje ali atribut entitete, medtem ko vsaka vrstica predstavlja zapis, ki je primerek entitete (Tilley, 2020). Na sliki 1.4 je prikazan primer tabele Izdelek.



PRODUCT			
ID	Name	CategoryID	Price
1032	Laptop	1	800.00
1086	T-shirt	2	20.00
1099	Smartphone	1	600.00
2033	Bread	3	2.00
2058	Sneakers	4	80.00
2069	Headphones	1	40.00

Slika 1.4 Primer tabele v RDBMS

Vir: Avtor: Avtor.

Ta tabela predstavlja preprost katalog izdelkov s 6 izdelki, od katerih ima vsak edinstven ID izdelka, ime, kategorijo in ceno.

Atribut je posebna vrsta podatkov o entiteti. Na primer, ID stranke, ime, priimek, naslov, poštna številka, mesto, država, e-poštni naslov so atributi entitete Customer. Vrstica v tabeli




ali zbirka povezanih polj, ki opisujejo en primerek entitete (na primer stranke), se imenuje **zapis**.

Vsaka tabela v zbirki podatkov mora imeti atribut, ki služi kot **primarni ključ**. To je polje (ali niz polj), ki daje vsakemu izdelku v tabeli posebno identiteto. To pomeni, da v preglednici ne moreta biti dva izdelka z enakim ID.

Tabele v zbirki podatkov so pogosto povezane z drugimi tabelami v zbirki podatkov, kar pomeni, da med njimi obstaja povezava. Razmerja določajo, kako so podatki v eni tabeli povezani s podatki v drugi tabeli.

Po Tilleyju (2020) lahko med entitetami obstajajo tri vrste razmerij: ena-za-eno, ena-za-več in mnogo-za-več. Primeri teh razmerij so prikazani na sliki 1.5.



Slika 1.5 Primeri odnosov med entitetami

Vir: Avtor: Avtor.

Logično strukturo podatkovne zbirke in razmerja med tabelami je mogoče vizualno prikazati s **diagramom razmerij entitet (Entity Relationship Diagram - ERD)**.

Za izdelavo ERD obstajajo različni zapisi, najpogostejša sta Chenov zapis in Martinov zapis (Crow's Foot). V tej knjigi bo predstavljen Martinov zapis.

V skladu z Martinovim zapisom (Crow's Foot) je entiteta predstavljena s pravokotnikom. To je lahko oseba, kraj, dogodek ali stvar, o kateri se zbirajo podatki. Atributi so navedeni kot samostalniki znotraj entitete. Odnosi med entitetami so prikazani s črtami, ki povezujejo entitete med seboj. Razmerja imajo kardinalnost, ki kaže, koliko primerkov ene entitete je povezanih s primerkom druge entitete (Dennis et al., 2018). V zapisu Crow's Foot so kardinalnosti prikazane z različnimi simboli. Na primer, enojna črtica označuje ena, dvojna



črtica označuje ena in samo ena, krog označuje nič, vranja noga pa veliko. V preglednici 1.1 so prikazani različni simboli za kardinalnost in njihov pomen.


Preglednica 1.1 Primeri kardinalnosti

Simbol	Pomen
	Ena in edina
	En ali več
	Nič ali veliko
	Nič ali ena

Vir: Tilley (2020).

Dennis in drugi (2018) navajajo, da obstajajo trije koraki pri oblikovanju ERD:

1. Določite subjekte,
2. Dodajte attribute in dodelite primarne ključne,
3. Prepoznavajte odnose.



Slika 1.6 Primer ERD prodajnega sistema

Vir: Avtor: Avtor.



Slika 1.6 prikazuje del ERD prodajnega sistema. Vsaka entiteta v tem ERD je prikazana kot pravokotnik s seznamom njenih atributov znotraj. Črte, ki povezujejo entitete, so uporabljene za prikaz njihovih razmerij:

- Stranka lahko odda več naročil. Vsakemu naročilu je pripisana edinstvena stranka.
- Eno naročilo lahko vključuje več kot en izdelek. Vsak izdelek je povezan z določenim nakupom.
- Naročilo je povezano s stranko in zaposlenim, ki je naročilo obdelal.
- Izdelek je povezan s kategorijo, saj vsak izdelek pripada eni sami kategoriji.

Osnovno razumevanje modeliranja in oblikovanja podatkov, kot je razvidno iz diagramov ER in RDBMS, je bistvenega pomena za učinkovito uporabo podatkov. To razumevanje vzpostavlja temelje za prehod na pragmatično izvajanje podatkov prek podatkovno usmerjenega odločanja, pri katerem sistematično strukturirani podatkovni modeli zagotavljajo dragocene vpogleda, ki spodbujajo utemeljene poslovne strategije in postopke odločanja.

1.4. Sprejemanje odločitev na podlagi podatkov

Na podatkih temelječe odločanje (DDDM) je strateški pristop, ki temelji na analizi in razlagi podatkov za usmerjanje odločitev in ukrepov. Z uporabo vpogledov, pridobljenih iz obsežnih zbirk podatkov, lahko podjetja natančno krmarijo po negotovosti ter tako zmanjšajo tveganja in povečajo priložnosti. Nelson (2022) opredeljuje odločanje na podlagi podatkov kot proces sprejemanja strateških poslovnih odločitev, ki so v skladu z nameni, cilji in pobudami organizacije, z uporabo dejstev, metrik in podatkov. Odločanje, ki temelji na podatkih, je po Provost & Fawcett (2013) proces sprejemanja odločitev, ki se bolj kot na intuicijo opira na analizo podatkov. Na primer, tržnik lahko izbere oglase samo na podlagi svojega obsežnega znanja o panogi in dobrega občutka za to, kaj bo pritegnilo potrošnike. Druga možnost je, da svojo odločitev utemelji na analizi podatkov, ki kažejo, kako se potrošniki odzivajo na različne oglase.

Pri tem pristopu se odločitve ne sprejemajo na podlagi intuicije, temveč na podlagi trdnih dejstev. Vključuje zbiranje, analiziranje in razlaganje podatkov, da bi ugotovili vzorce, trende in korelacije. Ne glede na to, ali gre za optimizacijo operativne učinkovitosti, izboljšanje izkušenj strank ali izpopolnjevanje strategij izdelkov, odločitve, ki temeljijo na podatkih, podjetjem omogočajo, da se prilagodijo dinamičnim trgom in na njih uspevajo.



Z vključevanjem podatkov v proces odločanja postanejo organizacije bolj prilagodljive, odzivne in odporne na spremembe, s čimer spodbujajo inovacije in trajnostno rast. Veliko število raziskovalnih člankov je pokazalo, da je odločanje na podlagi podatkov povezano z večjo produktivnostjo (npr. Brynjolfsson in McElheran, 2019; Sala et al., 2022; Colombari et al., 2023). Zato večina organizacij, zlasti velikih, vlaga v zbiranje in analiziranje svojih podatkov. Več kot dve tretjini od več kot 300 vodstvenih delavcev, ki so sodelovali v raziskavi družbe Bain & Company (2017), pravi, da njihovo podjetje veliko vlaga v podatkovno analitiko, več kot polovica pa pričakuje transformacijske donose svojih naložb.

Obstaja pet korakov za sprejemanje odločitev, ki temeljijo na podatkih (Asana, 2022):

1. Razumevanje vizije podjetja,
2. Iskanje virov podatkov,
3. Čiščenje in urejanje podatkov,
4. Izvajanje analize podatkov,
5. Sklepanje.

McKinsey Global Institute (2014) poroča, da imajo organizacije, ki temeljijo na podatkih, 23-krat večjo verjetnost, da bodo pridobile stranke, 6-krat večjo verjetnost, da jih bodo obdržale, in 19-krat večjo verjetnost, da bodo dobičkonosne.

Svetovno priznana podjetja, ki svoje odločitve sprejemajo na podlagi podatkov, so Google, Amazon in Netflix.

Da bi organizacija v celoti izkoristila potencial poslovne inteligence, je treba upoštevati kakovost podatkov, kar je podrobneje opisano v naslednjem razdelku. Ta kakovost zagotavlja natančnost in zanesljivost zaključkov in vpogledov, pridobljenih iz podatkov.

1.5. Kakovost podatkov

Stopnja natančnosti, doslednosti, zanesljivosti in primernosti za določen namen se imenuje kakovost podatkov. Kakovost podatkov je pomembna v okviru poslovnega obveščanja in analize podatkov, saj so zaključki in sodbe, pridobljeni na podlagi podatkov, večinoma odvisni od njihove natančnosti in zanesljivosti. Slaba kakovost podatkov lahko privede do napačnih sklepov, zgrešenih strategij in na koncu do škodljivih poslovnih rezultatov. Po podatkih družbe Gartner (2021) slaba kakovost podatkov vsako leto organizacije v povprečju stane 12,9 milijona dolarjev.



Kakovost podatkov lahko opišemo s šestimi najpogosteje uporabljenimi dimenzijami (Foote, 2022):

- **Natančnost:** kako natančne so vrednosti atributov v podatkih?
- **Popolnost:** ali so podatki popolni, brez manjkajočih informacij?
- **Doslednost:** kako dosledne so vrednosti v podatkovnih zbirkah in med njimi?
- **Pravočasnost:** kako pravočasni so podatki?
- **Veljavnost:** kako so podatki skladni z vnaprej določenimi poslovnimi pravili?
- **Edinstvenost:** ali je vsak zapis enolično identificiran, brez odvečnega shranjevanja?

Po Shermanu (2015) se lahko podatki štejejo za visokokakovostne, če imajo naslednje značilnosti (pet C podatkov):

- **Čistost (Clean)** - nanaša se na manjkajoče elemente, neveljavne vnose in druge podobne težave.
- **Doslednost (Consistent)** - enotnost in skladnost podatkov v različnih virih in znotraj samega nabora podatkov.
- **Skladni (Conformed)** - nanašajo se na podatke, ki so skladni z vnaprej določenimi podatkovnimi standardi in pravili.
- **Aktualni (Current)** - za sprejemanje odločitev in analizo je treba uporabljati najnovejše podatke.
- **Celovit (Comprehensive)** - vključuje vse bistvene podatkovne elemente, ki so potrebni za predvideni postopek odločanja, ne da bi izpustili ključne informacije.

Kenett in Shmueli (2016) pravita, da je treba skoraj vse podatke očistiti, preden jih je mogoče uporabiti za nadaljnjo analizo. Vendar pa cilj določa stopnjo čiščenja in strategijo čiščenja podatkov. V istih podatkih so lahko visokokakovostne informacije za en namen in nizkokakovostne informacije za drug namen.

Gartner (2023) je nedavno opredelil niz 12 ukrepov za izboljšanje kakovosti podatkov. Ti ukrepi so bili razvrščeni v štiri različne kategorije, ki jih je treba upoštevati pri ocenjevanju celovitosti podatkov:

- Pri postavljanju trdnih temeljev se osredotočite na prave stvari,
- Uporaba odgovornosti za kakovost podatkov,
- Vzpostavitev kakovosti podatkov, ki ustreza namenu,
- Vključite kakovost podatkov v kulturo podjetja.



Po mnenju Howsona (2014) se dosledni, celoviti in natančni podatki štejejo za zelo kakovostne. Dobro kakovost podatkov je težko doseči, saj imajo velik vpliv organizacijske in lastniške težave.

Sposobnost razumevanja in analiziranja podatkov je ključnega pomena za sprejemanje premišljenih odločitev na področju poslovne inteligence. Razumevanje procesa od surovih podatkov do uporabnih vpogledov, ki vključuje različne vire podatkov, vrste, modeliranje in oblikovanje, je sestavni del procesa pridobivanja vrednosti iz informacij.

VIRI

1. Asana (2022). Data-driven decision making: A step-by-step guide [available at: <https://asana.com/resources/data-driven-decision-making>, access November 5, 2023]
2. Bain & Company (2017). Closing the Results Gap in Advanced Analytics: Lessons from the Front Lines [available at: <https://www.bain.com/insights/closing-the-results-gap-in-advanced-analytics-lessons-from-the-front-lines/>, access November 5, 2023]
3. Blazquez, D. & Domenech, J. (2018). Big Data sources and methods for social and economic analyses. Technological Forecasting & Social Change, 130, pp. 99-113.
4. Brackett, M. (2015). The Data-Information-Knowledge Cycle. Dataversity [available at: <https://www.dataversity.net/the-data-information-knowledge-cycle/>, access November 5, 2023]
5. Brynjolfsson, E. & McElheran, K. (2019). Data in Action: Data-Driven Decision Making and Predictive Analytics in U.S. Manufacturing. Rotman School of Management Working Paper No. 3422397 [available at: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3422397, access November 5, 2023]
6. Chaffey, D. & Wood, S. (2005). Business Information Management: Improving Performance using Information Systems. FT Prentice Hall.
7. Colombari, R., Geuna, A., Helper, S., Martins, R., Paolucci, E., Ricci, R. & Seamans, R. (2023). International Journal of Production Economics, 255.



8. Cotton, R. (2023). The Data-Information-Knowledge-Wisdom Pyramid. Datacamp [available at: <https://www.datacamp.com/cheat-sheet/the-data-information-knowledge-wisdom-pyramid>, access November 5, 2023]
9. Dalkir, K. (2023). Knowledge Management in Theory and Practice, 4th Edition. MIT Press.
10. Dennis, A., Wixom, B. H. & Roth, R. M. (2018). Systems Analysis and Design, 7th Edition. Wiley.
11. EMC Education Services (2015). Data Science and Big Data Analytics: Discovering, Analyzing, Visualizing and Presenting Data. Wiley.
12. Foote, K. D. (2022). Data quality dimensions. Dataversity [available at: <https://www.dataversity.net/data-quality-dimensions/>, access November 5, 2023]
13. Gartner (2021). How to Improve Your Data Quality [available at: <https://www.gartner.com/smarterwithgartner/how-to-improve-your-data-quality>, access November 5, 2023]
14. Gartner (2023). Gartner Identifies 12 Actions to Improve Data Quality [available at: <https://www.gartner.com/en/newsroom/press-releases/2023-05-22-gartner-identifies-12-actions-to-improve-data-quality>, access November 5, 2023]
15. Howson, C. (2014). Successful Business Intelligence: Unlock the Value of BI & Big Data, 2nd Edition. McGraw-Hill Education.
16. Kenett, R. S. & Shmueli, G. (2016). Information Quality: The Potential of Data and Analytics to Generate Knowledge. Wiley.
17. Kitchen, R. & McArdle, G. (2016). What makes Big Data, Big Data? Exploring the ontological characteristics of 26 datasets. Big Data & Society, 3(1).
18. Marr, B. (n.d.). How Much Data Do We Create Every Day? The Mind-Blowing Stats Everyone Should Read. Bernard Marr & Co. [available at: <https://bernardmarr.com/how-much-data-do-we-create-every-day-the-mind-blowing-stats-everyone-should-read/>, access November 5, 2023]
19. McKinsey Global Institute (2011). Big data: The next frontier for innovation, competition, and productivity. [available at: https://www.mckinsey.com/~media/mckinsey/business%20functions/mckinsey%20digital/our%20insights/big%20data%20the%20next%20frontier%20for%20innovation/mgi_big_data_full_report.pdf, access November 5, 2023]



20. McKinsey Global Institute (2014). Five facts: How customer analytics boosts corporate performance [available at: <https://www.mckinsey.com/capabilities/growth-marketing-and-sales/our-insights/five-facts-how-customer-analytics-boosts-corporate-performance>, access November 5, 2023]
21. Nelson, M. (2022). Beyond The Buzzword: What Does Data-Driven Decision-Making Really Mean?. Forbes [available at: <https://www.forbes.com/sites/tableau/2022/09/23/beyond-the-buzzword-what-does-data-driven-decision-making-really-mean/?sh=2d35c4eb25d6>, access November 5, 2023]
22. Provost, F. & Fawcett, T. (2013). Data science and its relationship to big data and data-driven decision making. *Big data*, 1(1), pp. 51-59.
23. Rowley, J. (2007). The wisdom hierarchy: representations of the DIKW hierarchy. *Journal of Information Science*, 33(2), pp. 163–180.
24. Sala, R., Pirola, F., Pezzotta, G. & Cavalieri, S. (2022). Data-Driven Decision Making in Maintenance Service Delivery Process: A Case Study. *Applied Sciences*, 12(15).
25. Sherman, R. (2015). *Business Intelligence Guidebook: From Data Integration to Analytics*. Elsevier Inc.
26. Tilley, S. (2020). *Systems Analysis and Design*, 12th Edition. Cengage.



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.



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.

3.3.1. 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 vpogled, 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 vpogleda 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 34Naloge 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 35Koraki, 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.

VIRI

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.



4. STROJNO UČENJE

Avtor: Dejan Mirčetić

Veliko je vprašanj o tem, kaj je strojno učenje (ML – Machine Learning). Ali gre za dejanski proces, v katerem se stroji sami učijo iz zunanjega okolja, ali za formaliziran proces z matematičnimi algoritmi, ki računalnikom omogočajo, da "ugotovijo" pravila v zunanjem svetu? Katera orodja uporablja ML? Kako je videti tipičen pretok podatkov v cevovodu ML? Ali se uporablja v tradicionalnih panogah, ne le v panogah, povezanih z informacijsko tehnologijo in internetom? Kje je mesto ML v okviru poslovanja? Kako ga sistematično uporabiti za reševanje poslovnih vprašanj? Ali obstaja kakšna arhitektura, kako jo uporabiti v nadzornih organih?


Na ta in podobna vprašanja bomo poskušali odgovoriti v naslednjem poglavju, ki ga bomo zaključili s primerom študije primera uporabe algoritmov ML v verigi preskrbe s hrano.

4.1. Kaj je strojno učenje?

Strojno učenje je disciplina, ki se osredotoča na dve medsebojno povezani vprašanji: Kako lahko zgradimo računalniške sisteme, ki se samodejno izboljšujejo z izkušnjami? in Kateri so temeljni statistični računalniško-informacijsko teoretični zakoni, ki veljajo za vse učne sisteme, vključno z računalniki, ljudmi in organizacijami? Študij strojnega učenja je pomemben tako zaradi obravnavanja teh temeljnih znanstvenih in inženirskih vprašanj kot tudi zaradi zelo praktične računalniške programske opreme, ki je bila ustvarjena in uporabljena v številnih aplikacijah (Jordan in Mitchell, 2015).

ML izhaja iz tega vprašanja: ali lahko računalnik preseže "tisto, kar mu znamo naročiti", in se sam nauči, kako opraviti določeno nalogo? Ali nas lahko računalnik presenetiti? Namesto da bi programerji ročno oblikovali pravila za obdelavo podatkov, bi se lahko računalnik samodejno naučil teh pravil s pregledovanjem podatkov? To vprašanje odpira vrata novi paradigmi programiranja (Chollet, 2021).

ML omogoča temeljno spremembo paradigme programiranja (slika 4.1). Pri klasičnem programiranju programer vnaša pravila (program), podatki pa se analizirajo in obdelujejo v skladu s temi pravili. Rezultat je, da so na koncu na voljo odgovori. Po drugi strani pa pri ML človeški programer vnaša podatke s pričakovanimi odgovori na podlagi podatkov in rezultatom pravil.



Slika 41 Klasično programiranje v primerjavi s sistemom strojnega učenja

Vir: Chollet (2021).

Klasično programiranje bi lahko razumeli kot imperativno programiranje, saj programer vnaprej določi vsa pravila in se koda izvaja v skladu z njimi, medtem ko bi lahko ML razumeli kot deklarativno programiranje, kjer izrazimo cilje na višji ravni ali opišemo pomembne omejitve in se zanašamo na matematične algoritme, ki se odločijo, kako in/ali kdaj to prenesti v dejanja.

Danes je ML temelj nešteti pomembnih aplikacij, vključno s spletnim iskanjem, preprečevanjem neželene elektronske pošte, prepoznavanjem govora, priporočanjem izdelkov in drugimi (Ng, 2017). Številni razvijalci sistemov umetne inteligence se zdaj zavedajo, da je za številne aplikacije veliko lažje usposobiti sistem tako, da mu pokažemo primere želenega vhodno-izhodnega vedenja kot pa ga ročno programirati s predvidevanjem želenega odziva za vse možne vhode. Učinek ML se je pokazal tudi v računalništvu in v številnih panogah, ki ukvarjajo z vprašanji, ki zahtevajo veliko podatkov, kot so storitve za potrošnike, diagnosticiranje napak v kompleksnih sistemih in nadzor logističnih verig (Jordan in Mitchell, 2015).



4.2. Osnove in teoretične predpostavke ML

Ozadje ML je v matematiki, natančneje v statistiki. Zato ML uporablja teoretično ozadje in algoritme, razvite v **statističnem učenju**, pri čemer se razpravlja tudi o tem, ali je ML samostojno področje ali pa je le del statistike. V praksi algoritmi ML običajno nimajo določene stopnje matematične togosti in včasih zlahka presežejo nekatere matematične omejitve, ki so prisotne v statistiki. Algoritmi ML na primer pri optimizaciji koeficientov v parametričnih algoritmi ne posvečajo veliko pozornosti intervalom zaupanja, čeprav je to ena najpomembnejših tem v statistiki. Na splošno **se ML in statistika zelo prekrivata**, nekateri najvidnejši ustvarjalci algoritmov ML in profesorji pa trdijo, da je ML le del statistike (Hastie et al., 2009). Kljub temu je ML, ki je samostojno področje ali del statistike, sestavljen iz več korakov pri pridobivanju znanja iz podatkov. Splošnega soglasja o teh korakih ni, na splošno pa jih je mogoče predstaviti kot pretvorbo različnih virov podatkov v spoznanja poslovne inteligence.


V poslovnem kontekstu so modeli ML neuporabni brez ustrezne podpore pri predobdelavi podatkov, podatkovnem rudarjenju in uporabi spoznanj v dejanskih procesih. Zato ustvarjanje algoritmov ML brez možnosti posodabljanja modela in uporabe njegovih rezultatov za dejanski proces odločanja sodobnim podjetjem ne prinaša nobene vrednosti. V skladu s tem je v sodobni poslovni analitiki kvantitativni postopek ML običajno del delovnega procesa poslovne inteligence. Natančneje, je del pomembnih podprocesov poslovne inteligence (podatkovna znanost in podatkovna analitika del poslovne inteligence). Podrobnosti o vlogi ML v teh procesih in samih procesih ustvarjanja vrednosti za poslovanje s pomočjo ML bodo navedene v naslednjem podpoglavju.

4.3. Poslovna inteligenca in ML v SC

Poslovno obveščanje v kontekstu SC je postopek oblikovanja zaključkov o opazovanih procesih SC na podlagi modeliranja podatkov iz teh procesov. Večinoma temelji na statistiki, vendar so v igri tudi druga matematična področja: operacijske raziskave, linearna algebra, fuzzy logika (v primeru, ko je podatkov malo ali jih ni), numerična optimizacija, metahevrstika itd. Poleg tega postajajo pomemben vidik za analizo podatkov in pripravo zaključkov tudi nove prelomne tehnologije: **strojno učenje, umetna inteligenca, digitalni dvojčki, smartizacija, živi laboratoriji** itd.




Strogo organiziranih postopkov, kako naj bi bili organizirani poslovna inteligenca postopek in delovni tokovi ML, ni, vendar v praksi in literaturi obstaja nekaj uporabnih smernic, ki so se izkazale za uspešne pri izvajanju analize. Postopek izvajanja poslovne inteligenca se razlikuje tudi glede na izvor programske opreme, ki se uporablja za analizo. Microsoft na primer prek svojega kanala Microsoft Business Intelligence package ponuja več orodij, ki izvajajo različne naloge: **vnos podatkov, shranjevanje podatkov, integracija podatkov, upravljanje podatkov, obdelava podatkov, poročanje, izmenjava podatkov in podatkovna znanost** (slika 4.2).



Slika 4.2 Arhitektura Microsoftove poslovne inteligenca

Vir: ScienceSoft (n.d.).

V dani arhitekturi se postopki ML uporabljajo samo na ravni podatkovne znanosti z več orodji: Azure ML services, ML studio in R Server for HDInsight. Splošni postopek, kako se analiza podatkov v okviru ML izvaja v strežniku R, je predstavljen na sliki 4.3.




Slika 4.3 Koraki analize podatkov ML v R

Vir: Wickham et al. (2023).

Pri ML je običajno **zmotno prepričanje, da se večina časa in truda porabi za dejansko izdelavo algoritmov ML**. V resnici je ravno obratno, večina časa se običajno porabi za delo s podatki in naloge predobdelave, ne pa za postopek modeliranja. Včasih so vsi postopki pred postopkom modeliranja veliko bolj zahtevni in zahtevni. Zato ni soglasja o tem, kako je treba te korake izvesti. Na sliki 2.9 je predstavljen primer dobrega pristopa k preoblikovanju podatkov v poslovna spoznanja in splošno znanje. Postopek se začne s korakom uvoza, ki je eden najpomembnejših korakov pri gradnji modelov ML, saj brez uvoza podatkov v programsko opremo ni mogoče izvesti nobene analize. To običajno pomeni, da vzamete podatke, shranjene v datoteki, zbirki podatkov ali spletnem vmesniku za programiranje aplikacij (API), in jih naložite v podatkovni okvir v programu R (Wickham et al., 2023). Drugi korak je povezan z urejanjem podatkov, ki je postopek, edinstven za program R, in se nanaša na preoblikovanje podatkov v določeno obliko za nadaljnjo analizo (vsak stolpec je spremenljivka, vsaka vrstica pa je podatkovni okvir opazovanja-tibla). Naslednji korak je povezan s preoblikovanjem podatkov, ki običajno vključuje zožitev nabora opazovanj na podvzorec, ki nas zanima. Poleg tega lahko vključuje tudi ustvarjanje novih spremenljivk kot kombinacije več obstoječih ali generiranje zbirnih statistik. Vizualizacija in modeliranje imata na področju analize podatkov različni, vendar dopolnjujoči se vlogi. Vizualizacija je dejavnost, ki je v veliki meri osredotočena na človeka in ponuja vpogled, ki se lahko izmika bolj formaliziranim pristopom. Dobro pripravljena vizualizacija lahko razkrije nepričakovane vzorce, spodbudi nove poizvedbe in celo predlaga, da je prvotna vprašanja morda treba izboljšati ali uporabiti druge podatke. Nasprotno pa modeli zagotavljajo matematični ali računalniški okvir za odgovore na natančno oblikovana vprašanja. Ponujajo razširljivost in učinkovitost, zaradi česar so primerni za obdelavo velikih zbirk podatkov. Vendar imajo modeli (v katere so vključeni tudi ML) inherentne predpostavke in ne morejo postavljati vprašanj ali izpodbijati teh predpostavk. Posledično modeli morda ne



morejo presenetiti ali razkriti nepredvidenih spoznanj. Sinergija med vizualizacijo in modeliranjem se kaže v njuni skupni vlogi pri analizi podatkov. Vizualizacija pomaga pri začetnem raziskovanju in spodbuja oblikovanje natančnih vprašanj, medtem ko modeli sistematično zagotavljajo odgovore v okviru opredeljenih parametrov. Prepoznavanje prednosti in omejitev vsakega od pristopov je ključnega pomena, kar vodi k bolj celovitemu in informiranemu procesu analize podatkov. Zadnji korak predstavlja komunikacijo, ki je ključna za uspeh analize podatkov, saj če informacije niso posredovane nosilcu odločanja na pravilen in dosleden način, je lahko celotna analitika zaman. Ključni element podatkovne analitike so ML modeli, brez katerih ni mogoče izpeljati zaključkov o poslovnih procesih. Za reševanje specifičnih problemov SC je treba bolje prilagoditi arhitekturo za splošno namenske aplikacije poslovne inteligence (predstavljeno na sliki 4.2), prav tako tudi modele ML. V skladu s tem je podjetje **Equilibrium AI** za preoblikovanje delovanja oskrbovalnih verig s povečanjem operativne učinkovitosti, izboljšanjem odločanja in usmerjanjem k doseganju ciljev podjetja razvilo platformo AI & ML, predstavljeno na sliki 4.4.



Slika 4.4 Potek podatkov in znanja ML za podjetje Equilibrium AI

Vir: Equilibrium AI (n.d.).

Slika predstavlja dober primer vsakodnevne prakse, kako se v aplikacijah SC pridobivajo znanja in vpogledi. Na splošno je postopek sestavljen iz operacij zaledja in sprednjega dela, da bi ustvarili vrednost (poslovna spoznanja) za uporabnike. Postopek backend se začne z ekstrakcijo podatkov iz različnih podatkovnih virov, ki jih običajno najdemo v SC:



- Podatkovne zbirke;
- sistemi za načrtovanje virov podjetja (SAP, Navigator, Microsoft Dynamics itd.);
- aplikacije (spletni vmesniki API);
- ploščate datoteke (csv, xlsx, JSON itd.);
- Splet, internet in drugi spletni viri.

