



# BUSINESS ANALYTICS SKILLS FOR THE FUTURE-PROOFS SUPPLY CHAINS

## POSLOVNA INTELIGENCIJA

Autori:

Dario Šebalj  
Dejan Mirčetić  
Michał Adamczak



Financirano sredstvima Europske unije.

Izneseni stavovi i mišljenja su stavovi i mišljenja autora i ne moraju se podudarati sa stavovima i mišljenjima Europske unije ili Europske izvršne agencije za obrazovanje i kulturu (EACEA). Ni Europska unija ni EACEA ne mogu se smatrati odgovornima za njih.



BAS4SC - Business Analytics Skills for the Future-proofs Supply Chains

Dario Šebalj, Dejan Mirčetić, Michał Adamczak

# POSLOVNA INTELIGENCIJA

Poznanj, 2025.



Izdavač:

Fakultet za logistiku  
Estkowskiego 6  
61-755 Poznanj, Poljska  
[www.wsl.com.pl](http://www.wsl.com.pl)

Uredništvo:

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

ISBN 978-83-62285-67-9 (online)

Copyright by Fakultet za logistiku  
Poznanj 2025., Izdanje I

Recenzenti:

- prof. Ljubica Milanović Glavan, Sveučilište u Zagrebu, Ekonomski fakultet Zagreb, Zagreb, Hrvatska
- prof. Igor Pihir, Sveučilište u Zagrebu, Fakultet organizacije i informatike, Varaždin, Hrvatska

Tehnički urednik: Dario Šebalj, Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku, Osijek, Hrvatska

Dizajn naslovnice: Michał Adamczak, Fakultet za logistiku, Poznanj, Poljska

Preveo s engleskog jezika: Dario Šebalj, Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku, Osijek, Hrvatska

Knjiga je napisana u sklopu projekta Business Analytics Skills for Future-proof Supply Chains (BAS4SC) [2022-1-PL01-KA220-HED-000088856], financiranog putem programa ERASMUS+.

Financirano sredstvima Europske unije. Izneseni stavovi i mišljenja su stavovi i mišljenja autora i ne moraju se podudarati sa stavovima i mišljenjima Europske unije ili Europske izvršne agencije za obrazovanje i kulturu (EACEA). Ni Europska unija ni EACEA ne mogu se smatrati odgovornima za njih.



## Predgovor

U vremenu koje obilježava brza digitalna transformacija i donošenje odluka temeljenih na podacima, sposobnost snalaženja u velikim količinama podataka, njihovo tumačenje i korištenje više nije opcija – ona je nužnost. Ova knjiga izdvaja se kao pravovremen i vrijedan resurs za studente, nastavnike i stručnjake koji žele razviti ili dodatno produbiti svoje kompetencije iz područja poslovne analitike, osobito u kontekstu upravljanja lancem opskrbe i logistikom.

Knjiga je razvijena u sklopu Erasmus+ projekta BAS4SC (Business Analytics Skills for Future-proof Supply Chains), sufinanciranog od strane Europske unije, i usmjerenja je na rješavanje uočenog nesrazmjera između akademskih kurikuluma i potreba industrije diljem Europe. Temelji se na temeljitom istraživačkom procesu koji je uključivao analizu međunarodnih studijskih programa te izravnu suradnju s više od stotinu dionika iz akademskog i poslovnog svijeta. Rezultat je sveobuhvatan odabir najvažnijih analitičkih vještina koje će biti ključne za buduće stručnjake u području upravljanja opskrbnim lancima.

Knjiga započinje osnovama razumijevanja i interpretacije podataka, a zatim slijede ključne teme poput poslovne analitike, rudarenja podataka, strojnog učenja, upravljanja poslovnim procesima i informacijskih sustava. Posebna pažnja posvećena je suvremenim područjima poput e-logistike, geografskih informacijskih sustava (GIS) i podatkovne etike – temama koje sve više oblikuju konkurentsko okruženje modernih lanaca opskrbe.

Nadamo se da će ova knjiga poslužiti i kao obrazovni alat i kao stručno štivo. Bilo da ste student koji se tek priprema za ulazak u ovo područje ili praktičar koji želi prilagoditi svoje znanje i uspjeti u dinamičnom okruženju, uvidi i vještine predstavljeni u knjizi pomoći će vam donositi pametnije, brže i odgovornije odluke.

Dario Šebalj

Dejan Mirčetić

Michał Adamczak



# Sadržaj

UVOD.....	1
1. RAZUMIJEVANJE I TUMAČENJE PODATAKA.....	4
1.1. Podatak, informacija, znanje, mudrost .....	4
1.2. Izvori i vrste podataka .....	6
1.3. Modeliranje i oblikovanje podataka .....	10
1.4. Odlučivanje na temelju podataka.....	13
1.5. Kvaliteta podataka .....	14
REFERENCE.....	16
2. ANALITIKA POSLOVNIH PODATAKA .....	19
2.1. BDA u logistici i upravljanju opskrbnim lancem .....	20
2.2. Alati u analitici poslovnih podataka .....	22
2.2.1. Deskriptivna analitika .....	23
2.2.2. Predictive analytics.....	23
2.2.3. Prescriptive analytics.....	24
2.3. BDA ekosustav.....	24
2.3.1. Poslovni podaci .....	24
REFERENCE.....	29
3. RUDARENJE PODATAKA I OTKRIVANJE ZNANJA.....	31
3.1. Što je rudarenje podataka? .....	32
3.2. Otkrivanje znanja u logistici i upravljanju opskrbnim lancem .....	34
3.3. Delphi pristup prosudbenom stvaranju znanja .....	35
3.3.1. Koraci u provođenju Delphi metode .....	36
3.4. Kvantitativni pristup rudarenju podataka za otkrivanje znanja .....	38
REFERENCE.....	41
4. STROJNO UČENJE.....	43



4.1.	Što je strojno učenje?.....	43
4.2.	Temelji i teorijske pretpostavke strojnog učenja .....	44
4.3.	Poslovna inteligencija i ML u opskrbnom lancu.....	45
4.3.1.	ML i poslovni podaci iz opskrbnog lanca .....	50
	REFERENCE.....	52
5.	UPRAVLJANJE POSLOVNIM PROCESIMA I RUDARENJE PROCESA.....	54
5.1.	Poslovni proces .....	54
5.2.	Upravljanje poslovnim procesima.....	55
5.3.	Modeliranje poslovnih procesa.....	58
5.3.1.	Događaji .....	59
5.3.2.	Zadaci (aktivnosti) .....	60
5.3.3.	Odluke .....	60
5.3.4.	Objekti povezivanja.....	62
5.3.5.	Sudionici .....	62
5.3.6.	Artefakti.....	63
5.4.	Rudarenje procesa .....	64
	REFERENCE.....	66
6.	INFORMACIJSKI SUSTAVI U LOGISTICI.....	68
6.1.	Sustavi za upravljanje resursima poduzeća (ERP).....	68
6.1.1.	Troškovi ERP sustava .....	71
6.1.2.	Trendovi ERP sustava.....	73
6.2.	Sustavi za upravljanje skladištem .....	75
6.3.	Sustavi za upravljanje transportom.....	77
	REFERENCE.....	78
7.	E-LOGISTIKA.....	81
7.1.	Uvod.....	81
7.2.	E-poslovanje.....	82



7.3.	Definicija e-logistike .....	83
7.4.	Razvoj e-logistike .....	86
7.5.	Suvremene tehnologije koje podupiru e-logistiku .....	87
7.6.	E-logistika u praksi .....	89
7.7.	Sažetak .....	90
	REFERENCE .....	91
8.	GIS U LOGISTICI .....	94
8.1.	Geografski informacijski sustavi (GIS) .....	94
8.2.	GIS u logistici .....	98
8.3.	Budući trendovi vezani uz GIS .....	100
	REFERENCE .....	102
9.	METODE VIZUALIZACIJE PODATAKA .....	104
9.1.	Razumijevanje situacijskog konteksta .....	104
9.2.	Metode privlačenja pozornosti .....	106
9.3.	Odabir ispravne metode vizualizacije .....	110
9.3.1.	Jednostavan tekst .....	111
9.3.2.	Tablica .....	111
9.3.3.	Stupčasti grafikon .....	112
9.3.4.	Linijski grafikon .....	113
9.3.5.	Dijagram raspršenosti .....	114
9.3.6.	Koropletna karta .....	114
9.3.7.	Toplinska karta .....	115
9.3.8.	Bullet grafikon .....	115
9.4.	Smjernice dobrog vizualizacijskog dizajna .....	116
	REFERENCE .....	120
10.	PODATKOVNA ETIKA I INFORMACIJSKA SIGURNOST .....	122
10.1.	Važnost podatkovne etike .....	122



10.2. Temelji informacijske sigurnosti.....	126
10.2.1. Curenja podataka.....	128
10.2.2. Prijetnje informacijskoj sigurnosti .....	130
10.2.3. Smjernice za informacijsku sigurnost .....	133
REFERENCE.....	135
POPIS TABLICA.....	138
POPIS SLIKA.....	138



## UVOD

Ovaj udžbenik, pod naslovom Poslovna inteligencija, drugi je u nizu koji je razvijen u sklopu projekta Business Analytics Skills for Future-proof Supply Chains (BAS4SC). Provedeno je nekoliko preliminarnih istraživanja kako bi se odredio sadržaj ovog udžbenika. Prvo je provedeno opsežno istraživanje kako bi se analizirali kolegiji poslovne analitike u nastavnim planovima i programima različitih studijskih programa u Europskoj uniji, Sjedinjenim Državama i Ujedinjenom Kraljevstvu koji se bave logistikom i upravljanjem opskrbnim lancem. Metodologija istraživanja uključuje prikaze javno dostupnih nastavnih planova i programa te opise različitih studijskih programa (prvostupnički ili magistarski studiji). Fokus istraživanja bio je na studijskim programima iz područja poslovne ekonomije i primijenjenih znanosti. Ova analiza otkrila je jaz između logističkog znanja i vještina poslovne inteligencije potrebnih na tom području i onih koje se trenutno nude studentima. Kroz sveobuhvatne intervjuje i upitnike sa sveučilišnim nastavnim osobljem, studentima i stručnjacima iz industrije identificirano je više od 100 bitnih vještina poslovne analitike. Primjenom ABC metode klasifikacije rangiranja, 33 vještine odabrane su za uključivanje u ovu knjigu, s jakim fokusom na područja kao što su upravljanje podacima, analiza poslovnih procesa, strojno učenje, vizualizacija podataka i poslovni informacijski sustavi. Ove odabrane vještine i identificirane potrebe utjecale su na stvaranje deset poglavlja sa sadržajem, od kojih se svako bavi najvažnijim vještinama potrebnim u tom području.

Ova knjiga počinje postavljanjem temelja u Razumijevanje i tumačenje podataka, temeljno poglavje koje istražuje bitne koncepte podataka kao što su vrste podataka, kvaliteta i izvori podataka. Objasnjava kako je učinkovito donošenje odluka ukorijenjeno u snažnom razumijevanju podataka, omogućujući profesionalcima da izvuku značajne uvide i izbjegnu pristranosti koje mogu pomutiti poslovnu prosudbu. Teme kao što je piramida podataka-informacija-znanje-mudrost (DIKW), kao i metode za prepoznavanje trendova i korelacija u poslovnim podacima, nude čitateljima solidnu osnovu za navigaciju složenim podatkovnim krajolicima.

Drugo poglavje, Analitika poslovnih podataka, velike podatke stavlja u kontekst unutar poslovnih okruženja, objašnjavajući kako organizacije mogu iskoristiti analitiku podataka velikih razmjera za poboljšanje donošenja odluka. Obuhvaćajući "pet V" velikih podataka—



volumen, brzinu, raznolikost, istinitost i vrijednost—ovo poglavlje čitateljima pomaže razumjeti kako analitika velikih podataka podržava operativne i strateške ciljeve. Uključuje studije slučaja za ilustraciju praktičnih primjena, pokazujući kako uvidi iz velikih podataka mogu dovesti do konkurentske prednosti na dinamičnim tržištima.

U poglavlju Rudarenje podataka i otkrivanje znanja čitatelji se upoznaju s temeljnim tehnikama za izdvajanje vrijednih uzoraka iz velikih skupova podataka. Ovo poglavlje pokriva koncepte rudarenja podataka, kao što su klasteriranje, klasifikacija, rudarenje pravila pridruživanja i otkrivanje anomalija, koji pomažu tvrtkama da otkriju korisne uvide. Naglašava kritične korake u procesu otkrivanja znanja, od čišćenja podataka do tumačenja uzorka, osiguravajući da su uvidi koji proizlaze iz rudarenja podataka relevantni i primjenjivi u donošenju odluka u stvarnom svijetu.

Poglavlje o strojnog učenju istražuje ulogu strojnog učenja u prediktivnoj analitici i poslovnoj inteligenciji. Objasnjava osnove strojnog učenja, uključujući nadzirano i nenadzirano učenje, i kako te tehnike omogućuju računalima da prepoznaju obrasce, daju predviđanja i prilagode se na temelju novih podataka. Pokrivajući aplikacije strojnog učenja kao što su sustavi preporuka, predviđanje potražnje i otkrivanje anomalija, poglavlje pokazuje kako algoritmi strojnog učenja osnažuju organizacije da automatiziraju donošenje odluka, poboljšaju korisničko iskustvo i optimiziraju operacije.

Nakon toga, poglavlje Upravljanje poslovnim procesima (BPM) i rudarenje procesa ispituje strukture i strategije iza učinkovitih poslovnih procesa. Ovaj odjeljak opisuje kako organizacije mogu analizirati i poboljšati svoje procese, koristeći BPM i rudarenje procesa kako bi uskladile operacije sa strateškim ciljevima. Poglavlje uključuje alate i okvire za procjenu poslovnih procesa, objašnjavajući kako rudarenje procesa može otkriti uska grla i neučinkovitosti koje ometaju izvedbu.

Prelaskom na specijalizirane sustave, Informacijski sustavi u logistici nude pregled kritičnih IT sustava, kao što su ERP (eng. Enterprise Resource Planning), WMS (eng. Warehouse Management Systems) i TMS (eng. Transportation Management Systems). Ovo poglavlje govori o tome kako ovi sustavi integriraju različite logističke funkcije, usmjeravaju protok podataka i poboljšavaju učinkovitost u upravljanju resursima u opskrbnim lancima. Naglašava važnost ovih sustava u pružanju podataka u stvarnom vremenu i omogućavanju responzivnog logističkog upravljanja vođenog podacima.



Poglavlje o e-logistici istražuje transformativni utjecaj digitalnih tehnologija na logističke procese, naglašavajući besprijeckornu integraciju materijalnih i digitalnih tokova. Započinje definiranjem e-logistike i njezinim smještajem unutar šireg koncepta e-poslovanja, naglašavajući kako digitalni procesi podržavaju funkcije poput nabave materijala, skladištenja i transporta, posebno u kontekstu e-trgovine. U poglavlju se opisuje razvoj e-logistike od ranih sustava materijalnog planiranja do modernih ERP, WMS i TMS rješenja, koja omogućuju razmjenu podataka u stvarnom vremenu u opskrbnim lancima. S brzim rastom digitalnog gospodarstva, e-logistika je postala neophodna za organizacije koje imaju za cilj poboljšati konkurentsko pozicioniranje i pojednostaviti svoje logističke operacije.

Geografski informacijski sustavi (GIS) u logistici pružaju uvid u prostornu analizu i njihovu ulogu u optimizaciji logističkih mreža. Poglavlje pokriva kako GIS aplikacije omogućuju tvrtkama vizualizaciju, analizu i upravljanje geografskim podacima, podržavajući zadatke poput optimizacije rute, odabira lokacije i procjene rizika. Korištenjem GIS-a, tvrtke mogu donositi informiranje odluke koje uzimaju u obzir geografske i okolišne čimbenike, u konačnici poboljšavajući učinkovitost i korisničku uslugu.

Poglavlje o metodama vizualizacije podataka naglašava važnost pretvaranja složenih podataka u vizualne formate koji olakšavaju razumijevanje i donošenje odluka. Ovo poglavlje vodi čitatelje kroz učinkovite tehnike vizualizacije, od jednostavnih dijagrama i grafikona do naprednih interaktivnih nadzornih ploča. Razmatra alate i najbolje prakse koji podatke čine dostupnima dionicima, omogućujući tvrtkama da jasno komuniciraju uvide i pokreću informirane radnje.

Dodajući etičku perspektivu, Etika podataka i informacijska sigurnost bavi se etičkim razmatranjima upotrebe podataka u poslovnom kontekstu. Ovo poglavlje govori o zakonima o privatnosti, praksama zaštite podataka i etičkim implikacijama rukovanja osobnim podacima, posebno u analizi opskrbnog lanca. Obuhvaćajući teme kao što su protokoli za sigurnost podataka i etički okviri, poglavlje osposobljava čitatelje za održavanje standarda integriteta i povjerenja u okruženjima vođenim podacima.



# 1. RAZUMIJEVANJE I TUMAČENJE PODATAKA

Autor: Dario Šebalj

U ovom se poglavlju objašnjavaju temeljni koncepti razumijevanja i tumačenja podataka. Podaci su temelj učinkovitog donošenja odluka i imaju ključnu ulogu u ostvarivanju organizacijskog uspjeha. Stjecanjem vještina u analizi i tumačenju podataka, pojedinci (podatkovni analitičari, menadžeri, poslovni stručnjaci i sl.) mogu stići vještine potrebne za izvlačenje vrijednih dijelova iz ogromnog oceana dostupnih informacija. Podaci omogućuju analizu s činjeničnim temeljem. Organizacijama omogućuju donošenje odluka koje su objektivne i temeljene na činjenicama te da idu dalje od samih pretpostavki i intuicije. Poduzeća mogu koristiti podatke za uočavanje korelacija, trendova i obrazaca koje bi inače mogla propustiti.

Pronalaženje neučinkovitih procesa i područja za poboljšanje još je jedna od prednosti analize podataka. Analizom operativnih podataka, organizacije mogu pronaći uska grla, poboljšati radne tokove te opću učinkovitost poslovnih procesa. Dodatno, analiza podataka olakšava procjenu uspješnosti projekata ili provedenih strategija što ubrzava donošenje odluka i poboljšava planiranje.

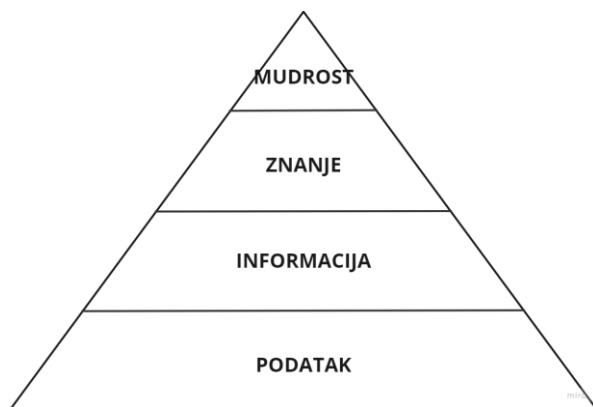
Prije postupka analize podataka, ključno je opisati različite vrste i izvore podataka, objasniti načine njihova modeliranja te naglasiti važnost kvalitete podataka. Ovo poglavlje će postaviti temelje poslovne inteligencije, pružajući korisnicima alate za iskorištavanje potencijala koji leži u podacima te donošenje poslovnih odluka.

## 1.1. Podatak, informacija, znanje, mudrost

Pri definiranju pojma „podatak”, kao polazište često se koristi poznata piramida podatak-informacija-znanje-mudrost (kratica DIKW, prema početnom slovu engleskim riječi) ili DIKW hijerarhija. Rowley (2007) navodi da ova hijerarhija služi u svrhu identificiranja i opisa procesa uključenih u transformaciju entiteta s niže razine u hijerarhiji (npr. podaci), u entitet na višoj razini u hijerarhiji (npr. informacije), kao i kontekstualiziranja podataka, informacija, znanja i



mudrosti u međusobnom odnosu. Svaka razina piramide nadograđuje se na razinu ispod nje, a da bi donošenje odluka na temelju podataka bilo učinkovito, potrebne su sve četiri razine (Cotton, 2023). Slika 1.1 prikazuje DIKW piramidu.



Slika 1.1 DIKW piramida

Izvor: Rowley (2007).

**Podatak** predstavlja sirovину bez ikakvог značenja. To je sadržaj koji je izravno vidljiv ili provjerljiv, neorganizirana činjenica koje nema nikakav kontekst i koju je teško razumjeti (Brackett, 2015; Dalkir, 2023). Podaci mogu biti u obliku brojeva, teksta, slika itd. Bez tumačenja, podaci ostaju besmisleni. Primjer podataka: skup podataka koji sadrži očitanja temperature prikupljena s meteoroloških stanica.

Skup podataka u kontekstu koji je relevantan za jednu ili više osoba u određenom trenutku ili određeno vrijeme naziva se **informacijom**. To su obrađeni, organizirani, strukturirani i kontekstualizirani podaci. Informacija daje odgovore na pitanja „tko”, „što”, „gdje” i „kada” (Brackett, 2015; Cotton, 2023). Primjer informacije: analizom temperturnih podataka vidljivo je kako je prosječna temperatura u proteklom mjesecu viša nego u istom razdoblju prošle godine.

Cotton (2023) tvrdi da je **znanje** rezultat analize i tumačenja informacija, a koje otkriva obrasce, trendove i veze. Nudi uvid „kako” i „zašto” se određeni događaji događaju. To podrazumijeva bolje razumijevanje temeljnih ideja. Chaffey i Wood (2005, citirano u Rowley, 2007) definiraju znanje kao „kombinaciju podataka i informacija, kojima je dodano stručno mišljenje, vještine i iskustvo, da bi rezultiralo vrijednom imovinom koja se može koristiti za pomoć u donošenju odluka”. Primjer znanja: pomoću znanja stečenog analizom povijesnih podataka o temperaturi, meteorolog može predvidjeti vremenske uvjete za nadolazeći tjedan.



Sposobnost razumijevanja temeljnih činjenica i donošenje informiranih odluka i učinkovitih radnji poznata je kao **mudrost** (Cotton, 2023). Primjer mudrosti: koristeći vremenske prognoze i razumijevajući lokalne klimatske uvjete, poljoprivrednik može donijeti odluku o sadnji određene vrste usjeva.

Razumijevanje međusobne povezanosti podataka, informacija, znanja i mudrosti čini temeljnu osnovu za iskorištavanje potencijala poslovne inteligencije. Ovo će razumijevanje poslužiti kao osnova za transformaciju podataka u korisne zaključke koji mogu pomoći pri vođenju poduzeća prema uspjehu.

## 1.2. Izvori i vrste podataka

U modernom dobu, podaci se često nazivaju „novom naftom” – vrijednim resursom koji potiče inovacije i donošenje odluka. U središtu svakog pothvata koji se temelji nad podacima, nalazi se niz tipova podataka, svaki sa svojim jedinstvenim karakteristikama i značajem. Svaki dan se proizvede ogromna količina podataka. Trenutne projekcije govore da u svijetu postoji 97 zetabajta podataka i da se svaki dan stvori više od 2,5 kvintilijuna podataka. 90% podataka u svijetu generirano je u posljednje dvije godine (Marr, n.d.).

Prema Kenettu i Shmueliju (2016), „podaci mogu proizaći iz različitih instrumenata prikupljanja: anketa, laboratorijskih testova, terenskih eksperimenata, računalnih eksperimenata, simulacija, web pretraživanja, mobilnih snimaka itd. Podaci mogu biti primarni, prikupljeni u svrhu studija, ili sekundarni, prikupljeni iz nekog drugog razloga. Podaci mogu biti jednovarijantni ili multivarijantni, diskretni, kontinuirani ili mješoviti. Podaci mogu sadržavati semantičke nestrukturirane informacije u obliku teksta, slika, zvuka i videa. Mogu imati i različite strukture, uključujući vremenske serije, panel podatke, umrežene podatke, geografske podatke i sl. Podaci mogu uključivati informacije iz jednog izvora ili iz više njih. Mogu biti bilo koje veličine i bilo koje dimenzije”.