Vsak vir podatkov ima drugačno strukturo, protokole in ustrezne postopke za pridobivanje in nalaganje podatkov za čiščenje in predobdelavo pred uporabo algoritmov ML. Zato se ta postopek izvaja s pomočjo nalagalnikov podatkov, ki imajo vnaprej programirano kodo za podatkovno rudarjenje različnih podatkovnih virov in prenos podatkov iz vrstic v novo podatkovno zbirko, ki je strukturirana in urejena za uporabo modelov ML. Pred uporabo modelov ML je potreben še en korak, ki se imenuje predobdelava podatkov. V tem koraku se podatki iz vrstic, zbrani od podjetij, preverijo glede na napačne vnose, nelogične vrednosti, pravilno strukturo vnosov, odstopanja, dvojne vnose, NA, NaN itd. Postopek se nadaljuje z združitvijo zunanjih podatkov s podatki podjetja. Ti podatki so običajno povezani z zunanjimi dejavniki, ki lahko potencialno vplivajo na opazovani poslovni proces SC, na primer vremenski podatki, indeks cen življenjskih potrebščin, povprečni dohodek v določeni regiji, posebne demografske značilnosti na določenem območju, cene plina, izbruhi pandemij, komentarji družbenih omrežij o izdelkih podjetja itd. To je zelo pomembno, ker se tako celostno zberejo vsi možni dejavniki (notranji in zunanji), ki bi lahko vplivali na določen poslovni proces, kar povečuje možnost, da bodo modeli ML v podatkih našli pravi signal in bodo lahko sprejeli pravilne sklepe in pravila, kateri so temeljni vzroki, zakaj se poslovni proces obnaša tako, kot je opazovan.

Po združitvi notranjih in zunanjih podatkov je predobdelava sestavljena iz zaznavanja signalov, odstranjevanja šuma iz podatkov, oblikovanja značilnosti in naključne razdelitve podatkov na učne in testne (včasih tudi na validacijske podatke, če je razvit model nevronske mreže). Podatki, pridobljeni v koraku predobdelave, se očistijo in strukturirajo za uporabo modelov ML.

Izhodni del je sestavljen iz vizualizacije podatkov, razvoja ML in AI ter izmenjave podatkov. Včasih se ti podatki delijo brez uporabe modelov ML z drugimi platformami, ki izvajajo različne vrste analiz (samo poročanje zainteresiranim stranem ali vladnim agencijam). Postopek vizualizacije se izvaja prek frontend dela platforme, ki je osredotočen na uporabnika in uporabnikom omogoča, da podajo zahteve o tem, katere podatke, kako in v kakšnih nastavitvah želijo videti opazovane podatke SC (na primer slika 4.5).




Equilibrum AI



Slika 4.5 Tipični vizualizacijski del platforme ML v SC

Nasprotno pa je del ML za obdelavo podatkov skrit pred očmi uporabnikov in ga ni lahko razumeti. Zato se modeli ML včasih obravnavajo kot modeli **črne skrinjice**, pri katerih ni jasno, kako natančno je stroj povezal opazovani vhod z opazovanim izходом. To je ena od ovir, ki preprečuje širšo uporabo modelov ML v praksi, zlasti tistih, ki so zapleteni za razlago (Rostami-Tabar in Mircetic, 2023). V skladu s tem bi lahko modele ML razdelili na tiste z visoko interpretabilnostjo - nizko prilagodljivostjo in nizko interpretabilnostjo - višjo prilagodljivostjo (slika 4.6). Na splošno velja, da se s povečevanjem prožnosti metode ML običajno povečuje natančnost modela ML in zmanjšuje interpretibilnost (Mirčetić et al., 2016).




Slika 46 Prikaz kompromisa med prožnostjo in razlagalnostjo z uporabo različnih metod ML

Vir: Hastie et al. (2009).

4.3.1. Poslovni podatki ML in SC

Če uporabniki bolje razumejo vizualizacijo in grafiko, kot je slika 4.5, zakaj sploh potrebujemo ML in ali bi lahko preskočili modeliranje podatkov z ML ter naredili samo informativno grafiko? Žal ne. Morda je glavni razlog, zakaj potrebujemo modele ML, ta, da v vseh primerih ni mogoče imeti lahko berljivih in zaznavnih vzorcev v podatkih, vidnih prek grafike (kot na sliki 4.5). Pogostejša situacija je, da z grafiko običajno ne moremo razkriti skrivnosti dogajanja v opazovanih poslovnih podatkih SC in potrebujemo močnejša orodja v obliki algoritmov ML, da se poglobimo v podatke in poiščemo **pravila, ki ustvarjajo podatke** (slika 4.7).



Slika 4.7 Statistične značilnosti izdelkov v verigi preskrbe s hrano (povzeto za vse izdelke)

Na podlagi slike 4.7 je zelo težko preprosto sklepati in izpeljati poslovna pravila o postopku ustvarjanja podatkov. Za iskanje vzorcev v podatkih s slike smo razvili model ML, ki bi ga lahko uporabili za povzemanje značilnosti in odkrivanje pomembnih signalov v podatkih. V skladu s tem je razviti ML model za verigo preskrbe s hrano predstavljen v enačbi 1. Osnovno gonilo in hrbtenica tega modela ML je avtoregresijski integrirani model drsečega povprečja z naslednjo splošno obliko:

$$y_t^i = c + (\phi_1 y_{t-1}^i + \dots + \phi_p y_{t-p}^i) + (\theta_1 e_{t-1} + \dots + \theta_q e_{t-q}) + e_t; \quad (1)$$

$$y_t - y_{t-1} = c + \phi_1 (y_{t-1} - y_{t-2}) + \dots + \phi_p (y_{t-p} - y_{t-p-1}) + (\theta_1 B e_t + \dots + \underbrace{\theta_q e_{t-q}}_{\theta_q B^q e_t});$$

$$y_t - B y_t = c + \phi_1 (y_{t-1} - B y_{t-1}) + \dots + \phi_p (y_{t-p} - B y_{t-p}) + (e_t (1 + \theta_1 B + \dots + \theta_q B^q));$$

$$(1 - B) y_t = c + \phi_1 (1 - B) (y_{t-1}) + \dots + \phi_p (1 - B) y_{t-p} + e_t (1 + \theta_1 B + \dots + \theta_q B^q);$$

$$(1 - B) y_t = c + \phi_1 (1 - B) B y_t + \dots + \phi_p (1 - B) B^p y_t + e_t (1 + \theta_1 B + \dots + \theta_q B^q);$$

$$\underbrace{(1 - B)^d y_t}_{\text{differencing } d_degree} \cdot \underbrace{(1 - \phi_1 B - \dots - \phi_p B^p)}_{AR(p)} = c + \underbrace{e_t (1 + \theta_1 B + \dots + \theta_q B^q)}_{MA(q)}.$$

Model ML jasno kaže na svojo nizko interpretabilnost in značilnosti črne skrinjice. Povprečen poslovni uporabnik težko razume povezave med vhodnimi in izhodnimi podatki. Poleg tega se povprečnemu poslovnemu uporabniku ob soočenju s predstavljenim modelom poraja



vprašanje! Kaj je enačba (1)? Lahko trdimo, da enačba (1) predstavlja pravila s slike 4.1, ki jih ustvari ML data & knowledge pipeline in ki razkrivajo skrivnost o procesih ustvarjanja podatkov v danem poslovnem okolju SC.

Na prvi pogled se zdi, da razviti model ML v enačbi (1) ne izboljša našega razumevanja podatkov. Še vedno smo zmedeni kot pri sliki 4.7, vendar ima ML model v primerjavi s sliko ključno prednost. V bistvu je model ML **matematična formula**, ki človeškemu uporabniku morda ni lahko razumljiva, je pa popolnoma razumljiva računalniku, ki ga **je mogoče programirati, da uporabi dano formulo** in **sprejme poslovne odločitve na** podlagi odkritih pravil.

VIRI

1. Chollet, F. (2021). Deep learning with Python. Simon and Schuster.
2. Equilibrium AI (n.d.). Equilibrium AI Data Pipeline [available: <https://eqains.com/>, access: January 23, 2024]
3. Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). The elements of statistical learning: Data mining, inference, and prediction (Vol. 2). Springer.
4. Jordan, M. I. & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. Science, 349(6245), pp. 255-260.
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. Ng, A. (2017). Machine learning yearning. [available: <http://www.mlyearning.org/>, access: January 23, 2024]
7. Rostami-Tabar, B. & Mircetic, D. (2023). Exploring the association between time series features and forecasting by temporal aggregation using machine learning. Neurocomputing, 548, 126376.
8. ScienceSoft (n.d.). Microsoft Business Intelligence to Drive Robust Analytics and Insightful Reporting [available: <https://www.scnsoft.com/services/business-intelligence/microsoft>, access: January 23, 2024]



9. Wickham, H., Çetinkaya-Rundel, M. & Grolemund, G. (2023). R for data science. O'Reilly Media, Inc.



5. UPRAVLJANJE POSLOVNIH PROCESOV IN PROCESOV RUDARJENJA

Avtor: Dario Šebalj

Za ohranjanje konkurenčnosti v današnjem poslovnem okolju sta ključnega pomena učinkovito upravljanje in nenehno izboljševanje procesov. To poglavje obravnava upravljanje poslovnih procesov (BPM) in procesno rudarjenje, dva pomembna dela poslovne inteligence, ki podjetjem pomagata analizirati, optimizirati in izboljšati njihove operativne procese.

BPM zagotavlja organizirano in strukturirano metodo za prepoznavanje, načrtovanje, izvajanje, spremljanje in izboljševanje poslovnih procesov ter njihovo usklajevanje s strateškimi cilji organizacije. Po drugi strani pa je procesno rudarjenje orodje za prepoznavanje in izboljševanje dejanskih procesov s pridobivanjem znanja iz dnevnikov dogodkov, ki jih najdemo v sodobnih poslovnih informacijskih sistemih. Kombinacija upravljanja poslovnih procesov in procesnega rudarjenja omogoča objektivno, s podatki podprto metodo za razumevanje in izboljševanje poslovnih procesov.

Z uporabo teh metodologij lahko organizacije najdejo skrite neučinkovitosti in težave, se prilagodijo spreminjajočim se zahtevam trga ter izboljšajo svojo uspešnost in zadovoljstvo strank. V tem poglavju bodo obravnavani temeljni koncepti, metodologije, orodja in dejanska uporaba BPM in procesnega rudarjenja.

5.1. Poslovni proces

Vsaka organizacija, ne glede na svojo velikost ali dejavnost, je zapleten sistem medsebojno povezanih procesov. Ti procesi predstavljajo strukturirane dejavnosti, usmerjene k doseganju določenih organizacijskih ciljev. V proizvodnem podjetju med ključne procese običajno sodijo zasnova izdelka, nabava surovin, proizvodnja, nadzor kakovosti in distribucija. V storitveno usmerjenem podjetju, kot je banka, procesi vključujejo odpiranje računov, obdelavo posojil, storitve za stranke in preverjanje skladnosti. Organizacije vsakodnevno izvajajo številne procese, ki so tako raznoliki, kot so raznolike same organizacije. V bolnišnici na primer procesi



obsegajo sprejem pacienta, zdravstveno obravnavo in odpust. V izobraževalni ustanovi pa zajemajo vpis študentov, izvajanje predavanj in upravljanje izpitov. Vsak proces je zaporedje korakov, ki vključujejo različne oddelke in zaposlene ter so pogosto podprti s tehnologijo.

Po Dumasu in sod. (2018) je vsak poslovni proces sestavljen iz več dogodkov in dejavnosti.

Dogodki predstavljajo enkratne, trenutne pojave brez trajanja, ki se zgodijo atomsko (npr. »Prejeto naročilo«). **Dejavnosti** pa so naloge ali operacije, ki so med seboj povezane in katerih izvedba prispeva k doseganju cilja poslovnega procesa (npr. »Plačilo računa«). Tipičen proces poleg dogodkov in dejavnosti vključuje tudi **odločitve**, ki označujejo točke, na katerih se določi nadaljnji potek procesa. Na primer, v prodajnem procesu je ena od odločitev lahko preverjanje zaloge izdelka. Če je izdelek na voljo, se proces nadaljuje z naslednjo dejavnostjo. Če izdelka ni na zalogi, se proces preusmeri (npr. z obvestilom stranki, da naročila ni mogoče izpolniti). Pomembni sestavni deli procesa so tudi **akterji** (udeleženci) in objekti. Med akterje štejemo ljudi, organizacije ali programske sisteme, ki izvajajo posamezne dejavnosti v procesu. **Objekti** pa so lahko fizični (npr. oprema, materiali, papirnati dokumenti) ali informacijski (npr. elektronski dokumenti, zapisi).

Dumas in drugi (2018) navajajo, da je rezultat izvajanja procesa eden ali več **rezultatov**. Rezultat naj bi teoretično koristil vsem strankam, vključenim v proces (*pozitivni rezultat*). Včasih pa je ta vrednost dosežena le delno ali nikoli (*negativni rezultat*).

Von Scheel in drugi (2015) opredeljujejo **poslovni proces** kot "zbirko nalog in dejavnosti (poslovnih operacij in dejanj), ki jo sestavljajo zaposleni, materiali, stroji, sistemi in metode, ki so strukturirani tako, da se oblikuje, ustvari in dostavi izdelek ali storitev potrošniku".

Razumevanje procesa je šele začetek. Pravi problem in priložnost je, da te procese upravljamo sistematično in načrtovano. To nas pripelje do naslednjega poglavja: Upravljanje poslovnih procesov (BPM). V tem poglavju si bomo ogledali pristope in okvire, ki organizacijam omogočajo ne le upravljanje, temveč tudi izvajanje njihovih procesov. BPM je več kot le beleženje in analiza procesov; je celovita metoda za razvoj, izvajanje, spremljanje in nenehno izboljševanje poslovnih procesov.

5.2. Upravljanje poslovnih procesov

V znanstveni in strokovni literaturi najdemo različne opredelitve upravljanja poslovnih procesov. Gartner (n.d.) opredeljuje BPM kot "disciplino, ki uporablja različne metode za odkrivanje, modeliranje, analiziranje, merjenje, izboljševanje in optimiziranje poslovnih



procesov". Po Camundi (n.d.) je BPM "sistemski pristop za zajemanje, načrtovanje, izvajanje, dokumentiranje, merjenje, spremljanje in nadzorovanje tako avtomatiziranih kot neavtomatiziranih procesov za doseganje ciljev in poslovnih strategij podjetja". Swenson in Rosing (2015) sta predlagala nekoliko širšo in morda najbolj natančno opredelitev: "Upravljanje poslovnih procesov (BPM) je disciplina, ki vključuje katero koli kombinacijo modeliranja, avtomatizacije, izvajanja, nadzora, merjenja in optimizacije tokov poslovnih dejavnosti v ustrezni kombinaciji za podporo ciljev podjetja, ki zajema organizacijske in sistemske meje ter vključuje zaposlene, stranke in partnerje znotraj in zunaj meja podjetja".

Po mnenju Freunda in Rückerja (2012) novi projekti BPM pogosto vključujejo enega od teh scenarijev:

1. Izboljšanje procesov z uporabo informacijske tehnologije (IT)
2. Dokumentiranje trenutnih postopkov
3. uvedba popolnoma novih postopkov.


Dumas in drugi (2018) vidijo BPM kot neprekinjen cikel, ki vključuje naslednje faze:

- **Identifikacija procesa** - V tem koraku je podan poslovni problem. Procesi, ki so pomembni za reševanje problema, se identificirajo, opredelijo in povežejo. Rezultat identifikacije procesov je nova ali izboljšana arhitektura procesov. Ta arhitektura prikazuje vse procese organizacije in njihovo medsebojno povezanost. Uporablja se za izbiro procesa ali sklopa procesov, ki se bodo obravnavali do konca življenjskega cikla.
- **Odkrivanje procesov (modeliranje obstoječih procesov)** - Pri tem se dokumentira trenutno stanje vseh pomembnih procesov, običajno v obliki enega ali več modelov obstoječih procesov.
- **Analiza procesa** - V tem koraku se opredelijo, dokumentirajo, in če je mogoče, izmerijo težave trenutnega obstoječega procesa z uporabo kazalnikov uspešnosti. Rezultat tega koraka je strukturiran seznam težav. Te težave so razvrščene po vrstnem redu glede na možen vpliv in ocenjeni napor, ki je potreben za njihovo odpravo.
- **Prenova procesa (modeliranje bodočega procesa)** - Cilj te faze je poiskati spremembe procesa, ki bodo podjetju omogočile doseganje ciljev uspešnosti, hkrati pa bodo obravnavale težave, ugotovljene v prejšnji fazi. Rezultat te faze je običajno model procesa To-be.
- **Izvajanje procesa** - v tej fazi se načrtujejo in izvedejo prilagoditve, ki so potrebne za prenos obstoječega procesa v bodoči proces. Avtomatizacija in upravljanje

organizacijskih sprememb sta dva vidika izvajanja procesov. Izraz "upravljanje organizacijskih sprememb" opisuje zbirko ukrepov, ki so potrebni za spremembo načina dela vseh udeležencev, vključenih v proces. Ustvarjanje in izvajanje sistemov IT (ali izboljšanih različic sedanjih sistemov IT) za podporo prihodnjega procesa se imenuje avtomatizacija procesa.

- **Spremljanje procesa** - po uvedbi preoblikovanega procesa se zberejo in analizirajo ustrezni podatki za oceno uspešnosti procesa. Ko se ugotovijo ozka grla, ponavljajoče se napake ali odstopanja od načrtovanega ravnanja, se sprožijo korektivni ukrepi.

Ta cikel je treba nenehno ponavljati, saj se lahko v istem ali drugih procesih pojavijo nove težave. Ta življenjski cikel BPM je prikazan na sliki 5.1.



Slika 51 Življenjski cikel BPM

Vir: Dumas et al. (2018).

Freund in Rücker (2012) navajata več vlog, ki so vključene v projekte BPM:

- **Lastnik procesa** - oseba, ki je strateško odgovorna za procese. Ima proračunska pooblastila in je pogosto član prve ali druge ravni vodstva. Lastnik procesa je lahko na primer generalni direktor podjetja.
- **Vodja procesa** - oseba, ki je operativno odgovorna za procese. Pogosto gre za vodjo na nižji ali srednji ravni. Na primer, vodja prodaje je lahko vodja procesa.
- **Udeleženec procesa** - oseba, ki dela s procesom in ustvarja vrednost (npr. prodajalec).



- **Procesni analitik** - oseba, ki razume BPM na splošno in še posebej BPMN ter je središče vsakega projekta BPM.

BPM podjetjem pomaga uskladiti njihove procese s splošnimi cilji, postati učinkovitejša in se prilagajati spreminjajočim se okoljem. V naslednjem razdelku bodo predstavljene metode in orodja, ki se uporabljajo za izdelavo natančnih modelov poslovnih procesov.

Cilj modeliranja poslovnih procesov je več kot le risanje diagramov zajeti ključne procese na način, ki omogoča njihovo lažje razumevanje, sporočanje in analiziranje. Zainteresirane strani ga lahko uporabljajo za vizualizacijo zapletenih procesov, ugotavljanje neučinkovitosti in ozkih grl ter zasnovo izboljšav in inovacij.

V naslednjem razdelku bo predstavljena najbolj priljubljena metoda modeliranja BPMN (Business Process Model and Notation). Obravnavano bo, kako lahko to orodje uporabimo za učinkovito dokumentiranje poslovnih procesov.

5.3. Modeliranje poslovnih procesov

Da bi zagotovili standardiziran grafični zapis za dokumentiranje, načrtovanje in analiziranje poslovnih procesov, je bil uveden **model in zapis poslovnih procesov (BPMN)**. Po podatkih podjetja Lucidchart (n.d.) je Iniciativa za upravljanje poslovnih procesov (BPMI) ustvarila notacijo za modeliranje poslovnih procesov, ki je doživela številne spremembe. Pobudo je po združitvi s skupino Object Management Group (OMG) leta 2005 prevzela ta skupina. OMG je izdala BPMN 2.0 in spremenila ime metode v Business Process Model and Notation. S širšim naborom simbolov in zapisov za diagrame poslovnih procesov je vzpostavila celovitejši standard za modeliranje poslovnih procesov.

Te štiri kategorije elementov so predstavljene z BPMN (Lucidchart, n.d.; Freund in Rücker, 2012):

- **Predmeti toka:** dogodki, opravila (dejavnosti) in prehodi.
- **Povezovanje predmetov:** tok zaporedja, tok sporočil in povezovanje
- **Udeleženci:** bazen in steze
- **Artefakti:** podatkovni objekti, podatkovna shramba in opombe

5.3.1. Dogodki

Aagesen in Krogstie (2015) dogodke opredeljujeta kot nekaj, kar se zgodi v procesu. V BPMN obstajajo tri vrste dogodkov: začetni, vmesni in končni dogodki. Začetni dogodek je sprožilec za začetek procesa. Vmesni dogodki se pojavijo med poslovnim procesom in pogosto označujejo nekatere mejnike ali čakanje v procesu. Končni dogodki označujejo konec poslovnega procesa. Predstavljeni so s krogi.



Slika 52 Zapisi začetnega, vmesnega in končnega dogodka

Vir: Avtor: Avtor.

Po Dumasu in drugih (2018) je treba dogodek poimenovati kot [predmet] + [glagol v pretekliku]. V nadaljevanju navajamo nekaj primerov, kako poimenovati dogodke: "Poslan račun", "Oddano naročilo", "Prejeti izdelki".

Preglednica 5.1 prikazuje različne vrste začetnih, vmesnih in končnih dogodkov (OMG, 2006).

Preglednica 51 Vrste dogodkov

Tip	Opis	Simbol
Začetek dogodka		
Ni	Vrsta dogodka ni prikazana.	
Sporočilo	Udeleženec pošlje sporočilo, ki sproži začetek postopka.	
Časovnik	Postopek se sproži ob določenem času (npr. vsak ponedeljek ob 9.00).	
Pogojno	Dogodek se sproži, ko je izpolnjen določen pogoj (npr. ko je raven zaloge nižja od 500 kosov).	
Vmesni dogodek		
Ni	Vrsta dogodka ni prikazana.	
Sporočilo	Udeleženec pošlje sporočilo in sproži dogodek. Zaradi tega se postopek nadaljuje, če je čakal na sporočilo.	



Časovnik	Deluje lahko kot mehanizem za zakasnitev. Na primer, če proces čaka na dostavo izdelka.	
Končni dogodek		
Ni	Vrsta dogodka ni prikazana.	
Sporočilo	Ob koncu postopka se udeležencu pošlje sporočilo.	
Napaka	Na koncu postopka se mora prikazati napaka.	
Prekinitev	Vse dejavnosti v postopku je treba takoj končati.	

Vir: OMG (2006).

5.3.2. Naloge (dejavnosti)

Naloge so nekaj, kar se izvaja v procesu, dejavnosti, ki jih izvaja oseba ali sistem. Predstavljena je s pravokotnikom z zaobljenimi vogali.

V BPMN obstaja posebna podmnožica običajnih nalog, ki se imenuje podproces. Predstavljen je s pravokotnikom z znakom "+" na dnu. Služi za predstavitev procesa znotraj procesa. Na ta način se zmanjša zapletenost glavnega procesa, tj. procesa, ki je v središču pozornosti.



Slika 53 Zapisi nalog in podprocesov

Vir: Avtor.

Naloga mora biti poimenovana kot [glagol v imperativu] + [predmet] (Dumas et al., 2018). V nadaljevanju navajamo nekaj primerov nalog: "Pošlji račun" ali "Oddaj naročilo".

5.3.3. Vrata


Vrata so mesta, kjer se procesi razdelijo ali združijo. Predstavljeni so v obliki romba. Obstajajo tri najpogostejše vrste prehodov: XOR (ekskluzivna) vrata, OR (vključujoča) vrata in AND (vzporedna) vrata.



Slika54Zapisi vrat OR, XOR in AND

Vir: Avtor: Avtor.

Po von Rosing et al. (2015) **vrata OR** pri delitvi omogočajo aktivacijo ene ali več vej glede na pogoje. Pred združitvijo morajo biti vse aktivne vhodne veje zaključene, da se tok lahko nadaljuje. Primer vrat XOR je prikazan na sliki 5.6.




Slika55Primer uporabe prehoda OR

Vir: Dumas et al. (2018).

V tem primeru ima podjetje skladišči v Amsterdamu in Hamburgu, v katerih hrani različne izdelke. Ob prejemu naročila se to razdeli med ta skladišča: v Amsterdam se pošlje podnaročilo, če se tam hranijo določeni izdelki, v Hamburg pa se pošlje podnaročilo, če se tam hranijo določeni izdelki. Postopek se konča, ko je naročilo registrirano (Dumas et al., 2018). Vidimo, da lahko postopek poteka v obe smeri (če se naročeni izdelki hranijo v obeh skladiščih) ali samo v eno smer (če se naročeni izdelki hranijo samo v enem skladišču).

Prehod XOR pri delitvi usmeri tok zaporedja samo v eno od izhodnih vej glede na pogoje. Pri združevanju počaka, da se zaključi ena vhodna veja, preden nadaljuje tok (von Rosing et al., 2015).

Vrata AND se uporabljajo za izvajanje dveh ali več nalog, ki med seboj niso odvisne od vrstnega reda in se lahko izvajajo hkrati (Dumas et al., 2018). Pri združevanju počaka, da se dokončajo vse veje in, preden nadaljuje cikel (von Rosing et al., 2015). Primer uporabe vrat XOR in AND je prikazan na sliki 5.6.



Slika 56Primer uporabe prehodov XOR in AND


Vir: Dumas et al. (2018).

V tem primeru prodajalec po prejemu naročila preveri razpoložljivost zaloge. Obstaja samo ena možna pot - ali so izdelki na zalogi ali ne. Po drugi strani pa ni pomembno, ali se najprej izvede dejavnost "Pošlji račun" ali "Pridobi naslov pošiljke". Toda šele po izvedbi obeh sklopov dejavnosti ("Pridobi naslov pošiljke" - "Odprem izdelek" in "Pošlji račun" - "Prejemi plačilo") se lahko naročilo arhivira.

5.3.4. Povezovanje predmetov

V BPMN obstajajo tri vrste povezovalnih objektov: tok zaporedja, tok sporočil in asociacija.

Po von Rosingu in drugih (2015) **tok zaporedja** prikazuje vrstni red, v katerem se bodo naloge v procesu izvajale. Predstavljen je s polno črto s črtno puščico. **Tok sporočil** je predstavljen s črtkano črto. Na eni strani črte je krog, na drugi pa bela puščica. Uporablja se za predstavitev pretoka sporočil med bazeni procesov. **Združenje** se uporablja za povezovanje besedila z objekti toka. Predstavljena je s črtkano črto.



Slika 57Potek zaporedja, tok sporočil in povezava

Vir: von Rosing et al. (2015).

5.3.5. Udeleženci

BPMN ponuja dva elementa za modeliranje udeležencev procesa: bazene in steze. Po podatkih Dumasa in drugih (2018) se **bazeni** uporabljajo za modeliranje celotne organizacije, **pasovi** pa za modeliranje oddelka ali poslovne enote. Na primer, bazen je lahko "Podjetje X", pasovi



pa "Prodajni oddelek", "Skladišče" in "Računovodstvo". Z uporabo bazenov in pasov je mogoče enostavno ugotoviti, kateri udeleženec opravlja katero dejavnost.

Company X	Sales
	Warehouse
	Accounting

Slika 58Bazen in steze

Vir: Avtor: Avtor.

5.3.6. Artefakti

Obstajajo različne vrste artefaktov: podatkovni objekti, podatkovna shramba in opombe. **Podatkovni objekti** predstavljajo podatke, ki so potrebni za izvajanje določenih nalog (vhodni podatki) ali so rezultat izvajanja nalog (izhodni podatki). Na primer, dokument "Naročilo" se ustvari po izvedbi naloge "Ustvari naročilo". Po drugi strani pa naloga "Pošlji račun" za izvedbo te naloge zahteva račun kot vhodni podatek. Dumas et al. (2018) navaja, da so lahko podatkovni objekti fizični objekti, ki nosijo informacije (npr. papirnati račun), ali elektronski objekti (npr. e-pošta ali račun v formatu PDF).



Slika 59Podatkovni predmeti

Vir: Avtor.


Po Dumasu in drugih (2018) **podatkovno skladišče** prostor, ki vsebuje podatkovne objekte, npr. podatkovna baza za elektronske objekte ali polnilna omara za fizične objekte. Podatkovna skladišča lahko uporabljajo procesne dejavnosti za pridobivanje in shranjevanje podatkovnih objektov. Na primer, naloga "Preveri razpoložljivost surovin" poišče katalog dobavitelja.



Slika 510 Shramba podatkov

Vir: Dumas et al. (2018).

Opombe so mehanizem, s katerim lahko modelar zagotovi dodatne besedilne informacije za bralca diagrama BPMN (von Rosing et al., 2015).



Slika 511 Opomba


Vir: Avtor.

BPM je prepoznan kot pomemben okvir za organizacije, ki želijo optimizirati svoje delovanje in uskladiti svoje procese s strateškimi cilji. To temeljno znanje je bistvenega pomena za naslednjo temo.

5.4. Procesno rudarjenje

Procesno rudarjenje je stičišče podatkovnega rudarjenja in modeliranja procesov. Predstavlja inovativen pristop k razumevanju in izboljšanju poslovnih procesov. V nasprotju s teoretičnim in metodološkim poudarkom BPM procesno rudarjenje raziskuje dejanske (realne) podatke, ki jih ustvarjajo poslovni procesi. Uporablja podatke iz različnih informacijskih sistemov, da bi zagotovilo objektivni pogled na izvajanje procesov v realnem času.

Slika 5.11 prikazuje razliko med BPM in procesnim rudarjenjem. Pri tradicionalnem upravljanju poslovnih procesov se najprej razvije model procesa. Nato ljudje in sistemi IT v skladu s tem modelom izvajajo naloge in dejavnosti. Pri procesnem rudarjenju se za oblikovanje modela procesa uporabijo zgodovinski podatki iz sistemov IT. Ta model prikazuje dejanske, resnične procese.



Slika 51 Upravljanje poslovnih procesov v primerjavi s procesnim rudarjenjem

Vir: Avtor.

IEEE (2012) opredeljuje **procesno rudarjenje** kot "tehniko, orodja in metode za odkrivanje, spremljanje in izboljševanje resničnih procesov (tj. ne predpostavljenih procesov) s pridobivanjem znanja iz dnevnikov dogodkov, ki so običajno na voljo v današnjih (informacijskih) sistemih". Dnevnik dogodkov je digitalni zapis dogodkov, ki so bili izvedeni v informacijskem sistemu.

Za izvedbo analize procesnega rudarjenja mora dnevnik dogodkov vsebovati ID primera, ime dejavnosti in časovni žig. **Primer** (primer procesa) je entiteta, ki jo obravnava proces, ki se analizira (npr. naročila strank, zavarovalniški zahtevki itd.), **dejavnost** je natančno opredeljen korak v procesu (IEEE, 2012), **časovni žig** pa je datum in čas, ko je dejavnost izvedena.

Preglednica 5.2 prikazuje primer dnevnika dogodkov. V tem primeru sta dva primera (1001 in 1002), ki sta sestavljena iz niza dogodkov za obravnavo poizvedb strank.

Preglednica 52 Primer dnevnika dogodkov

ID primera	Ime dejavnosti	Časovni žig	Viri
1001	Prejeti klic	2023-15-12 09:00	Agent A
1001	Ugotovljeno vprašanje	2023-15-12 09:15	Agent A
1002	Prejeti klic	2023-15-12 10:17	Agent C
1001	Eskalacija	2023-15-12 10:20	Agent A
1002	Podane informacije	2023-15-12 10:26	Agent C
1002	Zaključen klic	2023-15-12 10:28	Agent C
1001	Klic tehnične podpore	2023-15-12 11:43	Agent B
1001	Rešena težava	2023-15-12 11:59	Agent B

Vir: Avtor.



Po pridobitvi podatkov (dnevnikov dogodkov) iz informacijskih sistemov (npr. v obliki datoteke CSV ali XLS) se podatki uvozijo v posebno programsko opremo za rudarjenje procesov. Dandanes je na voljo širok nabor programske opreme za procesno rudarjenje. Najbolj priljubljene so ProM, Fluxicon Disco, ARIS Process Mining, Celonis itd. Na podlagi uvoženih podatkov programska oprema za rudarjenje procesov odkrije model procesa. Ta model je nato mogoče analizirati in ugotoviti, ali obstajajo ozka grla, težave ali priložnosti za izboljšave.

Po mnenju van der Aalsta (2018) se procesno rudarjenje uporablja za vse vrste operativnih procesov (organizacij in sistemov). Analiziranje postopkov zdravljenja v bolnišnicah, izboljševanje postopkov storitev za stranke v mednarodnem podjetju, razumevanje navad uporabnikov spletnih strani za rezervacije, ocenjevanje nepravilnosti sistema za ravnanje s prtljago in izpopolnjevanje uporabniških vmesnikov rentgenskih naprav so le nekateri primeri uporabe.

Reil et al. (2021) so analizirali uspešno izvajanje procesnega rudarjenja na praktičnem področju upravljanja oskrbovalne verige. Navedli so, da se je švedsko-švicarska skupina ABB, ki se ukvarja z energetsko in avtomatizacijsko tehnologijo, leta 2020 soočala z izzivi, kot sta povezovanje več kot 40 sistemov ERP in upravljanje terabajtov podatkov o procesih. Izvajanje procesnega rudarjenja v proizvodnih procesih je družbi ABB omogočilo vpogled v učinkovitost njene globalne poslovne mreže in prehod na popolnoma digitalizirano oskrbovalno verigo. Koristi so vključevale nižje stroške zalog, okrepljene prodajne procese, izboljšano produktivnost, pravočasne dobave, optimizirano uporabo opreme in povečane zmogljivosti. Ta strategija je zelo koristila vhodnim logističnim postopkom v avtomobilski oskrbovalni verigi, ki so občutljivi na ozka grla, ki lahko povzročijo velike izgube prihodkov. Procesno rudarjenje se je izkazalo za koristno pri učinkovitem reševanju teh težav.

Strukturiran način upravljanja in izboljševanja procesov, ki ga ponuja BPM, podjetjem omogoča prilagajanje spreminjajočim se potrebam strank in operativnim težavam. Po drugi strani pa procesno rudarjenje omogoča poglobljen vpogled v dejansko uspešnost procesov in izpostavlja področja za izboljšave. Integracija BPM in Process Mining ni le strateška prednost, temveč bo za podjetja pomembno, da bodo pripravljena na prihodnost, da bodo vedela, kako ju uporabljati in kako delujeta.



1. Aagesen, G. & Krogstie, J. (2015). BPMN 2.0. for Modeling Business Processes. In vom Brocke, J., Rosemann, M. (Eds.). Handbook on Business Process Management 1, 2nd edition. Heidelberg: Springer, pp. 219-250.
2. Camunda (n.d.). What is Business Process Management? [available at: <https://camunda.com/glossary/business-process-management-bpm/>, access December 28, 2023]
3. Dumas, M., La Rosa, M., Mendling, J. & Reijers, H. A. (2018). Fundamentals of Business Process Management, 2nd Edition. Springer.
4. Freund, J. & Rücker, B. (2012). Real-Life BPMN: Using BPMN 2.0 to Analyze, Improve, and Automate Processes in Your Company. Camunda.
5. Gartner (n.d.). Business Process Management (BPM) [available at: <https://www.gartner.com/en/information-technology/glossary/business-process-management-bpm>, access December 28, 2023]
6. IEEE (2012). Process Mining Manifesto. IEEE Task Force on Process Mining [available at: <https://www.tf-pm.org/upload/1580737631545.pdf>, access December 28, 2023]
7. Lucidchart (n.d.). What is Business Process Modeling Notation [available at: <https://www.lucidchart.com/pages/bpmn>, access December 28, 2023]
8. OMG (2006). Business Process Modeling Notation Specification. Object Management Group.
9. Reil, T., Groher, E. & Siegfried, P. (2021). Process Mining in Supply Chain Management. Supply Chain Management Journal, 12(2), pp. 1-13.
10. Swenson, K. D. & von Rosing, M. (2015). Phase 4: What Is Business Process Management?. In von Rosing, M., Scheer, A.-W., von Scheel, H. (Eds.). The complete business process handbook. Waltham: Morgan Kaufmann, pp. 79-88.
11. van der Aalst, W. (2018). Foreword: Process Mining Book. Fluxicon [available at: <https://fluxicon.com/book/read/foreword/>, access December 28, 2023]



12. von Rosing, M., Scheer, A.-W. & von Scheel, H. (2015). The BPM Way of Modeling. In von Rosing, M., Scheer, A.-W. and von Scheel, H. (Eds.). The complete business process handbook. Waltham: Morgan Kaufmann, pp. 431-457.
13. Von Scheel, H., von Rosing, M., Fonesca, M., Hove, M. & Foldager, U. (2015). Phase 1: Process Concept Evolution. In von Rosing, M., Scheer, A.-W. and von Scheel, H. (Eds.). The complete business process handbook. Waltham: Morgan Kaufmann, pp. 1-9.



6. INFORMACIJSKI SISTEMI V LOGISTIKI

Avtor: Dario Šebalj

Integracija tehnologije in sistemov upravljanja ima pomembno vlogo pri izboljšanju učinkovitosti, natančnosti in sprejemanju strateških odločitev. Trije bistveni sistemi za racionalizacijo poslovanja v logistiki so sistemi ERP (Enterprise Resource Planning), WMS (Warehouse Management Systems) in TMS (Transportation Management Systems).

Sistemi ERP so hrbtenica podjetja, saj združujejo različne oddelke (kot so računovodstvo, nabava, prodaja, proizvodnja itd.) in procese v enoten sistem. Sistem WMS pa se osredotoča na optimizacijo skladiščnega poslovanja, zagotavlja učinkovito upravljanje zalog in optimizacijo skladiščenja. Nazadnje, sistem TMS je namenjen načrtovanju, izvajanju in optimizaciji prevoza blaga. Ta sistem je ključnega pomena za zmanjšanje stroškov prevoza in izboljšanje učinkovitosti logistike.

To poglavje ne vsebuje le pregleda posameznih sistemov, temveč tudi razmislek o tem, kako lahko integracija vodi k bolj povezanemu in inteligentnemu poslovnemu okolju.


6.1. Sistemi za celovito načrtovanje virov podjetja (ERP)

Na začetku so bila podjetja razdeljena na različne oddelke glede na funkcije, ki so jih opravljali. Tako je obstajal oddelek za proizvodnjo, nabavo, prodajo, finance itd. Vsak oddelek je deloval ločeno tako, da je imel svoj sistem za zbiranje in analizo podatkov. Ti sistemi med seboj niso bili povezani. Danes se organizacije obravnavajo kot en sam sistem, vsi oddelki pa so njegovi podsistemi (Leon, 2014). Vsi si delijo isto, centralizirano podatkovno zbirko.

Obstoj neodvisnih informacijskih sistemov za posamezne oddelke je povzročil neučinkovitost, nedoslednost in odvečnost podatkov ter težave pri sprejemanju odločitev. Prehod na integriran sistem je bil pomemben pristop k upravljanju organizacije, saj so organizacije obravnavane kot en sam, enoten sistem. Ključna sestavina te integracije je centralizirana podatkovna zbirka, ki služi kot osrednji del organizacije in zagotavlja, da imajo vsi oddelki dostop do doslednih

podatkov v realnem času. To vodi k boljši komunikaciji, usklajevanju in sodelovanju med oddelki.

Slika 6.1 prikazuje razliko med tradicionalnim pristopom, kjer so oddelki neodvisni in ima vsak oddelek svojo podatkovno zbirko, in sodobnim pristopom, kjer si oddelki delijo eno osrednjo podatkovno zbirko.



Slika 6.1 Razlika med neodvisnimi oddelki in oddelki, ki si delijo isto osrednjo podatkovno zbirko

Vir: Avtor po Leonu (2014).

Po Bradfordu (2015) so sistemi za **celovito načrtovanje virov podjetja (ERP)** poslovni sistemi, ki združujejo in organizirajo podatke iz različnih oddelkov v organizaciji, da bi ustvarili enoten, celovit sistem, ki služi potrebam celotnega podjetja. Sistemi ERP povezujejo in usklajujejo procese ter funkcije, ki so bile prej razdrobljene in podprte z različnimi zastarelimi ali samostojnimi poslovnimi rešitvami. Na ta način omogočajo brezhibno delovanje, kar izboljša vse vidike ključnih dejavnosti podjetja, kot so nabava, računovodstvo, proizvodnja in prodaja.



Z drugimi besedami, sistem ERP je kompleksna, modularna programska rešitev, ki združuje vse poslovne funkcije podjetja, pomaga pri upravljanju poslovnih procesov in uporablja enotno zbirko podatkov za celoten sistem.

Sistem za celovito načrtovanje virov podjetja (ERP) velja za medfunkcijski sistem, ki avtomatizira in integrira bistvene poslovne dejavnosti organizacije, da bi povečal uspešnost in učinkovitost (Mahmood et al., 2019).

Bradford (2015) navaja, da lahko podjetja uvedejo modul ali module programske opreme ERP, ne da bi jim bilo treba kupiti in uvesti celoten paket, saj je večina dovolj prilagodljiva.

Po besedah Bradforda (2015) se sistemi ERP pogosto obravnavajo kot "zaledni" sistemi, saj združujejo "zaledne" funkcije, kot so izpolnjevanje naročil, nabava, računovodstvo in finance. Sistemi ERP so zdaj več kot le zaledni sistemi; vključujejo module za sprednjo pisarno, module za stike s strankami in module za pospeševanje oskrbovalne verige.

Sistemi ERP imajo številne **prednosti**, kot so (Bradford, 2015; Paredes Hernandez, 2023):

- Izboljšana preglednost in vpogledi - do podatkov iz vseh oddelkov lahko dostopajo zaposleni na vodstveni ravni,
- Dostop do informacij v realnem času - podatki so v realnem času na voljo vsem uporabnikom v vseh oddelkih,
- zmanjšanje stroškov poslovanja - z nižjimi stroški zalog, proizvodnje ali nabave,
- Enoten vmesnik v vseh modulih - moduli v sistemu ERP so videti enako in zagotavljajo enak način delovanja,
- Skalabilnost - sistemi ERP v oblaku omogočajo uporabo dodatnih računalniških virov v primeru rasti podjetja in podatkov,
- Izboljšane storitve za stranke - nov sistem, kot je programska oprema ERP, lahko omogoči bolj prilagojene in hitrejške storitve za stranke, saj centralizira vse podatke o strankah.

Nekatere **pomanjkljivosti** sistemov ERP so (Bradford, 2015; Paredes Hernandez, 2023; Oracle, n.d.a.):

- Zapleteno in dolgotrajno uvajanje - uvajanje sistema ERP lahko traja od nekaj mesecev do več let, odvisno od velikosti podjetja,
- Cena - sistemi ERP so pogosto zelo dragi, zlasti priljubljeni: SAP in Microsoft Dynamics NAV,



- Upravljanje sprememb - veliko časa in truda bo treba vložiti v to, da bodo vsi pomembni zaposleni ustrezno usposobljeni za uporabo novega sistema.

Glavni razlog, zakaj podjetja uvajajo sisteme ERP, je podpora rasti podjetja. Prav tako je uvedba ERP-a cilj precejšnjega števila podjetij, da bi izboljšala svojo produktivnost in procese (Software Path, 2022).



Izvajanje sistemov ERP je zelo zapleteno in večina projektov ERP je neuspešnih. Po podatkih Saundersa (2022) je približno 80 % projektov ERP neuspešnih. 25 % projektov ERP je bilo preklicanih ali odloženih, še 55 % pa je zgrešilo pričakovanja deležnikov glede projekta.

Mahmood in drugi (2019) so izvedli raziskavo, v kateri so opredelili najbolj kritična vprašanja/izzive, s katerimi se organizacije soočajo pri uvajanju ERP:

1. **Podpora najvišjega vodstva** - podpora, strateške usmeritve in dejavno sodelovanje najvišjega vodstva so bistvenega pomena za uspešno izvajanje in upravljanje sistemov ERP,
2. **Upravljanje sprememb** - odpor, zlasti pri vodstvenih delavcih na srednji ravni, ki so navajeni na tradicionalne metode, predstavlja velik izziv pri uvajanju novih sistemov ERP,
3. **Usposabljanje in razvoj** - kompleksnost sistemov ERP zahteva obsežno in stalno usposabljanje zaposlenih, pri čemer nezadostno usposabljanje vodi do morebitnih napak sistema ERP in pogosto predstavlja skrite stroške za organizacije.
4. **Učinkovita komunikacija** - jasna in stalna komunikacija ter usklajevanje med uporabniki iz različnih oddelkov sta bistvena za uspešno uvedbo ERP in upravljanje organizacijskih sprememb,
5. **Sistemska integracija** - vključuje zapleteno nalogo integracije različnih modulov ERP z obstoječimi poslovnimi aplikacijami in starejšimi sistemi v organizaciji, kar je bistven proces za optimizacijo poslovnih procesov in izboljšanje učinkovitosti, vendar je pogosto drag in zapleten.

Drugi enako pomemben vidik uvedbe sistema ERP je finančna naložba, ki je potrebna za uvedbo in vzdrževanje sistemov ERP. V tem prihodnjem pod- poglavju bodo obravnavane različne sestavine stroškov sistema ERP, ki vključujejo tako začetno naložbo kot tekoče operativne stroške.



6.1.1. Stroški sistemov ERP

Sistemi ERP (Enterprise Resource Planning) so postali sestavni del sodobnega poslovanja in ponujajo številne prednosti, od večje učinkovitosti do boljšega povezovanja podatkov. Vendar pa je uvedba takšnih sistemov povezana s precejšnjimi stroški, ki jih morajo organizacije skrbno pretehtati.

Sisteme ERP tradicionalno uporabljajo podjetja, ki prodajajo materialne dobrine. Te celovite programske rešitve so bile zasnovane za velike mednarodne organizacije. Zato je bila njihova uvedba izjemno draga in zapletena. Moduli ERP, kot so nabava, prodaja in logistika, so osnova za postopke finančnega poročanja, njihova avtomatizacija v globalni organizaciji pa bi lahko prinesla precejšnjo donosnost naložbe (Berry, 2021).

Skupni stroški uvedbe sistema ERP vključujejo stroške, povezane z licenciranjem programske opreme, zahtevami za strojno opremo, izvajanjem, vzdrževanjem, svetovanjem, formalnim in neformalnim usposabljanjem ter prilagajanjem. Ti stroški se običajno imenujejo **skupni stroški lastništva (TCO)**. Ti se lahko precej razlikujejo glede na obseg izvajanja, zapletenost programske opreme in izbranega prodajalca ERP. Za srednje velike organizacije lahko samo naložba v paketno programsko opremo ERP znaša nekaj milijonov dolarjev (Leon, 2014; Tilley, 2020).

Poleg stroškov programske opreme so za uvedbo sistemov ERP pogosto potrebne tudi znatne naložbe v infrastrukturo IT. To vključuje strežnike, sisteme za shranjevanje podatkov, omrežne komponente in morebitno nadgradnjo obstoječih komponent, ki se približujejo koncu življenjskega cikla (Bradford, 2015). Čeprav lahko računalništvo v oblaku zmanjša nekatere od teh stroškov strojne opreme, saj programska oprema ERP deluje na strežnikih prodajalca, začetna naložba v infrastrukturo ostaja pomemben del skupnih stroškov.

Pomembno vlogo pri skupnih izdatkih imajo tudi skriti stroški, povezani z uvajanjem ERP, kot so stroški svetovanja. Ti stroški vključujejo honorarje za zunanje svetovalce, ki poznajo sistem ERP, vendar morda nimajo poglobljenega znanja o posebnih poslovnih procesih organizacije (Leon, 2014).



Skoraj 80 % vseh stroškov nastane po nakupu strojne in programske opreme (Tilley, 2020).



Na stroške programske opreme ERP vplivajo različni dejavniki. Na primer (Hale, 2019; Wood, 2023):

- **Način uvajanja** - sisteme ERP je mogoče uvajati v oblaku, na lokaciji ali kot kombinacijo obojega.
- **Število uporabnikov** - sistemi ERP z manjšim številom uporabnikov so lahko cenejši.
- **Zahtevane prijave** - več modulov, od osnovnih modulov do nekaterih posebnih modulov.
- **Stopnja prilagoditve** - vse dodatne nadgradnje prvotne programske opreme povečajo ceno sistema ERP.
- **Usposabljanje uporabnikov in podpora** - običajno, vendar ne-vedno, stroški implementacije vključujejo eno leto podpore uporabnikom. Stalna podpora v realnem času je lahko povezana z dodatnimi stroški.
- **Nadgradnja strojne opreme** - podjetja bodo morda morala med izvajanjem kupiti dodatno strojno opremo (npr. strežnike, shrambo, omrežno infrastrukturo), da bodo lahko podpirala svoj novi ERP.

Po podatkih poročila Software Path (2022) je povprečni proračun na uporabnika za projekt ERP 9.000 USD. Vendar se ta strošek razlikuje glede na velikost podjetja in število uporabnikov. Po podatkih Halea (2019) lahko stroški vzdrževanja znašajo od 10 % do 20 % začetne licenčnine.

6.1.2. Trendi sistemov ERP

V zadnjih desetletjih so organizacije porabile milijone dolarjev za uvedbo sistemov ERP (Ruivo et al., 2020). Prihodki od programske opreme ERP se iz leta v leto povečujejo za 8 % in bodo leta 2023 znašali 44 milijard dolarjev (Haranas, 2023), do leta 2028 pa naj bi dosegli 62 milijard dolarjev (Statista, 2023).

Danes obstaja veliko število ponudnikov programske opreme ERP. Po podatkih Davidsona (2023) so glavni ponudniki programske opreme ERP Microsoft, SAP, Oracle, Sage, Epicor in Infor.

Ko gre za nakup programske opreme ERP, je proizvodna industrija najbolj zastopana (27 %). Gradbeništvo je z 20 % na drugem mestu. Distribucija in transport, ki sta vključena v širšo opredelitev industrije oskrbovalne verige, skupaj predstavljata 16 % (Wood, 2023).



Po podatkih družbe Statista (2023) je **zahteva po prilagajanju** ena od glavnih želja strank na trgu programske opreme ERP. Programska oprema, ki jo je mogoče prilagoditi tako, da ustreza edinstvenim zahtevam in specifikacijam podjetij, je bistvenega pomena. Posledično se je povečala potreba po prilagodljivih in skalabilnih rešitvah ERP v oblaku. Stranke želijo tudi programsko opremo, ki je preprosta za uporabo in se brez težav povezuje z drugimi sistemi.

Prihodnost in trende sistemov za načrtovanje virov podjetja (ERP) oblikujejo spreminjajoče se poslovne potrebe in tehnološki napredek. Do leta 2023 bo na področju ERP vidnih več ključnih trendov (Luther, 2023):

- **ERP v oblaku** - Rešitve ERP v oblaku postajajo vse bolj priljubljene zaradi enostavnejše namestitve, nižjih stroškov, prilagodljivosti in zmožnosti prilagajanja rasti podjetja. Pandemija je pospešila prehod z lokalne programske opreme na ERP v oblaku, saj ti sistemi zaposlenim omogočajo enostavno delo na daljavo. Po podatkih Wooda (2023) bo leta 2022 42 % podjetij uporabljalo ERP v oblaku (v primerjavi z letom 2013, ko je bil ta delež le 4 %). Običajno se ERP v oblaku zagotavlja kot programska oprema kot storitev (SaaS), kar pomeni, da morajo uporabniki za stalni dostop plačevati mesečno, četrtno ali letno pristojbino.
- **Dvostopenjski sistem ERP** - Dvostopenjski pristop k sistemu ERP se vedno bolj uveljavlja. Ta strategija uporablja primarni sistem ERP na ravni podjetja, medtem ko hčerinska podjetja in oddelki delujejo z drugačno rešitvijo ERP, pogosto v oblaku. Večja podjetja lahko še naprej uporabljajo glavni sistem ERP za finančne in druge temeljne procese, medtem ko manjše poslovne enote iščejo rešitve, prilagojene njihovim posebnim zahtevam.
- **Digitalna preobrazba** - sistemi ERP imajo ključno vlogo pri digitalni preobrazbi podjetij. Z vključevanjem digitalne tehnologije v vse poslovne funkcije sistemi ERP povečujejo prihodke in konkurenčnost ter izboljšujejo storitve za stranke in komunikacijo.
- **Integracija z drugimi tehnologijami** - Sodobni sistemi ERP so vse bolj integrirani z drugimi tehnologijami, kot sta internet stvari in družbeni mediji, da bi izboljšali osnovne procese ter zagotovili večjo preglednost in boljšo izkušnjo strank.
- **Prilagajanje** - sistemi ERP se razvijajo, da bi strankam ponudili bolj prilagojene izkušnje, ki jih podpirajo asistenčni in pogovorni uporabniški vmesniki na podlagi umetne inteligence, kot so klepetalni boti. Ta trend omogočajo platforme ERP v oblaku, ki so zasnovane za lažjo konfiguracijo in rešitve, prilagojene posameznim panogam.



- **Vpogledi in izboljšave na osnovi umetne inteligence** - umetna inteligenca in strojno učenje se vgrajujeta v sisteme ERP in z analiziranjem operativnih podatkov in podatkov o strankah zagotavljata dragocene poslovne vpogleda. Ta integracija pomaga pri optimizaciji vrste poslovnih procesov in izboljšanju personalizacije.
- **Prediktivna analitika** - Uporaba prediktivne analitike v sistemih ERP je v porastu, saj se osredotoča na analizo podatkov za napovedovanje prihodnjih trendov in rezultatov, kar pomaga pri boljšem odločanju in strateškem načrtovanju.
- **Mobilni ERP** - Mobilni ERP postaja vse bolj razširjen, saj omogoča dostop do ključnih poslovnih podatkov na poti in olajša delo na daljavo. Mobilne aplikacije ERP z uporabniku prijaznimi vmesniki pomagajo zaposlenim učinkovito opravljati naloge ne glede na njihovo lokacijo.

Ti trendi kažejo na pomemben premik sistemov ERP k bolj prilagodljivim, prilagojenim in integriranim rešitvam, ki ustrezajo sodobnim poslovnim praksam in tehnološkemu napredku.

Sistemi ERP upravljajo osnovne funkcije oskrbovalne verige, kot sta nadzor zalog in izpolnjevanje naročil, vendar so običajno zelo preprosti. Njihov glavni cilj je bil pomagati pri finančnih procesih. Modul za upravljanje zalog v sistemu ERP ni bil zelo dober pri upravljanju dela v skladišču, lahko pa je bil precej dober pri spremljanju vrednotenja zalog za bilanco stanja podjetja. Zato so se na trgu pojavile najboljše logistične aplikacije, ki so lahko dopolnile ERP in odpravile vrzeli. Sistemi za upravljanje skladišč (Warehouse management systems - WMS) in sistemi za upravljanje transporta (Transport management systems - TMS) so se pojavili kot dve glavni kategoriji logističnih aplikacij (Berry, 2021).

6.2. Sistemi za upravljanje skladišča

Sistem za upravljanje skladišča (WMS) podjetjem omogoča spremljanje in upravljanje skladiščnih dejavnosti od trenutka, ko material ali blago vstopi v distribucijski center ali center izpolnjevanja, do trenutka, ko ga zapusti. Glavni cilj sistema WMS je olajšati učinkovito in gospodarno gibanje materialov in blaga v skladiščih. Izbiranje, sprejem, oddaja in sledenje zalogam so le nekatere od številnih nalog, ki jih sistem WMS opravlja na spletni strani, da bi olajšal te premike. Programski sistemi WMS zagotavljajo pregled nad celotnim inventarjem podjetja v realnem času, tako na poti kot v skladiščih, in so ključni del upravljanja oskrbovalne verige (O'Donnell, 2020).



Po podatkih družbe SAP (n.d.a.) sistem za upravljanje skladišča optimizira različne dejavnosti v skladišču. S tehnologijo RFID racionalizira postopek sprejema in izdaje ter se povezuje z drugo programsko opremo za učinkovito ravnanje s predmeti. Pri upravljanju zalog sistem WMS zagotavlja preglednost v realnem času in podpira napredno analitiko za boljši nadzor zalog. Pri komisioniranju, pakiranju in izpolnjevanju naročil usmerja učinkovito skladiščenje, pridobivanje in pakiranje ter uporablja tehnologije, kot sta RF skeniranje in robotika, za optimizacijo obdelave naročil. Postopki pošiljanja so izboljšani z integracijo s programsko opremo za logistiko, kar zagotavlja pravočasno in natančno dostavo. Sistem WMS pomaga tudi pri upravljanju delovne sile, saj ponuja vpogled v stroške dela in produktivnost ter podpira učinkovito upravljanje nalog. Poleg tega olajšuje upravljanje dvorišč in dokov, izboljšuje učinkovitost nakladanja in podpira navzkrižno skladiščenje za hitro pokvarljivo blago. Sistem WMS zagotavlja dragocene skladiščne metrike in analitiko, kar omogoča boljše odločanje in optimizacijo procesov.

SAP (n.d.a.) navaja pet prednosti sistema WMS:

1. **Izboljšana operativna učinkovitost** - sistemi WMS povečujejo učinkovitost in obseg poslovanja z avtomatizacijo in racionalizacijo skladiščnih procesov od vhodnih prejemov do izhodnih dobav.
2. **Manj odpadkov in stroškov** - WMS pomaga zmanjšati količino odpadkov, zlasti pri zalogah z omejenim datumom ali pokvarljivih zalogah, in optimizira uporabo skladiščnega prostora.
3. **Vidljivost zalog v realnem času** - omogoča vpogled v gibanje zalog v realnem času, kar pripomore k natančnemu napovedovanju povpraševanja in boljši sledljivosti.
4. **Izboljšano upravljanje delovne sile** - WMS pomaga pri napovedovanju potreb po delovni sili in optimizaciji dodeljevanja nalog na podlagi različnih dejavnikov, s čimer izboljšuje moralo zaposlenih.
5. **Boljši odnosi s strankami in dobavitelji** - WMS omogoča boljšo izpolnitev naročil in hitrejšo dostavo, kar povečuje zadovoljstvo strank in izboljšuje odnose z dobavitelji.