Podaci se generiraju brzo i kontinuirano. Društvene mreže, pametni uređaji, tehnologije snimanja u medicijskoj dijagnozi samo su neki od primjera. Novi podaci se stoga moraju negdje i spremati. Uređaji i senzori automatski stvaraju podatke koje je potrebno odmah analizirati i pohraniti. Održavanje ove ogromne količine podataka dovoljno je teško, ali njihova analiza s ciljem pronaleta trendova i vrijednih informacija daleko je teža, osobito kada podaci nisu u obliku tradicionalnih struktura podataka (EMC Education Services, 2015).



Prema Blazquezu i Domenechu (2018), tehnologije povezane s internetom, pametnim telefonima i senzorima sve su više uključene u većinu poslovnih i privatnih dnevnih operacija. Primjerice, mnoga poduzeća koriste društvene mreže za promicanje svojih brendova, nude svoje proizvode online, koriste pametne telefone za praćenje ruta prodajnih predstavnika ili koriste specijalizirane senzore za praćenje rada strojeva. S druge strane, ljudi koriste računala, pametne telefone i tablete kako bi na internetu pretraživali proizvode, komunicirali s prijateljima, dijelili mišljenja i snalazili se u prostoru. Osim toga, senzori postavljeni po gradovima, na autocestama i na javnim mjestima bilježe dnevna kretanja i aktivnosti građana. Zbog toga se, uporabom ovih tehnologija, proizvodi ogromna količina novih digitaliziranih i svježih podataka o aktivnostima ljudi i poduzeća. Ako se ispravno analiziraju, ovi podaci mogu pomoći u prepoznavanju trendova i praćenju ekonomskog, industrijskog i društvenog ponašanja.

Sherman (2015) naglašava da može biti problem ako poduzeće ima više podataka nego što to može podnijeti. Kroz svoje svakodnevne interakcije s klijentima, partnerima i dobavljačima, poduzeće prikuplja ogromne količine podataka, kako interno, tako i eksterno. Poduzeća provode i istraživanja tržišta i prate informacije o svojim konkurentima. Web stranice im omogućuju praćenje točnog broja posjetitelja i mjesta odakle dolaze. Danas je vrlo aktualan internet stvari (IoT) koji prikuplja podatke sa senzora ugrađenih u predmete iz stvarnog svijeta poput ogrlice za pse, pacemakera i termostata. To je doslovno bujica podataka. Prema EMC Education Services (2015), među izvorima velikih podataka s najbržom stopom rasta su društveni mreži i genetsko sekvencioniranje, koji spadaju u netradicionalne izvore podataka u svrhu analize.

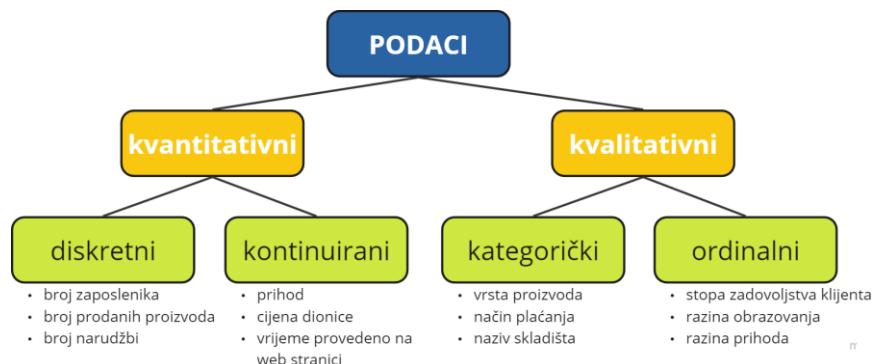
Howson (2014) smatra da uspjeh inicijative usmjerene prema poslovnoj inteligenciji (BI) ovisi o dostupnosti visokokvalitetnih i relevantnih podataka koji obuhvaćaju širok raspon izvora podataka potrebnih za proces poslovnog odlučivanja.

Podaci dolaze u različitim oblicima. Podaci se najčešće dijele na (slika 1.2):

1. **Kvantitativni (numerički) podaci** – podaci izraženi brojevima. Mogu se podijeliti na diskrete i kontinuirane podatke. Diskretni podaci mogu imati samo određenu vrijednost (npr. broj zaposlenih), dok kontinuirani podaci mogu imati beskonačan broj mogućih vrijednosti (npr. cijena proizvoda).
2. **Kvalitativni podaci** – ova vrsta podataka može se podijeliti na kategoričke i ordinalne podatke. Kategorički podaci predstavljaju tekstualne podatke koji se mogu grupirati u



različite kategorije (npr. mjesto rođenja, regija, kategorija proizvoda), dok se ordinalni podaci mogu rangirati ili poredati (npr. zadovoljstvo zaposlenika – vrlo nezadovoljan, nezadovoljan, neutralan, zadovoljan, vrlo zadovoljan; razina obrazovanja – osnovna škola, srednja škola, prvostupnik, magisterij, doktorat).



Slika 1.2 Osnovni tipovi podataka

Izvor: Autor.

Druga klasifikacija podataka je na strukturirane, polustrukturirane i nestrukturirane.

**Strukturirani podaci** mogu se pohranjivati, obrađivati i njima manipulirati u tradicionalnom relacijskom sustavu upravljanja bazama podataka. Ovi podaci dolaze iz raznih izvora, uključujući web obrasce, POS transakcije, senzore i sl. Mogu ih generirati ljudi ili strojevi. Ova vrsta podataka ima unaprijed određeni format, vrstu i organizaciju (EMC Education Services, 2015; Person i Porway, 2015).

**Polustrukturirani podaci** organizirani su pomoću oznaka (tagova) koji podacima daju hijerarhiju i poredak, čak i ako se ne uklapaju u sustav strukturirane baze podataka. Baze podataka i datotečni sustavi često sadrže polustrukturirane podatke. Logovi, HTML tekst, XML datoteke i JSON podatkovne datoteke primjeri su polustrukturiranih podataka (McKinsey Global Institute, 2011; Person i Porway, 2015).

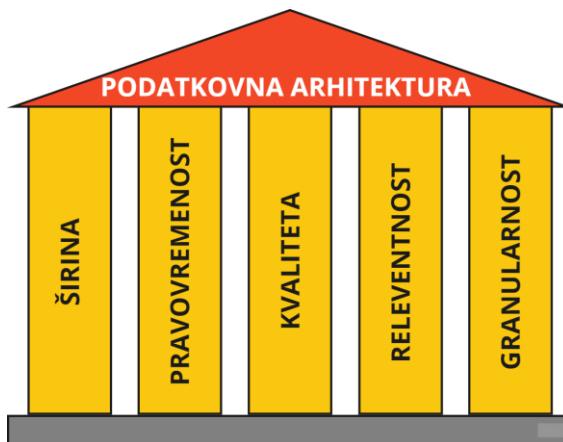
Budući da **nestrukturirane podatke** obično generira ljudska aktivnost i ne uklapaju se u format strukturirane baze podataka, smatraju se potpuno nestrukturiranim. Primjeri ove vrste podataka su tekstualni dokumenti, PDF datoteke, zapisi na blogovima, e-mailovi, slike i video (EMC Education Services, 2015; Person i Porway, 2015). Prema Shermanu (2015), s nestrukturiranim i polustrukturiranim podacima mora se postupati drugačije od tradicionalnih strukturiranih podataka.



Ta golema količina strukturiranih, a posebice nestrukturiranih podataka koji se generiraju, prikupljaju i obrađuju velikom brzonom i složenošću, naziva se Big data (veliki podaci). McKinsey Global Institute (2011) definira Big data kao "podatke čija veličina, distribucija, raznolikost i ili pravodobnost zahtijevaju upotrebu novih tehničkih arhitektura i analitike kako bi se došlo do rezultata koji stvaraju nove izvore poslovne vrijednosti". Prema Kitchenu i McArdleu (2016), Doug Laney je 2001. godine detaljno opisao da Big Data karakteriziraju tri značajke (tri V):

- **Volumen (eng. Volume)** - ogromne količine podataka,
- **Brzina (eng. Velocity)** - stvoren u realnom vremenu,
- **Raznolikost (eng. Variety)** - strukturirani, polustrukturirani i nestrukturirani.

Prema Howsonu (2014), temelj za uspješnu poslovnu inteligenciju je podatkovna arhitektura (slika 1.3) koja se sastoji od šest važnih aspekata vezanih uz širinu, pravovremenost, kvalitetu, relevantnost i granularnost podataka. Kvaliteta podataka središnji je stup jer se ogroman trud ulaže u osiguranje i poboljšanje kvalitete podataka.



**Slika 1.3 Arhitektura podataka kao temelj uspješne poslovne inteligencije**

Izvor: Autor, prema Howson (2014).

Kao što je već spomenuto, podaci se mogu prikupljati iz različitih izvora. To je povezano sa širinom podataka kao jednim od stupova podatkovne arhitekture. Ono se odnosi na višestrukе izvore podataka što je danas, u eri Big data, uobičajen način prikupljanja podataka. S druge strane, kombiniranje podataka iz više različitih izvora pridonosi problemima vezanim uz kvalitetu podataka (Howson, 2014).

U sljedećem potpoglavlju fokus će biti na iskorištavanju potencijala kojeg podaci pružaju. Istražit će se sustavi za upravljanje relacijskim bazama podataka (RDBMS) za pohranu i



dohvaćanje podataka te vizualni prikaz struktura baza podataka kroz dijagrame entiteta i odnosa (ER). Povezivanje razumijevanja izvora i tipova podataka s njihovim modeliranjem i oblikovanjem, značajan je korak prema praktičnoj primjerni poslovne inteligencije.

### 1.3. Modeliranje i oblikovanje podataka

Podatkovni model je formalni prikaz podataka koje poslovni sustav koristi i generira (Dennis et al., 2018). Kao što je već spomenuto, strukturirani podaci obično se pohranjuju u sustav za upravljanje relacijskim bazama podataka (eng. relational database management system - RDBMS). Prema Tilleyju (2020), „sustav za upravljanje bazom podataka zbirka je alata, značajki i sučelja koja korisnicima omogućuje dodavanje, ažuriranje, upravljanje, pristup i analizu podataka“. Neki od popularnih RDBMS sustava su Oracle (Oracle), DB2 (IBM) i SQL Server (Microsoft).

U RDBMS-u, podaci su organizirani u tablice koje sadrže zbirku zapisu koji pohranjuju informacije o određenom entitetu. Tablice su predstavljene kao dvodimenzionalne strukture sa stupcima i redovima. Svaki stupac predstavlja polje ili atribut entiteta, a svaki redak predstavlja zapis koji je instanca entiteta (Tilley, 2020). Slika 1.4 prikazuje primjer tablice Proizvod.

PROIZVOD			
ID	Naziv	KategorijaID	Cijena
1032	Laptop	1	800.00
1086	Majica	2	20.00
1099	Mobil	1	600.00
2033	Kruh	3	2.00
2058	Tenisice	4	80.00
2069	Slušalice	1	40.00

miro

Entitet / naziv tablice

Polja / atributi

Zapis

Vrijednosti atributa

Slika 1.4 Primjer tablice u RDBMS

Izvor: Autor.

Ova tablica predstavlja jednostavni katalog proizvoda sa 6 proizvoda, od čega svaki ima jedinstvenu šifru (ID), naziv, kategoriju i cijenu.

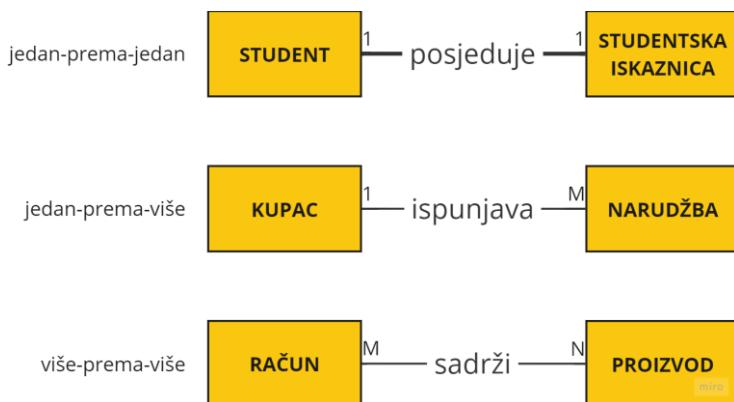


**Atribut** je posebna vrsta podatka o entitetu. Na primjer, ID kupca, ime, prezime, adresa, poštanski broj, grad, država, e-mail atributi su entiteta Kupac. Red u tablici ili skup povezanih polja koja opisuju jednu instancu entiteta (kao što je Kupac) naziva se **zapis**.

Svaka tablica u bazi podataka mora imati atribut koji služi kao **primarni ključ**. To je polje (ili skup polja) koje svakom proizvodu u tablici daje jedinstvenu vrijednost. To znači da u tablici ne mogu postojati dva proizvoda s istim ID-om.

Tablice u bazi podataka često su povezane s drugim tablicama, tj. između njih postoji veza. Veze (relacije) definiraju kako su podaci u jednoj tablici povezani s podacima u drugoj tablici.

Prema Tilleyju (2020), između entiteta mogu postojati tri vrste odnosa: jedan-prema-jedan, jedan-prema-više i više-prema-više. Primjeri ovih odnosa prikazani su na slici 1.5.



Slika 1.5 Primjeri odnosa među entitetima

Izvor: Autor.

Logička struktura baze podataka i odnosi među tablicama mogu se vizualno predstaviti pomoću **dijagrama entiteta i veza** (eng. Entity Relationship Diagram - ERD).

Postoje različite notacije za stvaranje ERD-ova, a najčešće su Chenova i Martinova (vranina noge). U ovoj će knjizi biti predstavljena Martinova notacija.

Prema Martinovoj (eng. Crow's Foot) notaciji, entitet je predstavljen pravokutnikom. To može biti osoba, mjesto, događaj ili stvar o kojoj se podaci prikupljaju. Atributi su navedeni kao imenice unutar entiteta. Odnosi između entiteta prikazani su linijama koje povezuju entitete. Odnosi imaju kardinalnost veze koja pokazuje koliko je instanci jednog entiteta povezano s instancom drugog entiteta (Dennis et al., 2018). U Crow's Foot notaciji, kardinalnosti su prikazane različitim simbolima. Na primjer, jedna crta označava jedan, dvostruka crta označava



jedan i samo jedan, krug označava nulu, a vrana nogu označava više. Tablica 1.1 prikazuje različite simbole kardinalnosti i njihovo značenje.

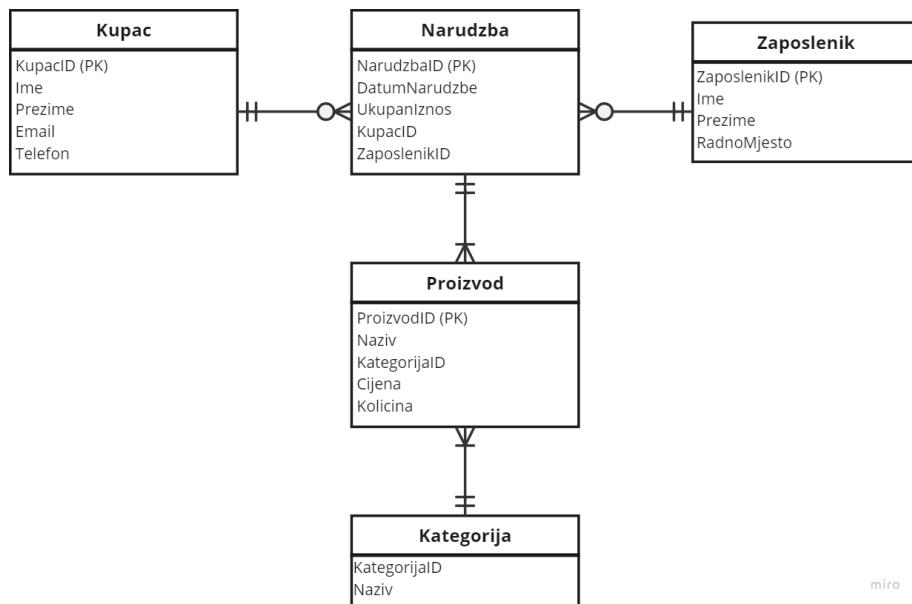
**Tablica 1.1 Primjeri kardinalnosti**

Simbol	Značenje
	Jedan i samo jedan
	Jedan ili više
	Nula ili više
	Nula ili jedan

Izvor: Tilley (2020).

Prema Dennis et al. (2018), tri su koraka pri izradi ERD-a:

1. Identifikacija atributa,
2. Dodavanje atributa i dodjela primarnog ključa,
3. Identifikacija veza.



**Slika 1.6 Primjer ERD-a za sustav prodaje**

Izvor: Autor.



Slika 1.6 prikazuje dio ERD-a za sustav prodaje. Svaki entitet u ovom ERD-u prikazan je kao pravokutnik s popisom svojih atributa. Linije koje povezuju entitete koriste se za prikaz njihovih odnosa:

- Kupac može napraviti više narudžbi. Neku narudžbu može napraviti samo jedan kupac.
- Određena narudžba može sadržavati više proizvoda. Svaki proizvod vezan je uz točno određenu narudžbu.
- Narudžba je povezana s kupcem i zaposlenikom koji ju je obradio.
- Proizvod je povezan s kategorijom jer svaki proizvod pripada određenoj kategoriji.

Temeljno razumijevanje modeliranja i dizajna podataka, kao što su ER dijagrami i RDBMS, bitno je za učinkovito korištenje podataka. Ono je temelj za pragmatičnu implementaciju podataka kroz donošenje odluka temeljenih na podacima, pri čemu strukturirani modeli podataka daju vrijedne uvide koji vode informiranim poslovnim strategijama i procesu donošenja odluka.

## 1.4. Odlučivanje na temelju podataka

Odlučivanje temeljeno na podacima (eng. Data-driven decision-making - DDDM) strateški je pristup koji se oslanja na analizu i tumačenje podataka s ciljem provedbe određenih radnji. Iskorištavanjem rezultata proizašlih iz golemih skupova podataka, tvrtke se mogu snalaziti u neizvjesnim situacijama, čime se smanjuju rizici i povećavaju prilike. Nelson (2022) definira donošenje odluka temeljeno na podacima kao proces donošenja strateških poslovnih odluka koje su u skladu s ciljevima i inicijativama organizacije korištenjem činjenica, metrika i podataka. Donošenje odluka temeljeno na podacima, prema Provostu i Fawcettu (2013), proces je donošenja odluka koje se više oslanjaju na analizu podataka nego na intuiciju. Na primjer, marketinški stručnjak može birati oglase koristeći svoje opsežno poznavanje industrije i istančan osjećaj za ono što će se svidjeti potrošačima. Međutim, svoju bi odluku mogao temeljiti i na analizi podataka koji pokazuju kako korisnici reagiraju na razne oglase.

U ovom pristupu odluke se ne donose na temelju intuicije, već na temelju čvrstih činjenica. Ono uključuje prikupljanje, analiziranje i tumačenje podataka kako bi se identificirali obrasci, trendovi i korelacije. Bilo da se radi o optimizaciji operativne učinkovitosti, poboljšanju korisničkih iskustava ili usavršavanju proizvodnih strategija, odluke temeljene na podacima omogućuju tvrtkama da se prilagode i napreduju na dinamičnim tržištima.



Integriranjem podataka u proces donošenja odluka, organizacije postaju prilagodljivije i otpornije na promjene, čime potiču inovacije i održivi rast. Velik broj istraživačkih radova pokazao je da je donošenje odluka temeljeno na podacima povezano s povećanom produktivnošću (npr. Brynjolfsson i McElheran, 2019; Sala et al., 2022; Colombari et al., 2023). To je razlog zašto većina organizacija, osobito velikih, ulaže u prikupljanje i analizu svojih podataka. Više od 2/3 od 300 rukovoditelja koje je ispitao Bain & Company (2017) kaže da njihova tvrtka ulaže velika sredstva u analitiku podataka, dok više od polovice predviđa transformacijski povrat svojih ulaganja.

Pet je koraka za donošenje odluka temeljenih na podacima (Asana, 2022):

1. Razumijevanje vizije tvrtke,
2. Pronalaženje izvora podataka,
3. Čišćenje i organizacija podataka,
4. Analiza podataka,
5. Izvođenje zaključaka.

McKinsey Global Institute (2014) izvještava da organizacije koje koriste podatke u svrhu odlučivanja imaju 23 puta veću vjerovatnost da će steći kupce, 6 puta veću vjerovatnost da će zadržati kupce i 19 puta veću vjerovatnost da će biti profitabilne.

Globalno prepoznatljive tvrtke koje svoje odluke donose na temelju podataka su Google, Amazon i Netflix.

Kako bi organizacija ostvarila potpuni potencijal poslovne inteligencije, ključno je uzeti u obzir kvalitetu podataka, što je opisano u sljedećem dijelu. Kvaliteta podataka osigurava preciznost i pouzdanost zaključaka i uvida do kojih se došlo na temelju podataka.

## 1.5. Kvaliteta podataka

Stupanj točnosti, dosljednosti, pouzdanosti i prikladnosti za određenu svrhu naziva se kvalitetom podataka. Kvaliteta podataka važna je u kontekstu poslovne inteligencije i analize podataka budući da zaključci i prosudbe donesene na temelju podataka uglavnom ovise o njihovoj točnosti i pouzdanosti. Loša kvaliteta podataka može dovesti do netočnih zaključaka, pogrešnih strategija i napisljetu štetnih poslovnih ishoda. Prema Gartneru (2021), svake godine loša kvaliteta podataka košta organizacije u prosjeku 12,9 milijuna dolara.



Kvaliteta podataka može se okarakterizirati pomoću šest najčešće korištenih dimenzija (Foote, 2022):

- **Točnost:** koliko su točne vrijednosti atributa u podacima?
- **Potpunost:** jesu li podaci potpuni, bez nedostajućih informacija?
- **Dosljednost:** koliko su dosljedne vrijednosti u i između baza podataka?
- **Pravodobnost:** koliko su podaci pravovremeni?
- **Valjanost:** kako su podaci u skladu s unaprijed definiranim poslovnim pravilima?
- **Jedinstvenost:** je li svaki zapis jedinstveno identificiran, bez redundancija?

Prema Shermanu (2015), podaci se mogu smatrati visokokvalitetnim ako imaju sljedeće karakteristike (5C podataka):

- **Čisti** (eng. Clean) – odnosi se na stavke koje nedostaju, nevažeće unose i druge slične probleme
- **Dosljedni** (eng. Consistent) - jednoobraznost i koherentnost podataka u različitim izvorima i unutar samog skupa podataka
- **Sukladni** (eng. Conformed) – odnosi se na podatke koji se pridržavaju unaprijed definiranih standarda podataka i pravila
- **Aktualni** (eng. Current) - neophodno je koristiti najnovije podatke za donošenje odluka i analizu
- **Sveobuhvatni** (eng. Comprehensive) - uključuje sve bitne podatkovne elemente potrebne za namjeravani proces donošenja odluka bez izostavljanja kritičnih informacija.

Prema Kenettu i Shmueliju (2016.), gotovo svi podaci moraju se očistiti prije nego što se mogu koristiti za daljnju analizu. Međutim, cilj određuje stupanj čistoće i strategiju čišćenja podataka. Isti podaci mogu sadržavati visokokvalitetne informacije za jednu svrhu i nekvalitetne informacije za drugu.