Na razvoj sistemov za upravljanje skladišč še vedno vpliva tehnološki napredek. Te so na primer (Scullin, 2023):

- **Orodja za avtomatizirano komisioniranje** - tehnologije, kot so glasovno avtomatizirano komisioniranje, robotsko komisioniranje in sistemi "pick-to-light", skupaj s prefinjenim črtnim kodiranjem,



- **Samodejno vodena vozila (AGV)** - izboljšujejo postopke skladiščenja in pridobivanja, kar je ključnega pomena za naloge, kot so skladiščenje palet in regalov, upravljanje zabojnikov in avtomatizacija postopka sprejema,
- **Internet stvari (IoT)** - Z vključitvijo interneta stvari se v enotnem omrežju nadzorujejo različni avtomatizirani in ročni elementi, kar izboljša nadzor nad zalogami, načrtovanje dela in izkušnjo strank s hitrejšo izpolnitvijo,
- **Obogatena (AR) in navidezna resničnost (VR)** - tehnologija AR z napravami, kot so pametna očala, omogoča prekrivanje navodil ali informacij v realnem času v skladiščnem okolju, kar pomaga pri opravilih, kot sta navigacija po poti in lokacija zabojnikov, brez uporabe rok. VR se uporablja za usposabljanje in varnost, na primer za usposabljanje upravljavcev dvigal in izboljšanje dostavnih poti.

Berry (2021) navaja, da je trg WMS zelo razvit in da obstaja veliko znanih podjetij za programsko opremo, ki ponujajo širok nabor funkcij za pomoč tudi pri najbolj zapletenih nalogah v skladišču. Veliko najboljših ponudnikov WMS zdaj ponuja modele dostave v oblaku. 40-50 % novih strank WMS se zdaj odloča za dobavo v oblaku namesto za lokalno namestitev. Nekateri od priljubljenih ponudnikov WMS so (Gartner, n.d.): WMS Cloud), Microsoft Dynamics 365 Supply Chain, Manhattan WMS in Infor WMS.


6.3. Sistemi za upravljanje prevoza

Sistem za upravljanje prevoza (TMS) je ključna programska oprema v logistiki, ki optimizira premikanje blaga med različnimi načini prevoza. Kot del širšega sistema za upravljanje oskrbovalne verige sistem TMS optimizira tovarne in oskrbovalne poti, sledi tovoru ter avtomatizira naloge, kot sta skladnost s predpisi in obračunavanje tovara. Ta sistem ne zagotavlja le pravočasne dostave, temveč tudi zmanjšuje stroške, kar koristi tako podjetjem kot strankam. Zagotavlja celovit pregled nad prevoznimi dejavnostmi, pomaga pri zagotavljanju skladnosti in poenostavlja postopek pošiljanja po kopnem, zraku ali morju (SAP, b.d.b.; Oracle, b.d.b.).

Berry (2021) navaja, da lahko sistem TMS zmanjša stroške prevoza na več načinov. Oddelek za odpremo lahko prihrani veliko časa in truda z avtomatizacijo postopka rezervacije in sledenja pošiljk. Zmožnosti usmerjevalnika poti zagotavljajo, da referenti za odpremo izberejo način prevoza, ki za vsako pošiljko stane najmanj. Veliko izdelkov TMS lahko optimizira pošiljke, ki so manjše od tovarnjaka, v pošiljke s polnim tovarnjakom, ki so veliko cenejše.

Nekatere prednosti sistema TMS so (SAP, n.d.b; Inbound Logistics, 2023):

- **Prihranek stroškov** - sistem TMS znatno zmanjša upravne stroške in stroške pošiljanja, saj optimizira upravljanje tovora in prevoza,
- **Vidljivost v realnem času** - omogoča kritičen vpogled v proces prevoza, izboljšuje učinkovitost poti in sledenje,
- **Večje zadovoljstvo strank** - zagotavlja pravočasno dostavo in izboljšuje izkušnje strank z boljšimi postopki sledenja in zaračunavanja,
- **Izboljšana učinkovitost** - sistem TMS povečuje splošno učinkovitost prevoznih dejavnosti,
- **Izboljšano sprejemanje odločitev** - ponuja dragocene podatke za premišljeno sprejemanje odločitev, kar izboljšuje strateško načrtovanje pri upravljanju prometa.



Slika 62Povezava med ERP, WMS in TMS

Vir: Essex (2020).

Slika 6.2 prikazuje povezavo med sistemi ERP, WMS in TMS. Po podatkih Essex (2020) sistem ERP upravlja računovodstvo, izdajanje računov, naročila in upravljanje zalog. Sistem WMS pomaga pri opravih izpolnjevanja, pošiljanja in prejemanja v skladišču, na primer pri pobiranju in skladiščenju blaga, ter posodablja modul za zaloge v sistemu ERP s podatki v realnem času, pridobljenimi s skeniranjem črtnih kod in RFID na spletnem mestu. Sistem ERP posreduje podrobnosti o naročilu sistemu TMS za pripravo in izvedbo pošiljk. Sistem TMS vrne podatke



o pošiljki v sistem ERP za računovodstvo in upravljanje naročil ter morebiti posodobi module za upravljanje odnosov s strankami (CRM) za posodobitve stanja naročil za stranke.

V tem poglavju je opisana pomembna vloga sistemov ERP, WMS in TMS za logistiko. Ti sistemi, ki so ključnega pomena v sodobni logistiki, skupaj povečujejo učinkovitost, zagotavljajo natančno upravljanje zalog in optimizirajo transportne procese. Integracija sistemov ERP, WMS in TMS ni le tehnološki napredek, temveč strateška nujnost, ki vodi podjetja k večji učinkovitosti, natančnosti in zadovoljstvu strank na področju logistike in upravljanja oskrbovalne verige.

VIRI

1. Berry, J. (2021). Logistics in the Cloud-Powered Workplace. In Sullivan, M. & Kern, J. (Eds.). The Digital Transformation of Logistics. Piscataway: IEEE Press.
2. Bradford, M. (2015). Modern ERP: Select, Implement, and Use Today's Advanced Business Systems, 3rd Edition. Lulu.com
3. Davidson, R. (2023). Top 6 ERP Software Vendors. SoftwareConnect [available at: <https://softwareconnect.com/erp/top-vendors/>, access January 15, 2024]
4. Essex, D. (2020). Transportation management system (TMS). TechTarget [available at: <https://www.techtarget.com/searcherp/definition/transportation-management-system-TMS>, access January 15, 2024]
5. Gartner (n.d.). Warehouse Management Systems Reviews and Ratings [available at: <https://www.gartner.com/reviews/market/warehouse-management-systems>, access January 17, 2024]
6. Hale, Z. (2019). What Factors Determine the Cost of ERP Software?. Software Advice [available at: <https://www.softwareadvice.com/resources/erp-software-pricing/>, access January 15, 2024]
7. Haranas, M. (2023). Oracle, Microsoft, SAP, Workday Lead Cloud ERP Market: Gartner. CRN [available at: <https://www.crn.com/news/cloud/oracle-microsoft-sap-workday-lead-cloud-erp-market-gartner>, access January 17, 2024]
8. Inbound Logistics (2023). Transportation Management System: Meaning, Importance, and Benefits [available at:



- <https://www.inboundlogistics.com/articles/transportation-management-system/>, access January 17, 2024]
9. Leon, A. (2014). ERP demystified, 3rd edition. McGraw Hill Education.
 10. Luther, D. (2023). 8 ERP Trends for 2023 & The Future of ERP. Oracle Netsuite [available at: <https://www.netsuite.com/portal/resource/articles/erp/erp-trends.shtml>, access January 15, 2024]
 11. Mahmood, F., Khan, A. Z. & Bokhari, R. H. (2019). ERP issues and challenges: a research synthesis. Kybernetes, 49(3), pp. 629–659.
 12. O'Donnell, J. (2020). Warehouse management system (WMS). TechTarget [available at: <https://www.techtarget.com/searcherp/definition/warehouse-management-system-WMS>, access January 15, 2024]
 13. Oracle (n.d.a). What are the benefits of an ERP system? [available at: <https://www.oracle.com/hk/erp/what-is-erp/erp-benefits/>, access January 20, 2024]
 14. Oracle (n.d.b). What Is a Transportation Management System? [available at: <https://www.oracle.com/scm/logistics/transportation-management/what-is-transportation-management-system/>, access January 15, 2024]
 15. Paredes Hernandez, J. (2023). The advantages and disadvantages of ERP systems. IBM [available at: <https://ibm.com/blog/enterprise-resource-planning-advantages-disadvantages/>, access January 16, 2024]
 16. Ruivo, P., Johansson, B., Sarker, S. & Oliveira, T. (2020). The relationship between ERP capabilities, use, and value. Computers in Industry, 117, 103209.
 17. SAP (n.d.a). What is a warehouse management system (WMS)? [available at: <https://www.sap.com/products/scm/extended-warehouse-management/what-is-a-wms.html>, access January 15, 2024]
 18. SAP (n.d.b). What is a transportation management system (TMS)? [available at: <https://www.sap.com/products/scm/transportation-logistics/what-is-a-tms.html>, access January 15, 2024]



19. Saunders, P. (2022). Are ERP Projects Really The Stuff Of Nightmares?. Forbes [available at: <https://www.forbes.com/sites/sap/2022/06/28/are-erp-projects-really-the-stuff-of-nightmares/>, access January 20, 2024]
20. Scullin, Ch. (2023). 7 Smart Warehouse Technologies to Implement Today. Camcode [available at: <https://www.camcode.com/blog/smart-warehouse-technologies/>, access January 10, 2024]
21. Software Path (2022). What 1,384 ERP projects tell us about selecting ERP (2022 ERP report) [available at: <https://softwarepath.com/guides/erp-report>, access January 15, 2024]
22. Statista (2023). Enterprise Resource Planning Software – Worldwide [available at: <https://www.statista.com/outlook/tmo/software/enterprise-software/enterprise-resource-planning-software/worldwide>, access January 15, 2024]
23. Tilley, S. (2020). Systems Analysis and Design, 12th Edition. Boston: Cengage Learning.
24. Wood, L. (2023). How Much Does ERP Cost?. SoftwareConnect [available at: <https://softwareconnect.com/erp/pricing/>, access January 22, 2024]



7. E-LOGISTIKA

Avtor: Michał Adamczak



To poglavje je posvečeno najpomembnejšim vprašanjem, povezanim z e-logistiko. V poglavju ta pojem ni le opredeljen, temveč je predstavljen tudi v širšem kontekstu možnosti, ki jih ponuja analiza podatkov za optimizacijo logističnih procesov. Poglavje vključuje teme, kot so:

- kontekst, v katerem deluje e-logistika, vključno s konceptom e-poslovanja,
- osnovne opredelitve e-logistike,
- razvoj e-logistike,
- sodobne e-logistične tehnologije in orodja,
- praktične e-logistične rešitve.

7.1. Uvod

Razvoj digitalnih tehnologij ima dolgo zgodovino. Zato ne moremo trditi, da so digitalne rešitve ali izmenjava informacij v oskrbovalnih verigah sodobna rešitev. Nasprotno, s časovnega vidika in z vidika strokovno aktivnih ljudi je digitalni vidik že zrela rešitev, ki je postala stalni del poteka logističnih procesov. Z drugimi besedami, logistike si ne moremo več predstavljati, kaj šele delovati brez vzporednega pretoka digitalno zapisanih informacij.


Sodobno gospodarstvo se imenuje postindustrijsko gospodarstvo ali digitalno gospodarstvo. Vendar to ne pomeni, da se je pretok materialov popolnoma ustavil ali opustil. Prav pretok materialov je ključnega pomena za gospodarski promet in potrošnjo. Tako bo tudi v prihodnje, dokler bodo potrebe ljudi zadovoljevale materialne dobrine. Seveda je potrebe nekaterih ljudi mogoče zadovoljiti z digitalnimi vsebinami, vendar v bližnji prihodnosti vseh potreb ljudi ne bo mogoče zadovoljiti z digitalnimi dobrinami. Tako se zdi, da bo soobstoj materialnih in digitalnih tokov v naslednjih desetletjih predstavljal neločljiv tandem. Namen izraza digitalno gospodarstvo je poudariti vlogo in obseg materialnih in informacijskih tokov. Kot bo prikazano v tem poglavju, postaja digitalni tok vse pomembnejši za vzpostavitev podatkov, ki izboljšujejo

učinkovitost materialnega toka in s tem konkurenčni položaj posameznih podjetij in celotnih oskrbovalnih verig.

E-logistika je torej rešitev, ki se uvršča v glavni tok sodobnega gospodarstva. Je odziv na zahteve sodobnega gospodarstva in hkrati rešitev, ki zagotavlja nove priložnosti za poslovanje.

7.2. E-poslovanje

E-logistika je rešitev, ki deluje v okviru širšega koncepta e-poslovanja. E-poslovanje je lahko ohlapno opredeljeno kot poslovni proces, ki uporablja internet ali drug elektronski medij kot kanal za izvedbo poslovnih transakcij (Jayashankar et al., 2003). Znotraj e-poslovanja lahko razlikujemo podrobne dejavnosti, kot so: e-trgovanje, e-oglaševanje, e-marketing, elektronsko bančništvo, elektronske dražbe itd. Pri teh vrstah poslovnih dejavnosti pridevnik "elektronski" označuje, da se te dejavnosti izvajajo izključno v elektronski (digitalni) obliki z uporabo interneta, mobilne povezave itd. (Skitsko, 2016). Umestitev e-logistike v okviru e-poslovanja in drugih konceptov, ki uporabljajo prenos podatkov prek interneta, je prikazana na sliki 7.1.



Slika 71 E-logistika v konceptu e-poslovanja

Vir: Skitsko (2016)

V e-poslovanju obstaja več osnovnih modelov komuniciranja med udeleženci na trgu (Shemet, 2012):

- B2B (business-to-business). V tem modelu prihaja do interakcije med podjetji (podjetji, pravnimi osebami), ki želijo pridobiti različne koristi.



- B2C (poslovanje s stranko). Pri tem modelu podjetje komunicira s končnim potrošnikom.
- C2C (odjemalec-odjemalec). V tem modelu ljudje (fizične osebe) medsebojno komunicirajo s pomočjo različnih komunikacijskih sredstev in tehnologije.
- C2B (odjemalec za podjetje). V tem modelu mnenja ali ideje končnih potrošnikov, izražene na različne načine, zlasti na različnih spletnih forumih, v družabnih medijih, elektronski pošti itd., pomembno vplivajo na izdelavo izdelkov (njihove značilnosti, lastnosti, ceno itd.) s strani proizvajalca.
- B2G (business-to-government). Pri tem modelu podjetje sodeluje z državnimi upravnimi organi.
- C2G (customer-to-government). V tem modelu poteka interakcija med osebo in državnimi upravnimi organi.
- G2B (government-to-business), G2C (government-to-customer). V teh modelih državni upravni organi podjetjem in fizičnim osebam zagotavljajo informacijske storitve prek interneta.

Vpliv razvoja tehnologij za obdelavo podatkov in interneta na oskrbovalne verige lahko razdelimo na tri področja (Jayashankar et al., 2003):

- razvoj sistemov, ki podpirajo upravljanje podjetij (ERP) in načrtovanje materialnih tokov (APS);
- razvoj sistemov, ki podpirajo proces poslovnega odločanja v realnem času;
- izmenjavo informacij med podjetji.

Vsa omenjena področja se pojavljajo tudi v okviru izvajanja logističnih procesov, ki so postali podlaga za oblikovanje koncepta e-logistike.

7.3. Opredelitev pojma e-logistika

Na začetku je težko podati enotno opredelitev e-logistike. Gre namreč za pojem, ki je zelo tesno povezan s tehničnimi možnostmi pridobivanja, zbiranja, obdelave ter prenosa podatkov in informacij. Zato so se opredelitve tega pojma skozi čas spreminjale in se bodo verjetno še naprej spreminjale.



"E-logistika je dinamičen sklop komunikacijskih, računalniških in sodelovalnih tehnologij, ki spreminjajo ključne logistične procese, tako da so usmerjeni k strankam, in sicer z izmenjavo podatkov, znanja in informacij s partnerji v oskrbovalni verigi." (Wang et al., 2004)



Še eno zanimivo opredelitev, čeprav z ožjim obsegom, je predstavila skupina avtorjev Quirk, Forder in Bentley. *"E-logistika je uporaba internetnih tehnologij za podporo nabavi materiala, skladiščenju, prevozu in omogoča distribucijo z optimizacijo poti s sledenjem zalogam"* (Quirk et al., 2003)

Obe zgornji opredelitvi se osredotočata na vidik podatkov, ki spremljajo pretok materialov v oskrbovalnih verigah. Naloga e-logistike je torej slediti pretoku materialov, da bi ga bolje nadzorovala in vsem deležnikom v realnem času zagotavljala informacije o tem pretoku, kar bo posledično omogočilo sinhronizacijo tega pretoka v oskrbovalni verigi (Mangiaracina et al., 2015).



Po drugi opredelitvi je e-logistika logistični proces, ki izvaja pretok izdelkov, kupljenih v elektronskih prodajnih kanalih (Erceg & Damoska Sekuloska, 2019). Prikaz tega načina razumevanja e-logistike je predstavljen na sliki 7.2.



Slika 72E-logistika

Vir: Moroz et al. (2014)

S primerjavo obeh pristopov k opredelitvi e-logistike so bile primerjane osnovne značilnosti tradicionalne logistike in e-logistike, ki podpira pretok materialov v e-trgovini. Rezultati primerjave so predstavljeni v preglednici 1

Preglednica 7.1 Osnovne razlike med tradicionalno in e-logistiko

Področje uporabe	Tradicionalna logistika	E-logistika
Pošiljke	Veleprodajni	Parcela
Stranka	Strateški	Neznano
Storitve za stranke	Reaktivni, togi	Odziven, prilagodljiv
Distribucijski model	Potisk, ki temelji na ponudbi	Privlačnost na podlagi povpraševanja
Pretok zalog / naročil	Neusmerjeno	Obojestranski
Destinacije	Koncentrirani	Zelo razpršeno
Povpraševanje	Stabilno in dosledno	Zelo sezonski, razdrobljeni
Naročila	Predvidljivo	Spremenljivka

Vir: Song & Hou (2004)



Če povzamemo zgornje opredelitve, je treba poudariti njihove podobnosti. Logistične dejavnosti, ki se izvajajo za potrebe materialnega toka, so si med seboj zelo podobne, ne glede na to, ali gre za tradicionalni tok ali za dejavnosti, ki se izvajajo v okviru elektronskega poslovanja. Pri opisu e-logistike je treba opozoriti, da je v obeh pristopih ta koncept povezan s tokom podatkov, ki opisujejo materialni tok. Osnovne funkcije e-logistike so enake za obe področji (Skitsko, 2016):

- oblikovanje informacijskega okolja, v katerem sodelujejo udeleženci logistične verige dobave blaga;
- opredelitev značilnosti elektronskih informacijskih tokov;
- oblikovanje zahtev in potreb podjetij, ki zagotavljajo informacijske in komunikacijske storitve ter ustrezne povezave;
- organizacija uporabe mednarodnih standardov za identifikacijo izdelkov;
- vzdrževanje pravilnega in zanesljivega delovanja, razvoj informacijskega sistema podjetja;
- zbiranje, analiza, shranjevanje, preoblikovanje in organizacija prenosa informacij v elektronski obliki;
- izbiro podatkov, potrebnih za sprejemanje upravljavskih odločitev.

Izvajanje teh funkcij ne bi bilo mogoče brez digitalnih tehnologij, ki omogočajo zbiranje, zbiranje in analizo podatkov. Opis najpomembnejših med njimi, ki so najbolj vplivale na razvoj e-logistike, je predstavljen v naslednjem podpoglavju.

7.4. Razvoj e-logistike

Na podlagi predstavljenih opredelitev je mogoče jasno ugotoviti, da se je e-logistika začela razvijati v času, ko so bili ustvarjeni prvi informacijski sistemi, ki so podpirali upravljanje materialnega toka, sistemi za načrtovanje materialnih potreb (MRP) in načrtovanje distribucijskih virov (DRP). Ti sistemi so se začeli razvijati v šestdesetih letih prejšnjega stoletja. Bili so prve rešitve za vzporedni pretok materialov in digitalno zapisanih informacij. V naslednjih letih se je zgodil dinamičen razvoj teh sistemov, ki je pripeljal do nastanka načrtovanja virov podjetja (ERP). Vzporedno so se razvijali sistemi, namenjeni posameznim logističnim funkcijam: sistemi za upravljanje transporta (TMS) in sistemi za upravljanje skladišč (WMS) (Wang, 2016). Več podrobnosti o sistemih IT je na voljo v poglavju 6 tega priročnika.



Razvoj sistemov ERP, zlasti koncentracija podatkov in večdimenzionalnost teh podatkov, je omogočil oblikovanje sistemov za podporo odločanju (DSS) (Turbanet al., 2002). Razvoj interneta in možnost izmenjave podatkov med sistemi posameznih podjetij sta sprožila razvoj sistemov razreda ERP II, ki so omogočali povezovanje podatkov med partnerji v oskrbovalnih verigah (Møller, 2005). Izmenjava podatkov med partnerji je mogoča zaradi rešitve elektronske izmenjave podatkov (EDI) (Huang idr., 2008).

Naslednji mejnik v razvoju e-logistike je bila vzpostavitev elektronskih tržnic (EM). Vzpostavitev platform, ki povezujejo podjetja neposredno s strankami (in druge konfiguracije, predstavljene v podpoglavju o e-poslovanju), je omogočila oblikovanje novih poslovnih modelov in s tem zahtev za logistiko (Wang idr., 2007).

Vzporedno z razvojem EM so se razvijali sistemi za zbiranje in analizo velikih zbirk podatkov, ki so omogočali izvajanje računalniških procesov v oblaku. Razvoj tehnologije zbiranja velikih količin podatkov in možnost njihove analize ter izmenjave analitičnih orodij in rezultatov analiz na daljavo prek interneta je omogočil povsem nove možnosti, zlasti na področju oskrbe DSS z informacijami in posledično možnost optimizacije logističnih procesov, zlasti na področjih, kot so: napovedovanje, upravljanje zalog, upravljanje transporta in upravljanje človeških virov (Waller in Fawcett, 2013). Za povzetek razvoja digitalnih tehnologij, ki se uporabljajo v e-logistiki, lahko uporabimo opažanje avtorjev Merali, Papadopoulos in Nadkarni (2012), ki so predstavili štiristopenjske spremembe na področju IKT od šestdesetih let prejšnjega stoletja, ki so pomembno vplivale na razvoj e-logistike (Merali et al., 2012):

- povezljivost (med ljudmi, aplikacijami in napravami);
- zmogljivosti za porazdeljeno shranjevanje in obdelavo podatkov;
- doseg in območje prenosa informacij;
- hitrost (hitrost in obseg) prenosa informacij.

Zgoraj omenjeni koraki v razvoju tehnologij IKT so nedvomno vplivali na možnosti praktične uporabe digitalnih rešitev v logističnih procesih. Te spremembe tudi jasno kažejo smer razvoja digitalnih tehnologij. Tehnologije, ki se trenutno uporabljajo v e-logistiki, so podrobneje opisane v naslednjem podpoglavju.

7.5. Sodobne tehnologije, ki podpirajo e-logistiko

Razvoj industrije 4.0 in logistike 4.0 ponuja dodatne priložnosti za razširitev rešitev in storitev, ki jih ponuja e-logistika. Med glavnimi tehnologijami, ki podpirajo e-logistiko, so trenutno:



- Blockchain;
- Internet stvari in senzorji (IoT);
- Generativna umetna inteligenca (AI);

Blockchain je sistem porazdeljene zbirke podatkov med vsemi udeleženci v istem omrežju. Ta sistem beleži in shranjuje podatke v obliki povezanih blokov, ki tvorijo zbirko zapisov. Ti so trajni in jih zato ni mogoče izbrisati. Pomembno je vedeti, da ni možnosti izvajanja posodobitev ali kakršnih koli sprememb. Vendar pa je mogoče zapis dodati ali prebrati (Dutta et al., 2020).

Tehnologija veriženja blokov omogoča varno in sledljivo sledenje različnim transakcijam v celotni oskrbovalni verigi. Dokumentirane transakcije in podatki so nepreklicno shranjeni v verigi blokov in jih ni mogoče uporabiti ali prebrati brez soglasja. Ob vsakem prevozu ali ravnanju s pošiljko se lahko transakcija dokumentira, s čimer se ustvari trajna zgodovina od proizvajalca do trgovca ali potrošnika (Aritua et al., 2021).

Internet stvari (IoT) omogoča, da med seboj komunicirajo naprave, ki niso računalniške. Koncept temelji na številnih tehnologijah, od komunikacijskih protokolov prek senzorjev, ki zbirajo podatke, infrastrukture, ki omogoča prenos podatkov, do sistemov, ki analizirajo zbrane podatke (Minerva, 2015). Rešitve interneta stvari so pogosto združene s senzorji RFID (radiofrekvenčna identifikacija), kar omogoča ne le lokalno identifikacijo blaga ali tovora, temveč tudi prenos teh podatkov kateremu koli uporabniku. Rešitve interneta stvari se lahko oblikujejo v dveh različicah (Idrissi et al., 2022):

- internetno usmerjeni - glavni element sistema so storitve, ki so na voljo v računalništvu v oblaku, objekti sistema pa so ponudniki podatkov;
- Objektno usmerjena - rešitev, pri kateri je osrednja točka omrežja objekt, ki ga je mogoče nadzorovati s sporočili, ki se prenašajo prek interneta.

Rešitve interneta stvari se pogosto uporabljajo v logistiki. Internet stvari omogoča sledenje različnim informacijam za nadzor kakovosti blaga, kot so svetloba, vlaga, temperature, vibracije, udarci itd. (Dash et al., 2019). Na primer, pri podjetju Maersk želi prevoznik zabojnikov tržiti storitev, ki zahteva dodatno zavarovanje na celotni poti. V zabojniku, opremljenem z instrumenti, je mogoče spremljati pogoje prevoza (vibracije, temperatura, vlaga, magnetizem, položaj itd.). Te informacije se lahko naložijo tudi v verigo blokov, da se sprožijo delna plačila med prevozom UI-ja je simulacija procesov človeške inteligence s stroji in računalniškimi sistemi. Ustvarjanje znanja z umetno inteligenco poteka v treh korakih (Samoili et al., 2020):



- učenje - pridobivanje informacij in pravil njihove uporabe;
- sklepanje - uporaba pravil za sklepanje;
- samopopravek.

Aplikacija umetne inteligence omogoča, da sistem vsakemu operaterju posreduje natančne podatke o vsakem naročilu. Sistem lahko to doseže z učenjem na podlagi zgodovine. To pomaga doseči največjo učinkovitost, zlasti v skladiščih z intenzivnim pobiranjem, kot je e-trgovina (Dash et al., 2019).

Predstavljene tehnologije ne predstavljajo zaprtega kataloga rešitev, ki se uporabljajo v e-logistiki. Sodelovanje teh tehnologij pri pridobivanju, zbiranju in obdelavi podatkov za ustvarjanje informacij, ki podpirajo učinkovite upravljalvske odločitve, je še posebej pomembno.

7.6. E-logistika v praksi

Ne glede na to, kako je opredeljena e-logistika, te rešitve delujejo v skoraj vseh vidikih logistične dejavnosti, ne glede na funkcijo ali fazo materialnega toka. Glede na prej predstavljeni pregled literature je treba pozornost usmeriti na povezavo med dobavitelji in prejemniki. Tu se zdi izmenjava podatkov in povezovanje subjektov za izboljšanje učinkovitosti materialnega toka še posebej pomembno. To je trenutno mogoče zaradi splošno dostopnega interneta in samodejnega pridobivanja podatkov. Praktične rešitve e-logistike ponujajo praktično vsi logistični operaterji, zlasti tisti, ki delujejo na globalnem trgu. Odličen primer rešitev, ki se uporabljajo v okviru e-logistike, so rešitve, ki jih ponuja podjetje Dachser. Ta evropski logistični operater svojim strankam zagotavlja neposredno povezavo s sistemi za upravljanje transporta in skladišč, zaradi česar imajo stranke neprekinjen dostop v realnem času do podatkov o izvajanju logističnih procesov tega operaterja. Funkcije, ki jih ponuja Dachser (n.d.) v okviru e-logistike, vključujejo:

- analiza izdelkov in storitev - s tem orodjem lahko hitro določite optimalne ali želene oskrbovalne roke za pošiljke v Evropi;
- spletno naročanje - samodejni uvoz podatkov v naročila prihrani čas. Funkcija uvoza naslovov iz sistema ERP dopolnjuje upravljanje naslovov. Ta funkcija



omogoča tudi pošiljanje dokumentov, shranjevanje podatkov o nevarnem blagu ter pošiljanje prihodnjih naročil in uporabo lastnih črtnih kod;

- nadzor vseh stroškov prevoza - omogoča hitro pridobivanje informacij o ceni prevoza, ne da bi bilo treba poslati obsežne poizvedbe;
- sledenje zalogam - omogoča spremljanje procesov, ki potekajo v skladiščih, od preverjanja statusa prejetih naročil do spremljanja serij. Ta funkcionalnost vam omogoča takojšnje ugotavljanje pomanjkanja in ravni zalog;
- trenutne informacije o stanju pošiljke in njeni lokaciji - funkcija Sledenje in spremljanje vam omogoča, da za vsako pošiljko ustvarite individualno povezavo, ki vas bo obveščala o trenutnem stanju pošiljke. To povezavo lahko nato posredujete strankam ali partnerjem;
- spletno upravljanje računov - spletni dostop do vseh podatkov o pošiljkah. Podatki so na voljo v datotekah PDF, Excelovih tabelah in datotekah CSV. Te podatke lahko pošljemo tudi digitalno prek centra EDI;
- elektronsko evidentiranje palet - upravlja nakladalno opremo, ki ji je treba slediti, tj. europalete in regale.

Drugi svetovni logistični operater, ki v velikem obsegu uporablja e-logistične rešitve, je DHL. Poleg zelo podobnih funkcij, ki so bile zgoraj predstavljene za drugega operaterja, DHL v veliki meri uporablja tudi rešitve s področja strojnega učenja, obogatene resničnosti in umetne inteligence. Obogatena resničnost se uporablja za optimizacijo skladiščne infrastrukture in logističnih operacij, ki se tam izvajajo. Strojno učenje in umetna inteligenca se uporabljata za povečanje učinkovitosti poslovanja in povečanje odpornosti organizacije z usmerjanjem sprejetih ukrepov v proaktivno in ne reaktivno delovanje. Sprejemanje proaktivnih ukrepov je mogoče zaradi analize velikih podatkovnih nizov in iskanja povezav med vzroki in posledicami v njih. Tako je mogoče na podlagi preteklih dogodkov napovedati nastanek prihodnjih pojavov. Takšni ukrepi vplivajo tudi na povečanje vrednosti storitev, namenjenih strankam družbe DHL, in na povečanje njihovega konkurenčnega položaja (DHL, 2017). To kaže, da logistični operater lahko poleg klasičnih logističnih storitev v obliki prevoza, skladiščenja ali obravnave naročil ponuja tudi napredne storitve na področju analize podatkov in priporočanja rešitev, ki izhajajo iz teh analiz. E-logistične rešitve tako postajajo vir konkurenčne prednosti, storitve, ki iz njih izhajajo, pa so naravni element sodelovanja med člani oskrbne verige



7.7. Povzetek

Rešitve, ki se uporabljajo v okviru e-logistike, so tako raznolike, kot so raznolike opredelitve tega pojma. Pri opredelitvi tega pojma je mogoče razlikovati dva glavna trenda. V širšem smislu so e-logistika vse vrste digitalnih rešitev, ki spremljajo pretok materiala. V ožjem smislu je e-logistika opredeljena kot izvajanje logističnih procesov, ki spremljajo elektronsko poslovanje. Seveda se oba pristopa ne izključujeta. Predstavljena zgodovina razvoja, predstavljena širitev področja, na katerem deluje e-logistika, in pričakovane smeri razvoja jasno kažejo, da bo ta pojem ne glede na način opredelitve predmet zanimanja tako poslovnih praktikov kot raziskovalcev.

Čeprav kot je navedeno v uvodu tega poglavja, materialnega toka ne bo nadomestil pretok informacij, pa pretok informacij v veliki meri določa učinkovitost materialnega toka. V tem pogledu se zdi podpora informacijskim procesom, ki se izvajajo v okviru e-logistike, z metodami in orodji za analizo podatkov še posebej pomembna. Sodobne tehnične rešitve omogočajo zbiranje velikih nizov podatkov in iskanje povezav med temi podatki, da bi pripravili informacije, uporabne za sprejemanje vodstvenih odločitev.

Podrobne rešitve na področju analize podatkov in priprave podatkov za sprejemanje vodstvenih odločitev so obravnavane v preostalih poglavjih tega priročnika. V njih so poleg konceptov poslovne analitike predstavljeni tudi sistemi ERP, ki omogočajo zbiranje podatkov, orodja BI, ki omogočajo analizo in vizualizacijo podatkov, ter sodobna vprašanja, povezana z uporabo strojnega učenja pri analizi podatkov in varnostjo podatkov.

Pomanjkanje jasnega okvira za opredelitev pojma e-logistika je posledica hitrega razvoja tega področja in brisanja meja med posameznimi rešitvami, ki podpirajo izvajanje pretoka informacij.



VIRI

1. Aritua, B., Wagener, C., Wagener, N. & Adamczak, M. (2021). Blockchain solutions for international logistics networks along the new silk road between Europe and Asia, *Logistics*, 5(3), pp. 1-14.
2. Dachser (n.d.). eLogistics: Internetowy portal do zarządzania logistyką [available at: dachser.pl/pl/elogistics-116, access April 07, 2024]
3. Dash, R., McMurtrey, M., Rebman, C. & Kar U.K. (2019). Application of Artificial Intelligence in Automation of Supply Chain Management, *Journal of Strategic Innovation and Sustainability*, West Palm Beach, 14(3), pp. 43-53.
4. DHL 2017. The 21st Century Spice Trade: A Guide to the Cross-Border E-Commerce Opportunity [available at: http://www.dhl.com/content/dam/downloads/g0/press/publication/g0_dhl_express_cross_border_ecommerce_21st_century_spice_trade.pdf, access June 23, 2018].
5. Dutta, P., Choi, T.M., Somani, S. & Butala, R. (2020). Blockchain technology in supply chain operations: applications, challenges and research opportunities. *Transp Res Part E: Logist Transp Rev*, 142(102067).
6. Erceg, A. & Damoska Sekuloska, J. (2019). E-logistics and e-SCM: how to increase competitiveness. *LogForum*, 15(1), pp. 155-169.
7. Huang, Z., Janz, B. & Frolick, M. (2008). A comprehensive examination of Internet-EDI adoption. *Information Systems Management*, 25(3), pp. 273-286.
8. Idrissi, Z. K., Lachgar, M. & Hrimech, H. (2022). Blockchain, IoT and AI revolution within transport and logistics, 2022 14th International Colloquium of Logistics and Supply Chain Management (LOGISTIQUA), EL JADIDA, Morocco, 25-27 May 2022.
9. Swaminathan, J. M. & Tayur, S. R. (2003). Models for Supply Chains in E-Business. *Management Science*, 49(10), pp. 1387-1406.
10. Mangiaracina, R., Marchet, G., Perotti, S. & Tumino, A. (2015). A review of the environmental implications of B2C e-commerce: a logistics perspective. *International Journal of Physical Distribution & Logistics Management*, 45(6), pp. 565-591.



11. Merali, Y., Papadopoulos, T. & Nadkarni, T. (2012). Information systems strategy: past, present, future? *The Journal of Strategic Information Systems*, 21(2), pp. 125–153.
12. Minerva, R., Biru A. & Rotondi, D. (2015). Towards a definition of the Internet of Things (IoT), IEEE.
13. Moroz, M., Nicu, C., Pawel, I. D. D., Polkowski, Z. (2014). The transformation of logistics into e-logistics with the example of electronic freight exchange, *Zeszyty Naukowe Dolnośląskiej Wyższej Szkoły Przedsiębiorczości i Techniki. Studia z Nauk Technicznych*, 3, pp. 111-128.
14. Møller, C. (2005). ERP II: a conceptual framework for next-generation enterprise systems?, *Journal of Enterprise Information Management*, 18(4), pp. 483–497.
15. Samoil, S., Cobo, M.L., Gomez, E., De Prato, G. Martinez-Plumed, F. & Delipetrev, B. (2020). Defining Artificial Intelligence. Towards an operational definition and taxonomy of artificial intelligence, Joint Research Centre, Luxembourg: Publications Office of the European Union, pp. 1-97.
16. Shemet A. D. (2012). Forms of E-commerce and its place in the system of digital economy, *Science and Transport Progress. Bulletin of Dnipropetrovsk National University of Railway Transport*, Dnipropetrovsk, Ukraine, 41, pp. 311-315.
17. Skitsko V. I. (2016). E-logistics and m-logistics in information economy. *LogForum*, 12(1), pp. 7-16.
18. Song, Y. & Hou, H., (2004). On traditional M. F and Modern M. F, *Journal of Beijing Jiaotong University (Social Sciences Edition)*, 3(1), pp. 10-16.
19. Quirk, A., Forder, J. & Bentley, D. (2003). *Electronic Commerce and the Law*, 2nd edition, John Wiley & Sons Ltd., USA.
20. Turban, E., McLean, E. & Wetherbe, J. (2002). *Information Technology for Management: Transforming business in the digital economy*, John Wiley & Sons, New York.
21. Wang, J., Yang, D., Guo, D. & Huo Y., (2004). Taking Advantage of E-Logistics to Strengthen the Competitive Advantage of Enterprises in China [in:] *Proceedings of The Fourth International Conference on Electronic Business*, Beijing, pp. 185-189.



22. Wang, Y., Potter, A. & Naim, M. M. (2007). Electronic marketplaces for tailored logistics, *Industrial Management and Data Systems*, 107 (8), pp. 1170–1187.
23. Wang, Y. (2016). E-logistics: an introduction, in Wang Y.I. & Pettit S., *E-Logistics: Managing Your Digital Supply Chains for Competitive Advantage*, Kogan Page, pp. 3-31.
24. Waller, M. A. & Fawcett, S. E. (2013). Data science, predictive analytics, and big data: a revolution that will transform supply chain design and management, *Journal of Business Logistics*, 34(2), pp. 77–84.



8. GIS V LOGISTIKI

Avtor: Dario Šebalj


Geografski informacijski sistemi (GIS) so revolucionarno spremenili logistično industrijo, saj zagotavljajo zmogljiva orodja za prostorsko analizo in sprejemanje odločitev. Ker podjetja vse bolj delujejo v globaliziranem okolju, je sposobnost vizualizacije in analize geografskih podatkov bistvena za optimizacijo oskrbovalnih verig, upravljanje transportnih omrežij in izboljšanje splošne učinkovitosti. Tehnologija GIS logističnim strokovnjakom omogoča kartiranje poti, sledenje pošiljkam in analizo prostorskih vzorcev, kar vodi k bolj informiranim odločitvam in boljšemu razporejanju virov. To poglavje obravnava vključevanje GIS v logistiko ter izpostavlja njene aplikacije, prednosti in prihodnje možnosti. Z razumevanjem uporabe GIS v logistiki lahko podjetja pridobijo konkurenčno prednost, zmanjšajo stroške in povečajo zadovoljstvo strank.

8.1. Geografski informacijski sistemi (GIS)

Geografski informacijski sistem (GIS) je računalniško orodje, ki združuje, shranjuje, analizira in vizualizira geografske podatke. Prostorske podatke povezuje z opisnimi informacijami, kar uporabnikom pomaga razumeti in razlagati prostorske odnose, vzorce in trende. GIS se uporablja v različnih panogah za kartiranje, analizo in odločanje ter zagotavlja dragocen vpogled v prostorske razsežnosti podatkov (Jonker, 2023; GisGeography, 2024a; Esri, n.d.a; National Geographic, n.d.).

Po podatkih podjetij Esri (n.d.b) in GisGeography (2024b) zgodovina geografskih informacijskih sistemov (GIS) sega v zgodnja šestdeseta leta 20. stoletja, ko je prvi računalniški GIS razvil **Roger Tomlinson**, ki ga pogosto imenujejo "oče GIS". Ta prvotni sistem je bil ustvarjen za kanadski zemljiški kataster za pomoč pri upravljanju rabe zemljišč in načrtovanju virov. V sedemdesetih in osemdesetih letih prejšnjega stoletja je napredek na področju računalniške tehnologije, daljinskega zaznavanja in prostorske analize privedel do razvoja bolj izpopolnjene programske opreme GIS. Leta 1969 je bilo ustanovljeno podjetje Esri (Environmental Systems Research Institute), ki je postalo ključni akter v industriji GIS in je predstavilo platformo ArcGIS, ki je znatno izboljšala zmogljivosti in dostopnost tehnologije GIS. Do devetdesetih let prejšnjega stoletja se je tehnologija GIS razvila in vključila širši spekter aplikacij, od

urbanističnega načrtovanja do okoljskega upravljanja. Integracija GIS z GPS (Global Positioning Systems) in pojav interneta sta še dodatno razširila njegovo uporabo. Danes je GIS sestavno orodje v različnih sektorjih, vključno s prometom, logistiko, kmetijstvom in javno varnostjo, saj zagotavlja ključne informacije in pomaga pri sprejemanju odločitev.



Slika 8.1 Sestavni deli GIS

Vir: Avtor, prilagojeno po Kishore in Rautray (n.d.).


Na sliki 8.1 je prikazanih pet bistvenih sestavnih delov geografskega informacijskega sistema (GIS) po Kishoreju in Rautrayju (n.d.):

- **Strojna oprema:** Računalniki, strežniki, naprave GPS in druge periferne naprave: fizične naprave, ki se uporabljajo za izvajanje programske opreme GIS in shranjevanje podatkov, kot so računalniki, strežniki, naprave GPS in druge periferne naprave.
- **Programska oprema:** Programska oprema: Programi in aplikacije, ki izvajajo funkcije GIS in uporabnikom omogočajo analizo in vizualizacijo prostorskih podatkov.
- **Podatki:** Podatki: prostorske in neprostorske informacije, ki jih analizirajo sistemi GIS, vključno z zemljevidi, satelitskimi posnetki in tabelaričnimi podatki.
- **Metode:** Metode: tehnike in postopki, ki se uporabljajo za analizo podatkov GIS, kot so algoritmi in statistični modeli.
- **Ljudje:** Ljudje: strokovnjaki in uporabniki, ki uporabljajo in upravljajo tehnologijo GIS, od podatkovnih analitikov do odločevalcev.

Geografski informacijski sistemi se uporabljajo v različnih panogah, zato so nepogrešljivo orodje za analizo prostorskih podatkov in sprejemanje odločitev. Na področju poslovnega obveščanja se GIS uporabljajo za analizo trga, izbiro lokacij in optimizacijo logistike, kar podjetjem pomaga pri sprejemanju odločitev, ki temeljijo na podatkih in geografskih trendih

(Longley et al., 2015). Pri upravljanju okolja se GIS uporablja za upravljanje naravnih virov, spremljanje okolja in odzivanje na nesreče, kar omogoča učinkovitejša prizadevanja za ohranjanje narave in načrtovanje izrednih razmer (Goodchild et al., 2018). Z združevanjem in analizo prostorskih podatkov GIS izboljšuje procese odločanja z natančnimi geografskimi vpogledi in vizualizacijami, kar organizacijam omogoča prepoznavanje vzorcev in povezav, ki v tradicionalnih oblikah podatkov niso takoj vidni (Longley et al., 2015).

Ena od ključnih sestavin tehnologije GIS je koncept slojev. Po podatkih podjetja Esri (n.d.c.) je sloj delček geografske stvarnosti na določenem območju. Vsak sloj v GIS ustreza določeni vrsti podatkov, kot so ceste, raba tal, nadmorska višina, vodna telesa ali gostota prebivalstva. Slika 8.2 prikazuje primer različnih vrst podatkov na enem zemljevidu (ulice, stavbe in vegetacija), od katerih vsak ustreza eni plasti.




Slika 8.2 Sloje GIS

Vir: Vir: Avtor, prilagojeno iz National Geographic (n.d.).

Geografski informacijski sistemi za predstavitev, analizo in vizualizacijo geografskih informacij uporabljajo različne vrste podatkov. Podatke GIS lahko na splošno razvrstimo v dve glavni vrsti: rastrske in vektorske podatke.

Dempsey (2024) navaja, da so prevladujoča oblika podatkov GIS **vektorski podatki**. Primeri vektorskih podatkov so točke, črte in poligoni, ki se uporabljajo za predstavitev geografskih podatkov. Pri vektorski predstavitvi so vse črte zajete kot točke, povezane s točno določenimi ravnimi črtami (Longley et al., 2015). Točkovni podatki predstavljajo diskretne podatkovne točke ali določene lokacije, kot so šole, imena mest ali zanimive točke. Linijski podatki predstavljajo linearne značilnosti, kot so ceste in reke, poligoni pa se uporabljajo za značilnosti območij, kot so jezera, upravne meje in gozdovi (Dempsey, 2024)

Rastrski podatki so mrežna podatkovna struktura, sestavljena iz slikovnih pik ali celic, ki imajo vsaka svoj atribut. Najpogostejši viri rastrskih podatkov so satelitski posnetki, letalski posnetki, podatki daljinskega zaznavanja ter podatki z osenčenim reliefom in topografijo (Dempsey, 2024; Longley et al., 2015).



Slika 83 Vektorski (levo) in rastrski (desno) podatki

Vir: Avtor.

Na sliki 8.3 sta prikazana dva prikaza zemljevida z vektorskimi (na levi) in rastrskimi (na desni) podatki. Vektorski podatki vključujejo poligone (jezero in gozd) in črte (reke), rastrski podatki pa mrežo, kjer vsaka celica predstavlja eno barvo (modro, rumeno ali zeleno).

Pomembno je razumeti različne vrste podatkov GIS, da bi jih lahko učinkovito uporabili pri poslovnem obveščanju. Vektorski podatki so idealni za natančno kartiranje in analizo diskretnih



geografskih značilnosti, medtem ko so rastrski podatki odlični za predstavitev neprekinjenih podatkov in obsežnih okoljskih podatkov.

8.2. GIS v logistiki

Geografski informacijski sistemi (GIS) so temeljito spremenili logistični sektor, saj zagotavljajo orodja, ki omogočajo učinkovitejše, stroškovno učinkovitejše in strateške postopke odločanja. Vključevanje GIS v logistiko omogoča vizualizacijo, analizo in interpretacijo prostorskih podatkov, kar je ključno za optimizacijo poti, upravljanje oskrbovalnih verig in izboljšanje splošne operativne učinkovitosti.

Za reševanje logističnih izzivov tehnologija GIS združuje najsodobnejše tehnike upravljanja podatkov in analitične tehnike z geografsko znanostjo. Strokovnjaki s področja logistike lahko vidijo vzorce, odnose in trende, ki niso vidni v tradicionalnih oblikah podatkov, saj z njo lažje prekrijejo različne podatkovne nize na zemljevidu. Po podatkih podjetja Esri (2017) ta prostorska perspektiva zelo koristi strateškemu načrtovanju in operativni optimizaciji.

Ena glavnih aplikacij GIS v logistiki je optimizacija poti. Z analizo prostorskih podatkov lahko logistična podjetja določijo najučinkovitejše poti za dostavo, s čimer zmanjšajo čas potovanja, porabo goriva in skupne stroške poslovanja. GIS lahko na primer upošteva prometne vzorce, stanje cest in omejitve hitrosti ter tako v realnem času optimizira potek poti (Ramzan, 2023). Ta zmožnost ne izboljšuje le učinkovitosti, temveč z zagotavljanjem pravočasne dostave povečuje tudi zadovoljstvo strank.

Sureshkumar in drugi (2017) so izvedli študijo, ki poudarja številne prednosti GIS in poudarja njegov transformativni potencial pri optimizaciji poti za upravljanje prometa. GIS omogoča uporabo podatkov v realnem času za dinamično prilagajanje prometa in celovito prostorsko analizo, saj omogoča integracijo različnih vrst podatkov, vključno z GPS in satelitskimi posnetki. Zaradi te integracije se zaradi krajših potovalnih razdalj in manjše porabe goriva bistveno prihranijo čas in stroški. Postopki odločanja se izboljšajo z zmožnostmi prostorske vizualizacije GIS, ki razkrivajo vzorce in trende, ki so skriti v običajnih oblikah podatkov. Vse skupaj kaže, da optimizacija poti na podlagi GIS ne le zmanjšuje vpliv na okolje in povečuje operativno učinkovitost, temveč ponuja tudi trden okvir za reševanje zapletenih mestnih prometnih vprašanj.

Uporaba geografskih informacijskih sistemov (GIS) pri optimizaciji poti zbiranja trdnih komunalnih odpadkov (TKO) se je izkazala za zelo učinkovito pri izboljšanju operativne



učinkovitosti in zmanjšanju stroškov. Singh in Behera (2018) sta dokazala, da je integracija GIS in orodja za analizo omrežja v ArcGIS znatno zmanjšala prevozne razdalje za povprečno 27,78 %, kar je poudarilo bistvene izboljšave v logistiki ravnanja z odpadki v mestu Kanpur v Indiji. Podobno so Nguyen-Trong et al. (2016) uporabili kombiniran pristop GIS, optimizacije na podlagi enačb in modeliranja na podlagi agentov za dinamično optimizacijo poti zbiranja odpadkov v mestu Hagiang v Vietnamu in dosegli 11,3-odstotno zmanjšanje stroškov. Te študije poudarjajo preobrazbeni potencial GIS pri obravnavanju zapletenosti ravnanja s komunalnimi odpadki, zlasti z vključevanjem podatkov v realnem času in naprednih tehnik modeliranja. Z uporabo GIS za prostorsko analizo in optimizacijo poti lahko občine dosežejo bolj trajnostne in učinkovite prakse ravnanja z odpadki, s čimer izboljšajo splošno izvajanje storitev in zmanjšajo vpliv na okolje.

Hemidat in drugi (2017) so izvedli študijo, katere cilj je bil izboljšati učinkovitost zbiranja trdnih komunalnih odpadkov v več jordanskih mestih z uporabo tehnik GIS. Raziskovalci so z orodjem ArcGIS Network Analyst razvili optimizirane scenarije zbiranja odpadkov s ciljem zmanjšati operativne stroške, čas delovanja vozil in vplive na okolje. Optimizirani scenariji so v primerjavi s trenutnim stanjem (S0) pokazali znatne prihranke. Scenarij S1 je pri Irbidu, Karaku in Mafraku prinesel 15-odstotne, 6-odstotne in 11-odstotne prihranke stroškov. Scenarij S2 je pokazal 13-odstotni, 3-odstotni in 6-odstotni prihranek stroškov za ista mesta. Kombinirani scenarij (S3) je prinesel največje prihranke s 23-odstotnim, 8-odstotnim in 13-odstotnim zmanjšanjem skupnih stroškov. Te ugotovitve poudarjajo znaten vpliv optimizacije poti na podlagi GIS na zmanjšanje operativnih stroškov, časa delovanja vozil in vplivov na okolje z zmanjšanjem porabe goriva in emisij.

Analitika, ki temelji na GIS, bistveno izboljša upravljanje verige preskrbe s krvjo, saj zagotavlja vidljivost v realnem času in omogoča boljše sprejemanje odločitev. Integracija GIS s podatkovnim rudarjenjem in drugimi analitičnimi tehnikami omogoča učinkovito sledenje, upravljanje in optimizacijo virov krvi, kar vodi k izboljšanju operativne učinkovitosti in zmanjšanju izgub (Delen et al., 2011).

GIS ima pomembno vlogo tudi pri načrtovanju in upravljanju mestne infrastrukture, saj zagotavlja zanesljivo platformo za povezovanje in analizo prostorskih podatkov. Uporaba GIS v tem kontekstu omogoča bolj informirano sprejemanje odločitev, kar vodi k optimizaciji naložb v infrastrukturo in izboljšanemu zagotavljanju storitev. Študija, ki so jo izvedli Irizarry in drugi



(2013), poudarja učinkovitost GIS pri upravljanju mestne infrastrukture in izboljšanju operativne učinkovitosti.

Uporaba GIS pri optimizaciji poti na različnih področjih, kot so ravnanje s trdnimi komunalnimi odpadki, upravljanje verige preskrbe s krvjo in načrtovanje mestne infrastrukture, je na spletni strani pokazala velike koristi. GIS povečuje operativno učinkovitost z združevanjem prostorskih podatkov z naprednimi analitičnimi orodji, kar olajša odločanje v realnem času in optimizira uporabo virov. Študije so pokazale znatno znižanje stroškov in izboljšano zagotavljanje storitev z optimizacijo poti na podlagi GIS, kar poudarja njegovo ključno vlogo pri upravljanju zapletenih logističnih dejavnosti. Z uporabo tehnologije GIS lahko organizacije dosežejo trajnostne prakse, zmanjšajo vplive na okolje in povečajo splošno operativno učinkovitost.

8.3. Prihodnji trendi na področju GIS-a

Geografski informacijski sistemi se zaradi tehnološkega napredka in vse večjih potreb po analizi prostorskih podatkov močno spreminjajo. V tem podpoglavju bodo obravnavani prihodnji trendi na področju GIS s poudarkom na novih tehnologijah, računalništvu v oblaku, vključevanju velikih količin podatkov ter vlogi umetne inteligence (AI) in strojnega učenja (ML).

Prihodnost GIS oblikuje več ključnih trendov in inovacij, ki spreminjajo način zbiranja, analiziranja in uporabe prostorskih podatkov. Pomemben trend je vključevanje naprednih tehnologij, kot so računalništvo v oblaku, umetna inteligenca, strojno učenje (ML) in zbiranje podatkov z droni. Te tehnologije povečujejo učinkovitost in zmogljivosti GIS, saj omogočajo obdelavo podatkov v realnem času in zahtevnejše prostorske analize. **Računalništvo v oblaku** revolucionarno spreminja GIS, saj zagotavlja skalabilne in dostopne platforme za shranjevanje in obdelavo velikih zbirk podatkov. Ta premik organizacijam omogoča, da izkoristijo velike količine geoprostorskih podatkov, ne da bi za to potrebovale obsežno lokalno infrastrukturo. Vedno bolj se uveljavlja GIS kot storitev, ki uporabnikom omogoča dostop do zmogljivih orodij GIS in zmožnosti analize podatkov prek platform v oblaku. Zaradi tega trenda postaja GIS dostopnejši in stroškovno učinkovitejši, zlasti za manjše organizacije in panoge z omejenimi viri. **AI in ML** imata pomembno vlogo pri avtomatizaciji in izboljšanju analize prostorskih podatkov. Te tehnologije lahko prepoznavajo vzorce, napovedujejo in zagotavljajo vpogled v kompleksne podatkovne nize, ki bi jih bilo težko analizirati ročno. Algoritmi umetne inteligence lahko na primer obdelajo satelitske posnetke in zaznajo spremembe v rabi zemljišč, medtem ko lahko modeli ML na podlagi preteklih podatkov predvidijo prometne vzorce.



Integracija umetne inteligence in ML z GIS omogoča natančnejše in pravočasnejše sprejemanje odločitev v različnih sektorjih, od urbanističnega načrtovanja do obvladovanja naravnih nesreč. Tudi napredek na področju **tehnologije brezpilotnih letalnikov** je pomemben trend na področju GIS. Droni, opremljeni s kamerami in senzorji visoke ločljivosti, se vse pogostejše uporabljajo za zbiranje podatkov na težko dostopnih območjih. Ta orodja zagotavljajo zelo natančne podatke v realnem času, ki jih je mogoče vključiti v GIS za podrobno kartiranje in analizo. Ta trend je še posebej koristen za spremljanje okolja, pregledovanje infrastrukture in upravljanje kmetijstva. Drug nov trend je uporaba **razširjene resničnosti** (AR) in **navidezne** resničnosti (VR) v GIS. Te tehnologije ponujajo nove načine vizualizacije in interakcije s prostorskimi podatki ter zagotavljajo potopitvene izkušnje, ki lahko izboljšajo razumevanje in sprejemanje odločitev. AR lahko na primer prekrije geoprostorske podatke s pogledi iz realnega sveta, kar uporabnikom pomaga pri vizualizaciji podzemnih komunalnih naprav ali navigaciji v zapletenih okoljih. VR lahko ustvari podrobne simulacije urbanih pokrajin, ki načrtovalcem omogočajo raziskovanje različnih scenarijev in njihovih morebitnih vplivov. **Analiza podatkov v realnem času** postaja vse pomembnejša v aplikacijah GIS. Zmožnost obdelave in analize podatkov med njihovim zbiranjem omogoča bolj odzivno in dinamično sprejemanje odločitev. To zmožnost povečuje povezava GIS z internetom stvari (IoT), kjer je mogoče podatke iz povezanih naprav nenehno spremljati in analizirati. GIS v realnem času se uporablja v aplikacijah, kot so upravljanje prometa, odzivanje na izredne razmere in spremljanje okolja, kjer so pravočasne informacije ključnega pomena. Omeniti je treba tudi širitev aplikacij GIS v nove industrije in sektorje. GIS se zdaj uporablja na področjih, kot je zdravstvo, kjer pomaga spremljati izbruhe bolezni in optimizirati zdravstveno oskrbo. V maloprodaji GIS analizira demografske podatke o strankah in optimizira lokacije trgovin. Tehnologija je ključna tudi pri pobudah za pametna mesta, saj zagotavlja prostorsko inteligenco, potrebno za učinkovito upravljanje mestne infrastrukture in virov (Kerski, 2022; MGISS, 2023).

Kot je razvidno, je vključitev GIS v logistiko povzročila revolucijo v panogi, saj je povečala učinkovitost delovanja, zmanjšala stroške in izboljšala zadovoljstvo strank. Ker se tehnologija GIS še naprej razvija, se bo njena uporaba v logistiki še razširila in ponudila še bolj izpopolnjena orodja za reševanje zapletenih izzivov. Z izkoriščanjem teh napredkov lahko logistična podjetja ohranijo konkurenčno prednost in se prilagodijo dinamičnim zahtevam svetovnega trga.