Gartner (2023) je nedavno identificirao skup od 12 radnji usmjerenih na poboljšanje kvalitete podataka. Ove radnje su klasificirane u četiri različite kategorije, koje treba uzeti u obzir pri procjeni integriteta podataka:

- Usredotočite se na prave stvari u postavljanju jakih temelja,
- Primijenite odgovornost za kvalitetu podataka,
- Uspostavite kvalitetu podataka koja odgovara svrsi,
- Integrirajte kvalitetu podataka u korporativnu kulturu.



Prema Howsonu (2014), dosljedni, sveobuhvatni i točni podaci smatraju se visokim stupnjem kvalitete. Teško je dobiti kvalitetne podatke zbog velikog utjecaja organizacijskih i vlasničkih problemi.

Sposobnost razumijevanja i analize podataka ključna je za donošenje informiranih odluka u području poslovne inteligencije. Bitno je razumjeti da je put od neobrađenih podataka do dobivanja praktičnih rezultata iz njih, a koji obuhvaća različite izvore podataka, vrste, modeliranje i dizajn, sastavni dio procesa izvlačenja vrijednosti iz informacija.

## REFERENCE

1. Asana (2022). Data-driven decision making: A step-by-step guide [dostupno na: <https://asana.com/resources/data-driven-decision-making>, pristupljeno November 5, 2023]
2. Bain & Company (2017). Closing the Results Gap in Advanced Analytics: Lessons from the Front Lines [dostupno na: <https://www.bain.com/insights/closing-the-results-gap-in-advanced-analytics-lessons-from-the-front-lines/>, pristupljeno 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 [dostupno na: <https://www.dataversity.net/the-data-information-knowledge-cycle/>, pristupljeno 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 [dostupno na: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3422397](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3422397), pristupljeno 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 [dostupno na: <https://www.datacamp.com/cheat-sheet/the-data-information-knowledge-wisdom-pyramid>, pristupljeno 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 [dostupno na: <https://www.dataversity.net/data-quality-dimensions/>, pristupljeno November 5, 2023]
13. Gartner (2021). How to Improve Your Data Quality [dostupno na: <https://www.gartner.com/smarterwithgartner/how-to-improve-your-data-quality>, pristupljeno November 5, 2023]
14. Gartner (2023). Gartner Identifies 12 Actions to Improve Data Quality [dostupno na: <https://www.gartner.com/en/newsroom/press-releases/2023-05-22-gartner-identifies-12-actions-to-improve-data-quality>, pristupljeno 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. [dostupno na: <https://bernardmarr.com/how-much-data-do-we-create-every-day-the-mind-blowing-stats-everyone-should-read/>, pristupljeno November 5, 2023]
19. McKinsey Global Institute (2011). Big data: The next frontier for innovation, competition, and productivity. [dostupno na: [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](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), pristupljeno November 5, 2023]



20. McKinsey Global Institute (2014). Five facts: How customer analytics boosts corporate performance [dostupno na: <https://www.mckinsey.com/capabilities/growth-marketing-and-sales/our-insights/five-facts-how-customer-analytics-boosts-corporate-performance>, pristupljeno November 5, 2023]
21. Nelson, M. (2022). Beyond The Buzzword: What Does Data-Driven Decision-Making Really Mean?. Forbes [dostupno na: <https://www.forbes.com/sites/tableau/2022/09/23/beyond-the-buzzword-what-does-data-driven-decision-making-really-mean/?sh=2d35c4eb25d6>, pristupljeno 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 PODATAKA

Autor: Dejan Mirčetić

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

Koncept Big data prvi su predstavili Cox i Ellsworth u listopadu 1997., u članku objavljenom na ACM Digital Library (Tiwari et al., 2018). Proučavanje velikih podataka i njihova konceptualizacija kontinuirano se razvijaju. U početku je Big data karakterizirao koncept 3V, koji je obuhvaćao **volumen**, **brzinu** i **raznolikost**, kao što je objašnjeno u prethodnom poglavlju. Kasnije se ovaj koncept proširio na koncept 5V, uključivši dva dodatna atributa: **istinitost** (eng. Veracity) i **vrijednost** (eng. Value) (Nguyen et al., 2018; Tiwari et al., 2018). Volumen se odnosi na količinu generiranih podataka budući da količina digitalnih podataka eksponencijalno raste (Arunachalam et al., 2018.). Raznolikost se odnosi na činjenicu da se podaci mogu generirati iz heterogenih unutarnjih i vanjskih izvora, u strukturiranim, polustrukturiranim i nestrukturiranim formatima. Brzina se odnosi na brzinu generiranja i isporuke podataka, koji se mogu obrađivati u serijama, u stvarnom vremenu ili gotovo u stvarnom vremenu. Istinitost naglašava važnost kvalitete podataka jer mnogi izvori podataka sami po sebi sadrže određeni stupanj nesigurnosti i nepouzdanosti. Vrijednost se odnosi na pronalaženje nove vrijednosti sadržane u podacima koja se može koristiti za bolje poslovno planiranje (Nguyen et al., 2018).

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



vrijednih informacija i znanja, s ciljem povećanja poslovne koristi, operativne učinkovitosti i istraživanja novih tržišta i prilika (Nguyen et al., 2018; Tiwari et al., 2018). BDA je privukao značajnu pozornost u različitim područjima, kako akademskim tako i poslovnim, posebice u logistici i upravljanju opskrbnim lancem.

## 2.1. BDA u logistici i upravljanju opskrbnim lancem

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

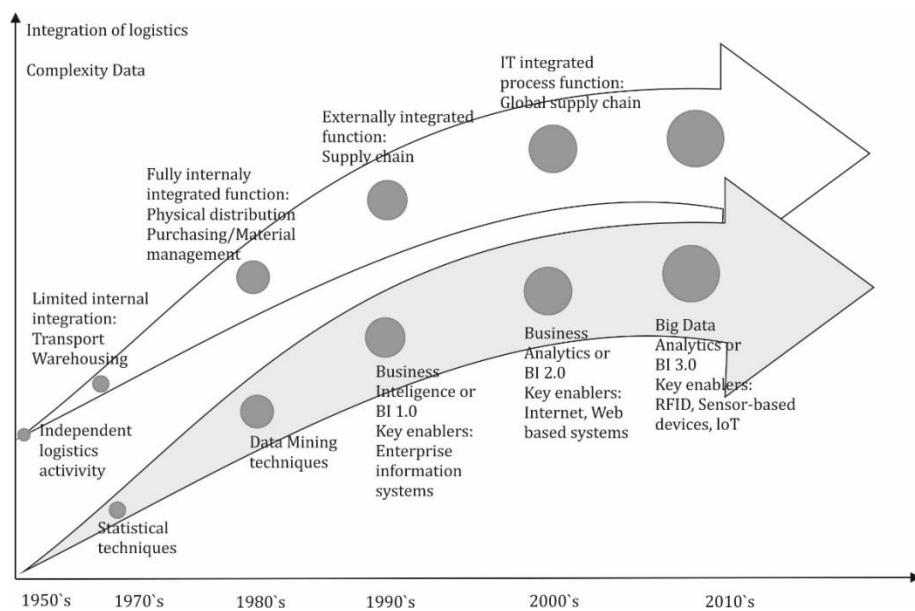
Opskrbni lanac je skup fizičkih elemenata, njihovih aktivnosti i procesa kroz koje se odvija njihova interakcija. Fizički elementi, koji čine lančanu strukturu, predstavljaju fiksni dio opskrbnog lanca. Na strateškoj razini donose se odluke o oblikovanju strukture opskrbnog lanca, a na taktičkoj i operativnoj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

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



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

U području upravljanja opskrbnim lancem, interes za poslovnu analitiku raste. Ona se naziva još i **analitika opskrbnog lanca (SCA)**. SCA se koristi kao sinonim za pojmove kao što su 'Big Data analitika' i 'poslovna analitika' unutar poslovnih i akademskih zajednica (Srinivasan i Swink, 2018.). SCA se odnosi na korištenje podataka i kvantitativnih alata i tehnika za poboljšanje operativnih performansi, često mjerenih metrikama kao što su ispunjavanje narudžbi i fleksibilnost. Analitika u opskrbnim lancima nije nužno nova ideja jer se različite kvantitativne tehnike i metode modeliranja već dugo koriste u proizvodnim tvrtkama. Nedavni porast interesa za SCA popraćen je novim izazovima i prilikama u poslovnom i informacijskom okruženju. Ti izazovi uključuju probleme koji proizlaze iz upravljanja velikim količinama podataka (npr. dostupnost podataka i kvaliteta podataka) i suočavanje s neizvjesnostima u okruženju. Pravilno primijenjen SCA može utjecati na nekoliko područja u opskrbnom lancu i može generirati značajne prednosti u logističkim performansama: poboljšano planiranje i raspoređivanje; poboljšani odziv; poboljšano planiranje potražnje; optimizacija narudžbi; optimizirano upravljanje zalihami; poboljšano planiranje popunjavanja zaliha. Posljednjih desetljeća, pod utjecajem tehnološkog razvoja, globalizacije i sve zahtjevnijih kupaca, promijenile su se i poslovne paradigme. Slika 2.1 prikazuje tipična razdoblja (s kratkim opisom) u evoluciji logistike, SCM i BDA.

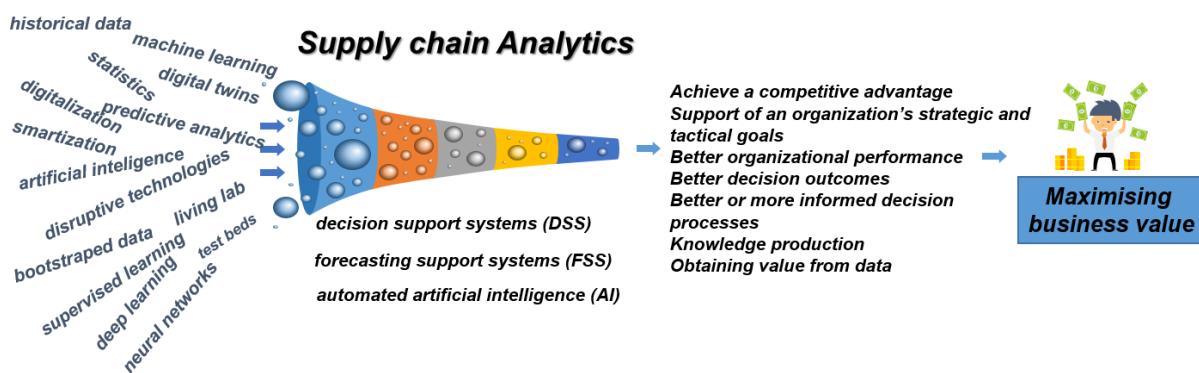


Slika 2.1 Evolucija logistike, SCM-a i BDA

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

## 2.2. Alati u analitici poslovnih podataka

Slika 2.2 prikazuje različite trendove, alate i prednosti koje se koriste u BDA ili SCA. Sve predstavljene analitičke tehnike mogu se kategorizirati u tri vrste: deskriptivne, prediktivne i preskriptivne. **Deskriptivna analitika** gleda podatke i analizira prošle događaje radi uvida u to kako pristupiti budućnosti. Traži se odgovor iza prošlih neuspjeha i uspjeha. **Prediktivna analitika** koristi povijesne podatke kako bi odredila vjerojatni budući ishod nekog događaja ili vjerojatnost da se situacija dogodi. Ona iskorištava obrasce pronađene u podacima za prepoznavanje budućih rizika i prilika. **Preskriptivna analitika** automatski sintetizira velike podatke, poslovna pravila i strojno učenje za predviđanje budućnosti. Ona nadilazi predviđanje budućnosti sugerirajući radnje koje je potrebno poduzeti kako bi se postigli željeni ciljevi. Također, njome je moguće pokazati implikacije svake moguće odluke i djelovati kao alat za podršku odlučivanju za stručnjake iz područja SCM-a. U sljedećim potpoglavlјjima bit će predstavljeni i opisani različiti analitički alati koji se koriste za BDA u SCM-u. Dodatno, fokus će biti na strategijama o tome kako unaprijediti znanje o BDA za stručnjake 21. stoljeća, putem nekoliko studija slučaja.



Slika 2.2 Trendovi, alati i koristi SCA

Izvor: Autor.

### 2.2.1. Deskriptivna analitika

Deskriptivna analitika daje sažetak deskriptivne statistike za određeni uzorak podataka, na primjer: srednja vrijednost, mod, medijan, raspon, histogram i standardna devijacija. Deskriptivna analitika opisuje što se dogodilo u prošlosti i izvodi informacije iz značajnih količina podataka kako bi odgovorila na pitanje što se događa. Na temelju informacija u stvarnom vremenu o lokacijama i količinama robe u opskrbnom lancu, menadžeri donose odluke na operativnoj razini (npr. prilagođavaju raspored otpreme, raspoređuju vozila, izdaju naloge za obnavljanje zaliha proizvoda itd.) (Souza, 2014). Deskriptivna analitika pokušava identificirati prilike i probleme korištenjem online sustava analitičke obrade i alata za vizualizaciju podržanih informacija u stvarnom vremenu i tehnologijom izvješćivanja (npr. GPS, RFID, transakcijski bar-kod). Uobičajeni primjeri deskriptivne analitike su izvješća koja pružaju povijesne uvide u proizvodnju, financije, poslovanje, prodaju, financije, zalihe i kupce tvrtke (Tiwari et al., 2018.).

### 2.2.2. Predictive analytics

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



### 2.2.3. Prescriptive analytics

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

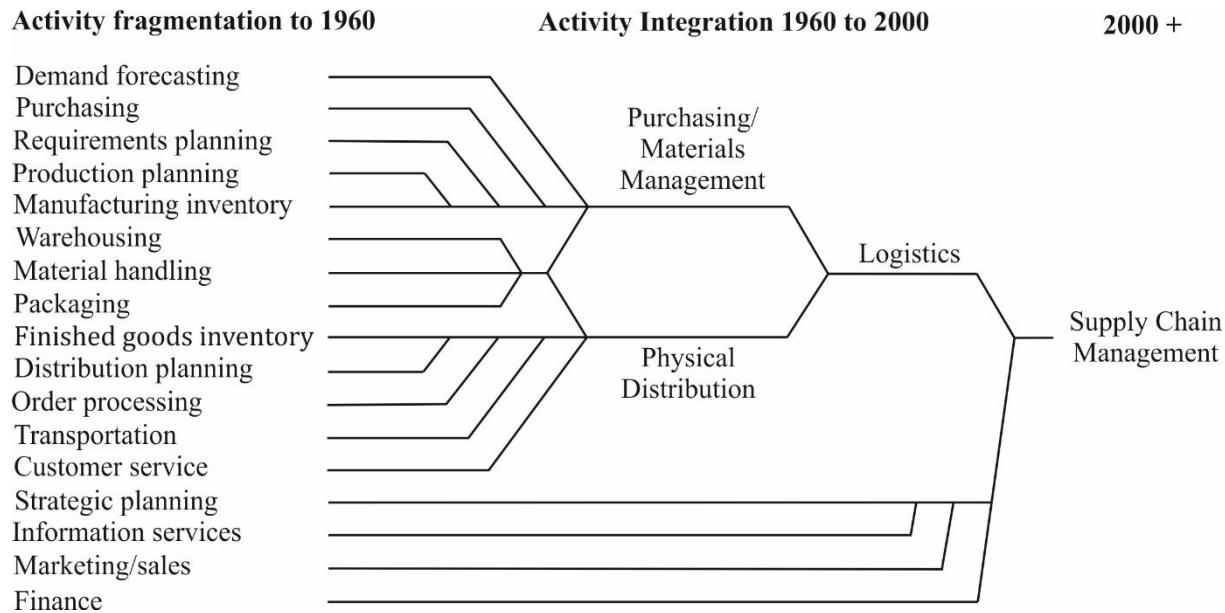
## 2.3. BDA ekosustav

Glavna svrha BDA ekosustava je isporuka vrijednosti za donositelja odluka. Sukladno tome, BDA ima primarni cilj omogućiti uvid u poslovne procese i odgovoriti kako smanjiti troškove i povećati razinu usluge za krajnje kupce. Kako bi se ispunio cilj, BDA rješenja obično se isporučuju u obliku sustava za podršku odlučivanju (DSS) ili eksperthog sustava (ES). Stoga će se u ovom i nadolazećim potpoglavlјima pojasniti ključni stupovi BDA: **poslovni podaci, rudarenje podataka i otkrivanje znanja** (analiza podataka, DSS, ES platforme itd.).

### 2.3.1. Poslovni podaci

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

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



**Slika 2.3 Evolucija logistike i opskrbnog lanca**

Izvor: Hesse i Rodrigue (2004).

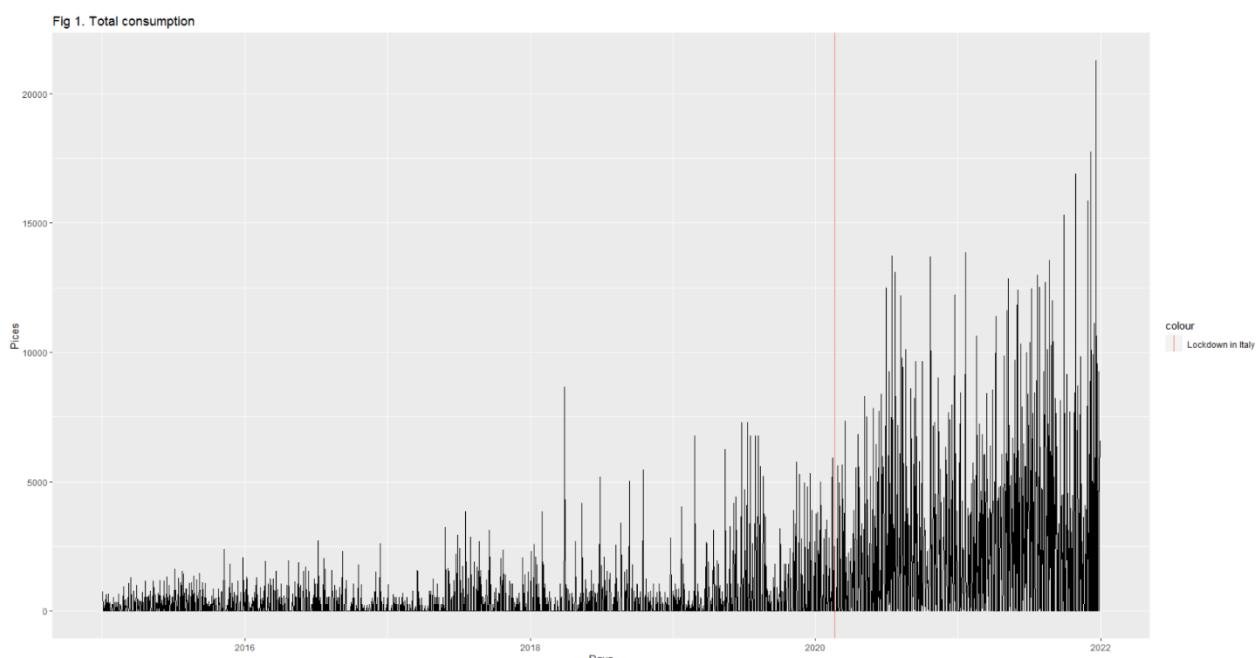
Vanjski podaci odnose se na podatke generirane izvan organizacije, koji mogu biti javni, nestrukturirani ili prikupljeni od strane trećih organizacija (privatni podaci). Za analitičare opskrbnog lanca posebno su značajni vanjski podaci koji se dijele između tvrtki unutar opskrbnog lanca, uključujući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

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



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

Drugi „problem“ s tržišno generiranim podacima je taj što ne slijede uobičajene statističke procese. To je problem jer većina matematičkih i statističkih metoda pretpostavlja da podaci slijede neki statistički proces. Ovo je vrlo vidljivo u opskrbnom lancu, gdje modeli zaliha pretpostavljaju da potražnja tijekom vremena isporuke slijedi normalnu distribuciju i razvijaju jednadžbe za izračun sigurnosnih zaliha na temelju te pretpostavke. Prema Mirčetiću et al. (2017), Mirčetiću et al. (2022) i Mirčetiću et al. (2018.), 90% podataka iz skupa od 97 serija u empirijskoj studiji industrije piva ne slijedi normalnu distribuciju. Također, modeli zaliha pretpostavljaju da je potražnja deterministička i ravnomjerno raspoređena kroz sva razdoblja, što u stvarnosti nije baš tako. Na primjer, na slici 2.4 prikazana je potražnja za unaprijed narezanim salamama u razdoblju od 2015. do 2022. za talijanskog proizvođača. Potražnja pokazuje jasno nedeterminističko, tj. stohastičko ponašanje (sa nasumičnim fluktuacijama i trendom).

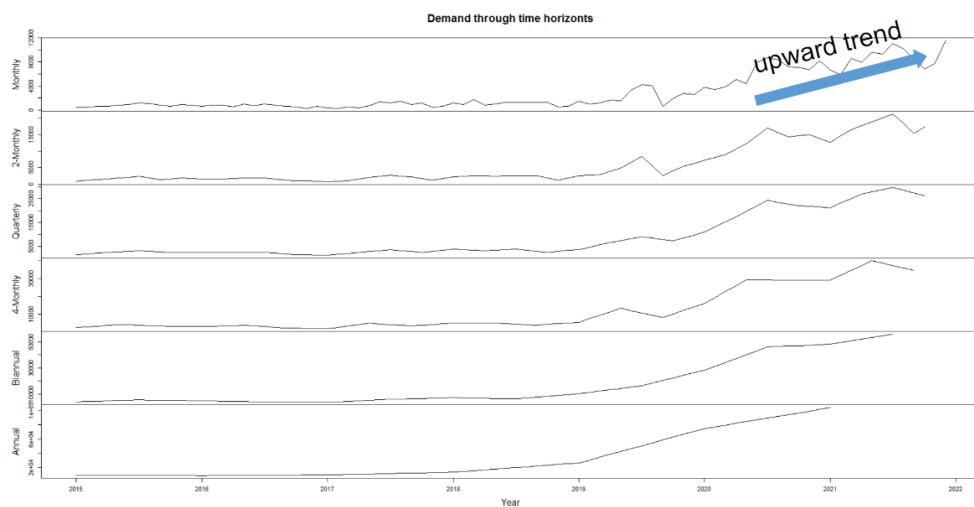


Slika 2.4 Potražnja za unaprijed narezanim salamama u razdoblju od 2015.-2022.

Izvor: Autor.



Dodatno, dnevna potražnja pokazuje vrlo nestabilno ponašanje, stoga agregacija potražnje kroz različita vremenska razdoblja (tjedno, mjesечно itd.) pokazuje jasan galopirajući trend potražnje (slika 2.5).

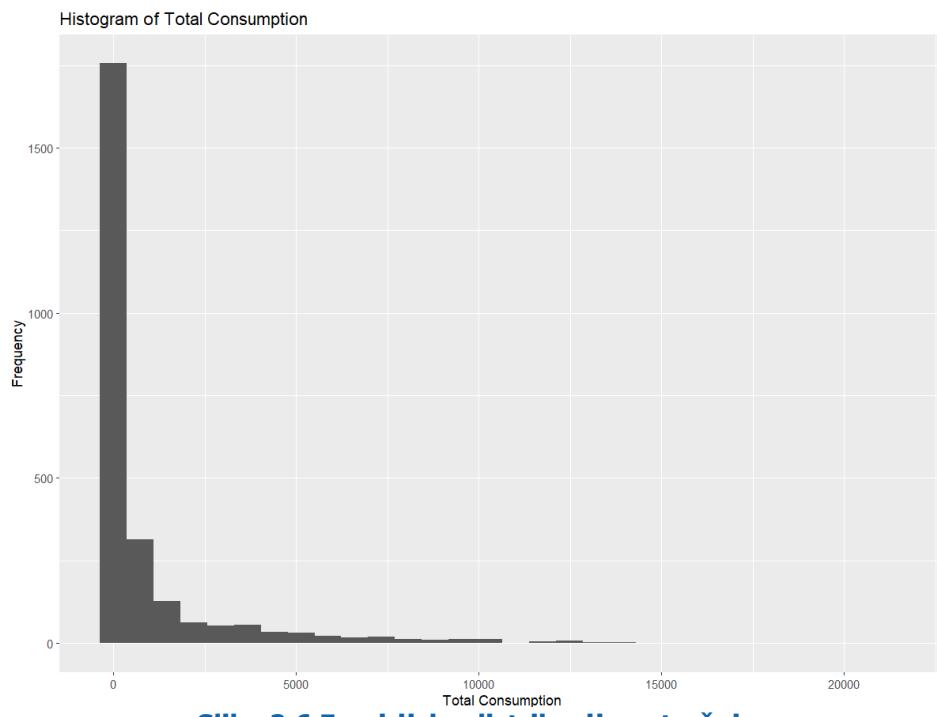


Slika 2.5 Agregacija potražnje kroz različite vremenske periode

Izvor: Autor.