VIRI

1. Delen, D. & Erraguntla, M. (2011). Better management of blood supply-chain with GIS-based analytics. *Annals of Operations Research*, 185, 181-193.
2. Dempsey, C. (2024). Types of GIS Data Explored: Vector and Raster. *Geography Realm* [available at: <https://www.geographyrealm.com/geodatabases-explored-vector-and-raster-data/>, access June 9, 2024]
3. Esri (2017). *The ArcGIS Book: 10 Big Ideas about Applying The Science of Where*, 2nd Edition. Esri Press.
4. Esri (n.d.a). What is GIS? [available at: <https://www.esri.com/en-us/what-is-gis/overview>, access May 27, 2024]
5. Esri (n.d.b). History of GIS? [available at: <https://www.esri.com/en-us/what-is-gis/history-of-gis>, access May 27, 2024]
6. Esri (n.d.c). Layer. GIS dictionary [available at: <https://support.esri.com/en-us/gis-dictionary/layer>, access June 8, 2024]
7. GisGeography (2024a). The Remarkable History of GIS [available at: <https://gisgeography.com/history-of-gis/>, access May 27, 2024]
8. GisGeography (2024b). What is GIS? Geographic Information Systems [available at: <https://gisgeography.com/what-is-gis/>, access May 27, 2024]
9. Goodchild, M. F., Steyaert, L. T., Parks, B. O., Johnston, C., Maidment, D., Crane, M. & Glendinning, S. (2018). *GIS and Environmental Modeling: Progress and Research Issues*, 4th Edition. John Wiley & Sons.
10. Hemidat, S., Oelgemöller, D., Nassour, A., Nelles, M. (2017). Evaluation of Key Indicators of Waste Collection Using GIS Techniques as a Planning and Control Tool for Route Optimization. *Waste and Biomass Valorization*, 8, 1533-1554.
11. Hguyen-Trong, K., Nguyen-Thi-Ngoc, A., Nguyen-Ngoc, D. & Dinh-Thi-Hai, V. (2017). Optimization of municipal solid waste transportation by integrating GIS analysis, equation-based, and agent-based model. *Waste Management*, 59, pp. 14-22.



12. Irizarry, J., Karan, E. P. & Jalaei, F. (2013). Integrating BIM and GIS to improve the visual monitoring of construction supply chain management. *Automation in Construction*, 31, pp. 241–254.
13. Jonker, A. (2023). What is a geographic information system (GIS)? IBM [available at: <https://www.ibm.com/topics/geographic-information-system>, access May 27, 2024]
14. Kerski, J. (2022). 5 Trends in GIS and How to Successfully Navigate Them. Esri [available at: <https://community.esri.com/t5/esri-young-professionals-network-blog/5-trends-in-gis-and-how-to-successfully-navigate/ba-p/1169616>, access June 9, 2024]
15. Kishore, P. & Rautray, S. (n.d.). The five essential components of GIS. Infosys BPM [available at: <https://www.infosysbpm.com/blogs/geospatial-data-services/gis-five-essential-components.html>, access June 8, 2024]
16. Longley, P. A., Goodchild, M. F., Maguire, D. J. & Rhind, D. W. (2015). *Geographic Information Science and Systems*, 4th edition. John Wiley & Sons.
17. MGISS (2023). The Future of Gis: Trends and Innovations in Geospatial Technology [available at: <https://mgiss.co.uk/the-future-of-gis-trends-and-innovations-in-geospatial-technology/>, access June 9, 2024]
18. National Geographic (n.d.). GIS (Geographic Information System) [available at: <https://education.nationalgeographic.org/resource/geographic-information-system-gis/>, access May 27, 2024]
19. Ramzan, H. (2023). Optimizing Route Planning with GIS: A Comprehensive Approach for GIS Engineers. Medium [available at: <https://medium.com/@hadiaramzan.2199/optimizing-route-planning-with-gis-a-comprehensive-approach-for-gis-engineers-f12d94dd7a16>, access June 8, 2024]
20. Singh, S. & Behera, S. N. (2018). Development of GIS-Based Optimization Method for Selection of Transportation Routes in Municipal Solid Waste Management. *Advances in Waste Management*, pp. 319–331.
21. Sureshkumar, M., Supraja, S. & Bhavani Sowmya, R. (2017). GIS Based Route Optimization for Effective Traffic Management. *International Journal of Engineering Research And Management*, 4(3), pp. 62-65.



9. METODE VIZUALIZACIJE PODATKOV

Avtor: Dario Šebalj

V današnjem svetu, ki temelji na podatkih, je za organizacije, ki želijo učinkovito uporabljati svoje podatke, nujna sposobnost učinkovitega pretvarjanja zapletenih podatkovnih nizov v jasne in intuitivne vizualizacije. Vizualizacija podatkov presega zgolj estetski prikaz; je temeljna sestavina poslovnega obveščanja, ki odločevalcem pomaga prepoznati trende, odstopanja in vzorce, skrite v neobdelanih podatkih. V tem poglavju so predstavljene različne vrste vizualizacij, od preprostih grafov, kot so stolpčni in vrstični, do bolj zapletenih grafičnih predstavitev, kot so toplotni zemljevidi in točkovni grafi. Vsaka vrsta vizualizacije služi različnim namenom in je primerna za različne nabore podatkov, zato je za podatkovne analitike ključnega pomena, da izberejo ustrezno vizualizacijo za učinkovito posredovanje predvidenega sporočila.

Vizualizacija podatkov je postopek preoblikovanja informacij v vizualni kontekst, kot sta zemljevid ali graf, in se uporablja za lažje razumevanje in sklepanje na podlagi podatkov v človeškem umu. Glavni cilj vizualizacije podatkov je olajšati prepoznavanje vzorcev, trendov in odstopanj v velikih podatkovnih nizih. Pogoste vrste vizualizacije podatkov vključujejo grafe, tabele, zemljevide in nadzorne plošče (Brush, 2022; GeeksForGeeks, 2024).

Zaradi vse večje priljubljenosti projektov analize velikih količin podatkov in podatkov je vizualizacija zdaj pomembnejša kot kdaj koli prej. Podjetja vse pogosteje uporabljajo strojno učenje za zbiranje velikih količin podatkov, ki jih je težko in počasi obdelati, razumeti in razložiti. To je mogoče pospešiti s pomočjo vizualizacije, ki omogoča tudi lažje razumevanje informacij za deležnike in lastnike podjetij (Brush, 2022).

Pred izbiro metode vizualizacije je pomembno razumeti kontekst vizualizacije.

9.1. Razumevanje okoliščin

Nussbaumer Knaflič (2015) navaja, da je razumevanje in kontekstualizacija prvi in najpomembnejši korak pred začetkom uporabe tehnik vizualizacije podatkov in metod pripovedovanja zgodb. Ključni vidik konteksta je razumevanje občinstva. Nussbaumer Knaflič



poudarja, da je pomembno vedeti, kdo je občinstvo, kakšna je njegova raven strokovnega znanja in kaj je pomembno za. To razumevanje zagotavlja, da sta vizualizacija podatkov in pripovedovanje zgodb prilagojena potrebam in željam občinstva, zaradi česar so informacije ustreznejše in bolj zanimive.

Po podatkih IBM (n.d.) splošne informacije o ozadju pomagajo občinstvu razumeti pomen določene podatkovne točke. Če je na primer stopnja odprtosti elektronske pošte podjetja podpovprečna, moramo prikazati, kakšna je stopnja odprtosti v primerjavi s celotno panogo, da bi ponazorili, da ima podjetje s tem tržnim kanalom težave. Občinstvo mora razumeti, kako se trenutna uspešnost primerja z določenim ciljem, referenčno vrednostjo ali drugimi ključnimi kazalniki uspešnosti (KPI), da bi bilo motivirano za ukrepanje.

Odgovoriti je treba na tri pomembna vprašanja (Nussbaumer Knaflc, 2015; IBM, n.d.):

- **Kdo:** Pri tem je treba opredeliti občinstvo in razumeti njegovo perspektivo, da bi vedeli, kako naj bo zgodba prilagojena. To zagotavlja, da je vizualizacija namenjena neposredno ciljnemu občinstvu, zaradi česar je učinkovitejša in bolj privlačna. Medtem ko na primer četrtletno letno poročilo morda zahteva le povzetek podatkov na visoki ravni, lahko finančni analitik potrebuje podrobno analizo trendov za več let. Odločitev o zapletenosti, stopnji podrobnosti in vpogledih, ki jih je treba poudariti, je odvisna od tega, kdo si bo vizualizacijo ogledal.
- **Kaj:** To se nanaša na ključno sporočilo ali spoznanje, ki ga je treba posredovati občinstvu. Pri tem je treba jasno opredeliti dejanje ali odločitev, na katero naj bi vizualizacija podatkov vplivala. Kontekst opredeljuje namen vizualizacije. Ali gre za prepričevanje, informiranje, raziskovanje ali potrjevanje? Vsak namen lahko privede do različnih odločitev o vrsti vizualizacije in poudarjenih podatkovnih točkah. Na primer, prepričljiva vizualizacija, namenjena pridobivanju podpore za novo pobudo, se lahko osredotoči na drugačne podatke kot vizualizacija, namenjena zgolj obveščanju o pretekli uspešnosti.
- **Kako:** Gre za izbiro najprimernejšega in najučinkovitejšega načina sporočanja zgodbe ali spoznanja, pri čemer je treba upoštevati medij, format in tehnike vizualizacije, ki bodo najbolj odmevali pri ciljnem občinstvu. Določene vrste podatkovnih nizov zahtevajo tudi posebno vizualizacijo. Diagrami razpršitve so na primer dobri za prikaz razmerja med dvema spremenljivkama, linijski grafi pa so dober način za prikaz podatkov v časovnih vrstah. Vizualizacija mora občinstvu pomagati razumeti glavno



sporočilo. Nepravilna razporeditev grafov in podatkov ima lahko nasproten učinek in občinstvo prej zmede kot razsvetli.

Pri vizualizaciji in analizi podatkov razlikujemo med raziskovalno in pojasnjevalno vizualizacijo. Raziskovalna vizualizacija motivira uporabnika, da podrobneje razišče podatke ali temo in tako pride do lastnih odkritij. Razlagalna vizualizacija postavi rezultate v ospredje in bralcu posreduje avtorjevo hipotezo ali argument (Schwabish, 2021).

Po tem, ko smo raziskali pomen razumevanja konteksta, v katerem se uporabljajo vizualizacije podatkov, je jasno, da to temeljno znanje določa način, kako občinstvo najbolje sporoča in dojema informacije.

Naslednji ključni korak je učinkovito vključevanje občinstva. V naslednjem podpoglavju so opisane strategije za pritegnitev in ohranjanje zanimanja gledalcev. To vključuje izbiro elementov, ki povečujejo vizualno privlačnost in berljivost vizualizacije podatkov ter zagotavljajo, da ključna spoznanja ne ostanejo neopažena. Z uporabo tehnik, ki pritegnejo pogled gledalca in poudarijo pomembne podatke, so lahko vizualizacije več kot le informativne - lahko so privlačne in prepričljive.

9.2. Metode za pritegnitev pozornosti

Pri oblikovanju vizualizacij podatkov je zelo pomembno, da pritegnete in usmerite pozornost občinstva. Od medsebojnega vpliva mehanike vida in načel vizualnega zaznavanja je odvisno, kako učinkovito bo vizualizacija prenesla predvideno sporočilo. Razumevanje, kako človeško oko zaznava vizualne elemente, je prvi korak pri ustvarjanju prepričljivih vizualizacij.



Približno 70 % čutnih receptorjev v našem telesu je namenjenih vidu (Few, 2012).

Oko je predelavno pritegnjeno k določenim vidnim značilnostim, kar pomeni, da te značilnosti vizualni sistem hitro in samodejno obdela brez zavestnega napora. Značilnosti, kot so barva, velikost, oblika in usmerjenost, lahko uporabimo za poudarjanje ključnih podatkovnih točk ali področij v prikazu ter za takojšnje usmerjanje gledalčeve pozornosti.

Po besedah Schwabisha (2021) **teorija gestalta** opisuje, kako ljudje običajno združujejo vizualne elemente. Beseda *Gestalt* pomeni *vzorec* (Cairo, 2013). Razvili so jo nemški psihologi



v začetku 20. stoletja. Pri ustvarjanju diagramov in drugih vizualizacij je šest načel teorije Gestalt še posebej koristnih.


Načelo **bližine** pravi, da naše zaznavanje združuje predmete, ki so si blizu (npr. Slika 9.1).



Slika 91 Bližina kot načelo teorije Gestalt

Vir: Schwabish (2021).


Načelo **podobnosti** pravi, da človeški možgani razvrščajo predmete na podlagi njihovih skupnih lastnosti, kot so barva, oblika ali smer (npr. Slika 9.2).



Slika 92 Podobnost kot načelo teorije Gestalt

Vir: Schwabish (2021).

V skladu z načelom **zaprтости** zaznavamo omejene predmete kot skupino (npr. Slika 9.3).



Slika 93 Zaprтost kot načelo teorije Gestalt

Vir: Schwabish (2021).

V skladu z načelom zaprtosti naši možgani ne upoštevajo vrzeli in zapolnijo manjkajoče informacije, da bi oblikovali popolno strukturo. Ko analiziramo vrstični diagram, ki vsebuje


manjkajoče podatke, običajno miselno zapolnimo vrzeli z uporabo najpreprostejšega pristopa (npr. slika 9.4).



Slika 94Zaprte kot načelo teorije Gestalt

Vir: Schwabish (2021).


Načelo **kontinuitete** kaže, da gledalec elemente, ki so poravnani v ravni črti ali gladki krivulji, dojema kot bolj povezane kot elemente, ki ne ležijo na črti ali krivulji (npr. slika 9.5).



Slika 95Kontinuiteta kot načelo teorije Gestalt

Vir: Schwabish (2021).

Na podlagi načela **povezanosti** naše zaznavanje razvršča predmete, ki so med seboj povezani, v isto skupino (npr. Slika 9.6).



Slika 96Povezanost kot načelo teorije Gestalt

Vir: Schwabish (2021).

Pri vizualizaciji podatkov ima pomembno vlogo koncept, ki izhaja iz teorije Gestalt, in sicer tako imenovana predpozorna obdelava (angl. preattentive processing). Schwabish (2021) pojasnjuje, da predpozorne značilnosti pritegnejo našo pozornost na določen del grafa ali slike.



Gre za vidne značilnosti, ki jih človeški vid zazna v zgodnjih fazah vizualne obdelave brez zavestnega osredotočanja, zaznavanje pa običajno poteka v nekaj milisekundah. Med predpozorne značilnosti, uporabljene v tej knjigi, sodita barva (modra) in teža pisave (krepko besedilo).

Zelo znan primer take zaznave je iskanje določene številke v matriki števil (npr. Wexler idr., 2017). Slika 9.7 prikazuje matriko števil brez (levo) in z (desno) predpomenskimi atributi.


2	2	5	6	7	1	1	6	9	1
9	1	7	5	5	5	6	2	5	9
4	5	2	9	6	9	7	6	4	6
8	1	5	7	8	5	6	6	6	7
7	2	3	6	8	9	1	7	9	1
3	8	6	8	4	5	6	9	4	5
4	9	9	2	3	7	1	9	1	2
3	7	8	1	6	1	5	6	1	6
5	6	6	8	6	6	9	1	2	6
3	2	4	2	6	9	4	2	7	1

2	2	5	6	7	1	1	6	9	1
9	1	7	5	5	5	6	2	5	9
4	5	2	9	6	9	7	6	4	6
8	1	5	7	8	5	6	6	6	7
7	2	3	6	8	9	1	7	9	1
3	8	6	8	4	5	6	9	4	5
4	9	9	2	3	7	1	9	1	2
3	7	8	1	6	1	5	6	1	6
5	6	6	8	6	6	9	1	2	6
3	2	4	2	6	9	4	2	7	1

Slika 9.7 Uporaba predpomenskih atributov pri vizualizaciji podatkov

Vir: Wexler et al. (2017).

Iz leve matrike lahko dolgo časa ugibate, koliko števk devet je v njej. Toda že ena sama sprememba v matriki pomeni veliko razliko. Spremenila se je le barva – številke devet so rdeče, vse druge številke pa svetlo sive. Barva (v tem primeru odtenek) je eden od več predpomenskih atributov. Na sliki 9.8 so prikazani primeri nekaterih predznačnih atributov, ki se pogosto uporabljajo pri vizualizaciji podatkov.



Slika 98 Vrste predpomenskih atributov, ki se uporabljajo pri vizualizaciji podatkov

Vir: Wexler et al. (2017).

Pretenciozne lastnosti gledalcem omogočajo skoraj takojšnje prepoznavanje vzorcev, odstopanj ali pomembnih podatkovnih točk. Z uporabo strategij, ki usmerjajo pogled gledalca na najpomembnejše informacije, lahko vizualizacije podatkov bistveno izboljšajo komunikacijo in razumevanje zapletenih podatkovnih nizov.

V naslednjem podpoglavju bomo preučili, kako različne vrste podatkov in vpogledi, ki naj bi jih zagotavljali, vplivajo na izbiro metod vizualizacije. Od preprostih stolpčnih diagramov do bolj zapletenih toplotnih zemljevidov ali grafikonov s kroglicami je izbira prave metode vizualizacije bistvenega pomena pri zagotavljanju, da podatki ne le pritegnejo pozornost, temveč tudi učinkovito in natančno posredujejo predvideno sporočilo.

9.3. Izbira prave metode vizualizacije

Prvi korak pri izbiri ustrezne metode je temeljito poznavanje podatkov. Katera so ključna sporočila, ki jih želimo posredovati? S katero vrsto podatkov imamo opravka? Ali delamo s podatki časovnih vrst, geografskimi informacijami ali hierarhičnimi strukturami? Vrsta uporabljenih podatkov lahko pomembno vpliva na izbrano metodo vizualizacije. Choropleth zemljevidi so na primer najprimernejši za prikazovanje geografskih podatkov, medtem ko so vrstični diagrami morda primernejši za podatke o časovnih vrstah.

Pri izbiri metode vizualizacije imajo pomembno vlogo tudi ozadje in pričakovanja občinstva. Tehnično občinstvo lahko ceni podrobne in zapletene vizualizacije, kot so toplotni zemljevidi



ali mrežni diagrami. Po drugi strani pa se splošnemu občinstvu zdijo preprostejši diagrami, kot so črtni ali linijski, bolj dostopni in privlačni.

Interaktivnost je še en pomemben vidik, ki ga je treba upoštevati. Interaktivni vizualni elementi, kot so dinamične nadzorne plošče, uporabnikom omogočajo, da raziskujejo različne ravni podatkov s filtriranjem, povečevanjem in izbiranjem določenih elementov. Ta interaktivnost lahko privede do globljih vpogledov, saj lahko uporabniki vizualizacijo prilagodijo svojim specifičnim vprašanjem.

Metoda vizualizacije ni vedno nujno grafikon. Lahko je tudi tabela ali celo preprosto besedilo. Kot navaja Few (2012), je namen tabel in grafov učinkovito posredovati pomembne informacije in bralcu zagotoviti pomembne, smiselne in uporabne vpoglede.

V naslednjih nekaj podpoglavjih bodo na kratko pojasnjene najbolj priljubljene metode vizualizacije.

9.3.1. Preprosto besedilo

Nussbaumer Knaflič (2015) predlaga uporabo preprostega besedila, kadar je treba deliti le eno ali dve številki (slika 9.9).

23%
sales growth compared
to 2022

Slika 99 Enostavno besedilo v vizualizaciji

Vir: Avtor.

Po Schwabishu (2021) se to preprosto besedilo pogosto imenuje BAN (Big Ass Numbers). Običajno se uporabljajo za opozarjanje na ključne metrike ali kazalnike uspešnosti in gledalcu omogočajo takojšen dostop do pomembnih informacij. S poudarjanjem področij, ki zahtevajo pozornost ali ukrepanje, BAN običajno pomagajo pri sprejemanju odločitev, saj uporabnikom pomagajo usmeriti pozornost na pomembne vidike podatkov (Tay, 2024). Čeprav so BAN preprosti, jih je mogoče izboljšati s subtilnimi vizualnimi elementi, kot so barvne oznake ali ikone, ki označujejo uspešnost glede na cilje ali spremembe skozi čas. Na primer, rdeča puščica navzdol ob prodajni številki lahko takoj nakazuje upad, medtem ko zelena puščica navzgor signalizira rast.



9.3.2. Tabela


Tabele so bistven del vizualizacije podatkov, saj omogočajo strukturiran in jasen način predstavitve številčnih podatkov. Tabele so izjemno uporabne za natančno in jasno predstavitev podrobnih informacij, čeprav morda nimajo enakega vizualnega učinka kot grafiki ali zemljevidi. Po Schwabishu (2020) v večini primerov niso namenjene hitri vizualni predstavitvi podatkov. Namesto tega so tabele uporabne, kadar je treba prikazati natančne vrednosti podatkov ali ocene. Čeprav niso idealna možnost za predstavitev velike količine podatkov ali na majhnem prostoru, lahko dobro oblikovana tabela bralcu pomaga najti določene številke ter opaziti trende in odstopanja. Few (2012) ugotavlja, da so tabele uporabne za sklicevanje in primerjave ena na ena zaradi svoje preproste strukture in dejstva, da so kvantitativne vrednosti izražene kot besedilo, ki ga lahko takoj razumemo, ne da bi ga morali prevajati.

Tabele morajo biti oblikovane na naslednji način (Schwabish, 2020; Nussbaumer Knaflic, 2015):

- odstranite vse robove okoli mize
- čim bolj ublažite mrežne črte ali jih popolnoma odstranite.
- jasno ločite glavo od jedra tabele.
- besedilo v tabeli in glavi poravnajte na levo, številke pa na desno.
- uporabite ustrezno raven podrobnosti podatkov (npr. uporabite številke z enim decimalnim mestom, če to zadostuje za razumevanje podatkov).

9.3.3. Stolpčni diagram

Stolpčni diagram je idealen za prikaz številčnih vrednosti po skupinah ali kategorijah (npr. če želimo prikazati število zaposlenih po oddelkih). Lahko je poravnan navpično ali vodoravno. Vodoravna poravnava (kot na sliki 9.10) je priporočljiva, če so imena kategorij predolga ali če je kategorij preveč. Stolpčni diagram na sliki 9.10. prikazuje prodajo (kvantitativni podatki) po regijah (kvalitativni podatki).




Slika 910 Stolpčni diagram v vizualizaciji

Vir: Wexler et al. (2017).

Po mnenju Fewa (2013) je najučinkovitejši način za predstavitev ukrepov, povezanih z diskretnimi postavkami na nominalni ali ordinalni lestvici, stolpčni diagram. Posamezne vrednosti je enostavno primerjati tako, da preprosto primerjamo višino stolpcev. Os stolpčnega diagrama se mora začeti pri ničli. Če se os začne pri vrednosti, ki je drugačna od nič, lahko to preveč poudari razliko med vrsticami in izkrivlja naše dožemanje vrednosti v stolpčnem diagramu, ki temelji na dolžini vrstic (Schwabish, 2021).

9.3.4. Črtni diagram

Črtni diagram se uporablja za prikaz spremembe kvantitativne vrednosti, ki leži na osi y, v času, ki se nahaja na vodoravni osi x. Yi (n.d.) predlaga, da linijski graf ne sme vsebovati več kot pet vrstic. Prav tako ni treba vključiti ničelne izhodiščne črte za črtni graf. Sprejemljivo je razširiti območje navpične osi do točke, kjer so spremembe vrednosti najbolj informativne, če ničelna črta ni niti razumljiva niti koristna.




Slika 911 Črtni diagram v vizualizaciji

Vir: Wexler et al. (2017).

Črtni diagram na sliki 9.11 prikazuje prodajo (kvantitativne podatke) v obdobju štirih let in je razčlenjen tudi po segmentih.

Ploskovni diagram (slika 9.12), ki je različica linijskega diagrama, dodaja senco med linijo in ničelno osnovno črto (Yi, n.d.a.)



Slika 912 Območni diagram v vizualizaciji

Vir: Yi (n.d.)

Območni diagram lahko razumemo kot križanec med črtnim in stolpčnim diagramom, saj vrednosti ni mogoče razlagati le po njihovem navpičnem položaju, temveč tudi po območju, ki je osenčeno med vsako točko in osnovno črto (Yi, n.d.).

9.3.5. Diagram razpršitve

Diagram razpršitve se uporablja, kadar želimo ugotoviti, ali obstaja povezava med dvema kvantitativnima spremenljivkama. Po podatkih The Data Visualisation Catalogue (n.d.) lahko



vzorci, ki jih vidimo na razpršeni ploskvi, uporabimo za razlago narave korelacije. Ti so: pozitivni (vrednosti se skupaj povečujejo), negativni (ena vrednost se zmanjšuje, medtem ko se druga povečuje) ali ničelni (ni korelacije).



Slika 913Razpršeni diagram v vizualizaciji


Vir: Wexler et al. (2017).

Razpršeni diagram na sliki 9.13 prikazuje razmerje med dobičkom in prodajo (obe kvantitativni spremenljivki).

Po Yi (n.d.) je zelo pomembno omeniti, da v diagramu razpršitve samo zato, ker vidimo povezavo med dvema spremenljivkama, še ne pomeni, da spremembe ene spremenljivke povzročijo spremembe druge. Iz tega izhaja v statistiki pogosto uporabljena fraza: "korelacija ne pomeni vzročne zveze".

9.3.6. Choropleth zemljevid

Choropleth zemljevid uporablja razlike v senčenju ali barvi znotraj vnaprej določenih območij za označevanje vrednosti ali kategorij na teh območjih (Wexler et al., 2017). Po besedah Schwabisha (2021) je barvno paleto na horopletni karti enostavno razumeti, manjše vrednosti ustrezajo svetlejšim barvam, večje vrednosti pa temnejšim barvam.



Slika 914Choropleth zemljevid v vizualizaciji

Vir: Wexler et al. (2017).

Choropleth zemljevid na sliki 9.14 prikazuje vsoto prodaje v različnih zveznih državah v ZDA.

9.3.7. Toplotni zemljevid

Toplotna karta je vizualizacija podatkov v obliki tabele, kjer barvne celice predstavljajo relativno velikost števil (Nussbaumer Knaflic, 2015).

Ker je barva ključni element te vrste grafikona, morate poskrbeti, da se izbrana barvna paleta ujema s podatki. Najpogostejša vrsta barve je zaporedna barva, kjer temnejše barve korelirajo z višjimi vrednostmi, svetlejše barve pa z nižjimi vrednostmi ali obratno (Yi, b.d.b).

	Regija A	Regija B	Regija C
Kategorija 1			
Kategorija 2			
Kategorija 3			
Kategorija 4			
Kategorija 5			

Slika 915Vizualizacija toplotne karte

Vir: Avtor, prirejeno po Nussbaumer Knaflic (2015).


Toplotni zemljevid na sliki 9.15 prikazuje različne vrednosti nekaterih kvantitativnih podatkov (npr. prodaje) po kategorijah (v vrsticah) in regijah (v stolpcih).

9.3.8. Kazalni stolpčni grafikon

Kazalni stolpčni grafikon je leta 2005 izumil Stephen Few (Few, 2013). V bistvu gre za stolpčni graf z eno samo črno vodoravno črto, ki predstavlja dejansko vrednost, dodatno (navpično)



oznako za ciljno vrednost (ki jo želimo doseči) in osenčenimi območji v ozadju, ki predstavljajo lestvico uspešnosti (npr. slabo, dobro, odlično).



Slika 916Kazalni stolpčni grafikon

Vir: Schwabish (2021).

Graf na sliki 9.16 kaže, da želimo doseči oceno zadovoljstva strank 3,4 (od 5). Naša trenutna ocena zadovoljstva je 4, kar je nad ciljno vrednostjo. V ozadju so prikazana tri področja zadovoljstva strank - nizko (slabo), srednje (dobro) in visoko (odlično).

Izbira prave metode vizualizacije je zelo pomembna za učinkovito komuniciranje, vendar imajo načela oblikovanja, ki usmerjajo te tehnike, prav tako ključno vlogo pri jasnosti in učinkovitosti predstavitve podatkov. V naslednjem razdelku si bomo ogledali pomen postavitve, tipografije, barvnih shem in strateške uporabe prostora, ki so ključnega pomena za to, da vizualizacije niso le estetsko prijetne, temveč tudi enostavne za razumevanje in interpretacijo.

9.4. Smernice za dobro oblikovanje vizualizacije

Učinkovito oblikovanje vizualizacije je namenjeno izboljšanju gledalčeve zmožnosti razumevanja in interakcije s podatki. To vključuje skrbno ravnanje med estetskimi elementi in funkcionalnostjo, pri čemer imajo izbira barve, pisave in postavitve ključno vlogo pri jasnem in učinkovitem posredovanju informacij. Vodilo mora biti tudi preprostost. Vendar po mnenju Caira (2013) grafika ne sme poenostavljati sporočil. Morala bi jih pojasniti, poudariti trende, odkriti vzorce in razkriti resničnosti, ki prej niso bile vidne.