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

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



Slika 2.6 Empirijska distribucija potražnje

Izvor: Autor.

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

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

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



## REFERENCE

1. Arunachalam, D., Kumar, N. & Kawalek, J. P. (2018). Understanding big data analytics capabilities in supply chain management: Unravelling the issues, challenges and implications for practice. *Transportation Research Part E*, 114, pp. 416-436.
2. Hesse, M. & Rodrigue, J.-P. (2004). The transport geography of logistics and freight distribution. *Journal of Transport Geography*, 12(3), pp. 171–184.
3. Mircetic, D., Rostami-Tabar, B., Nikolicic, S. & Maslarić, 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., Nikolićić, 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., Nikolićić, 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. Nikolićić, 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. RUDARENJE PODATAKA I

### OTKRIVANJE ZNANJA

Autor: Dejan Mircetić

Kao što je objašnjeno u 2. poglavlju, koncept izdvajanja podataka i generiranja znanja iz njih usko je povezan s **tehnikama rudarenja podataka (eng. Data Mining)**. U suvremenim poduzećima tehnike rudarenja podataka imaju veliki utjecaj na ukupne performanse poduzeća, jer se operativne, taktičke i strateške odluke donose na temelju ulaznih informacija dobivenih procesom rudarenja podataka. U 1. poglavlju navedeno je da je u svijetu dosad kreirano više od 97 zetabajta podataka, pri čemu pojedine baze podataka često dosežu veličinu u terabajtima. U većini organizacija podaci se udvostručuju svake dvije godine. Podaci pohranjuju na različitim platformama i u različitim formatima, uključujući strukturirane, nestrukturirane i polustrukturirane podatke (vidi Poglavlje 1). Procjenjuje se da do 90% poslovnih podataka postoji u nestrukturiranom formatu. Osim toga, značajan dio ovih podataka može sadržavati pogreške zbog neprikladne pohrane ili oblikovanja ili ručnih pogrešaka tijekom prikupljanja podataka. Kao rezultat toga, nisu svi podaci koje organizacije posjeduju nužno točni ili pouzdani. Ipak, ova golema količina podataka sadrži vrijedne strateške informacije za tvrtke. Međutim, kada se suočite s tako velikom količinom složenih tipova podataka, kako se oni mogu učinkovito 'rudariti' da bi se izvukli značajni uvidi koje sadrže? Odgovor leži u rudarenju podataka, koje služi za povećanje prihoda i smanjenje troškova brzim i automatskim izvlačenjem korisnog znanja i poslovnih uvida iz ogromnih skupova podataka.

Rudarenje podataka nastalo je iz potrebe za učinkovitim izvlačenjem vrijednih informacija, zahtijevajući tehnike koje su usmjerene na prepoznavanje razumljivih obrazaca koji se mogu protumačiti kao korisno ili zanimljivo znanje. Dakle, **rudarenje podataka je iterativni i interaktivni proces** usmjeren na otkrivanje valjanog, novog, korisnog i razumljivog znanja (obrasci, modeli, pravila itd.) u masivnoj bazi podataka (Behera et al., 2019). Glavni cilj rudarenja podataka je **otkriti kritične uvide** koji **podržavaju donošenje odluka** unutar poslovne organizacije.

U sljedećim potpoglavlјima govorit će se o tome kako se podaci 'rudare' za poslovnu analitiku i otkrivanje znanja.



### 3.1. Što je rudarenje podataka?

Prije definiranja rudarenja podataka, važno je smjestiti ovaj pojam u kontekst s drugim pojmovima s kojima se obično povezuje i često pogrešno poistovjećuje. Nestručnjaci često miješaju pojmove rudarenje podataka i Big data tehnologija. Međutim, to su dva različita pojma. **Big data opisuje** iznimno velike i složene **skupove podataka** koji zahtijevaju specijalizirane softverske aplikacije za obradu. S druge strane, **rudarenje podataka ide korak dalje** jer uključuje analizu tako golemih količina podataka kako bi se otkrila skrivena pravila i obrasci koji možda nisu lako vidljivi.

Data Mining je širok pojam koji obuhvaća različite analitičke tehnike, uključujući statistiku, umjetnu inteligenciju i strojno učenje. Ove se metode koriste za filtriranje golemih količina podataka pohranjenih u bazama podataka ili mrežnim spremištima organizacije. Primarni cilj je otkriti obrasce unutar skupa podataka. **Poslovna analitika (BA)** odnosi se na sveobuhvatan proces korištenja vještina, tehnologija, uspostavljenih praksi i algoritama povezanih s rudarenjem podataka. Stoga **rudarenje podataka obično služi kao pozadina BA funkcije**, dok se sučelje BA funkcije sastoji od metrika izvješćivanja i informacija predstavljenih u formatu koji omogućuje menadžerima donošenje informiranih poslovnih odluka. Kada koriste rudarenje podataka, BA stručnjaci ponašaju se kao 'podatkovni detektiv' (Lee, 2013), analizirajući podatke kako bi bolje opisali i razumijeli sadašnju i prošlu situaciju organizacije (deskriptivna analitika), predvidjeli buduće ishode (prediktivna analitika) i poduzeli učinkovite radnje (preskriptivna analitika).

Data Mining ključna je komponenta procesa **otkrivanja znanja u bazama podataka (KDD)**, ali predstavlja samo jedan korak u cijelokupnom procesu. Aspekt rudarenja podataka unutar KDD procesa usredotočen je na korištenje algoritama za izdvajanje i identificiranje uzoraka iz podataka. U širem KDD procesu, ti izrudareni obrasci se procjenjuju i potencijalno tumače kako bi se utvrdilo koji se obrasci mogu smatrati novim "znanjem" (Behera et al., 2019). Definirani na ovaj način, rudarenje podataka kao pozadina i otkrivanjem znanja kao nekom vrstom sučelja BA, predstavljaju, zajedno s poslovnim podacima, njegove ključne stupove kako je navedeno u poglavlju 2.

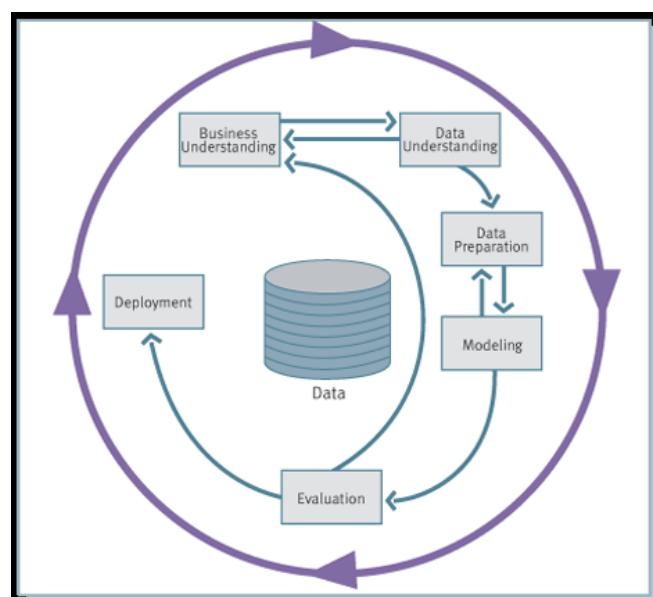
**Rudarenje podataka koristi razne algoritme za rudarenje ogromnih skupova podataka, identificirajući obrasce koji mogu dati vrijedne poslovne uvide.** Rudarenje podataka je alat, a ne čarobno rješenje. Ne promatra pasivno vašu bazu podataka i ne upozorava vas na zanimljive obrasce. I dalje je ključno razumijevanje vašeg poslovanja, vaših



podataka i analitičkih metoda. Rudarenje podataka pomaže poslovnim analitičarima otkriti obrasce i odnose u podacima, ali ne određuje vrijednost tih obrazaca za organizacije. Stoga rudarenje podataka ne zamjenjuje vješte poslovne analitičare, već im pruža snažan novi alat za poboljšanje njihovog rada.

Rudarenje podataka uključuje računalni proces identificiranja trendova, pravila, skrivenih obrazaca i drugih vrijednih informacija analizom velikih skupova podataka. Tehnika rudarenja podataka korijene ima u mnogim istraživačkim područjima, uključujući statistiku, strojno učenje, sustave baza podataka, vizualizaciju, neuronske mreže itd. To je proces izvlačenja djelotvornog znanja iz različitih izvora podataka raspoređenih u različite formate. Rudarenje podataka je posljednjih godina postalo sve relevantnije zbog napretka u tehnologijama pohrane podataka (Big data), umjetne inteligencije (AI) i robotske automatizacije procesa (RPA).

Proces **otkrivanja znanja u bazama podataka (KDD)** uključuje korištenje baze podataka, uključujući potrebnu selekciju, prethodnu obradu, poduzorkovanje i transformacije, za primjenu algoritama rudarenja podataka za identifikaciju obrazaca (Behera et al., 2019). Također uključuje ocjenjivanje rezultata rudarenja podataka. Uobičajeni standard za opisivanje koraka procesa otkrivanja znanja je CRISP-DM (eng. Cross-Industry Standard Process for Data Mining), koji je prikazan na slici 3.1.



Slika 3.1 Međuindustrijski standardni proces za rudarenje podataka (CRISP-DM)

Izvor: Rahman et al. (2016).

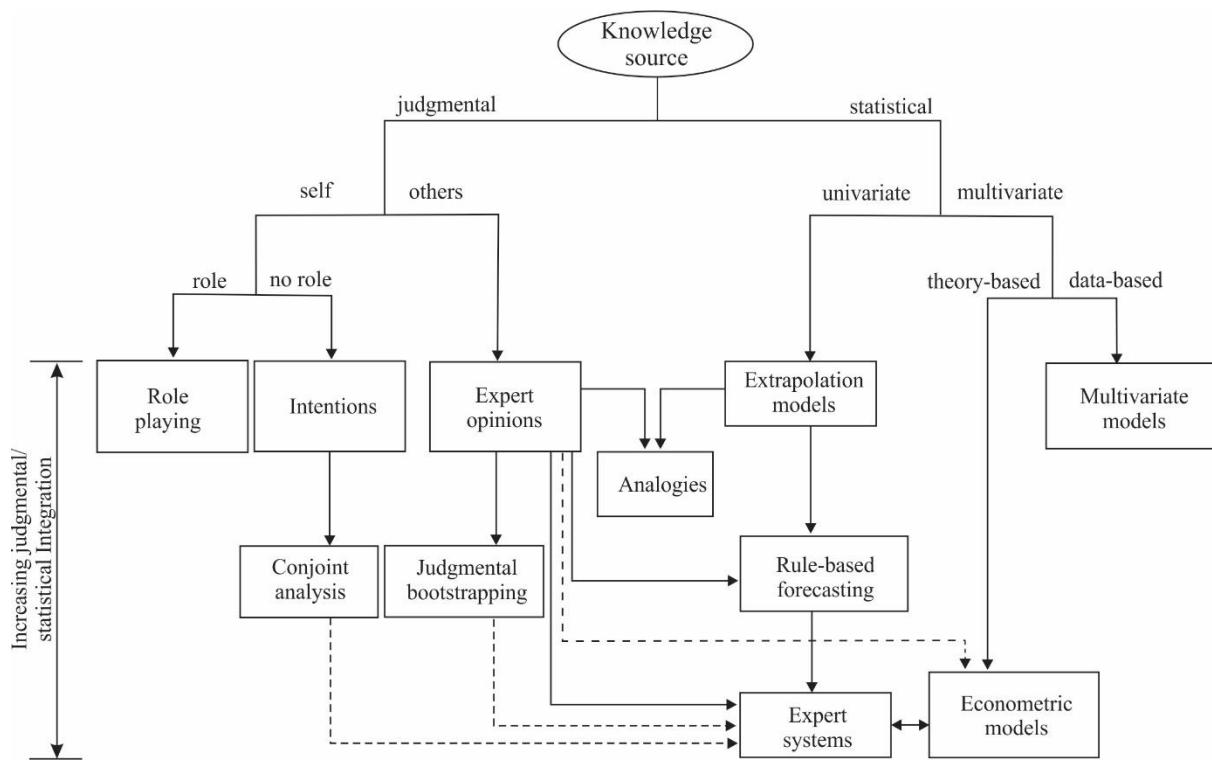


Na slici 3.1, prva faza je poslovno razumijevanje, što uključuje razumijevanje ciljeva koji se žele postići i provođenje detaljnog utvrđivanja činjenica o resursima i pretpostavkama. Druga faza, razumijevanje podataka, istražuje različite deskriptivne karakteristike podataka. Treća faza, priprema podataka, najzahtjevniji je i najdugotrajniji dio procesa KDD-a, s ciljem odabira relevantnih podataka i njihovog prikladnog oblikovanja za analizu. Ova faza uključuje aktivnosti poput odabira podataka, filtriranja, transformacije i integracije. Četvrta faza, modeliranje, podrazumijeva primjenu analitičkih metoda i odabir najprikladnijih algoritama. Ova faza također uključuje provjeru kvalitete modela kroz testiranje i unakrsnu validaciju. Peta faza, evaluacija, uključuje interpretaciju i procjenu otkrivenog znanja (Rahman et al., 2016).

### 3.2. Otkrivanje znanja u logistici i upravljanju opskrbnim lancem

U kontekstu opskrbnih lanaca i logistike, rudarenje podataka se razlikuje od drugih aplikacija opće namjene. Razlog je vezan uz već spomenutu raznolikost izvora podataka i struktura poslovnih podataka koji predstavljaju značajne izazove za inženjere pri dizajniranju odgovarajućih rješenja za modeliranje. Proces generiranja znanja iz podataka može se sažeti na slici 3.2.

Kao što je vidljivo na slici 3.2, otkrivanje i generiranje znanja iz podataka uvelike ovisi o izvoru znanja i može se podijeliti na **prosudbeno** i **statističko**. Oba smjera imaju svoje prednosti, ali je postupak izvlačenja znanja iz izvora bitno drugačiji. Za primjenu formalnijeg pristupa rudarenja podataka, tj. statističkog pristupa, ključni temelj je postojanje kvantitativnih podataka. U opskrbnim lancima postoji velik broj sektora, lokacija i transakcija koje generiraju tokove podataka koji se mogu koristiti za rudarenje podataka i izvlačenje korisnih povratnih informacija. S druge strane, u opskrbnom lancu i logistici također postoji puno izvora podataka koji nisu kvantitativni, pa stoga nisu podvrgnuti formalnim kvantitativnim postupcima. Ti su podaci tradicionalno podvrgnuti stručnim procjenama (Delphi metoda), a odluke se donose na temelju iskustva, znanja i autoriteta stručnjaka.



Slika 3.2 Principi izvlačenja znanja iz podataka

Izvor:

U ovoj knjizi naglasak će biti stavljen na **kvantitativnim/matematičkim tehnikama**, iako će se ukratko spomenuti i neke metodologije za dohvaćanje stručnog znanja u strukturiranim okvirima, tj. raspravlјат će se o ekspertnom sustavu i njegovim primjenama i primjerima.

### 3.3. Delphi pristup prosudbenom stvaranju znanja

Vrijedni uvidi iskusnih stručnjaka u domeni opskrbnog lanca i logistike često ostaju neprepoznati. Ove uvide treba podijeliti s manje iskusnim stručnjacima u tom području. Delphi metoda je jedan od pristupa za prikupljanje i širenje stručnog znanja. Prema Steureru (2011), metoda Delphi, nazvana po proročištu u Delfima u staroj Grčkoj, koja se u početku koristila za savjetovanje o raznim javnim i osobnim pitanjima u staroj Grčkoj, 1950-ih je evoluirala u tehniku u kojoj su stručnjaci zamijenili proroke za postizanje konsenzusa među grupom stručnjaka u nekom području. „Projekt Delphi”, osnovan od strane Zračnih snaga SAD-a, bio je prvi projekt koji koristi ovu metodu za predviđanje tehnološkog razvoja. Od tada se Delphi metoda razvijala i poboljšavala, pronalazeći primjene u raznim znanstvenim disciplinama. Delphi metoda razvijena je za postizanje pouzdanog stručnog konsenzusa, često služeći kao zamjena za empirijske dokaze kada takvi dokazi nedostaju. To jest, Delphi tehnika je iterativni



proces u kojem stručnjaci anonimno daju prosudbe o određenom pitanju, s ciljem prikupljanja konsenzusa i neslaganja zajedno sa svojim opravdanjima. To je visoko strukturirani grupni komunikacijski proces u kojem stručnjaci procjenjuju nesigurna i nepotpuna znanja (Naisola-Ruiter, 2022). Prema Paivarinti et al. (2011), Delphi metoda se, među ostalim, intenzivno koristi u istraživanju informacijskih sustava. Koristi se za odabir projekata IS-a, određivanje prioriteta za rizike projekta razvoja softvera, definiranje projektnih zahtjeva IS-a, preciziranje ključnih problema u upravljanju IS-om, stvaranje okvira za aktivnosti manipulacije znanjem, razumijevanje uloga i opsega sustava upravljanja znanjem u organizacijama.

Delphi metoda je postala standardna praksa za kvantificiranje ishoda grupnih procesa izvlačenja informacija. Koristi se u raznim disciplinama za predviđanje trendova, određivanje prioriteta istraživačkih područja, procjenu mogućih učinaka izbora različitih politika, utvrđivanje pokazatelja uspješnosti i razvoj kliničkih smjernica, među ostalim primjenama. **Delphi tehnika se također koristi u području opskrbnog lanca i logistike.** Na primjer, toplo se preporučuje kao instrument za identifikaciju i procjenu rizika opskrbe, za razne vrste evaluacije u logističkim procesima, za utvrđivanje najboljih logističkih praksi, za strateško odlučivanje i razvoj politike, za mapiranje budućih SCM praksi i za logističko predviđanje. Četiri ključne karakteristike ili osnovna načela Delphi metode su:

- Iterativni i višefazni proces (kao i prikupljanje podataka);
- Povratne informacije sudionika (kontrolirane na nekoj razini) s mogućnošću da sudionici revidiraju svoje odgovore;
- Statističko određivanje grupnog odgovora; i
- Određeni stupanj anonimnosti.

Tipičan Delphi proces uključuje predstavljanje niza pitanja u više rundi. Panelisti, odabrani zbog svoje stručnosti i znanja, odgovaraju anonimno. Nakon svakog kruga slijedi povratna informacija o agregiranim odgovorima, omogućujući sudionicima da vide kako se njihovi odgovori uspoređuju s odgovorima svih panelista. Panelisti tada mogu prilagoditi svoje odgovore i dati obrazloženja za sve promjene u sljedećim krugovima. Ovaj iterativni proces se nastavlja dok se ne postigne konsenzus ili dok se ne završi unaprijed određeni broj krugova.

### 3.3.1. Koraci u provođenju Delphi metode

Delphi metoda je strukturirani pristup koji podrazumijeva prikupljanje stručnih uvida i mišljenja kako bi se postigao konsenzus o određenoj temi. Proces obično uključuje četiri glavna koraka (Slika 3.3).



Slika 3.3 Koraci u provođenju Delphi metode

Izvor:

**Korak 1 - Definiranje ciljeva:** Početni korak uključuje definiranje ciljeva i opsega Delphi studije. To uključuje identificiranje specifičnih pitanja ili tema koje zahtijevaju mišljenje stručnjaka i navođenje ključnih pitanja o kojima će se raspravljati. Ovaj temeljni korak osigurava fokus i relevantnost studije kroz cijelo vrijeme.

**Korak 2 – Odabir stručnjaka:** Odabir ispravne grupe stručnjaka ključan je za uspjeh i učinkovitost Delphi tehnike. Ti bi stručnjaci trebali imati odgovarajuće znanje, vještine i iskustvo u vezi s temom koja se proučava. Grupa bi trebala biti raznolika kako bi ponudila širok spektar gledišta. Broj sudionika može varirati ovisno o veličini i složenosti studije, ali općenito se savjetuje uključivanje najmanje 10-15 stručnjaka.

**Korak 3 – Razrada i pokretanje upitnika:** Ovaj korak uključuje izradu upitnika za prikupljanje informacija od stručnjaka. Inicijalni upitnik je obično otvorenog tipa kako bi se stručnjacima omogućilo slobodno dijeljenje mišljenja bez utjecaja. U 1. krugu stručnjaci dobivaju upitnik otvorenog tipa i samostalno daju uvide, predviđanja ili prijedloge u vezi s ciljevima studije. U 2. krugu moderator sažima i anonimizira odgovore iz 1. kruga kako bi izradio konkretniji upitnik za sljedeći krug. Ako je potrebno, mogu se provesti dodatni krugovi za pročišćavanje mišljenja na temelju postignutih razina konsenzusa, nastavljajući dok se ne postigne unaprijed definirani konsenzus ili moderator ne odluči prekinuti proces.

**Korak 3 – Razrada i pokretanje upitnika:** Ovaj korak uključuje izradu upitnika za prikupljanje informacija od stručnjaka. Obično je početni upitnik otvorenog tipa kako bi se stručnjacima omogućilo slobodno dijeljenje mišljenja bez utjecaja. U 1. krugu stručnjaci dobivaju upitnik otvorenog tipa i samostalno daju uvide, predviđanja ili prijedloge u vezi s ciljevima studije. U 2. krugu voditelj sažima i anonimizira odgovore iz 1. kruga kako bi izradio usredotočeniji upitnik za sljedeći krug. Ako je potrebno, mogu se provesti dodatni krugovi za pročišćavanje mišljenja na temelju postignutih razina konsenzusa, nastavljajući dok se ne postigne unaprijed definirani konsenzus ili moderator ne odluči prekinuti proces.



**Korak 4 – Korištenje rezultata:** Nakon dovršetka Delphi procesa i postizanja konsenzusa, rezultati se analiziraju i koriste za donošenje odluka, predviđanje, razvoj politika ili druge svrhe navedene u ciljevima studije. Anonimnost Delphi studija pomaže osigurati da su konačni rezultati nepristrani i odražavaju kombiniranu stručnost uključenih stručnjaka.

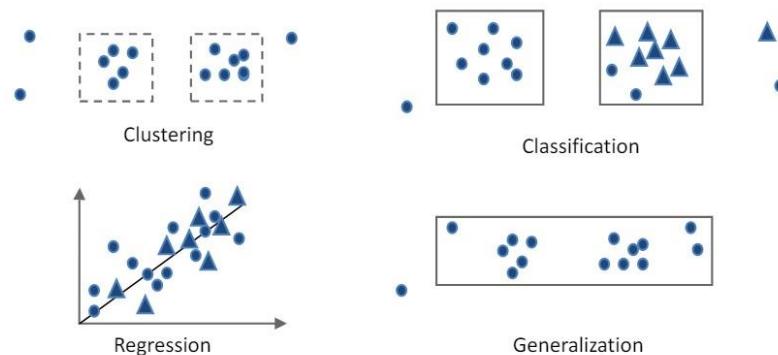
### 3.4. Kvantitativni pristup rudarenju podataka za otkrivanje znanja

Kao što je prikazano na slici 3.2, **kvantitativno rudarenje podataka uvelike se oslanja na formalne matematičke alate, točnije one statističke**. Mogli bismo tvrditi da se svaka statistička operacija nad podacima može smatrati kvantitativnom analizom. Glavna svrha ovih operacija je izvući stvarne obrazce iz podataka i dobiti korisne uvide u promatranom procesu (u slučaju analize u poduzeću ili opskrbnom lancu). Ovo nije jednostavan zadatak budući da postoji značajna neusklađenost između pretpostavki statističke/matematičke teorije i distribucija i obrazaca koji su prisutni u stvarnim poslovnim podacima. Većina poslovnih analiza u praksi temeljena je na toj neusklađenosti. Kod primjene kvantitativnih metoda od vitalne je važnosti da podaci ispunjavaju teorijske matematičke pretpostavke ograničene promatranim modelom, kako bi se rezultati modela tretirali kao valjani i potencijalno donosile odluke na temelju njih.

Kao što je objašnjeno u prethodnom poglavlju, metode rudarenja podataka čine temeljnu komponentu KDD procesa i stalno se koriste u njemu. Rudarenje podataka je multidisciplinarna tehnika, sa svojim analitičkim metodama utemeljenim na matematici. Statistika posebno igra vitalnu ulogu u analizi podataka tijekom faze pripreme podataka, čineći temelj za nekoliko metoda rudarenja podataka. Rudarenje podataka uključuje korištenje učinkovitih algoritama za otkrivanje očekivanih ili prepostavljenih obrazaca. Kao što je prikazano na slici 3.4, **zadaci rudarenja podataka** mogu se klasificirati u pet kategorija: grupiranje, klasifikacija, regresija, asocijacijska pravila i generalizacija. **Klasteriranje** ima za cilj grupirati objekte baze podataka tako da su objekti unutar klastera slični, dok su oni u drugim klasterima različiti. **Klasifikacija** uključuje učenje funkcije koja dodjeljuje vrijednosti atributa unaprijed definiranim klasama. **Regresija**, statistička metoda, procjenjuje odnose među varijablama i obično se koristi za predviđanje i predviđanje, a značajno se preklapa sa strojnim učenjem. **Asocijacijska pravila** koriste se za opisivanje jakih odnosa unutar transakcijskih procesa, kao što je "ako A i B tada C". **Generalizacija** nastoji izraziti veliku količinu podataka što kompaktnije (Su, 2016). Glavne



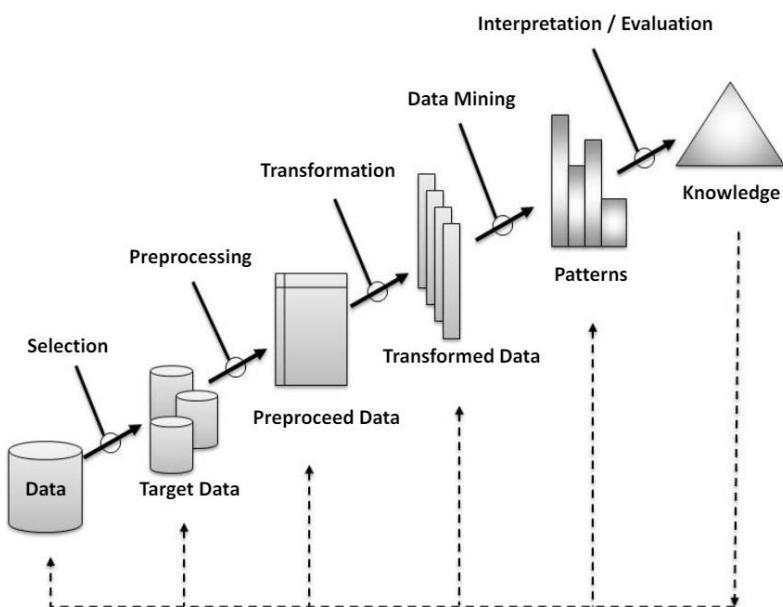
tehnike koje se koriste u rudarenju podataka su: pravila klasifikacije ili stabla odlučivanja, regresija, klasteriranje, genetski algoritmi, modeliranje temeljeno na agentima itd.



Slika 3.4 Zadaci rudarenja podataka

Izvor: Su (2016).

Znanje se može izvući iz obrađenih kvantitativnih podataka. **KDD proces sastoji se od devet koraka** kao što je prikazano na slici 3.5. Važno je napomenuti da se rudarenje podataka provodi nad transformiranim podacima, pri čemu su nerelevantne informacije već isključene iz izvornog skupa podataka. Obrasci otkriveni kroz ovaj proces zatim se tumače i procjenjuju unutar specifičnog konteksta kako bi se steklo znanje koje može pomoći u donošenju odluka.



Slika 3.5 Koraci koji čine KDD proces

Izvor: Fayyad et al. (1996).



Kao što je prethodno navedeno, zajednički standard za opisivanje koraka KDD procesa je CRISP-DM, koji predstavlja vodeći industrijski model. S obzirom na trenutne publikacije i studije koje je istražio Su (2016), tipične tehnike rudarenja podataka i primjene u opskrbnim lancima uključuju:

- **Stabla odlučivanja:** Rješavanje problema dobavljača koji se mogu svesti npr. za svaku odluku, skup mogućih ishoda, zajedno s procjenom vjerojatnosti da će se svaki ishod dogoditi
- **Regresija:** Predviđanje i procjena potražnje kupaca za novim proizvodom
- **Asocijacijska pravila:** Identificiranje ključnog uzroka kvara proizvoda, optimiziranje proizvodnog kapaciteta i omogućavanje održavanja temeljenog na stanju
- **Genetski algoritam:** Evaluacija poboljšane hipoteze rada VMI-a u neizvjesnom okruženju potražnje
- **Algoritmi klasteriranja:** S k-Mean algoritmom za kategoriziranje vraćene robe kako bi se poboljšala kvaliteta proizvodnih procesa ili raspoređivanje kupaca u različite segmente na temelju njihove demografije i kupovnog ponašanja.
- **Sustav rudarenja podataka s više agenata:** podrška odlukama o planiranju proizvodnje na temelju analize povijesne potražnje za proizvodima

Znanje izvučeno rudarenjem podataka obično se pohranjuje i prezentira korištenjem **ekspertnih sustava (ES)**. ES je sofisticirani sustav znanja dizajniran da oponaša ljudsku stručnost u različitim područjima primjene. Olson i Courtney (1992) definiraju ES kao „računalni program unutar određene domene, koji uključuje određenu količinu umjetne inteligencije za oponašanje ljudskog razmišljanja kako bi se došlo do istih zaključaka kao što bi to učinio ljudski stručnjak“. ES komponenta je idealna za pomoć donositelju odluka u području gdje je potrebna stručnost (Turban, 1995). U osnovi, ES prenosi stručnost od stručnjaka (ili drugog izvora) na računalo. Može podržati donositelje odluka ili ih u potpunosti zamijeniti, a najprimjenjiva je i komercijalno najuspješnija tehnologija umjetne inteligencije (Turban i dr., 2007.). Jedno od opravdanja za izgradnju ES-a je pružanje stručnog znanja velikom broju korisnika (Kock, 2005). Prema Turbanu et al. (2007), ES-ovi se smatraju dijelom sustava za potporu odlučivanju (eng. Decision Support Systems - DSS), koji bi se mogao okarakterizirati kao informacijski sustav temeljen na računalu koji kombinira modele i podatke u pokušaju rješavanja polustrukturiranih i nestruktuiranih problema uz opsežno sudjelovanje korisnika (Turban et al., 2007; Mirčetić et al., 2016). Sljedeće poglavje odnosi se na strojno učenje (ML), koje se odnosi na sposobnost računala da uče i predstavljaju znanje iz ulaznih podataka. ML se može



promatrati kao most između rezultata dobivenih rudarenjem podataka i alata poslovne inteligencije koji se koriste za predstavljanje metrike izvješćivanja u formatu koji omogućuje menadžerima donošenje informiranih poslovnih odluka.

## REFERENCE

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., Nikolić, 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

Autor: Dejan Mirčetić

Mnogo je pitanja o tome što je strojno učenje (eng. *Machine Learning* - ML). Je li to doista proces u kojem strojevi sami uče od vanjskog okruženja ili je to formalizirani proces putem matematičkih algoritama koji omogućuju računalima da „shvate“ pravila iz vanjskog svijeta? Koje alate koristi ML? Kako izgleda tipični tok podataka u ML cjevovodu? Je li ono primjenjivo na tradicionalne industrije, a ne samo na IT i industrije povezane s internetom? Gdje je mjesto ML-a u kontekstu poslovanja? Kako ga sustavno koristiti za rješavanje poslovnih problema? Postoji li arhitektura kako to primijeniti na opskrbne lancе?

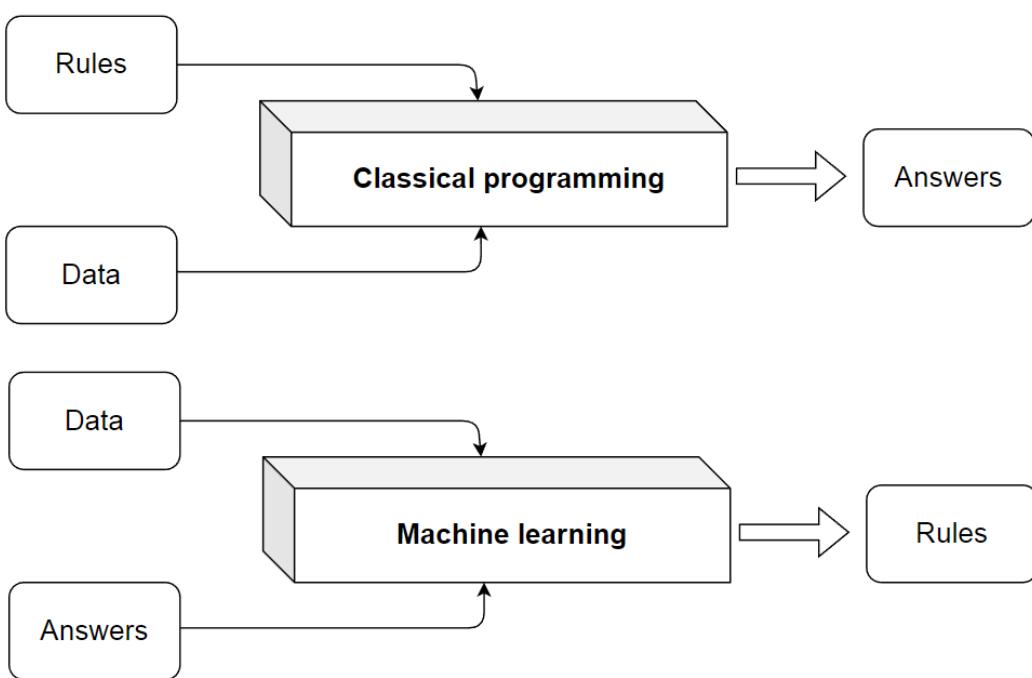
Na ova i slična pitanja pokušat će se dati odgovore u sljedećem poglavlju, a na kraju će se prikazati stvarne studije slučaja primjene ML algoritama u lancu opskrbe hranom.

### 4.1. Što je strojno učenje?

Strojno učenje je disciplina usmjerenata na dva međusobno povezana pitanja: Kako se može konstruirati računalni sustav koji se automatski poboljšava kroz iskustvo? i Koji su temeljni statistički računalno-informacijsko-teorijski zakoni koji upravljaju svim sustavima učenja, uključujući računala, ljudje i organizacije? Proučavanje strojnog učenja važno je za rješavanje ovih temeljnih znanstvenih i inženjerskih pitanja, ali i za vrlo praktičan računalni softver koji se koristi u mnogim aplikacijama (Jordan i Mitchell, 2015).

**ML proizlazi iz ovog pitanja: može li računalo ići dalje od onoga "Što znamo kako mu narediti da nešto izvrši" i samostalno naučiti kako izvršiti određeni zadatak?** Može li nas računalo iznenaditi? Umjesto da programeri ručno izrađuju pravila za obradu podataka, može li računalo automatski naučiti ta pravila gledajući podatke? Ovo pitanje otvara vrata novoj paradigmi programiranja (Chollet, 2021).

ML omogućuje temeljnu promjenu u paradigmi programiranja (slika 4.1). U klasičnom programiranju ljudski programer unosi pravila (program) i podatke koji se analiziraju i obrađuju u skladu s tim pravilima. Kao rezultat toga, odgovori se dobivaju kraju. S druge strane, kod ML-a ljudski programer unosi podatke s odgovorima koji se očekuju od podataka, i ishodom pravila.



Slika 4.1 Klasično programiranje vs. treniranje sustava pomoću ML-a

Izvor: Chollet (2021).

Klasično programiranje bi se moglo shvatiti kao imperativno programiranje budući da programer unaprijed definira sva pravila, a izvršavanje koda se izvodi u skladu s tim, dok bi se ML moglo shvatiti kao deklarativno programiranje gdje se izražavaju ciljevi više razine ili opisuju važna ograničenja, i oslanja se na matematičke algoritme za odluku kako i/ili kada to pretočiti u djelo.

Danas je ML temelj bezbrojnih važnih aplikacija, uključujući pretraživanje weba, zaštitu od neželjene pošte, prepoznavanje govora, preporuke proizvoda i još mnogo toga (Ng, 2017). Mnogi programeri sustava umjetne inteligencije sada prepoznaju da, za mnoge aplikacije, daleko lakše može biti uvježbati sustav pokazujući mu primjere željenog ulazno-izlaznog ponašanja, nego ga ručno programirati predviđanjem željenog odgovora za sve moguće ulaze. Učinak ML-a također se široko osjetio u računalnoj znanosti i u nizu industrija koje se bave problemima koji zahtijevaju veliki broj podataka, kao što su potrošačke usluge, dijagnoza grešaka u složenim sustavima i kontrola logističkih lanaca (Jordan i Mitchell, 2015).

## 4.2. Temelji i teorijske prepostavke strojnog učenja

Pozadina ML-a leži u matematici, točnije statistici. Stoga ML koristi teorijsku pozadinu i algoritme razvijene u **statističkom učenju**, a također postoji rasprava je li ML stvarno



područje za sebe ili je samo dio statistike. U praksi, ML algoritmima obično nedostaje određena razina matematičke rigidnosti i ponekad lako prelaze neka matematička ograničenja prisutna u statistici. Na primjer, ML algoritmi ne obraćaju puno pozornosti na intervale pouzdanosti kada optimiziraju koeficijente u parametarskim algoritmima, iako je to jedna od najvažnijih tema u statistici. Općenito, **postoji veliko preklapanje ML-a i statistike**, a neki od najpoznatijih kreatora ML algoritama i profesora koji se njima bave tvrde da je to samo dio statistike (Hastie et al., 2009). Bez obzira je li zasebno područje ili dio statistike, ML se sastoji od nekoliko koraka u stjecanju znanja iz podataka. Ne postoji opći konsenzus o ovim koracima, ali općenito, oni se mogu predstaviti kao transformacija različitih izvora podataka u uvide poslovne inteligencije.

U poslovnom kontekstu, ML modeli su beskorisni ako nemaju odgovarajuću podršku u pogledu predobrade podataka, rudarenja podataka i primjene uvida u stvarne procese. Stoga izrada ML algoritama bez mogućnosti ažuriranja modela i korištenja njegovog izlaza za stvarni proces donošenja odluka ne donosi nikakvu vrijednost modernim tvrtkama. U skladu s tim, u suvremenoj poslovnoj analitici, kvantitativni ML proces obično je dio tijeka rada poslovne inteligencije. Točnije, dio je važnih potprocesa poslovne inteligencije (znanost o podacima i analitika podataka kao dio poslovne inteligencije). Pojedinosti o ulozi ML-a u tim procesima i samim stvarnim procesima generiranja vrijednosti za poslovanje putem ML-a bit će navedene u sljedećem potpoglavlju.

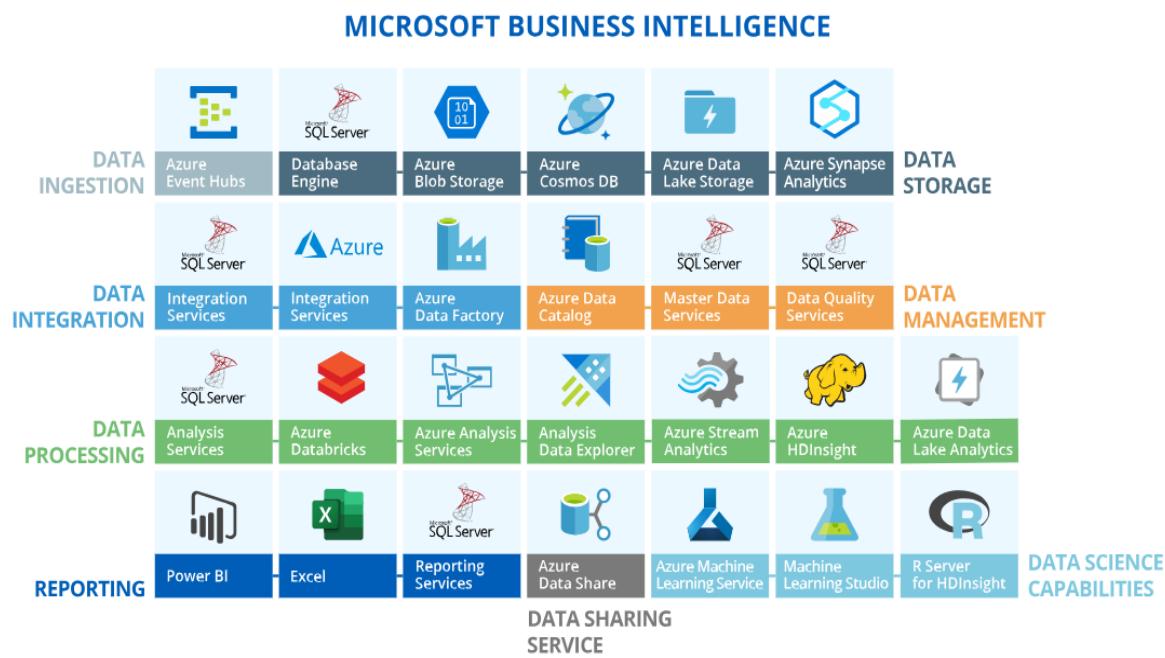
### 4.3. Poslovna inteligencija i ML u opskrbnom lancu

Poslovna inteligencija, u kontekstu opskrbnih lanaca, je proces donošenja zaključaka o promatranim procesima u opskrbnom lancu, na temelju modeliranja podataka iz tih procesa. Uglavnom se temelji na statistici, ali u obzir dolaze i druga matematička područja: operacijska istraživanja, linearna algebra, neizrazita logika (u slučaju kada su podaci oskudni ili nedostaju), numerička optimizacija, metaheuristika itd. Dodatno, nove disruptivne tehnologije također postaju važan aspekt za analizu podataka i donošenje zaključaka: **strojno učenje, umjetna inteligencija, digitalni blizanci, smartizacija, živi laboratorijski** itd.

Ne postoje stroge procedure o tome kako treba organizirati postupak poslovne inteligencije i rad ML-a, ali postoje neke korisne smjernice u praksi i literaturi koje su se pokazale uspješnim prilikom provođenja analize. Procedura za provođenje poslovne inteligencije također se razlikuje prema podrijetlu softvera koji se koristi za analizu. Na primjer, Microsoft nudi nekoliko alata putem svog kanala Microsoft Business Intelligence paketa koji obavljaju različite zadatke:



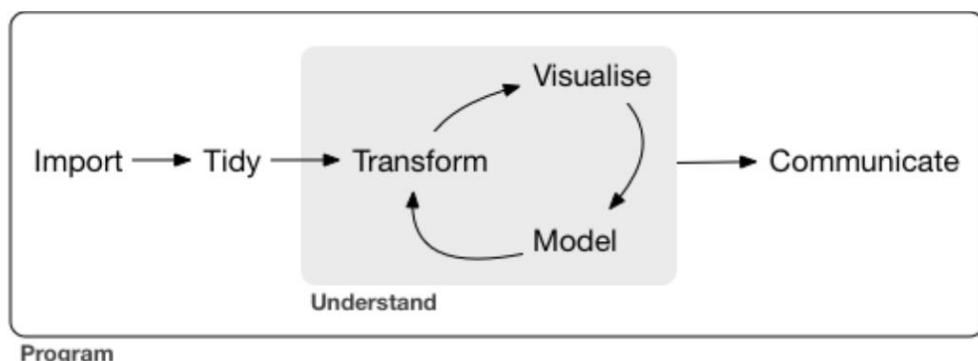
unos podataka, pohranu podataka, integraciju podataka, upravljanje podacima, obradu podataka, izvješćivanje, dijeljenje podataka i znanost o podacima (slika 4.2).



Slika 4.2 Arhitektura Microsoft business intelligence

Izvor: ScienceSoft (n.d.).

U određenoj arhitekturi ML procedure se primjenjuju samo na razini znanosti o podacima putem nekoliko alata: Azure ML usluge, ML studio i R Server za HDInsight. Opći postupak kako se analiza podataka u kontekstu ML-a izvodi u R Serveru prikazan je na slici 4.3.



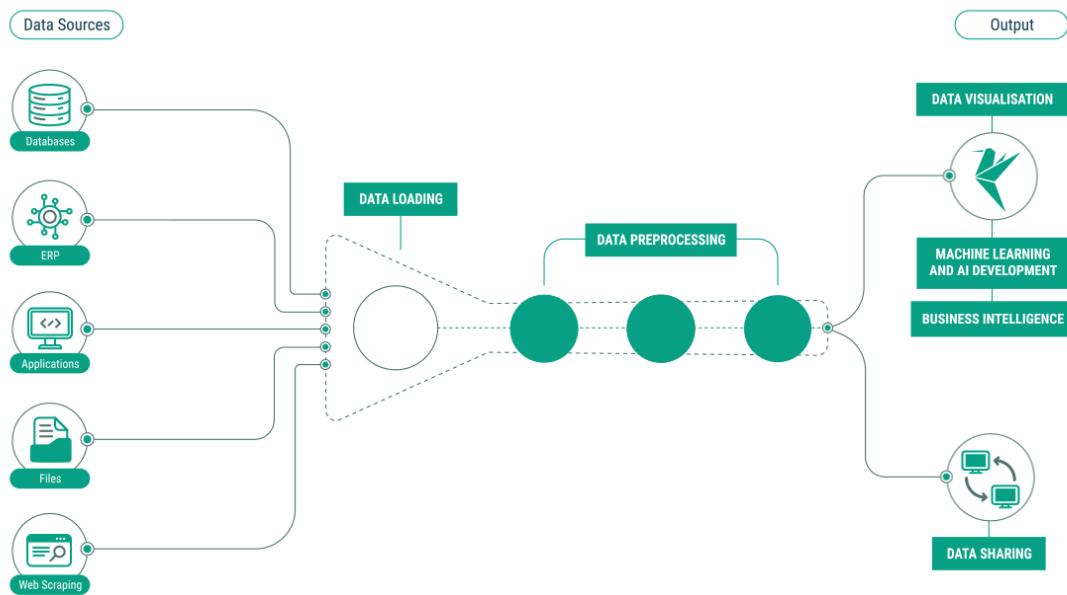
Slika 4.3 Koraci za analizu podataka pomoću ML-a u R Serveru

Izvor: Wickham et al. (2023).