Pogosta past je pretirano zapletanje vizualne podobe s prevelikim številom elementov, ki prej zmedejo kot pojasnijo. Cilj je, da so podatki dostopni in razumljivi ciljnemu občinstvu ter da vizualizacija služi svojemu namenu, tj. obveščanju in podpori pri sprejemanju odločitev.




Jasnost in učinkovitost vizualizacije podatkov je mogoče izboljšati z odstranitvijo nepotrebnih motečih dejavnikov. Nussbaumer Knaflič (2015) poudarja, da se vsak element, ki ne dodaja vrednosti ali neposredno ne podpira razumevanja podatkov, šteje za **nered**. To vključuje nepotrebne mrežne črte, pretirane barve, nepomembne podatkovne točke in preveč zapletene okraske grafikonov. Ti elementi lahko odvrnejo pozornost od ključnih sporočil, ki naj bi jih posredovali podatki. Priporoča tehnike, kot so poenostavitev barvnih shem, zmanjšanje besedila in uporaba belega prostora. S strateško uporabo belega prostora lahko ustvarite vizualno hierarhijo, ki poudari ključne podatkovne točke ter naredi celotno predstavitev jasnejšo in lažje razumljivo. Poleg tega lahko učinkovita uporaba belega prostora pomaga ustvariti uravnoteženo postavitev, ki je manj natrpana in bolj organizirana.

Barva je zelo pomemben del vsake vizualizacije podatkov. Ne služi le za pritegnitev pozornosti, temveč tudi za organizacijo informacij in učinkovito posredovanje pomena. Ob pravilni uporabi lahko barva močno poveča jasnost in učinek vizualizacije. Obstaja več predlogov za učinkovito uporabo barv v vizualizacijah (Few, 2012; Cairo, 2013; Few, 2013; Nussbaumer Knaflič, 2015; Wexler et al, 2017; Schwabish, 2021; Lidwell, 2023; Interaction Design Foundation, n.d.):

- **Izberite ustrezno barvno kombinacijo:** s pomočjo barvnega kolesa lahko ustvarite vizualizacije, ki so vizualno uravnotežene in prijetne za oko. Obstaja več običajnih barvnih kombinacij (slika 9.17):
 - **Enobarvno** - ena barva v različnih odtenkih.
 - **Analogne** - tri barve, ki so druga ob drugi na barvnem kolesu. Te barve so prijetne za oko in ustvarjajo harmonično oblikovanje.
 - **Komplementarni** - dve nasprotni barvi na barvnem kolesu. Te barve so kontrastne in jih je treba uporabiti, da nekaj poudarimo (npr. povečanje - zelena/pomanjkanje - rdeča).
 - **Triadna** - tri enako oddaljene barve na barvnem kolesu. Te barve so dinamične in pritegnejo pozornost.


Poleg tega je treba za elemente v ospredju uporabljati toplejše barve, za elemente v ozadju pa hladnejše barve.



Slika 917 Barvne kombinacije

Vir: Avtor, prirejeno po Lidwell (2023).

- **Izberite ustrezne barvne sheme:** izbira barvne sheme je odvisna od vrste podatkov, ki jih je treba vizualizirati. **Zaporedna** barvna shema je uporaba ene barve od svetle do temne in je idealna za prikaz številčnih podatkov, ki napredujejo od nizke do visoke vrednosti (npr. prodaja po državah). **Divergentna** barvna shema je uporabna za poudarjanje vrednosti nad ali pod srednjo vrednostjo (npr. dobiček/izguba). **Kategorična** barvna shema je najboljša za kategorične podatke, pri katerih morajo barve razlikovati med različnimi skupinami, ne da bi nakazovale vrstni red ali vrednost (npr. kategorije izdelkov). Slika 9.18 prikazuje različne barvne sheme, ki se uporabljajo pri vizualizacijah.



Slika 918 Barvne sheme

Vir: Wexler et al. (2017).



- **Barve uporabljajte zmerno:** pretirana uporaba barv lahko povzroči zmedo in oteži razumevanje grafa. Barvno paleto je treba omejiti na tisto, ki jo človeško oko lahko hitro, torej na približno pet različnih barv.
- **Poglejmo barvno slepoto:** približno 8 % moških in 0,5% žensk je barvno slepih. Izogibajte se barvnim kombinacijam, ki jih barvno slepi uporabniki težko razlikujejo, kot sta rdeča in zelena. Namesto teh barv je primernejša kombinacija oranžne in modre barve.
- **Barve morajo biti dosledne:** dosledna uporaba barv v več vizualizacijah omogoča gledalcu lažje razumevanje in primerjavo podatkov. Ko je enkrat določena barvna shema za določene vrste ali kategorije podatkov, jo je treba ohraniti v vseh povezanih vizualizacijah.
- **Uporabite barvo za poudarjanje pomembnih podatkov:** barva je lahko močan kazalnik, kam je treba pogledati. S svetlo ali kontrastno barvo lahko opozorite na ključne podatkovne točke ali ugotovitve, medtem ko lahko bolj nevtralne barve uporabite za manj pomembne informacije. Nekateri avtorji predlagajo, da se ustvarjanje jasne in razumljive vizualizacije začne s sivo barvo. Vsi podatkovni elementi v grafikonu (npr. stolpci v stolpčnem grafikonu ali črte v vrstičnem grafikonu) naj bodo sive barve. Nato dodajte oznake in barvo samo za elemente, ki jih želite poudariti.
- **Naj bo preprosto:** na področju vizualizacije podatkov je zelo pomembno in koristno načelo KISS, kar je kratica za "Keep It Simple, Stupid". Nanaša se na uporabo preprostih diagramov, saj lahko zapleteni diagrami ali preveč podrobni vizualni prikazi preobremenijo uporabnike in otežijo prepoznavanje ključnih sporočil ali podatkovnih točk. Pomeni tudi, da se morate izogibati vizualnemu neredu in zmanjšati nepotrebne vizualne komponente, kot so preveč svetle barve, pisave in mrežne črte. Pri uporabi načela KISS se je treba osredotočiti na same podatke in ne na okrasne ali preveč zapletene elemente oblikovanja.

Ta načela so ključna za zagotavljanje, da vizualizacije podatkov dosežejo svoj glavni cilj, tj. sporočanje zapletenih informacij na način, ki je dostopen in razumljiv vsem občinstvom.

Iz tega poglavja je razvidno, da je učinkovita vizualizacija podatkov ključna sestavina v procesu odločanja na podlagi podatkov. Na podlagi razumevanja situacijskega konteksta je bilo v tem poglavju poudarjeno, kako pomembno je vizualizacije prilagoditi posebnim potrebam ciljnega občinstva. S podrobno preučitvijo različnih metod vizualizacije in načel oblikovanja se je



pokazalo, da je preiščena vizualna predstavitev podatkov pomembna za omogočanje boljšega razumevanja in sporočanja zapletenih informacij.

VIRI

1. Brush, K. (2022). Data visualization. TechTarget [available at: <https://www.techtarget.com/searchbusinessanalytics/definition/data-visualization>, access April 15, 2024]
2. Cairo, A. (2013). The functional art: An introduction to information graphics and visualization. New Riders.
3. Data Visualisation Catalogue (n.d.). Scatterplot [available at: <https://datavizcatalogue.com/methods/scatterplot.html>, access April 17, 2024]
4. Few, S. (2012). Show Me the Numbers. Analytics Press.
5. Few, S. (2013). Information dashboard design: Displaying data for at-a-glance monitoring. Analytics Press.
6. GeeksForGeeks (2024). What is Data Visualization and Why is It Important? [available at: <https://www.geeksforgeeks.org/data-visualization-and-its-importance/>, access April 15, 2024]
7. IBM (n.d.). What is data visualization? [available at: <https://www.ibm.com/topics/data-visualization>, access April 15, 2024]
8. Interaction Design Foundation (n.d.). Color Theory [available at: <https://www.interaction-design.org/literature/topics/color-theory>, access April 18, 2024]
9. Lidwell, W., Holden, K. & Butler, J. (2023). Universal Principles of Design, 3rd Edition. Quarto Publishing Group USA.
10. Nussbaumer Knaflic, C. (2015). Storytelling with data: A data visualization guide for business professionals. Wiley.
11. Schwabish (2020). Ten guidelines for better tables. Journal of Benefit-Cost Analysis, 11(2), pp. 151-178.



12. Schwabish (2021). Better data visualization: A guide for scholars, researchers and wonks. Columbia university press.
13. Tay, J. (2024). Effective use of BANs. Medium [available at: <https://medium.com/@e0373084/eye-catching-bans-88d29632e4fa>, access April 12, 2024]
14. Wexler, S., Shaffer, J. & Cotgreave, A. (2017). The big book of dashboards: Visualizing your data using real-world business scenarios. Wiley.
15. Yi, M. (n.d.a). A complete guide to line charts. Atlassian [available at: <https://www.atlassian.com/data/charts/line-chart-complete-guide>, access April 17, 2024]
16. Yi, M. (n.d.b). A complete guide to heatmaps. Atlassian [available at: <https://www.atlassian.com/data/charts/heatmap-complete-guide>, access April 17, 2024]



10. PODATKOVNA ETIKA IN INFORMACIJSKA VARNOST

Avtor: Dario Šebalj

V dobi digitalne preobrazbe sta etično ravnanje s podatki in njihova varnost postali glavni vprašanji za posameznike in organizacije. Ker se dnevno zbirajo in obdelujejo velike količine osebnih in občutljivih podatkov, je zelo pomembno zagotoviti odgovorno in varno upravljanje teh podatkov.

To poglavje obravnava načela etike ravnanja s podatki, poudarja moralne vidike in najboljše prakse ravnanja s podatki ter raziskuje različne grožnje informacijski varnosti. Z razumevanjem in obravnavanjem teh vprašanj lahko zaščitimo zasebnost, ohranimo zaupanje in spodbujamo varnejše digitalno okolje.

10.1. Pomen podatkovne etike

Podatkovna etika se nanaša na moralna načela in prakse, ki usmerjajo zbiranje, obdelavo, souporabo in uporabo podatkov, da bi zagotovili spoštovanje pravic posameznikov, družbeno blaginjo in zaupanje. Vključuje preglednost, odgovornost, poštenost in zasebnost ter zagotavlja, da so podatkovne prakse usklajene z etičnimi standardi in pravnimi okviri za preprečevanje škode in spodbujanje odgovornih inovacij (Cognizant, n.d.; Gov.uk, 2020; Knight, 2021; McKinsey, 2022; Cepelak, 2023)

V današnjem digitalnem okolju je etično ravnanje s podatki ključnega pomena za ohranjanje zaupanja in zagotavljanje konkurenčne prednosti. Članek McKinsey (2022) o etiki ravnanja s podatki poudarja pomen vključevanja etičnih vidikov v prakse ravnanja s podatki. Opozarja na tri pogoste napake: predpostavljjanje, da je podatkovna etika nepomembna, zanašanje izključno na pravne ekipe in ekipe za skladnost pri nadzoru ter dajanje prednosti kratkoročnim finančnim dobičkom pred etičnimi praksami. Za reševanje teh vprašanj priporočajo več strategij. Prvič, podjetja bi morala določiti jasne, za podjetje specifične smernice za podatkovno etiko. Te smernice služijo kot osnova za etično upravljanje podatkov in pomagajo pri določanju standardov v celotni organizaciji. Drugič, oblikovanje različnih skupin za obravnavo vprašanj, povezanih s podatki, zagotavlja različne poglede in zmanjšuje tveganje pristranskega



odločanja. Tretjič, vključevanje višjega vodstva kot zagovornikov pobud za etično ravnanje s podatki je ključnega pomena za uveljavljanje teh praks v celotni organizaciji.



Slika 1015C podatkovne etike

Vir: Avtor, prirejeno po Atlan (2023).

Slika 10.1 prikazuje 5C podatkovne etike, ki jo je opisal Atlan (2023) in predstavlja bistvena načela za etično ravnanje s podatki:

- **Soglasje (Consent):** Pred zbiranjem podatkov posameznikov pridobite njihovo prostovoljno soglasje, ki je osveščeno, in zagotovite preglednost uporabe podatkov.
- **Zbirka (Collection):** Zbiranje podatkov: zbirajte le podatke, ki so potrebni za določene namene, in se izogibajte pretiranemu zbiranju podatkov.
- **Nadzor (Control):** Omogočite posameznikom, da dostopajo do svojih podatkov, jih pregledujejo in posodablajo ter tako zagotavljajo nadzor nad njihovo uporabo.
- **Zaupnost (Confidentiality):** Zaščitite podatke pred nepooblaščenim dostopom in kršitvami z zanesljivimi varnostnimi ukrepi.
- **Skladnost s predpisi (Compliance):** Upoštevanje zakonskih in regulativnih zahtev ter izvajanje rednih revizij za zagotavljanje stalne skladnosti.

Podobno kot Atlanova načela tudi Cote (2021) opredeljuje pet ključnih načel podatkovne etike, ki jih morajo spoštovati poslovni strokovnjaki:

- **Lastništvo** poudarja, da posamezniki ohranijo lastništvo nad svojimi osebnimi podatki. Zbiranje osebnih podatkov brez izrecne privolitve je nezakonito in neetično. Podjetja morajo soglasje pridobiti z jasnimi sporazumi ali digitalnimi politikami zasebnosti, ki



zagotavljajo, da so uporabniki seznanjeni s praksami zbiranja podatkov in se z njimi strinjajo.

- **Preglednost** vključuje jasno obveščanje o načinu zbiranja, shranjevanja in uporabe podatkov. Podjetja morajo posameznike obvestiti o metodah in namenih zbiranja podatkov. Ta preglednost krepi zaupanje in uporabnikom omogoča, da se o svojih podatkih odločajo na podlagi informacij. Zavajajoče prakse ali prikrivanje informacij o uporabi podatkov so neetične in nezakonite.
- **Zasebnost** se osredotoča na odgovornost podjetij za zaščito zasebnosti osebnih podatkov. Osební podatki ne smejo biti javno dostopni brez izrecnega dovoljenja posameznika, tudi če je ta privolil. Podjetja morajo izvajati zanesljive varnostne ukrepe za zaščito osebnih podatkov pred nepooblaščenim dostopom ali kršitvami.
- **Namen** se nanaša na etične motive za zbiranje in uporabo podatkov. Podatke je treba zbirati in uporabljati za namene, ki so koristni in ne škodljivi za posameznike ali družbo. Etične podatkovne prakse vključujejo uporabo podatkov za izboljšanje uporabniške izkušnje in izboljšanje storitev brez izkoriščanja ali povzročanja škode.
- **Rezultat** obravnava širše vplive uporabe podatkov na posameznike in družbo. Podjetja morajo oceniti morebitne posledice svojih podatkovnih praks in si prizadevati, da bi se izognila negativnim posledicam. To načelo poudarja potrebo po etičnem predvidevanju in odgovornosti pri sprejemanju odločitev na podlagi podatkov.

Guzman in Dyer (2020) poudarjata, da etični izzivi pri podatkovnih praksah niso enostavni in pogosto nimajo jasnih rešitev. Navedla sta, da obstaja razhajanje med etičnimi pričakovanji na spletu in zunaj njega. Mnogi posamezniki zaznavajo obliko izjemnosti v spletnih prostorih, kjer se zdi, da tradicionalna etična pravila ne veljajo. Takšna miselnost lahko privede do upravičevanja dejanj na spletu, ki bi se brez povezave štela za neetična. Avtorji predlagajo etični pristop, ki povezuje obe področji, in poudarjajo, da morajo etična načela ostati dosledna ne glede na medij.

Članek o etiki podatkov, ki so ga objavili Basl in drugi (2021), obravnava zapleten proces prehoda od abstraktnih etičnih načel do konkretnih, izvedljivih obljub v kontekstu velikih količin podatkov in umetne inteligence. Ugotovili so, da je ta premik težaven in pomemben, da bi zagotovili, da etično ravnanje ne bo le teoretično, temveč tudi praktično in pomembno.

O'Reilly (2018) navaja, da sta Princetonski center za politiko informacijske tehnologije in Center za človekove vrednote pripravila štiri anonimne študije primerov, da bi spodbudila etični



diskurz. Ena od študij primera obravnava etične dileme, ki jih povzroča avtomatizirana zdravstvena aplikacija, zasnovana za pomoč bolnikom s sladkorno boleznijo odraslih z uporabo umetne inteligence. Poudarja potrebo po uravnoteženju tehnoloških koristi z etičnimi načeli, kot so avtonomija, pravičnost in odgovornost. Obravnava teh etičnih izzivov je ključna za odgovorno vključevanje umetne inteligence v zdravstveno varstvo, saj zagotavlja, da ta služi najboljšim interesom vseh bolnikov. Obravnavati je treba nekaj ključnih vprašanj:

- **Paternalizem:** Namen aplikacije je spodbujati zdravo vedenje bolnikov s tem, da jih spodbuja k boljšim odločitvam. To lahko sicer izboljša zdravstvene rezultate, vendar pa sproža etična vprašanja o avtonomiji in paternalizmu. Ali je etično, da aplikacija vpliva na vedenje bolnikov, ali pa bi morali biti bolniki popolnoma samostojni pri svojih zdravstvenih odločitvah?
- **Soglasje in preglednost:** Aplikacija za učinkovito delovanje zbira občutljive zdravstvene podatke. Ključnega pomena je zagotoviti informirano soglasje in preglednost glede zbiranja, uporabe in izmenjave podatkov. Pacienti morajo biti v celoti seznanjeni s tem, kateri podatki se zbirajo, kako se bodo uporabljali in kdo bo imel dostop do njih.
- **Zasebnost in varnost podatkov:** Ravnanje z občutljivimi zdravstvenimi podatki zahteva stroge ukrepe za zasebnost in varnost. Študija primera poudarja potrebo po zanesljivih protokolih za zaščito podatkov, da se podatki o bolnikih zavarujejo pred kršitvami in nepooblaščenim dostopom.
- **Odgovornost in odgovornost:** Določitev, kdo je odgovoren za odločitve in dejanja aplikacije, je še en ključni vidik. Če aplikacija poda napačno priporočilo, ki negativno vpliva na pacientovo zdravje, je določitev odgovorne osebe (razvijalci, ponudniki zdravstvenih storitev ali aplikacija sama) zapletena, vendar potrebna za odgovornost.

Sodobno upravljanje podatkov v osnovi temelji na podatkovni etiki, ki zagotavlja poštene, pregledne, odgovorne in zasebnost spoštuječe podatkovne prakse. Organizacije lahko z upoštevanjem etičnih standardov spodbujajo odgovorne inovacije, se izognejo pravnim pastem in povečajo zaupanje. Vključevanje močnih etičnih okvirov v prakse upravljanja podatkov ni le najboljša praksa, temveč tudi zahteva za trajnostno in odgovorno rast, saj podatki postajajo vse pomembnejši za delovanje in odločanje.

Drug pomemben vidik je informacijska varnost, saj sta etika podatkov in informacijska varnost neločljivo povezani. Zagotavljanje etičnega ravnanja s podatki je temelj za zanesljive ukrepe



informacijske varnosti. Zaščita podatkov pred nepooblaščenim dostopom, vdori in drugimi varnostnimi grožnjami ne le ohranja zasebnost in zaupnost, temveč tudi podpira etična načela, obravnavana v tem poglavju.

10.2. Osnove informacijske varnosti

Informacijska varnost pomeni celovit sklop praks in načel, katerih cilj je varovanje informacij in informacijskih sistemov pred nepooblaščenim dostopom, uporabo, razkritjem, motnjami, spreminjanjem ali uničenjem. Z izvajanjem zaščitnih ukrepov, politik in tehnologij zagotavlja zaupnost, celovitost in razpoložljivost podatkov. Ti ukrepi vključujejo nadzor dostopa, šifriranje, obnovitev po nesreči ter skladnost z zakonskimi in regulativnimi standardi za zmanjšanje tveganj in zaščito pred morebitnimi grožnjami (Fruhlinger, 2020; CISCO, n.d., NIST, n.d.).

Informacijska varnost je zdaj bistvenega pomena za verodostojnost in celovitost organizacije v digitalni dobi. Njena pomembnost se kaže v vse večji odvisnosti od digitalnih podatkov in naraščanju kibernetских groženj, ki ogrožajo občutljive podatke. Informacijska varnost predvsem varuje občutljive podatke pred nepooblaščenim dostopom, vdori in krajo. To vključuje osebne podatke, finančne podatke, intelektualno lastnino in zaupne poslovne komunikacije. Ker so kibernetски napadi vse bolj izpopolnjeni, se tveganje kršitev varnosti podatkov povečuje, kar lahko povzroči velike finančne izgube in škodo ugledu. V primeru kršitve Equifax leta 2017 so bili na primer izpostavljeni osebni podatki 147 milijonov ljudi, zaradi česar je bila sklenjena poravnava v višini do 425 milijonov dolarjev (Federal Trade Commission, 2022). Takšni incidenti opozarjajo na hude posledice neustreznih ukrepov za informacijsko varnost.

Poleg tega je varnost informacij ključnega pomena za ohranjanje zaupanja potrošnikov. V dobi, ko je zasebnost podatkov ključnega pomena, stranke vse bolj skrbijo, kako se ravna z njihovimi podatki. Močna arhitektura informacijske varnosti zagotavlja, da so podatki potrošnikov varni, kar spodbuja zvestobo in zaupanje. Glede na raziskavo podjetja IBM **75 %** strank ne bi kupovalo pri podjetju, ki mu ne zaupajo, da varuje njihove podatke (PR Newswire, 2018). Zato je informacijska varnost tako tehnološka potreba kot strateška poslovna nujnost.

Informacijska varnost je prav tako ključnega pomena za ublažitev motenj v delovanju. Kibernetски napadi, kot je izsiljevalska programska oprema, lahko motijo delovanje podjetja, saj uporabnikom onemogočijo dostop do pomembnih sistemov, dokler ne plačajo odkupnine.




Napad z izsiljevalsko programsko opremo 2021 Colonial Pipeline, ki je povzročil pomanjkanje goriva na vzhodu Združenih držav, je primer motečega potenciala takšnih groženj (Kerner, 2022). Z izvajanjem strogih varnostnih ukrepov lahko organizacije zavarujejo neprekinjeno delovanje in odpornost proti takšnim motnjam.

Kim in Solomon (2018) pravita, da se informacije štejejo za varne, če izpolnjujejo tri glavna načela:

- **Zaupnost (Confidentiality):** do občutljivih informacij lahko dostopajo le pooblaščen osebe.
- **Integriteta (Integrity):** informacije lahko spreminjajo le osebe z dovoljenjem.
- **Razpoložljivost (Availability):** informacije in viri so dostopni pooblaščenim uporabnikom, kadar koli jih potrebujejo.

Ta načela se pogosto imenujejo triada CIA, kot je prikazano na sliki 10.2.



Slika 10.2 CIA TRIADA

Vir: Avtor, prirejeno po Kim in Solomon (2018).

V informacijski varnosti so koncepti tveganja, grožnje in ranljivosti osrednjega pomena za razumevanje in upravljanje varnosti. **Tveganje** je verjetnost, da se bo sredstvu zgodilo nekaj slabega. Pri informacijski varnosti je tveganje verjetnost škodljivega dogodka, ki bo vplival na zaupnost, celovitost ali razpoložljivost informacij. Podjetje lahko na primer oceni tveganje kibernetkega napada na svoje omrežje tako, da upošteva verjetnost takega napada in morebitno škodo, ki bi jo lahko povzročil. Grožnja je vsako dejanje, ki lahko povzroči škodo informacijskim sistemom ali podatkom. **Grožnje** so lahko namerne, na primer kibernetki napadi hekerjev, ali nenamerne, na primer naravne nesreče ali človeške napake. **Ranljivost** se nanaša na slabosti ali vrzeli v obrambi sistema, ki jih lahko grožnje izkoristijo za povzročitev



škode. To so lahko pomanjkljivosti v programski in strojni opremi, organizacijskih procesih ali človeškem vedenju (Kim in Solomon, 2018).

Za učinkovito zaščito informacijskih sistemov morajo organizacije razumeti medsebojno delovanje tveganj, groženj in ranljivosti. Na primer, ranljivost v programski opremi (kot je varnostna pomanjkljivost) lahko izkoristi povzročitelj grožnje (kot je heker), kar privede do vdora v podatke, ki predstavlja tveganje za organizacijo. Z ugotavljanjem in zmanjševanjem ranljivosti lahko organizacije zmanjšajo tveganje, da bi grožnje povzročile veliko škodo.

10.2.1. Kršitve podatkov

V digitalni dobi so kršitve varnosti podatkov postale velika grožnja, ki je prizadela organizacije v različnih sektorjih. Te kršitve ogrožajo občutljive podatke, kar vodi do finančnih izgub, škode ugledu in pravnih posledic. Razumevanje obsega in vpliva kršitev varnosti podatkov je ključno za razvoj učinkovitih varnostnih strategij za zaščito pred takšnimi incidenti. Po podatkih podjetja Fortinet (n.d.) je **kršitev varnosti podatkov** "dogodek, zaradi katerega so zaupni, zasebni, zaščiteni ali občutljivi podatki izpostavljeni osebi, ki ni pooblaščen za dostop do njih". Te kršitve se lahko zgodijo na različne načine (Kaspersky, b.d.):

1. **Naključni insajder:** Zaposleni nenamerno dostopa do občutljivih informacij brez ustreznega dovoljenja. Na primer: uporabi računalnik sodelavca in si ogleda zaupne datoteke.
2. **Zlonamerni notranji uporabnik:** Posameznik s pooblaščenim dostopom namerno zlorabi podatke v škodljive namene. To lahko vključuje krajo ali uhajanje občutljivih informacij.
3. **Izgubljene ali ukradene naprave:** Nešifrirane in nezavarovane naprave, kot so prenosni računalniki ali zunanji diski z občutljivimi podatki, se izgubijo ali ukradejo, zaradi česar so podatki izpostavljeni nepooblaščenemu dostopu.
4. **Zlonamerni zunanji kriminalci:** Hakerji za vdor v sisteme uporabljajo različne metode, vključno z napadi z ribarjenjem, napadi z grobo silo in zlonamerno programsko opremo. Ti kibernetски kriminalci izkoriščajo ranljivosti v programski opremi, omrežjih in vedenju uporabnikov, da bi pridobili dostop do občutljivih podatkov.

Po podatkih družbe Kaspersky (n.d.) so pogoste metode, ki se uporabljajo pri kršitvah varnosti podatkov, **ribarjenje**, pri katerem se kibernetски kriminalci izdajajo za zaupanja vredne subjekte, da bi posameznike prepričali, da razkrijejo občutljive informacije. Druga metoda so **napadi z grobo silo**, pri katerih hekerji s pomočjo programske opreme večkrat ugibajo gesla



in izkoriščajo šibke ali večkrat uporabljene poverilnice za pridobitev nepooblaščenega dostopa do računov. Poleg tega se **zlonamerna programska oprema**, kot je vohunska programska oprema, uporablja za neopažen vdor v sisteme in krajo podatkov. Te metode bodo razložene v nadaljevanju poglavja.



Človeška napaka je vzrok za **95 %** vseh kršitev varnosti podatkov (Cybernews, 2022).

V 21. stoletju smo bili priča nekaterim najhujšim kršitvam varnosti podatkov, ki so opozorile na ranljivosti digitalnih sistemov in na nujno potrebo po zanesljivih varnostnih ukrepih. Po podatkih Hill in Swinhoe (2022) ter družbe ESET (n.d.) je nekaj najodmevnejših kršitev varnosti podatkov:

- **Yahoo (2013-2014):** Yahoo je doživel enega največjih vdorov v podatke v zgodovini, saj so bile leta 2013 ogrožene vse tri milijarde njegovih uporabniških računov. Ta kršitev je razkrila imena, e-poštne naslove, datume rojstva ter varnostna vprašanja in odgovore. Druga kršitev leta 2014 je prizadela 500 milijonov računov, kar je še dodatno opozorilo na varnostne ranljivosti podjetja.
- **Marriott International (2018):** Marriott je objavil kršitev, ki je prizadela približno 500 milijonov gostov. Hakerji so imeli dostop do podatkovne zbirke rezervacij gostov družbe Starwood, pri čemer so bili izpostavljeni osebni podatki, kot so imena, naslovi, telefonske številke, e-poštni naslovi in številke potnih listov. Ta kršitev je bila posledica nepooblaščenega dostopa iz leta 2014. Urad informacijskega pooblaščenca (ICO), britanski organ za nadzor podatkov, je leta 2020 korporaciji izrekel globo v višini 18,4 milijona funtov, ker ni zaščitila zasebnosti osebnih podatkov svojih strank.
- **Iskalnik prijateljev za odrasle (2016):** Pri kršitvi v storitvi Adult Friend Finder so bili razkriti osebni podatki 412 milijonov računov, vključno z imeni, e-poštnimi naslovi in gesli, od katerih so bili številni slabo šifrirani. Ta incident je sprožil veliko zaskrbljenost glede varnostnih praks spletnih platform, ki ravnaajo z občutljivimi osebnimi podatki.
- **MySpace (2013):** V primeru kršitve varnosti podatkov MySpace leta 2013 je bilo izpostavljenih več kot 360 milijonov uporabniških računov. Podatki so vključevali imena, e-poštne naslove in gesla. Hakerji so te podatke pozneje prodali na temnem spletu, kar



je opozorilo na ranljivosti varnostnih sistemov platform družbenih medijev v tistem času.

- **LinkedIn (2021):** Na temnem spletnem forumu so bili leta 2021 objavljeni osebni podatki 700 milijonov uporabnikov LinkedIna. Haker je s tehnikami strganja podatkov prek LinkedInovega vmesnika API pridobil e-poštne naslove, telefonske številke in druge osebne podatke. Čeprav ni šlo za tradicionalni vdor, je ta incident sprožil resno zaskrbljenost glede zasebnosti podatkov in morebitne zlorabe strganih podatkov za napade s socialnim inženiringom.
- **Equifax (2017):** Ta kršitev je razkrila osebne podatke skoraj 148 milijonov Američanov, 15,2 milijona Britancev in 19.000 Kanadčanov. Hakerji so izkoristili ranljivost v ogrodju spletnih aplikacij Apache Struts, ki je Equifax ni popravil. Ukradeni podatki so vključevali številke socialnega zavarovanja, rojstne datume in naslove, zaradi česar je družba Equifax utrpela za približno 1,7 milijarde dolarjev stroškov.
- **eBay (2014):** eBay je razkril kršitev, ki je prizadela 145 milijonov uporabnikov. Napad je izhajal iz kompromitiranih prijavnih podatkov zaposlenih, zaradi česar so bila razkrita imena, e-poštni naslovi, fizični naslovi, telefonske številke in šifrirana gesla. Ta kršitev je opozorila na ranljivosti pri nadzoru dostopa zaposlenih in na pomen močnih ukrepov avtentikacije.
- **Cilj (2013):** Vdor, ki je prizadel več kot 41 milijonov računov plačilnih kartic in kontaktne podatke več kot 60 milijonov strank. Kibernetski kriminalci so dostopali do podatkov strank, vključno z imeni, telefonskimi številkami, e-poštnimi naslovi, številkami kreditnih in debetnih kartic ter šifriranimi kodami PIN. Podjetje Target je imelo precejšnje pravne stroške in stroške poravnave, vključno s skupinsko tožbo v višini 10 milijonov USD in poravnavo v višini 18,5 milijona USD v več državah.

Te kršitve dokazujejo daljnosežne posledice kibernetskih napadov in ključno potrebo po močnih praksah kibernetske varnosti. Na podlagi teh odmevnih primerov lahko organizacije bolje zaščitijo svoje podatke, izboljšajo svoje varnostne protokole in zmanjšajo tveganje za prihodnje kršitve. Vdori v podatke so pogosto posledica številnih osnovnih groženj. Razumevanje teh groženj je ključnega pomena za oblikovanje uspešnih ukrepov za informacijsko varnost. Kibernetske grožnje se lahko pojavijo iz različnih virov, vključno z zlonamernimi notranjimi uporabniki, kibernetskimi kriminalci in celo akterji, ki jih sponzorira država. Poleg tega se lahko ranljivosti v sistemih in omrežjih izkoristijo za nepooblaščen dostop do občutljivih informacij.



10.2.2. Grožnje informacijske varnosti

Varnostna grožnja je zlonamerno dejanje, ki poskuša poškodovati ali ukrasti podatke, ogroziti sisteme organizacije ali ogroziti podjetje kot celoto (TechTarget, 2024). Obstaja veliko različnih informacijskih varnostnih groženj, ki resno ogrožajo razpoložljivost, celovitost in zaupnost podatkov.

Kim in Solomon (2018) ter Grubb (2021) pravita, da je **zlonamerna** programska oprema namenjena vdoru, poškodovanju ali onemogočanju računalnikov in omrežij. Pogoste vrste zlonamerne programske opreme vključujejo viruse, črve, trojanske konje, izsiljevalsko programsko opremo in vohunsko programsko opremo. **Virus** je vrsta zlonamerne programske opreme, ki se pritrdi na zakonit program ali datoteko in se ob izvajanju okužene programske opreme razširi na druge programe in datoteke. Virusi lahko poškodujejo ali izbrišejo podatke, motijo delovanje sistema in se razširijo na druge sisteme prek priponk elektronske pošte, omrežnih povezav ali izmenljivih medijev. V nasprotju z virusi so **črvi** samostojna zlonamerna programska oprema, ki se lahko samostojno razmnožuje in širi po omrežjih, ne da bi se ji bilo treba priključiti na gostiteljski program. Črvi za širjenje izkoriščajo ranljivosti v operacijskih sistemih ali aplikacijah, pri čemer pogosto povzročajo preobremenitev omrežja in preobremenitev sistemov, saj porabljajo pasovno širino in vire. **Trojanski konj** ali trojanski konj je zlonamerna programska oprema, prikrita kot zakonita programska oprema. Uporabniki so prevarani, da ga namestijo in verjamejo, da gre za neškodljiv ali uporaben program. **Ransomware** je vrsta zlonamerne programske opreme, ki zašifrira podatke žrtve in jih naredi nedostopne, dokler se napadalcu ne plača odkupnina. Napadi izsiljevalske programske opreme so lahko uničujoči, saj povzročijo veliko izgubo podatkov in motnje v delovanju, če odkupnina ni plačana ali če varnostne kopije niso na voljo. **Vohunska programska oprema** je zlonamerna programska oprema, namenjena zbiranju informacij o osebi ali organizaciji brez njene vednosti. Zbira lahko različne vrste podatkov, kot so pritiski tipk, navade brskanja in osebne informacije, ter jih posreduje tretji osebi.

Druga vrsta grožnje je **lažno ribarjenje**. Kosinski (2024) pojasnjuje, da phishing napadi vključujejo goljufiva e-poštna sporočila, besedila, klice ali spletna mesta, katerih namen je prevarati posameznike, da razkrijejo osebne podatke ali prenesejo zlonamerno programsko opremo. Ti napadi izkoriščajo človeške napake in zaupanje, zato so zelo učinkoviti. V boju proti ribarjenju morajo organizacije uporabljati napredna orodja za odkrivanje groženj in zagotoviti temeljito usposabljanje zaposlenih za učinkovito prepoznavanje in odzivanje na te prevare.



Glavni vzrok za kršitve varnosti podatkov je ribarjenje, ki predstavlja 16 % kršitev in organizacije v povprečju stane **4,76 milijona dolarjev** na kršitev (Kosinski, 2024).

Obstajajo štiri glavne vrste ribarjenja (Forbes, 2024):

- **Goljufanje po e-pošti:** uporaba e-pošte za krajo občutljivih podatkov. Napadalci lahko ciljajo na veliko občinstvo tako, da prevzamejo identiteto uglednih organizacij.
- **Izsiljevanje (Spear phishing):** pošiljanje posameznih e-poštnih sporočil, besedilnih sporočil ali telefonskih klicev z namenom pridobitve dostopa do računalniških sistemov ali občutljivih informacij. Pri uporabi te tehnike napadalci običajno uporabijo podatke iz odprtih podatkovnih zbirk, družabnih medijev ali preteklih kršitev, da okrepijo svojo legitimnost.
- **Kitolov:** osredotoča se na visoko rangirano ali vodilno osebje, vključno s finančniki in izvršnimi direktorji. Napadalci oblikujejo zelo prepričljiva in zelo prilagojena sporočila, da bi od podjetja pridobili občutljive podatke in informacije.
- **Vishing:** telefoniranje ali puščanje glasovne pošte pod pretvezo zanesljivega vira. Cilj je pridobiti bančne račune, izkoristiti osebne podatke in ukrasti denar.

Notranje grožnje so varnostna tveganja, ki izvirajo iz organizacije. To so lahko zaposleni, izvajalci ali poslovni partnerji, ki imajo dostop do sistemov in podatkov organizacije. Te grožnje so lahko še posebej nevarne, ker imajo notranji uporabniki pogosto zakonit dostop do občutljivih informacij in sistemov, zaradi česar je njihove zlonamerne dejavnosti težje odkriti (TechTarget, 2024).

Druga vrsta nevarnosti so napadi DDoS (**Distributed Denial-of-Service**). Njihov cilj je prekiniti normalen promet ciljnega strežnika, storitve ali omrežja tako, da ga preplavijo s poplavo internetnega prometa. To se doseže z uporabo več ogroženih računalniških sistemov kot virov napadalnega prometa. Ko te naprave, ki so pogosto razporejene po vsem svetu, hkrati pošljejo številne zahteve ciljnemu strežniku, porabijo njegovo razpoložljivo pasovno širino in vire, kar povzroči izpad storitev in prepreči dostop do storitve zakonitim uporabnikom (TechTarget, 2024).

Spletne varnostne grožnje so tesno povezane z dejanji hakerjev, ki izkoriščajo ranljivosti v sistemih za različne zlonamerne namene. Po besedah Grubba (2021) se hakerji pogosto razvrščajo glede na njihove namene in metode. Dve osnovni kategoriji sta hakerji belega



klobuka in hekerji črnega klobuka. **White hat hekerji**, znani tudi kot etični hekerji, uporabljajo svoje spretnosti v obrambne namene. Prizadevajo si za zaščito organizacij pred kibernetскими grožnjami tako, da prepoznajo in odpravijo varnostne ranljivosti, preden jih zlonamerni hekerji lahko izkoristijo. Nasprotno pa **hekerji črnega klobuka** izvajajo nezakonite dejavnosti z zlonamernimi nameni. Varnostne ranljivosti izkoriščajo za osebno korist, kar lahko vključuje krajo podatkov, širjenje zlonamerne programske opreme ali povzročanje motenj.

Ena od ključnih obrambnih ukrepov pred grožnjami informacijski varnosti je uporaba močnih gesel. Močna gesla, ki morajo biti kompleksna in edinstvena za vsak račun, bistveno zmanjšajo tveganje nepooblaščenega dostopa

V preglednici 10.1 je prikazan čas, ki ga heker potrebuje, da z grobo silo pridobi geslo, v skladu z raziskavo, ki jo je izvedla družba Hive Systems (2024).

Preglednica 10.1 Čas, ki ga heker potrebuje, da v letu 2024 z grobo silo pridobi geslo

Število znakov	Samo številke	Male črke	Velike in male črke	Številke, velike in male črke	Številke, velike in male črke, simboli
4	Takoj	Takoj	3 sekunde	6 sekund	9 sekund
5	Takoj	4 sekunde	2 minuti	6 minut	10 minut
6	Takoj	2 minuti	2 uri	6 ur	12 ur
7	4 sekunde	50 minut	4 dni	2 tedna	1 mesec
8	37 sekund	22 ur	8 mesecev	3 leta	7 let
9	6 min	3 tedne	33 let	161 let	479 let
10	1 ura	2 leti	1k let	9k let	33 tisoč let
11	10 ur	44 let	89k let	618k let	2 milijona let
12	4 dni	1k let	4 milijone let	38 milijonov let	164 milijonov let
13	1 mesec	29k let	241 milijonov let	2 milijardi let	11 milijard let
14	1 leto	766k let	12 milijard let	147 milijard let	805 milijard let
15	12 let	19 milijonov let	652 milijard let	9tn let	56tn let
16	119 let	517 milijonov let	33tn let	566tn let	3qd let
17	1k let	13 milijard let	1qd let	35qd let	276qd let
18	11k let	350 milijard let	91qd let	2qn let	19qn let

Vir: Avtor, prilagojeno po Hive Systems (2014).



Razumevanje različnih vrst groženj informacijski varnosti, kot so phishing napadi, zlonamerna programska oprema in napadi DDoS, kaže na ključno potrebo po zanesljivih ukrepih kibernetске varnosti. Te grožnje pomenijo veliko tveganje za osebne podatke, finančne informacije in organizacijsko celovitost. Zaradi tega je nujno sprejeti celovite varnostne strategije. V naslednjem podpoglavju so predstavljeni predlogi za vzdrževanje močne internetne varnosti, vključno s praktičnimi nasveti, ki jih lahko ljudje in institucije uporabijo za zaščito svojih digitalnih virov.

10.2.3. Priporočila za informacijsko varnost

Veliko število varnostnih tveganj, kot sta ribarjenje in zlonamerna programska oprema, je mogoče močno zmanjšati, če jih razumete in izvajate v praksi. Obstaja več najpomembnejših priporočil za zagotavljanje informacijske varnosti (Rubenking & Duffy, 2023; NSW Government, n.d.; Kaspersky, n.d.b):

- **Uporabljajte močna gesla:** za vsak račun ustvarite zapletena gesla, ki vsebujejo črke, številke in simbole. Izogibajte se uporabi podatkov, ki jih je mogoče zlahka uganiti, kot so rojstni dnevi. Za varno shranjevanje in upravljanje gesel uporabite upravitelja gesel.
- Če je mogoče, **omogočite večfaktorsko preverjanje pristnosti (MFA):** dodajte dodatno raven varnosti tako, da za dostop do računov zahtevate dva ali več načinov preverjanja, na primer geslo in enkratno kodo, poslano na vaš telefon.
- **Posodablajte programsko opremo:** redno posodablajte operacijske sisteme, brskalnike in aplikacije, da popravite varnostne ranljivosti. Če je mogoče, omogočite samodejne posodobitve, da boste vedno zaščiteni pred najnovejšimi grožnjami.
- **Bodite pozorni na goljufije:** ne klikajte na povezave in ne prenašajte priponk iz neznanih ali sumljivih e-poštnih sporočil. Preverite podatke pošiljatelja in poiščite znake ribarjenja, kot so na primer pravopisne napake ali nujne zahteve po osebnih podatkih.
- **Uporaba varnih povezav:** zagotovite varnost svoje internetne povezave z uporabo virtualnih zasebnih omrežij (VPN) in se izogibajte javnim omrežjem Wi-Fi za občutljive dejavnosti, kot je spletno bančništvo. Preverite, ali je v naslovu URL zapisano "https://", kar pomeni, da gre za varno povezavo.
- **Redno varnostno kopiranje podatkov:** redno varnostno kopirajte podatke na zunanje diske ali v storitve shranjevanja v oblaku. Ta praksa zagotavlja, da lahko



obnovite podatke v primeru okvare strojne opreme, kraje ali napada z izsiljevalsko programsko opremo.

- **Namestite protivirusno programsko opremo:** uporabite ugledno varnostno programsko opremo za odkrivanje, preprečevanje in odstranjevanje zlonamerne programske opreme. Protivirusno programsko opremo posodablajte in redno preverjajte, ali je vaš sistem čist.
- **Redno nadzorujte račune:** pogosto preverjajte svoje finančne in spletne račune za morebitne nepooblaščne dejavnosti. Nastavite opozorila za nenavadne transakcije in o vsakem sumljivem ravnanju takoj obvestite ponudnika storitev.

Z razumevanjem etičnih posledic ravnanja s podatki in prepoznavanjem obstoječih varnostnih groženj lahko posamezniki in organizacije razvijejo učinkovite strategije za zaščito občutljivih podatkov. Te prakse skupaj zagotavljajo celovitost, zaupnost in razpoložljivost podatkov, od vzpostavitve etičnih smernic in uporabe močnih, edinstvenih gesel do izvajanja naprednih varnostnih ukrepov in obveščanja o morebitnih grožnjah. Z dajanjem prednosti etiki ravnanja s podatki in zanesljivim varnostnim protokolom lahko ustvarimo varnejše in bolj zaupanja vredno digitalno okolje.

VIRI

1. Atlan (2023). Data Ethics Unveiled: Principles & Frameworks Explored [available at: <https://atlan.com/data-ethics-101/>, access May 17, 2024]
2. Basl, J., Sandler, R. & Tiell, S. (2021). Getting from commitment to content in AI and data ethics: Justice and explainability. Atlantic Council [available at: <https://www.atlanticcouncil.org/in-depth-research-reports/report/specifying-normative-content/>, access May 17, 2024]
3. Cepelak, C. (2023). What is Data Ethics? Datacamp [available at: <https://www.datacamp.com/blog/introduction-to-data-ethics>, access May 14, 2024]
4. CISCO (n.d.). What Is Information Security? [available at: <https://www.cisco.com/c/en/us/products/security/what-is-information-security-infosec.html>, access May 20, 2024]



5. Cognizant (n.d.). Data ethics [available at: <https://www.cognizant.com/us/en/glossary/data-ethics>, access May 14, 2024]
6. Cote (2021). 5 Principles of Data Ethics for Business. Harvard Business School Online [available at: <https://online.hbs.edu/blog/post/data-ethics>, access May 17, 2024]
7. Cybernews (2022). World Economic Forum finds that 95% of cybersecurity incidents occur due to human error [available at: <https://cybernews.com/editorial/world-economic-forum-finds-that-95-of-cybersecurity-incidents-occur-due-to-human-error/>, access May 21, 2024]
8. ESET (n.d.). 5 scary data breaches that shook the world [available at: <https://www.eset.com/in/about/newsroom/corporate-blog/corporate-blog/eset-5-scary-data-breaches-that-shook-the-world/>, access May 21, 2024]
9. Federal Trade Commission (2022). Equifax Data Breach Settlement [available at: <https://www.ftc.gov/enforcement/refunds/equifax-data-breach-settlement>, access May 20, 2024]
10. Forbes (2024). Cybersecurity Stats: Facts And Figures You Should Know [available at: <https://www.forbes.com/advisor/education/it-and-tech/cybersecurity-statistics/>, access May 24, 2024]
11. Fortinet (n.d.). What Is A Data Breach? [available at: <https://www.fortinet.com/resources/berglossary/data-breach>, access May 21, 2024]
12. Fruhlinger, J. (2020). What is information security? Definition, principles, and jobs. CSO [available at: <https://www.csoonline.com/article/568841/what-is-information-security-definition-principles-and-jobs.html>, access May 20, 2024]
13. Gov.uk (2020). Data Ethics Framework: glossary and methodology [available at: <https://www.gov.uk/government/publications/data-ethics-framework/data-ethics-framework-glossary-and-methodology>, access May 14, 2024]
14. Grubb, S. (2021). How Cybersecurity Really Works: A Hands-on Guide for Total Beginners. No starch press.
15. Guzman, L. & Dyer, S. (2020). Ten questions we're asking about ethics, data, and open source research. Amnesty International [available at:



- <https://citizenevidence.org/2020/11/10/ethics-data-open-source/>, access May 17, 2024]
16. Hill, M. & Swinhoe, D. (2022). The 15 biggest data breaches of the 21st century. CSO Online [available at: <https://www.csoonline.com/article/534628/the-biggest-data-breaches-of-the-21st-century.html>, access May 21, 2024]
 17. Hive Systems (2024). Are Your Passwords in the Green? [available at: https://www.hivesystems.com/blog/are-your-passwords-in-the-green?utm_source=tabletext, access May 24, 2024]
 18. Kaspersky (n.d.a). How Data Breaches Happen & How to Prevent Data Leaks [available at: <https://www.kaspersky.com/resource-center/definitions/data-breach>, access May 21, 2024]
 19. Kaspersky (n.d.b). Top 15 internet safety rules and what not to do online [available at: <https://www.kaspersky.com/resource-center/preemptive-safety/top-10-preemptive-safety-rules-and-what-not-to-do-online>, access May 25, 2024]
 20. Kerner, S. M. (2022). Colonial Pipeline hack explained: Everything you need to know. TechTarget [available at: <https://www.techtarget.com/whatis/feature/Colonial-Pipeline-hack-explained-Everything-you-need-to-know>, access May 20, 2024]
 21. Kim, D. & Solomon, M. G. (2018). Fundamentals of Information Systems Security, 3rd Edition. Jones & Bartlett Learning.
 22. Knight, M. (2021). What Is Data Ethics?. Dataversity [available at: <https://www.dataversity.net/what-are-data-ethics/>, access May 14, 2024]
 23. Kosinski, M. (2024). What is a phishing attack? IBM [available at: <https://www.ibm.com/topics/phishing>, access May 24, 2024]
 24. McKinsey (2022). Data ethics: What it means and what it takes [available at: <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/data-ethics-what-it-means-and-what-it-takes>, access May 14, 2024]
 25. National Institute of Standards and Technology (NIST) (n.d.). Information security [available at: https://csrc.nist.gov/glossary/term/information_security, access May 20, 2024]



26. NSW Government (n.d.). 10 Tips for Cyber Security [available at: <https://www.digital.nsw.gov.au/sites/default/files/2022-09/top-10-cyber-security-tips.pdf>, access May 25, 2024]
27. O'Reilly (2018). Case studies in data ethics [available at: <https://www.oreilly.com/content/case-studies-in-data-ethics/>, access May 17, 2024]
28. PR Newswire (2018). New Survey Finds Deep Consumer Anxiety over Data Privacy and Security [available at: <https://www.prnewswire.com/news-releases/new-survey-finds-deep-consumer-anxiety-over-data-privacy-and-security-300630067.html>, access May 20, 2024]
29. Rubenking, N. J. & Duffy, J. (2023). 12 Simple Things You Can Do to Be More Secure Online. PC mag [available at: <https://www.pcmag.com/how-to/12-simple-things-you-can-do-to-be-more-secure-online>, access May 25, 2024]
30. TechTarget (2024). Top 10 types of information security threats for IT teams [available at: <https://www.techtarget.com/searchsecurity/feature/Top-10-types-of-information-security-threats-for-IT-teams>, access May 24, 2024]



SEZNAM TABEL

Preglednica 1.1 Primeri kardinalnosti	12
Preglednica 5.1 Vrste dogodkov	60
Preglednica 5.2 Primer dnevnika dogodkov	66
Preglednica 7.1 Osnovne razlike med tradicionalno in e-logistiko	88
Preglednica 10.1 Čas, ki ga heker potrebuje, da v letu 2024 z grobo silo pridobi geslo.....	138

SEZNAM SLIK

Slika 1.1 Piramida DIKW (Data, Information, Knowledge, Wisdom).....	5
Slika 1.2 Glavne vrste podatkov	8
Slika 1.3 Podatkovna arhitektura kot temelj za uspešno BI.....	9
Slika 1.4 Primer tabele v RDBMS.....	10
Slika 1.5 Primeri odnosov med entitetami	11
Slika 1.6 Primer ERD prodajnega sistema	12
Slika 2.1 Razvoj logistike, SCM in BDA.....	22
Slika 2.2 Trendi, orodja in prednosti SCA.....	23
Slika 2.3 Razvoj logistike in SC	25
Slika 2.4 Povpraševanje po predhodno narezani salami v obdobju 2015-2022.....	26
Slika 2.5 Združevanje povpraševanja v različnih časovnih obdobjih	27
Slika 2.6 Empirična porazdelitev povpraševanja.....	28
Slika 3.1 Medpanožni standardni postopek za podatkovno rudarjenje (CRISP-DM)	34
Slika 3.2 Načela pridobivanja znanja iz podatkov	35
Slika 3.3 Koraki za izvedbo metode Delphi	37
Slika 3.4 Naloge podatkovnega rudarjenja	39
Slika 3.5 Koraki, ki sestavljajo postopek KDD	39
Slika 4.1 Klasično programiranje v primerjavi s sistemom strojnega učenja.....	44
Slika 4.2 Arhitektura Microsoftove poslovne inteligence.....	46
Slika 4.3 Koraki analize podatkov ML v R	47
Slika 4.4 Potek podatkov in znanja ML za podjetje Equilibrium AI	48
Slika 4.5 Tipični vizualizacijski del platforme ML v SC	50



Slika 4.6 Prikaz kompromisa med prožnostjo in razlagalnostjo z uporabo različnih metod ML	51
Slika 4.7 Statistične značilnosti izdelkov v verigi preskrbe s hrano (povzeto za vse izdelke) .	52
Slika 5.1 Življenjski cikel BPM	58
Slika 5.2 Zapisi začetnega, vmesnega in končnega dogodka.....	60
Slika 5.3 Zapisi nalog in podprocesov	61
Slika5 .4 Zapisi vrat OR, XOR in AND.....	62
Slika5 .5 Primer uporabe prehoda OR.....	62
Slika 5.6 Primer uporabe prehodov XOR in AND	63
Slika 5.7 Potek zaporedja, tok sporočil in povezava	63
Slika 5.8 Bazen in steze	64
Slika 5.9 Podatkovni predmeti	64
Slika 5.10 Shramba podatkov	65
Slika 5.11 Opomba	65
Slika 5.12 Upravljanje poslovnih procesov v primerjavi s procesnim rudarjenjem.....	66
Slika 6.1 Razlika med neodvisnimi oddelki in oddelki, ki si delijo isto osrednjo podatkovno zbirko	71
Slika 6.2 Povezava med ERP, WMS in TMS.....	80
Slika 7.1 E-logistika v konceptu e-poslovanja	85
Slika 7.2 E-logistika	88
Slika 8.1 Sestavni deli GIS.....	99
Slika 8.2 Sloje GIS.....	100
Slika 8.3 Vektorski (levo) in rastrski (desno) podatki.....	101
Slika 9.1 Bližina kot načelo teorije Gestalt.....	111
Slika 9.2 Podobnost kot načelo teorije Gestalt.....	111
Slika 9.3 Zaprtost kot načelo teorije Gestalt	111
Slika 9.4 Zaprtje kot načelo teorije Gestalt.....	112
Slika 9.5 Kontinuiteta kot načelo teorije Gestalt.....	112
Slika 9.6 Povezanost kot načelo teorije Gestalt.....	112
Slika9.7 Uporaba predpomenskih atributov pri vizualizaciji podatkov	113
Slika 9.8 Vrste predpomenskih atributov, ki se uporabljajo pri vizualizaciji podatkov	114
Slika 9.9 Enostavno besedilo v vizualizaciji.....	115
Slika 9.10 Stolpčni diagram v vizualizaciji.....	117



Slika 9.11 Črtni diagram v vizualizaciji	118
Slika 9.12 Območni diagram v vizualizaciji	118
Slika 9.13 Razpršeni diagram v vizualizaciji	119
Slika 9.14 Choropleth zemljevid v vizualizaciji	120
Slika 9.15 Vizualizacija toplotne karte	120
Slika 9.16 Kazalni stolpčni grafikon	121
Slika 9.17 Barvne kombinacije	123
Slika 9.18 Barvne sheme	123
Slika 10.1 5C podatkovne etike	128
Slika 10.2 CIA TRIADA	132

**Dario Šebalj, PhD**

Docent na Ekonomskem fakultetu v Osijeku, Katedra za kvantitativne metode in informatiko. Predava na področjih upravljanja poslovnih procesov, vodenja IKT-projektov, poslovne analize in e-logistike. Objavil je več kot 20 znanstvenih člankov v revijah in mednarodnih konferenčnih zbornikih. Od leta 2020 do 2023 je bil izvršni urednik revije Ekonomski vjesnik, med letoma 2017 in 2019 pa tajnik združenja Alumni EFOS. Sodeloval je kot raziskovalec pri dveh projektih Erasmus+ ter pri projektu Hrvaške znanstvene fundacije. ORCID: 0000-0002-8295-7847

**Dejan Mirčetić, PhD**

Raziskovalni sodelavec na Inštitutu za raziskave in razvoj umetne inteligence Srbije ter docent na Fakulteti tehničnih znanosti Univerze v Novem Sadu. Dr. Dejan Mirčetić je doktoriral na področju napovedovanja povpraševanja in analitike oskrbovalnih verig ter je avtor več kot 60 znanstvenih prispevkov. Njegovo raziskovalno delo je usmerjeno predvsem v reševanje praktičnih izzivov v poslovnem in industrijskem okolju. Na Inštitutu za umetno inteligenco Srbije je odgovoren za zasnovo in razvoj rešitev umetne inteligence za podjetja in industrijo. Trenutno vodi projekt ISIOP, ki je del platforme AIPlan4EU v okviru raziskovalnega in inovacijskega programa Horizon 2020. Poleg dela na področju upravljanja oskrbovalnih verig dr. Mirčetić pomembno prispeva tudi k uporabi umetne inteligence v zdravstvu in živilski industriji, pri čemer se osredotoča na inovativne pristope k optimizaciji procesov in izboljšanju učinkovitosti. ORCID: 0000-0002-1602-7908



Michał Adamczak, PhD Eng.

Raziskovalec in pedagoški delavec na Logistični šoli v Poznaniu ter predstojnik Oddelka za logistiko na tej univerzi. Član upravnega odbora Poljskega logističnega združenja. Specializiran je za management, upravljanje zalog, upravljanje oskrbovalnih verig in proizvodno upravljanje. Pri svojem delu uporablja orodja za analizo logističnih podatkov, statistične analize, modeliranje in procesne simulacije, vključno s preglednicami v programu MS Excel. Avtor odprtih in zaprtih izobraževalnih programov s področij, povezanih z omenjenimi temami. Izvajalec več deset svetovalnih projektov za trgovska in proizvodna podjetja. Vodilni raziskovalec v številnih projektih, izvedenih v okviru programa ERASMUS+. Avtor več kot 100 znanstvenih publikacij v priznanih domačih in tujih revijah ter udeleženec številnih mednarodnih konferenc.

ORCID: 0000-0003-4183-7264

BUSINESS ANALYTICS SKILLS FOR THE FUTURE- PROOF SUPPLY CHAINS