Kada se radi o ML-u, obično postoji **zabluda da se većina vremena i truda troši na stvaranje ML algoritama**. Stvarnost je potpuno suprotna, većina vremena obično se troši na natezanje s podacima i zadatke predobrade, a ne na proces modeliranja. Ponekad su svi



procesi prije samog procesa modeliranja puno izazovniji i zahtjevniji. Zbog toga nema dvojbi o tome kako ove korake treba izvesti. Slika 2.9 prikazuje primjer dobrog pristupa pretvaranju podataka u poslovne uvide i opće znanje. Postupak započinje korakom uvoza, koji je jedan od najvažnijih koraka u izgradnji ML modela, budući da bez uvoza podataka u softver nije moguće provesti bilo kakvu analizu. To obično znači da se uzimaju podaci pohranjeni u datoteci, bazi podataka ili programskom sučelju web aplikacije (API) i učitavaju se u podatkovni okvir u R (Wickham et al., 2023). Drugi korak se odnosi na pospremanje podataka, što je postupak jedinstven za R i odnosi se na transformaciju podataka u određeni oblik za daljnju analizu (svaki stupac je varijabla, a svaki red je podatkovni okvir promatranja). Sljedeći korak vezan je uz transformaciju podataka koja obično uključuje sužavanje skupa opažanja na poduzorak od interesa. Dodatno, može također uključivati stvaranje novih varijabli kao kombinacije nekoliko postojećih ili generiranje skupne statistike. Vizualizacija i modeliranje imaju različite, ali komplementarne uloge u području analize podataka. Vizualizacija je aktivnost koja je duboko usmjerena na čovjeka i nudi uvide koji mogu promaknuti formaliziranim pristupima. Dobro kreirana vizualizacija može otkriti neočekivane uzorce, potaknuti nove upite i čak sugerirati da izvorna pitanja možda trebaju doradu ili drugačije podatke. Nasuprot tome, modeli pružaju matematički ili računalni okvir za odgovore na precizno formulirana pitanja. Nude skalabilnost i učinkovitost, što ih čini prikladnim za rukovanje velikim skupovima podataka. Međutim, modeli (u koje je također uključeno i ML) dolaze s inherentnim pretpostavkama i ne mogu dovesti u pitanje ili osporiti te pretpostavke. Posljedično, modeli možda neće imati mogućnost iznenaditi ili razotkriti nepredviđene uvide. Sinergija između vizualizacije i modeliranja očita je u njihovoj zajedničkoj ulozi u analizi podataka. Vizualizacija pomaže u početnom istraživanju, potičući formuliranje preciznih pitanja, dok modeli sustavno daju odgovore unutar definiranih parametara. Prepoznavanje snaga i ograničenja svakog pristupa je ključno, što vodi do sveobuhvatnijeg i informiranijeg procesa analize podataka. Posljednji korak predstavlja komunikaciju koja je ključna za uspjeh analize podataka jer ako se informacija ne dostavi donositelju odluka na pravi i dosljedan način, onda bi cijela analitika mogla biti uzaludna. Ključni element u analitici podataka su ML modeli, bez kojih se ne bi mogli donositi zaključci o poslovnim procesima. Kako bi se uhvatili u koštac sa specifičnim problemima opskrbnog lanca, arhitektura za aplikacije poslovne inteligencije opće namjene (predstavljene na slici 4.2) mora biti bolje podešena, kao i ML modeli. U skladu s tim, kako bi transformirala način na koji lanci opskrbe funkcioniraju povećanjem operativne učinkovitosti, poboljšanjem donošenja odluka i usmjeravanjem prema postizanju korporativnih ciljeva, tvrtka Equilibrium AI razvila je AI & ML platformu prikazanu na slici 4.4.



**Slika 4.4 Cjevod ML podataka i znanja za tvrtku Equilibrium AI**

Izvor: Equilibrium AI (n.d.).

Slika predstavlja dobar primjer svakodnevne prakse kako se ekstrakcija znanja i uvida generira u aplikacijama vezanim uz opskrbni lanac. Općenito, proces se sastoji od backend i frontend operacija kako bi se stvorila vrijednost (poslovni uvidi) za korisnike. Pozadinski proces počinje izdvajanjem podataka iz različitih izvora podataka koji se obično nalaze u opskrbnim lancima:

- Baze podataka;
  - Sustavi za planiranje resursa poduzeća (SAP, Navigator, Microsoft Dynamics, itd.);
  - Aplikacije (web API);
  - Flat datoteke (csv, xlsx, JSON, itd.);
  - Web, internet i drugi mrežni izvori.

Svaki od izvora podataka ima drugačiju strukturu, protokole i sukladno tome postupke za to kako se podaci ekstrahiraju i učitavaju za čišćenje i preprocesiranje prije primjene ML algoritama. Sukladno tome, ovaj se proces odvija preko tzv. *data loadera* koji imaju unaprijed programiran kod za rudarenje različitih izvora podataka i prijenos redova podataka u novu bazu podataka, koja je strukturirana i uređena za primjenu ML modela. Prije primjene ML modela, postoji jedan dodatni korak koji se zove preprocesiranje podataka. U ovom koraku u retku podataka prikupljenih od tvrtki provjeravaju se pogrešni ulazi, nelogičke vrijednosti, ispravna struktura ulaza, outlieri, dvostruki unosi, NA, NaN, itd. Postupak se nastavlja



spajanjem vanjskih podataka s podacima tvrtke. Ti su podaci obično povezani s vanjskim čimbenicima koji mogu potencijalno utjecati na promatrani poslovni proces opskrbnog lanca, na primjer, vremenski podaci, indeks potrošačkih cijena, prosječni dohodak u određenoj regiji, specifične demografske karakteristike u određenom području, cijene plina, izbjivanja pandemije, komentari na društvenim mrežama o proizvodima tvrtke itd. Ovo je vrlo važno jer holistički prikuplja sve moguće čimbenike (unutarnje i vanjske) koji mogu utjecati na određeni poslovni proces, čime se povećava šansa da će ML modeli pronaći pravi signal u podatku i moći donijeti ispravan zaključak i pravila koji su glavni uzroci razlozi zašto se poslovni proces ponaša kao što je opaženo.

Nakon spajanja unutarnjih i vanjskih podataka, preprocesiranje se sastoji od otkrivanja signala, uklanjanja grešaka iz podataka, inženjeringu značajki i nasumične podjele podataka skup za treniranje i testiranje (ponekad na validacijske podatke ako se razvija model neuronske mreže). Podaci koji izlaze iz koraka preprocesiranja čiste se i strukturiraju za primjenu ML modela.

Izlazni dio sastoji se od vizualizacije podataka, razvoja ML & AI i dijeljenja podataka. Ponekad se ti podaci dijele bez primjene ML modela na druge platforme koje provode različite vrste analiza (samo izvješćivanje dionika ili vladinih agencija). Proces vizualizacije izvodi se preko frontend dijela platforme koji je usmjeren na korisnika i omogućuje korisnicima da postavljaju zahtjeve o tome koje podatke, kako i u kojim postavkama žele vidjeti promatrane podatke (na primjer slika 4.5).

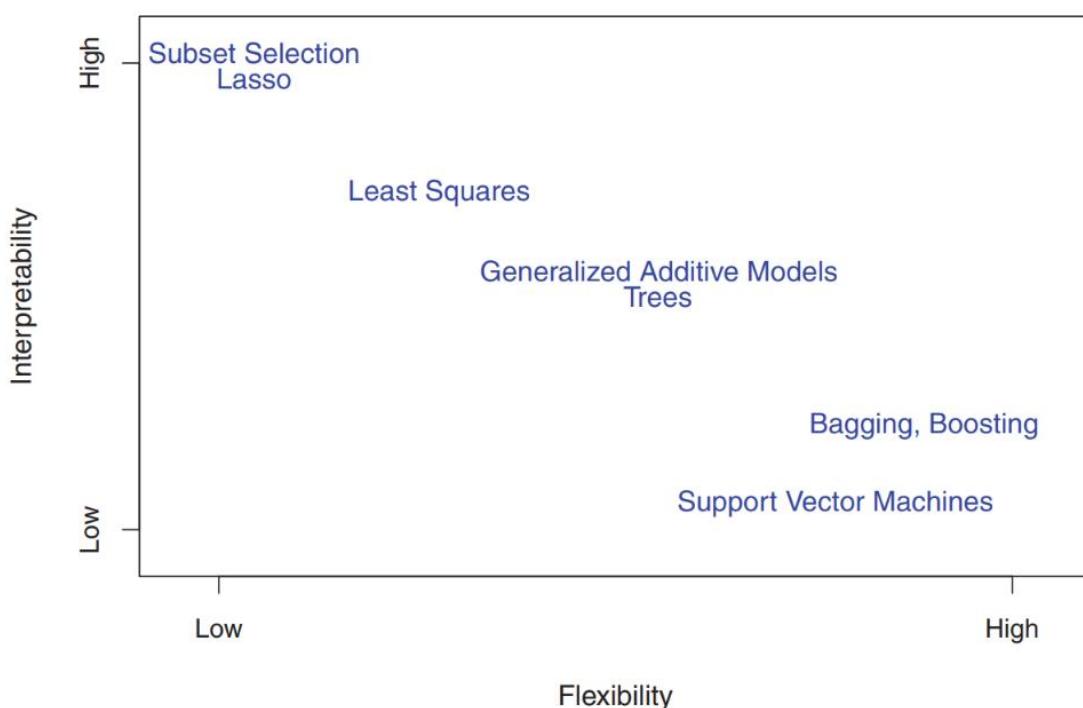


Slika 4.5 Tipični dio vizualizacije ML platforme u opskrbnim lancima

Izvor:



S druge strane, ML dio obrade podataka skriven je od očiju korisnika i nije ga lako razumjeti. Zbog toga se ML modeli ponekad smatraju modelima **crne kutije** u kojima ne postoji jasno razumijevanje kako je stroj točno povezao promatrani ulaz s promatranim izlazom. To je jedna od prepreka koja onemogućuje širu upotrebu ML modela u praksi, posebno onih koji su složeni za tumačenje (Rostami-Tabar i Mircetic, 2023). Sukladno tome, mogli bismo podijeliti ML modele na one s visokom interpretabilnošću - niskom fleksibilnošću i s niskom interpretabilnošću - većom fleksibilnošću (slika 4.6). Općenito, kako se fleksibilnost ML metode povećava, točnost ML modela se obično povećava, a interpretabilnost smanjuje (Mirčetić et al., 2016).



**Slika 4.6 Prikaz kompromisa između fleksibilnosti i interpretabilnosti, korištenjem različitih ML metoda**

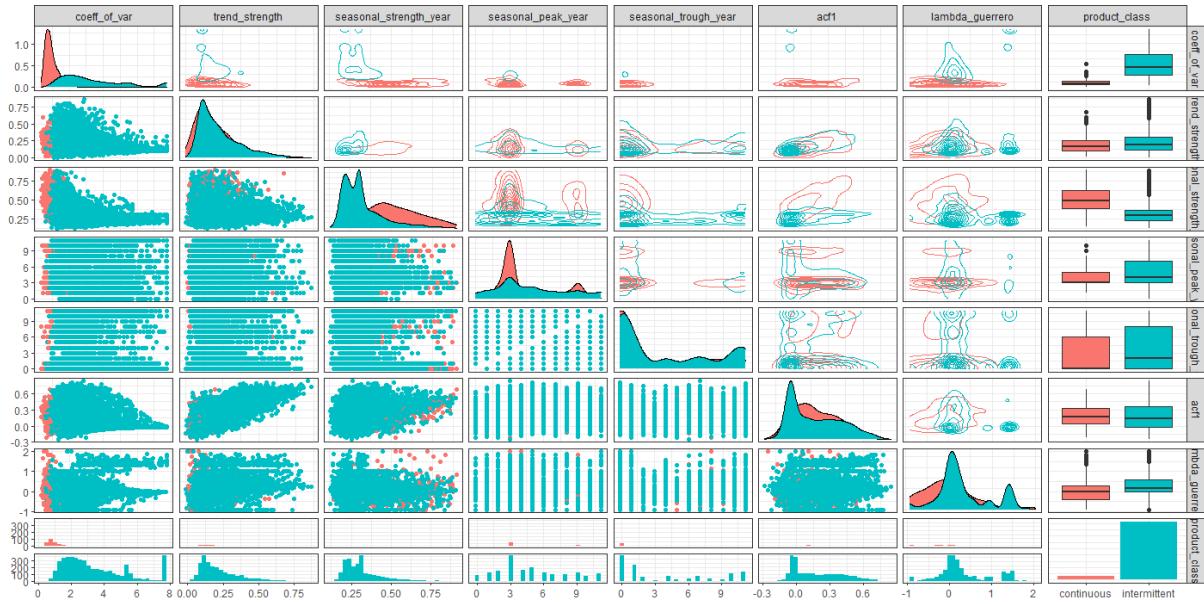
Izvor: Hastie et al. (2009).

#### 4.3.1. ML i poslovni podaci iz opskrbnog lanca

Ako korisnici bolje razumiju vizualizaciju i grafiku kao što je slika 4.5, zašto nam uopće treba ML i možemo li preskočiti modeliranje podataka pomoću ML-a i samo napraviti informativnu grafiku? Nažalost ne. Možda je glavni razlog zašto su nam potrebni ML modeli taj što nije moguće u svim situacijama imati lako čitljive i detektabilne uzorke u podacima koji se vide putem grafike (kao na slici 4.5). Češća je situacija da grafika obično ne može otkriti misterij onoga što se događa u promatranim poslovnim podacima i potrebni su nam jači alati u obliku



ML algoritama za dublje kopanje u podatke i traženje **pravila za generiranje podataka** (slika 4.7) .



**Slika 4.7 Statističke karakteristike proizvoda u lancu opskrbe hranom (sažeto za sve proizvode)**

Izvor:

Vrlo je teško donijeti lake zaključke iz slike 4.7 i izvesti poslovna pravila o procesu generiranja podataka. Kako bismo pronašli uzorke u podacima sa slike, razvili smo ML model koji bi se mogao koristiti za sažimanje karakteristika i otkrivanje važnih signala u podacima. U skladu s tim, razvijeni ML model za lanac opskrbe hranom predstavljen je u jednadžbi 1. Osnovni pokretač i okosnica ovog ML modela je autoregresivni integrirani model pomicnog prosjeka, sa sljedećim općim oblikom:

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

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

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

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

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

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



ML model jasno pokazuje svoju nisku interpretabilnost i karakteristike crne kutije. Prosječnom poslovnom korisniku teško je razumjeti veze između ulaznih i izlaznih podataka. Štoviše, prosječnom poslovnom korisniku kada se suoči s predstavljenim modelom nameće se pitanje! Što je jednadžba (1)? Mogli bismo tvrditi da jednadžba (1) predstavlja pravila sa slike 4.1, generirana cjevovodom ML podataka i znanja, koji otkriva misterij o procesima generiranja podataka u danom SC poslovnom okruženju.

Na prvi pogled, čini se da razvijeni ML model u jednadžbi (1) ne poboljšava naše razumijevanje podataka. Još uvijek smo zbuljeni kao sa slikom 4.7, ali ML model ima ključnu prednost u odnosu na sliku. U biti, ML model je **matematička formula** koja možda nije lako razumljiva ljudskom korisniku, ali je potpuno razumljiva računalu, koje **se može programirati da koristi zadalu formulu** i donosi **poslovne odluke** na temelju otkrivenih pravila.

## REFERENCE

1. Chollet, F. (2021). Deep learning with Python. Simon and Schuster.
2. Equilibrium AI (n.d.). Equilibrium AI Data Pipeline [available: <https://eqains.com/>, pristupljeno: 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., Nikolićić, 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.mlyarning.org/](http://www.mlyearning.org/), pristupljeno: 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>, pristupljeno: January 23, 2024]



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



## 5. UPRAVLJANJE POSLOVNIM PROCESIMA I RUDARENJE PROCESA

Autor: Dario Šebalj

Da biste ostali konkurentni u današnjem poslovnom okruženju, ključni su učinkovito upravljanje i kontinuirano poboljšanje procesa. Ovo poglavlje istražuje upravljanje poslovnim procesima (BPM) i rudarenje procesa, dva važna dijela poslovne inteligencije koji pomažu tvrtkama analizirati, optimizirati i poboljšati svoje operativne procese.

BPM pruža organiziranu i strukturiranu metodu za identificiranje, projektiranje, izvršavanje, praćenje i poboljšanje poslovnih procesa dok ih istovremeno usklađuje sa strateškim ciljevima organizacije. Rudarenje procesa je, s druge strane, alat za identifikaciju i poboljšanje stvarnih procesa ekstrakcijom znanja iz dnevnika događaja koji se nalaze u modernim poslovnim informacijskim sustavima. Kombinacija upravljanja poslovnim procesima i rudarenja procesa omogućuje objektivnu, podacima vođenu metodu za razumijevanje i poboljšanje poslovnih procesa.

Korištenjem ovih metodologija, organizacije mogu pronaći skrivene neučinkovitosti i probleme, prilagoditi se promjenjivim zahtjevima tržišta i poboljšati svoje performance te povećati zadovoljstvo kupaca. U ovom poglavlju bit će obrađeni temeljni koncepti, metodologije, alati i stvarne primjene BPM-a i rudarenja procesa.

### 5.1. Poslovni proces

Svaka organizacija, bez obzira na veličinu ili sektor, složen je sustav međusobno povezanih procesa. Ovi procesi su strukturirane aktivnosti koje se poduzimaju kako bi se postigao određeni organizacijski cilj. Na primjer, u proizvodnoj tvrtki ključni procesi mogu uključivati dizajn proizvoda, nabavu sirovina, proizvodnju, kontrolu kvalitete i distribuciju. U poslu orijentiranom na usluge kao što je banka, procesi uključuju otvaranje računa, obradu kredita, korisničku službu i provjere usklađenosti. Organizacije svakodnevno koriste procese, a ti procesi mogu biti različiti kao i same organizacije. U bolnici procesom se smatra sve od prijema



pacijenta do liječenja i otpusta. U obrazovnoj instituciji oni obuhvaćaju upis studenata, izvođenje nastave i provođenje ispita. Svaki proces je slijed koraka koji uključuje različite odjele i osoblje, a često je podržan tehnologijom.

Prema Dumasu et al. (2018), svaki se poslovni proces sastoji od nekoliko događaja i aktivnosti.

**Događaji** predstavljaju stvari koje nemaju trajanje i događaju se u određenom trenutku (npr. 'Narudžba zaprimljena'). S druge strane, **aktivnosti** su zadaci ili operacije koje su međusobno povezane i čijim se izvršavanjem ispunjava cilj poslovnog procesa (npr. 'Plaćanje računa'). Tipičan proces, osim događaja i aktivnosti, uključuje i **odluke**, koje označavaju fazu u kojoj proces odlučuje u kojem će smjeru ići. Na primjer, u procesu prodaje jedna točka odluke može biti kada prodavač provjerava je li proizvod na zalihi, proces prelazi na sljedeću aktivnost. Ukoliko proizvoda nema na skladištu, proces se odvija na drugi način (npr. obaveštavanjem kupca da se narudžba ne može izvršiti). Važni dijelovi procesa su sudionici i objekti. **Sudionici** uključuju ljudе, organizacije ili softverske sustave koji izvode procesne aktivnosti, dok su **objekti** oprema, materijali, papirnati dokumenti (fizički objekti), elektronički dokumenti i zapisi (informacijski objekti).

Dumas et al. (2018) navode da izvršenje procesa rezultira jednim ili više **ishoda**. Ishod bi, u teoriji, trebao koristiti svim stranama uključenim u proces (*pozitivan ishod*). Ponekad je ta vrijednost samo djelomično postignuta ili nije nikad postignuta (*negativan ishod*).

Von Scheel et al. (2015) definiraju **poslovni proces** kao „skup zadataka i aktivnosti (poslovnih operacija i akcija) koji se sastoje od zaposlenika, materijala, strojeva, sustava i metoda koji su strukturirani na takav način da dizajniraju, stvaraju i isporučuju proizvod ili uslugu potrošaču”.

Razumijevanje procesa samo je početak. Istinski problem, ali i prilika, jest sustavno i planski upravljanje tim procesima. To dovodi do sljedećeg poglavljа: Upravljanje poslovnim procesima (BPM). U ovom potpoglavlju bit će dan pregled pristupa i okvira koji organizacijama omogućuju, ne samo upravljanje, već i izvršavanje svojih procesa. BPM je više od pukog snimanja i analize procesa; to je sveobuhvatna metoda razvoja, implementacije, praćenja i stalnog poboljšanja poslovnih procesa.

## 5.2. Upravljanje poslovnim procesima

U znanstvenoj i stručnoj literaturi susrećemo različite definicije upravljanja poslovnim procesima. Gartner (n.d.) definira BPM kao „disciplinu koja koristi različite metode za otkrivanje, modeliranje, analizu, mjerjenje, poboljšanje i optimizaciju poslovnih procesa”.



Prema Camundi (n.d.), BPM je „sistemski pristup za snimanje, projektiranje, izvođenje, dokumentiranje, mjerjenje, praćenje i kontrolu automatiziranih i neautomatiziranih procesa kako bi se ispunili ciljevi i poslovne strategije tvrtke“. Swenson i Rosing (2015) predložili su širu i možda najprecizniju definiciju: „Upravljanje poslovnim procesima (BPM) je disciplina koja uključuje bilo koju kombinaciju modeliranja, automatizacije, izvršenja, kontrole, mjerjenja i optimizacije tokova poslovnih aktivnosti u primjenjivoj kombinaciji za podršku ciljeva poduzeća, nadilazeći organizacijske i sistemske granice te uključujući zaposlenike, klijente i partnere unutar i izvan granica poduzeća“.

Prema Freundu i Rückeru (2012), novi BPM projekti često uključuju jedan od ovih scenarija:

1. Poboljšanje procesa korištenjem informacijske tehnologije (IT)
2. Dokumentacija tekućih procesa
3. Uvođenje potpuno novih procesa.

Dumas et al. (2018) vide BPM kao kontinuirani ciklus koji se sastoji od sljedećih faza:

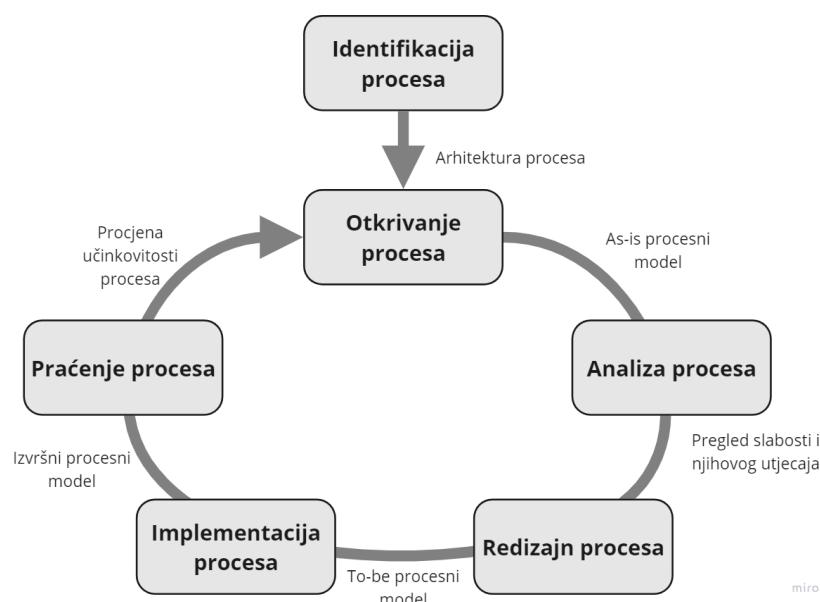
- **Identifikacija procesa** - U ovom koraku dan je poslovni problem. Identificiraju se, definiraju i povezuju procesi koji su važni za problem koji se rješava. Rezultat identifikacije procesa je nova ili poboljšana arhitektura procesa. Ova arhitektura prikazuje sve procese u organizaciji i kako su međusobno povezani. Koristi se za odabir procesa koji će se analizirati kroz cijeli životni ciklus.
- **Otkrivanje procesa (As-is modeliranje)** - Ovdje se dokumentira trenutno stanje svih važnih procesa, obično u obliku jednog ili više "As-is" procesnog modela.
- **Analiza procesa** - Tijekom ovog koraka, problemi s trenutnim As-is procesom se identificiraju, dokumentiraju i, ako je moguće, mjere pomoću pokazatelja performansi. Rezultat ovog koraka je strukturirani popis problema koji su poredani prema mogućem utjecaju i procijenjenom trudu potrebnom za njihovo rješavanje.
- **Redizajn procesa (To-be modeliranje)** – Cilj ove faze je pronaći modifikacije procesa koje će omogućiti tvrtki da ispuni svoje ciljane performanse, a istovremeno se bavi problemima pronađenim u prethodnoj fazi. Ova faza obično rezultira modelom budućeg procesa.
- **Implementacija procesa** - Tijekom ove faze planiraju se i provide prilagodbe potrebne za transformaciju As-is procesa u To-be proces. Automatizacija i upravljanje organizacijskim promjenama dva su aspekta implementacije procesa. Pojam "upravljanje organizacijskim promjenama" opisuje skup radnji potrebnih za promjenu



načina rada svih sudionika uključenih u proces. Izrada i implementacija IT sustava (ili poboljšanih verzija postojećih IT sustava) za podršku budućim procesima naziva se automatizacija procesa.

- **Praćenje procesa** – nakon implementacije redizajniranog procesa prikupljaju se i analiziraju relevantni podaci kako bi se procijenila učinkovitost procesa. Korektivna radnja se pokreće nakon što se identificiraju uska grla, ponavljajuće pogreške ili odstupanja od planiranog ponašanja.

Ovaj ciklus se mora stalno ponavljati jer bi se mogli pojaviti novi problemi u istom ili nekim drugim procesima. Životni ciklus BPM-a prikazan je na slici 5.1.



Slika 5.1 BPM životni ciklus

Izvor: Dumas et al. (2018).

Freund i Rücker (2012) navode nekoliko uloga koje su uključene u BPM projekte:

- **Vlasnik procesa** – osoba koja ima stratešku odgovornost za procese. Ima proračunske ovlasti, a često je i član prvog ili drugog sloja menadžmenta. Na primjer, vlasnik procesa može biti izvršni direktor tvrtke.
- **Voditelj procesa** – osoba koja ima operativnu odgovornost za procese. Često je to menadžer niže ili srednje razine. Na primjer, voditelj prodaje može biti voditelj procesa.
- **Sudionik procesa** – osoba koja radi unutar procesa i stvara vrijednost (npr. prodavač).



- **Analitičar procesa** – osoba koja razumije BPM općenito, a posebno BPMN, te je središte svakog BPM projekta.

BPM pomaže tvrtkama da usklade svoje procese s općim ciljevima, postanu učinkovitije i prilagode se promjenjivim okruženjima. U sljedećem dijelu bit će prikazane metode i alati koji se koriste za izradu preciznih modela poslovnih procesa.

Više od pukog crtanja dijagrama, modeliranje poslovnih procesa ima za cilj obuhvatiti ključne procese na način koji ih čini lakšim za razumijevanje, komunikaciju i analizu. Dionici ga mogu koristiti za vizualizaciju složenih procesa, uvid u neučinkovitosti i uska grla te konceptualiziranje poboljšanja i inovacija.

U sljedećem dijelu bit će predstavljena najpopularnija metoda modeliranja BPMN (Business Process Model and Notation). Bit će riječi o tome kako se ovaj alat može koristiti za učinkovito dokumentiranje poslovnih procesa.

### 5.3. Modeliranje poslovnih procesa

Kako bi se osigurala standardizirana, grafička notacija za dokumentiranje, projektiranje i analizu poslovnih procesa, uveden je **Business Process Model and Notation (BPMN)**. Prema Lucidchartu (n.d.), Inicijativa za upravljanje poslovnim procesima (BPMI) stvorila je *Business Process Modeling Notation* koja je kasnije doživjela brojne promjene. BPMI je preuzet od strane organizacije *Object Management Group* (OMG) nakon spajanja 2005 godine. OMG je potom izdao BPMN 2.0 i promijenio naziv metode u *Business Process Model and Notation*. Uz širi raspon simbola i oznaka za dijagrame poslovnih procesa, uspostavio je opsežniji standard za modeliranje poslovnih procesa.

Ove četiri kategorije elemenata predstavljaju BPMN (Lucidchart, n.d.; Freund i Rücker, 2012):

- **Objekti toka:** događaji, zadaci (aktivnosti) i odluke
- **Povezivanje objekata:** sekvensijski tok, tok poruka i asocijacija
- **Sudionici:** bazen i staze
- **Artefakti:** podatkovni objekti, skladišta podataka i anotacije



### 5.3.1. Događaji

Aagesen i Krogstie (2015) definiraju događaje kao nešto što se događa u procesu. Postoje tri vrste događaja u BPMN-u: početni, intermedijarni i završni događaji. Početni događaj je okidač za početak procesa. Intermedijarni događaji se događaju tijekom poslovnog procesa i često označavaju neka postignuća ili čekanja u procesu. Završni događaji označavaju kraj poslovnog procesa. Svi događaji predstavljeni su krugovima.



Slika 5.2 Oznake za početni, intermedijarni i završni događaj

Izvor: Autor.

Prema Dumasu et al. (2018), događaj treba imenovati kao [objekt] + [glagolski pridjev trpni]. Evo nekoliko primjera kako imenovati događaje: „Račun poslan”, „Narudžba potvrđena”, „Proizvodi zaprimljeni”.

Tablica 5.1. prikazuje različite vrste početnih, intermedijarnih i završnih događaja (OMG, 2006).

Tablica 5.1 Vrste događaja

Tip	Opis	Simbol
<b>Početni događaj</b>		
Nijedan	Vrsta događaja nije prikazana.	
Poruka	Od sudionika stiže poruka koja pokreće proces.	
Vremenski	Proces se pokreće u točno određeno vrijeme (npr. svaki ponedjeljak u 9 ujutro).	
Uvjetni	Događaj se pokreće kada se ispuní neki uvjet (npr. kada je razina zaliha manja od 500 komada).	
<b>Intermedijarni događaj</b>		
Nijedan	Vrsta događaja nije prikazana.	
Poruka	Poruka stiže od sudionika i pokreće događaj. Proces se nastavlja u slučaju da je čekao poruku.	



Vremenski	Može djelovati kao mehanizam odgode. Na primjer, ako proces čeka isporuku proizvoda.	
<b>Završni događaj</b>		
Nijedan	Vrsta događaja nije prikazana.	
Poruka	Poruka se šalje sudioniku na kraju procesa.	
Greška	Na kraju procesa trebala bi se generirati pogreška.	
Prekid	Sve aktivnosti u procesu treba odmah prekinuti.	

Izvor: OMG (2006).

### 5.3.2. Zadaci (aktivnosti)

Zadaci su nešto što se provodi tijekom procesa, aktivnosti koje obavlja osoba ili sustav. Predstavljeni su pravokutnikom sa zaobljenim kutovima.

U BPMN-u postoji poseban podskup redovitih zadataka koji se naziva podproces. Predstavljen je pravokutnikom sa znakom '+' na dnu. Služi za predstavljanje procesa unutar procesa. Na taj način se smanjuje složenost glavnog procesa, odnosno procesa u fokusu.



**Slika 5.3 Zadatak i potproces**

Izvor: Autor.

Zadatak bi trebao biti imenovan kao [glagol u imperativu] + [objekt] (Dumas et al., 2018). Primjerice: „Pošalji račun“ ili „Potvrди narudžbu“.

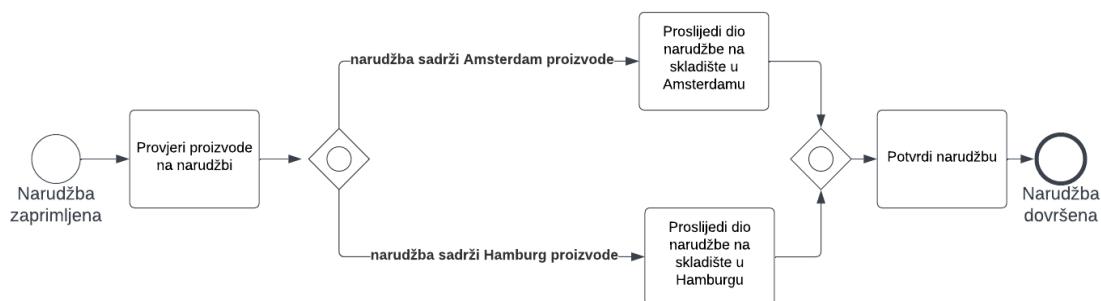
### 5.3.3. Odluke

Odluke su mjesta gdje se procesi razdvajaju ili spajaju. Predstavljene su u obliku dijamanta. Postoje tri najčešće vrste odluka: XOR (isključiva) odluka, OR (uključujuća) odluka i AND (paralelna) odluka.

**Slika 5.4 Odluke OR, XOR i AND**

Izvor: Autor.

Prema von Rosingu et al. (2015), **OR odluka**, prilikom razdvajanja, dopušta aktiviranje jedne ili više grana, ovisno o uvjetima. Prije spajanja, sve aktivne dolazne grane moraju biti dovršene kako bi se nastavio tok. Primjer XOR pristupnika prikazan je na slici 5.6.

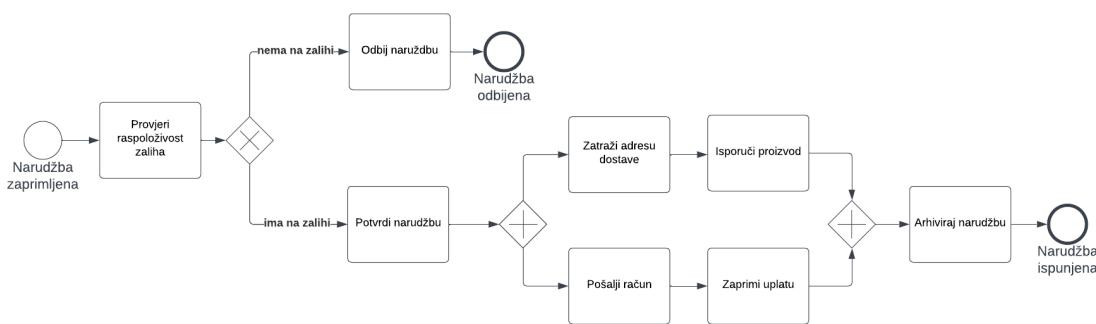
**Slika 5.5 Primjer korištenja OR odluke**

Izvor: Dumas et al. (2018).

U ovom primjeru, tvrtka ima skladišta u Amsterdalu i Hamburgu, gdje drži različite proizvode. Po primitku narudžbe, ona se dijeli na ta skladišta: dio narudžbe se šalje u Amsterdam ako se tamo drže određeni proizvodi, a dio u Hamburg ako se pak tamo drže određeni proizvodi. Proces završava kada se narudžba potvrdi (Dumas et al., 2018). Vidimo da proces može ići u oba smjera (ako se naručeni proizvodi drže u oba skladišta) ili samo u jednom smjeru (ako se naručeni proizvodi drže samo u jednom skladištu).

**XOR odluka**, prilikom razdvajanja, usmjerava tok samo u jednu od izlaznih grana, na temelju uvjeta. Prilikom spajanja, čeka se dovršenje jedne dolazne grane prije nastavka toka (von Rosing et al., 2015).

**AND odluka** se koristi za izvršavanje dvaju ili više zadataka koji ne ovise jedan o drugome i mogu se izvršavati istovremeno (Dumas et al., 2018). Prilikom spajanja čeka da se završe sve ulazne grane prije nastavka toka (von Rosing et al., 2015.). Primjer korištenja XOR i AND odluke prikazan je na slici 5.6.

**Slika 5.6. Primjer korištenja XOR i AND odluka**

Izvor: Dumas et al. (2018).

U ovom primjeru, po primitku narudžbe, prodavač provjerava dostupnost zaliha. Postoji jedan i samo jedan mogući put – proizvodi jesu na skladištu ili nisu. S druge strane, nije važno hoće li se prvo izvršiti aktivnost „Pošalji račun“ ili „Zatraži adresu za dostave“. Ali tek nakon što su oba skupa aktivnosti (“Zatraži adresu za dostave” – “Isporuči proizvod” i “Pošalji račun” – “Zaprими uplatu”) izvršena, narudžba se može arhivirati.

#### 5.3.4. Objekti povezivanja

U BPMN-u postoje tri vrste povezujućih objekata: sekvenički tok, tok poruke i asocijacija.

Prema von Rosingu et al. (2015), **sekvencijski tok** prikazuje redoslijed kojim će zadaci biti dovršeni u procesu. Predstavljen je punom linijom s punim vrhom strelice. Tijek **poruke** predstavljen je isprekidanom linijom. Na jednoj strani linije nalazi se krug, a na drugoj bijeli vrh strelice. Koristi se za predstavljanje protoka poruka između procesnih bazena. **Asocijacija** se koristi za povezivanje teksta s objektima toka. Predstavljena je isprekidanom linijom.

**Slika 5.6 Sekvencijski tok, tok poruka i asocijacija**

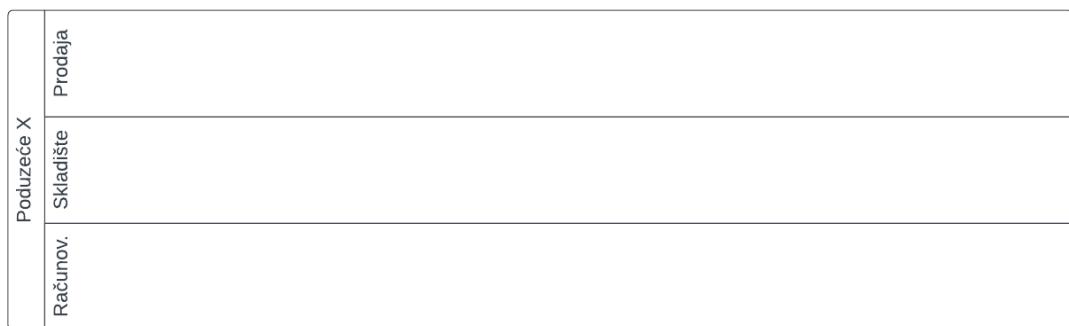
Izvor: von Rosing et al. (2015).

#### 5.3.5. Sudionici

BPMN nudi dva elementa za modeliranje sudionika procesa: bazene i staze. Prema Dumasu et al. (2018), **bazeni** se koriste za prikaz cijele organizacije, a **staza** za modeliranje odjela ili poslovne jedinice. Na primjer, bazen može biti „Poduzeće X“, a staze „Odjel prodaje“,



"Skladište" i "Računovodstvo". Korištenjem bazena i staza lako se može vidjeti koji sudionik obavlja koju aktivnost.



Slika 5.7 Bazen i staze

Izvor: Autor.

### 5.3.6. Artefakti

Postoje različite vrste artefakata: podatkovni objekti, spremišta podataka i anotacije.

**Podatkovni objekti** predstavljaju podatke koji su potrebni za obavljanje određenih zadataka (podaci kao ulaz) ili su rezultat izvršenja zadatka (podaci kao izlaz). Na primjer, dokument "Narudžba" kreira se nakon izvršenja zadatka "Kreiraj narudžbu". S druge strane, zadatak "Pošalji račun" zahtijeva račun kao ulaz kako bi izvršio ovaj zadatak. Dumas et al. (2018) navode da podatkovni objekti mogu biti fizički objekti koji sadrže informacije (npr. papirni račun) ili elektronički objekti (npr. e-pošta ili račun u PDF-u).



Slika 5.8 Podatkovni objekti

Izvor: Autor.

Prema Dumasu et al. (2018), **spremište podataka** je mjesto koje sadrži podatkovne objekte, npr. baza podataka za elektroničke objekte ili ormarić u koji se spremaju fizički objekti. Spremišta podataka procesne aktivnosti koriste za pohranjivanje podatkovnih objekata. Na primjer, zadatak "Provjeri raspoloživost sirovina" pregledava katalog dobavljača.

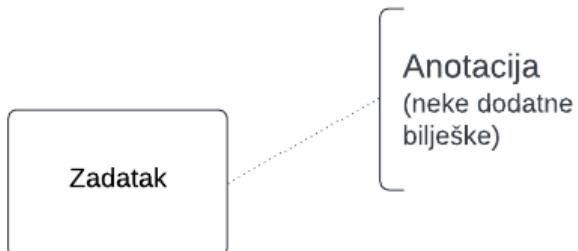




### Slika 5.9 Spremište podataka

Izvor: Dumas et al. (2018).

**Anotacije** su mehanizam pomoću kojeg se pružaju dodatne tekstualne informacije čitatelju BPMN dijagrama (von Rosing et al., 2015.).



### Slika 5.10 Anotacija

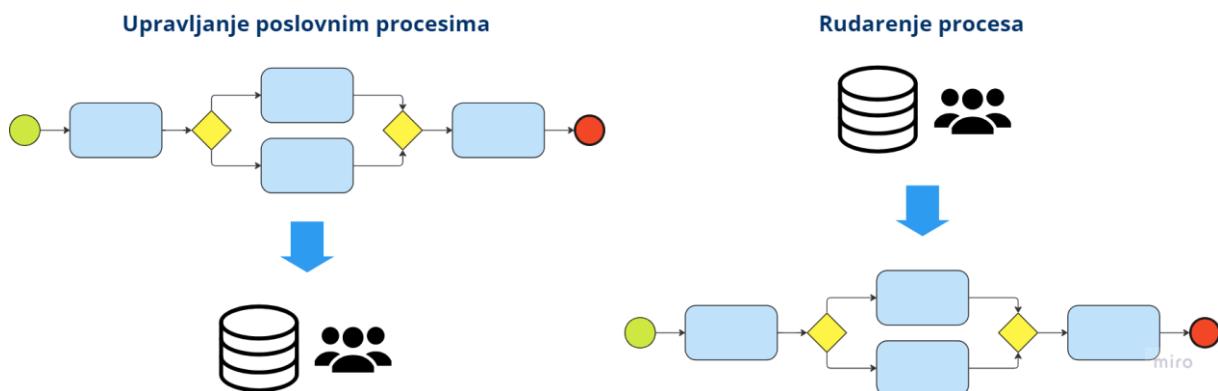
Izvor: Autor.

BPM je prepoznat kao važan okvir za organizacije koje žele optimizirati svoje poslovanje i uskladiti svoje procese sa strateškim ciljevima. Ova temeljna znanja neophodna su za sljedeću temu – rudarenje procesa.

## 5.4. Rudarenje procesa

Rudarenje procesa (eng. *Process Mining*) nalazi se na sjecištu rudarenja podataka i modeliranja procesa. Predstavlja inovativan pristup razumijevanju i unapređenju poslovnih procesa. Za razliku od teorijskog i metodološkog fokusa BPM-a, rudarenje procesa istražuje stvarne podatke koje generiraju poslovni procesi. Koristi podatke iz različitih informacijskih sustava kako bi pružio objektivan prikaz izvršenja procesa u stvarnom vremenu.

Slika 5.11 pokazuje razliku između BPM-a i rudarenja procesa. U tradicionalnom upravljanju poslovnim procesima najprije se razvija model procesa. Zatim ljudi i IT sustavi obavljaju zadatke u skladu s tim modelom. U rudarenju procesa, povijesni podaci iz IT sustava koriste se za izradu modela procesa. Stoga, ovaj model prikazuje stvarne procese.



Slika 5.11 Upravljanje poslovnim procesima vs. Rudarenje procesa

Izvor: Autor.

IEEE (2012) definira **rudarenje procesa** kao "tehnike, alate i metode za otkrivanje, praćenje i poboljšanje stvarnih procesa (tj. ne prepostavljenih procesa) izdvajanjem znanja iz dnevnika događaja koji su obično dostupni u današnjim (informacijskim) sustavima". Dnevnik događaja je digitalni zapis događaja koji su se dogodili unutar informacijskog sustava.

Kako bi se izvršila analiza rudarenja procesa, dnevnik događaja mora sadržavati ID slučaja, naziv aktivnosti i vremensku oznaku. **Slučaj** (instanca procesa) je entitet kojim se bavi proces koji se analizira (npr. narudžbe kupaca, potraživanja od osiguranja itd.), **aktivnost** je dobro definiran korak u procesu (IEEE, 2012), a **vremenska oznaka** je datum i vrijeme kada se aktivnost obavlja.

Tablica 5.1 prikazuje primjer dnevnika događaja. U ovom primjeru postoje dva slučaja (1001 i 1002), a svaki se sastoji od niza događaja za obradu upita korisnika.

Tablica 5.2 Primjer dnevnika događaja

ID slučaja	Naziv aktivnosti	Vremenska oznaka	Resurs
1001	Poziv zaprimljen	2023-15-12 09:00	Agent A
1001	Problem identificiran	2023-15-12 09:15	
1002	Poziv zaprimljen	2023-15-12 10:17	Agent C
1001	Problem proslijeden	2023-15-12 10:20	Agent A
1002	Informacije pružene	2023-15-12 10:26	Agent C
1002	Poziv zaključen	2023-15-12 10:28	Agent C
1001	Poziv tehničke podrške	2023-15-12 11:43	Agent B
1001	Problem riješen	2023-15-12 11:59	Agent B

Izvor: Autor.



Nakon izdvajanja podataka (dnevnika događaja) iz informacijskog sustava (npr. u obliku CSV ili XLS datoteke), podaci se uvoze u poseban softver za rudarenje procesa. Danas postoji širok raspon softvera za rudarenje procesa. Najpopularniji su ProM, Fluxicon Disco, ARIS Process Mining, Celonis itd. Na temelju uvezenih podataka, softver za rudarenje procesa otkriva model procesa. Ovaj se model zatim može analizirati kako bi se utvrdilo postoje li neka uska grla, problemi ili prilike za poboljšanje.

Prema van der Aalstu (2018), rudarenje procesa primjenjivo je na sve vrste operativnih procesa (organizacija i sustava). Analiza postupaka bolničkog liječenja, poboljšanje postupaka korisničke službe u multinacionalnoj tvrtki, razumijevanje navika pregledavanja korisnika stranice za rezervacije, procjena neispravnosti sustava za rukovanje prtljagom i usavršavanje korisničkih sučelja rendgenskih uređaja samo su neke od mogućnosti primjena.

Reil et al. (2021) analizirali su uspješnu implementaciju procesnog rudarenja u praktičnim područjima upravljanja opskrbnim lancem. Naveli su da se 2020. godine švedsko-švicarska tehnološka grupacija za energiju i automatizaciju ABB suočila s izazovima poput povezivanja preko 40 ERP sustava i upravljanja terabajtima procesnih podataka. Implementacija procesnog rudarenja u njihovim proizvodnim procesima omogućila je ABB-u da stekne uvid u performanse njihove globalne poslovne mreže i okrene se prema potpuno digitaliziranom opskrbnom lancu. Prednosti su uključivale smanjene troškove zaliha, poboljšane procese prodaje, poboljšanu produktivnost, pravovremene isporuke, optimizirano korištenje opreme i povećani kapacitet. Dolazne logističke procedure lanca opskrbe automobilske industrije, koje su osjetljive na uska grla koja mogu uzrokovati velike gubitke prihoda, imale su velike koristi od ove strategije. Rudarenje procesa pokazalo se korisnim u učinkovitom rješavanju ovih problema.

BPM-ov strukturirani način upravljanja i poboljšanja procesa omogućuje tvrtkama da se prilagode promjenjivim potrebama kupaca i operativnim problemima. Rudarenje procesa, s druge strane, nudi duboke uvide u stvarnu izvedbu procesa, ističući područja poboljšanja. Integracija BPM-a i rudarenja procesa nije samo strateška prednost, već je vrlo važno da poduzeća znaju kako ih koristiti kako bi ostali konkurentni u budućnosti.

## REFERENCE

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? [dostupno na: <https://camunda.com/glossary/business-process-management-bpm/>, pristupljeno 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) [dostupno na: <https://www.gartner.com/en/information-technology/glossary/business-process-management-bpm>, pristupljeno December 28, 2023]
6. IEEE (2012). Process Mining Manifesto. IEEE Task Force on Process Mining [dostupno na: <https://www.tf-pm.org/upload/1580737631545.pdf>, pristupljeno December 28, 2023]
7. Lucidchart (n.d.). What is Business Process Modeling Notation [dostupno na: <https://www.lucidchart.com/pages/bpmn>, pristupljeno 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 [dostupno na: <https://fluxicon.com/book/read/foreword/>, pristupljeno 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 SUSTAVI U LOGISTICI

Autor: Dario Šebalj

Integracija tehnologije i sustava upravljanja igra važnu ulogu u poboljšanju učinkovitosti, točnosti i donošenju strateških odluka. Tri ključna sustava za racionalizaciju poslovnih operacija u logistici su sustavi za upravljanje resursima poduzeća (ERP), sustavi upravljanja skladištem (WMS) i sustavi upravljanja transportom (TMS).

ERP sustavi čine okosnicu poduzeća, integrirajući različite odjele (kao što su računovodstvo, nabava, prodaja, proizvodnja itd.) i procese u jedinstveni sustav. WMS se, s druge strane, fokusira na optimizaciju skladišnih operacija te osigurava učinkovito upravljanje i optimizaciju zaliha. Na kraju, TMS je usmjeren na planiranje, izvršenje i optimizaciju prijevoza robe. Ovaj sustav je ključan za smanjenje troškova prijevoza i poboljšanje učinkovitosti logistike.

Ovo poglavlje ne samo da daje pregled svakog sustava, već također istražuje kako integracija može dovesti do kohezivnijeg i inteligentnijeg poslovnog okruženja.

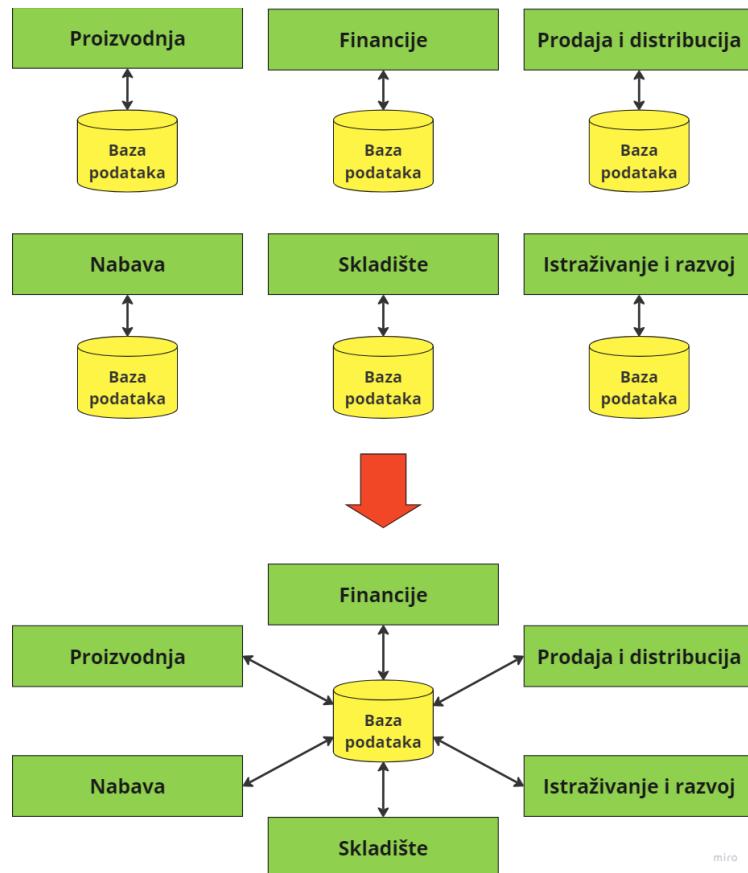
### 6.1. Sustavi za upravljanje resursima poduzeća (ERP)

U početku su tvrtke bile podijeljene u različite odjele, ovisno o funkcijama koje su obavljale. Tako je postojao odjel proizvodnje, nabave, prodaje, financija itd. Svaki odjel je djelovao izolirano na način da je imao svoj sustav prikupljanja i analize podataka. Ti sustavi nisu bili međusobno povezani. Danas se organizacije promatraju kao jedan sustav, a svi odjeli su njegovi podsustavi (Leon, 2014). Također, svi dijele istu, centraliziranu bazu podataka.

Postojanje neovisnih informacijskih sustava za svaki odjel dovelo je do neučinkovitosti, nedosljednosti podataka i redundancije te izazova prilikom donošenja odluka. Pomak prema integriranom sustavu bio je važan pristup organizacijskom upravljanju budući da se na organizacije gleda kao na jedan jedinstveni sustav. Kritična komponenta ove integracije je centralizirana baza podataka koja služi kao ključni dio organizacije, osiguravajući da svi odjeli imaju pristup dosljednim podacima u **stvarnom vremenu**. To dovodi do bolje komunikacije, koordinacije i suradnje između odjela.



Slika 6.1 prikazuje razliku između tradicionalnog pristupa gdje su odjeli neovisni i svaki odjel ima vlastitu bazu podataka i modernog pristupa gdje odjeli dijele jednu središnju bazu podataka.



**Slika 6.1 Razlika između neovisnih odjela i odjela koji dijele zajedničku centralnu bazu podataka**

Izvor: Autor, prema Leon (2014).

Prema Bradford (2015), **sustavi za upravljanje resursima poduzeća** (eng. Enterprise Resource Planning System - ERP) su poslovni sustavi koji kombiniraju i organiziraju podatke iz različitih odjela unutar organizacije kako bi stvorili jedinstveni, sveobuhvatni sustav koji služi potrebama cijelog poduzeća. ERP sustavi na besprijekoran način integriraju i koordiniraju procese i funkcije koji su prethodno bili fragmentirani i podržani od strane različitih starijih, samostalnih poslovnih sustava, poboljšavajući sve aspekte kritičnih operacija, uključujući nabavu, računovodstvo, proizvodnju i prodaju.

Drugim riječima, ERP sustav je složeno, modularno softversko rješenje koje integrira sve poslovne funkcije tvrtke, pomaže u upravljanju poslovnim procesima i dijeli jedinstvenu bazu podataka za cijeli sustav.



Sustav za upravljanje resursima poduzeća (ERP) smatra se višefunkcionalnim sustavom koji automatizira i integrira bitne poslovne operacije organizacije kako bi se maksimizirala učinkovitost (Mahmood et al., 2019).

Bradford (2015) navodi da tvrtke mogu implementirati jedan ili više modula ERP softvera bez potrebe za kupnjom i implementacijom kompletног paketa jer je većina modula dovoljno fleksibilna.

Prema Bradford (2015), ERP sustavi se često smatraju "pozadinskim" sustavima budući da integriraju "pozadinske" funkcije poput ispunjavanja narudžbi, nabave, računovodstva i financija. ERP sustavi danas predstavljaju više od samo pozadinskog sustava; oni uključuju različite module, module za korisnike i module za vezane za upravljanje opskrbnoim lancem.

ERP sustavi imaju mnoge **prednosti**, kao što su (Bradford, 2015; Paredes Hernandez, 2023):

- Poboljšana transparentnost i uvidi – podacima iz svakog odjela mogu pristupiti zaposlenici na izvršnoj razini,
- Pristup informacijama u stvarnom vremenu – podaci su dostupni u stvarnom vremenu svim korisnicima u svim odjelima,
- Smanjenje operativnih troškova – kroz niže troškove zaliha, troškove proizvodnje ili troškove nabave,
- Jedinstveno sučelje kroz sve module – moduli u ERP sustavu izgledaju isto i pružaju isti način funkcioniranja,
- Skalabilnost – ERP sustavi temeljeni na oblaku omogućuju korištenje dodatnih računalnih resursa u slučaju rasta tvrtke i podataka,
- Poboljšana korisnička usluga - novi sustav kao što je ERP softver može omogućiti personalizirajući i bržu korisničku uslugu jer centralizira sve korisničke podatke.

Neki od **nedostataka** ERP sustava su (Bradford, 2015; Paredes Hernandez, 2023; Oracle, n.d.a.):

- Složena i dugotrajna implementacija – implementacija ERP sustava može trajati od nekoliko mjeseci do nekoliko godina, ovisno o veličini poduzeća,
- Cijena – ERP sustavi su često vrlo skupi, posebno oni popularni: SAP i Microsoft Dynamics NAV,
- Upravljanje promjenama - trebat će puno vremena i truda da svaki važan zaposlenik bude adekvatno obučen za korištenje novog sustava.



Glavni razlog zašto tvrtke implementiraju ERP sustave je podrška rastu. Također, implementacija ERP-a cilj je značajnog broja poduzeća kako bi poboljšali svoju produktivnost i procese (Software Path, 2022).



Implementacija ERP sustava vrlo je složena i većina ERP projekata propadne. Prema Saundersu (2022), oko 80% ERP projekata ne uspije. 25% ERP projekata je otkazano ili odgođeno, a još 55% nije ispunilo očekivanja dionika.

Mahmood et al. (2019) proveli su istraživanje u kojem su identificirali najkritičnije probleme/izazove s kojima se susreću organizacije prilikom implementacije ERP-a:

1. **Podrška najvišeg menadžmenta** – podrška, strateško usmjerenje i aktivno uključivanje najvišeg menadžmenta ključni su za uspješnu implementaciju i upravljanje ERP sustavima,
2. **Upravljanje promjenama** - otpor, posebno kod srednjih menadžera naviknutih na tradicionalne metode, predstavlja značajne izazove usvajanju novih ERP sustava,
3. **Obuka i razvoj** - složenost ERP sustava zahtijeva opsežnu i stalnu obuku zaposlenika, pri čemu nedovoljna obuka dovodi do potencijalnih kvarova ERP-a i često predstavlja skrivenе troškove za organizacije.
4. **Učinkovita komunikacija** - jasna i kontinuirana komunikacija i koordinacija između različitih korisnika odjela ključna je za uspješnu implementaciju ERP-a i upravljanje organizacijskim promjenama,
5. **Integracija sustava** - uključuje složen zadatak integracije različitih ERP modula s postojećim poslovnim aplikacijama i naslijedenim sustavima unutar organizacije, proces neophodan za optimizaciju poslovnih procesa i poboljšanje učinkovitosti, ali često skup i složen.

Drugi jednako bitan aspekt implementacije ERP sustava su financijska ulaganja potrebna za implementaciju i održavanje ERP sustava. U sljedećem potpoglavlju istražiti će se različite komponente troškova ERP sustava, uključujući i početno ulaganje i tekuće operativne troškove.

### 6.1.1. Troškovi ERP sustava

ERP sustavi su postali sastavni dio modernih poslovnih operacija, nudeći niz prednosti, od veće učinkovitosti do poboljšane integracije podataka. Međutim, implementacija takvih sustava dolazi sa značajnim troškovima koje organizacije moraju pažljivo razmotriti.



ERP sustave tradicionalno koriste tvrtke koje prodaju opipljivu (materijalnu) robu. Ova sveobuhvatna softverska rješenja dizajnirana su da služe velikim multinacionalnim organizacijama. Zbog toga je njihova implementacija izuzetno skupa i složena. ERP moduli poput nabave, prodaje i logistike temelj su za procese finansijskog izvješćivanja, a njihova automatizacija u globalnoj organizaciji mogla bi stvoriti značajne povrate ulaganja (Berry, 2021).

Ukupni trošak implementacije ERP sustava uključuje troškove vezane uz licenciranje softvera, hardverske zahtjeve, implementaciju, održavanje, savjetovanje, formalnu i neformalnu obuku i prilagodbu. Ti se troškovi obično nazivaju **ukupnim troškom vlasništva** (eng. *Total cost of ownership* - TCO). Oni mogu značajno varirati, ovisno o opsegu implementacije, složenosti softvera i odabranom ERP dobavljaču. Za organizacije srednje veličine samo ulaganje u paketni ERP softver može doseći nekoliko milijuna dolara (Leon, 2014; Tilley, 2020).

Osim troškova softvera, implementacija ERP sustava često zahtijeva značajna ulaganja u IT infrastrukturu. To uključuje poslužitelje, sustave za pohranu podataka, mrežne komponente i eventualnu nadogradnju postojećih komponenti koje su pri kraju svog životnog ciklusa (Bradford, 2015). Iako računalstvo u oblaku može smanjiti neke od ovih troškova hardvera jer ERP softver radi na poslužiteljima dobavljača, početno ulaganje u infrastrukturu ostaje značajna komponenta ukupnih troškova.

Skriveni troškovi vezani uz implementaciju ERP-a, kao što su konzultantske naknade, također igraju značajnu ulogu u ukupnim izdacima. Ovi troškovi uključuju naknade za vanjske konzultante koji su upoznati s ERP sustavom, ali možda nemaju dubinsko znanje o specifičnim poslovnim procesima organizacije (Leon, 2014).



Gotovo 80% ukupnih troškova javljaju se nakon kupovine hardvera i softvera (Tilley, 2020).

Na cijenu ERP softvera utječu različiti čimbenici. Na primjer (Hale, 2019; Wood, 2023):

- **Način implementacije** – ERP sustavi mogu se implementirati u oblaku, na lokaciji korisnika ili kao kombinacija ove dvije metode.
- **Broj korisnika** – ERP sustavi s manjim brojem korisnika obično koštaju manje.
- **Potrebne aplikacije** – broj modula može varirati od osnovnih modula do nekih specifičnih modula.



- **Razina prilagodbe** – svaka dodatna nadogradnja inicijalnog softvera povećava cijenu ERP sustava.
- **Korisnička obuka i podrška** – obično, ali ne uvijek, naknade za implementaciju uključuju godinu dana korisničke podrške. Podrška u stvarnom vremenu može biti dodatni trošak.
- **Nadogradnje hardvera** – tvrtke će možda morati kupiti dodatni hardver (npr. poslužitelje, pohranu, mrežnu infrastrukturu) kako bi podržale svoj novi ERP.

Prosječni proračun po korisniku za ERP projekt, prema izvješću Software Path (2022), iznosi 9.000 USD. Međutim, ovaj trošak varira ovisno o veličini poduzeća i broju korisnika. Prema Haleu (2019), troškovi održavanja mogu iznositi od 10% do 20% početne naknade za licencu.

### 6.1.2. Trendovi ERP sustava

Posljednjih desetljeća organizacije su potrošile milijune dolara na implementaciju ERP sustava (Ruivo et al., 2020). Prihodi od ERP softvera iz godine u godinu rastu 8% do tržišne vrijednosti od 44 milijarde USD 2023. godine (Haranas, 2023), a predviđa se da će dosegnuti 62 milijarde USD do 2028. godine (Statista, 2023).

U današnje vrijeme postoji veliki broj dobavljača ERP softvera. Prema Davidsonu (2023) najbolji dobavljači ERP softvera su Microsoft, SAP, Oracle, Sage, Epicor i Infor.

Kada je riječ o kupnji ERP softvera, proizvodnja je industrija s najvećom zastupljenosću (27%). S 20% na drugom je mjestu građevinarstvo. Zajedno, distribucija i transport, koji su uključeni u širu definiciju industrije opskrbnog lanca, čine 16% (Wood, 2023).

Prema Statisti (2023), **zahtjev za prilagodbom** jedna je od primarnih preferencija korisnika na tržištu ERP softvera. Neophodan je softver koji se može prilagoditi kako bi zadovoljio jedinstvene zahtjeve i specifikacije poduzeća. Kao rezultat toga, povećana je potreba za fleksibilnim i skalabilnim ERP rješenjima temeljenim na oblaku. Kupci također žele softver koji je jednostavan za korištenje i može se integrirati s drugim sustavima.

Budućnost i trendovi ERP sustava oblikovani su razvojem poslovnih potreba tehnološkim napretkom. Od 2023. nekoliko je ključnih trendova istaknuto u području ERP-a (Luther, 2023.):

- **ERP u oblaku** - ERP rješenja temeljena na oblaku postaju sve popularnija zbog svoje jednostavnije implementacije, nižih troškova, elastičnosti i sposobnosti prilagođavanja poslovnom rastu. Pandemija je ubrzala prijelaz s *on-premise* softvera na ERP u oblaku jer ti sustavi zaposlenicima omogućuju lak rad na daljinu. Prema Woodu (2023), 2022.



godine 42% tvrtki koristilo je ERP temeljen na oblaku (u usporedbi s 2013., kada je taj postotak iznosio samo 4%). Obično se ERP u oblaku nudi kao softver kao usluga (SaaS), što znači da korisnici moraju plaćati mjesecnu, tromjesečnu ili godišnju naknadu za stalni pristup.

- **Dvoslojni ERP** - dvoslojni ERP pristup sve više dobiva na važnosti. Ova strategija koristi primarni ERP sustav na korporativnoj razini, dok podružnice rade na drugačijem, često temeljenom na oblaku, ERP rješenju. Veće tvrtke koriste svoj glavni ERP sustav za financije i druge ključne procese, dok manje poslovne jedinice traže rješenja prilagođena njihovim specifičnim zahtjevima.
- **Digitalna transformacija** - ERP sustavi igraju ključnu ulogu u digitalnoj transformaciji poslovanja. Integracijom digitalne tehnologije u sve poslovne funkcije, ERP sustavi povećavaju prihode, konkurentnost i poboljšavaju korisničku uslugu i komunikaciju.
- **Integracija s drugim tehnologijama** - moderni ERP sustavi sve su više integrirani s drugim tehnologijama, kao što su IoT i društveni mediji, kako bi poboljšali temeljne procese i pružili veću vidljivost i bolje korisničko iskustvo.
- **Personalizacija** - ERP sustavi se razvijaju kako bi klijentima ponudili više personalizirana iskustva, podržana pomoćnim korisničkim sučeljima temeljenim na umjetnoj inteligenciji poput *chatbot-a*. Ovaj trend olakšavaju ERP platforme u oblaku dizajnirane za lakšu konfiguraciju i rješenja specifična za industriju.
- **Dobivanje informacija i poboljšanja procesa pomoći umjetne inteligencije** - AI i strojno učenje ugrađeni su u ERP sustave, pružajući vrijedne poslovne uvide analizom operativnih i korisničkih podataka. Ova integracija pomaže u optimiziranju niza poslovnih procesa i poboljšanju personalizacije.
- **Prediktivna analitika** - upotreba prediktivne analitike u ERP sustavima je u porastu, fokusirajući se na analizu podataka za predviđanje budućih trendova i ishoda, što pomaže u boljem donošenju odluka i strateškom planiranju.
- **Mobilni ERP** - Mobilni ERP postaje sve češći, nudi pristup kritičnim poslovnim podacima u pokretu i olakšava rad na daljinu. Mobilne ERP aplikacije sa sučeljima jednostavnim za korištenje pomažu zaposlenicima da učinkovito izvrše zadatke, bez obzira na njihovu lokaciju.



Ovi trendovi ukazuju na značajan pomak u ERP sustava prema prilagodljivijim, personaliziranim i integriranim rješenjima koja su usklađena s modernim poslovnim praksama i tehnološkim napretkom.

ERP sustavi upravljaju osnovnim funkcijama opskrbnog lanca kao što su kontrola zaliha i ispunjavanje narudžbi, ali obično su to vrlo osnovne funkcije. Uglavnom služe kao potpora financijskim procesima. Modul za upravljanje zalihami ERP-a nije se pokazao kao dobar u upravljanju radnom snagom u skladištu, ali zato je prilično dobar u praćenju vrednovanja zaliha za bilancu poduzeća. Kao rezultat toga, na tržištu su se pojavile logističke aplikacije koje su primjeri dobre prakse i koje bi mogle nadopuniti ERP i zatvoriti praznine. Kao dvije glavne kategorije logističkih aplikacija pojavili su se sustavi upravljanja skladištem (WMS) i sustavi upravljanja transportom (TMS) (Berry, 2021).

## 6.2. Sustavi za upravljanje skladištem

Od trenutka kada materijali ili roba uđu u distribucijski ili centar za isporuku pa sve do njihovog odlaska, **sustav upravljanja skladištem** (eng. Warehouse management system - WMS) omogućuje tvrtkama praćenje i upravljanje skladišnim operacijama. Primarni cilj WMS-a je omogućiti učinkovito i ekonomično kretanje materijala i robe kroz skladišta. Odabir, zaprimanje, skladištenje i praćenje zaliha samo su neki od mnogih zadataka koje WMS obavlja kako bi olakšao ta kretanja. WMS softverski sustavi pružaju pregled cijelokupnog inventara tvrtke u stvarnom vremenu, kako u tranzitu tako i u skladištima te su ključni dio upravljanja opskrbnim lancem (O'Donnell, 2020).

Prema SAP-u (n.d.a), sustav upravljanja skladištem optimizira različite aktivnosti skladišta. Pojednostavlja proces zaprimanja i odlaganja koristeći RFID tehnologiju i integrira se s drugim softverom za učinkovito rukovanje artiklima. U upravljanju zalihami, WMS pruža vidljivost u stvarnom vremenu i podržava naprednu analitiku za bolju kontrolu zaliha. Za aktivnosti odabira, pakiranja i ispunjavanja narudžbi, omogućuje učinkovito skladištenje, pronalaženje i pakiranje, koristeći tehnologije kao što su RF skeniranje i robotiku za optimizaciju obrade narudžbi. Procesi otpreme poboljšani su integracijom s logističkim softverom, čime se osiguravaju pravovremene i točne isporuke. WMS također pomaže u upravljanju radom, nudeći uvid u troškove rada i produktivnost te podržava učinkovito upravljanje zadacima. Dodatno, olakšava upravljanje dvorištem i dokovima, poboljšava učinkovitost utovara i podržava *cross-docking* za kvarljivu robu. Konačno, WMS pruža vrijedne skladišne metrike i analitiku, omogućujući bolje donošenje odluka i optimizaciju procesa.



SAP (n.d.a) navodi 5 prednosti WMS-a:

1. **Poboljšana operativna učinkovitost** - WMS sustavi poboljšavaju učinkovitost automatiziranjem i pojednostavljenjem skladišnih procesa od ulaza robe pa sve do izlaza.
2. **Smanjeni otpad i troškovi** - WMS pomaže u smanjenju otpada, posebno za zalihe koje su ograničene rokom trajanja ili koje su kvarljive, i optimizira iskorištenost skladišnog prostora.
3. **Vidljivost zaliha u stvarnom vremenu** - nudi uvid u kretanje zaliha u stvarnom vremenu, pomaže u točnim predviđanjima potražnje i poboljšanoj sljedivosti.
4. **Poboljšano upravljanje radom** - WMS pomaže u predviđanju potreba za radnom snagom i optimiziranju dodjele zadataka na temelju različitih čimbenika, čime se poboljšava moral zaposlenika.
5. **Bolji odnosi s kupcima i dobavljačima** - WMS vodi do boljeg ispunjavanja narudžbi i bržih isporuka, povećavajući zadovoljstvo kupaca i poboljšavajući odnose s dobavljačima.

Razvoj sustava upravljanja skladištem i dalje je pod utjecajem tehnološkog napretka. Na primjer (Scullin, 2023):

- **Automatizirani alati za komisioniranje** - tehnologije kao što su glasovno automatizirano komisioniranje, robotsko komisioniranje i sustavi *pick-to-light*, zajedno sa sofisticiranim barkodiranjem,
- **Automatski vođena vozila (AGV)** - poboljšavaju procese skladištenja i preuzimanja, ključni su za zadatke kao što su skladištenje paleta i regala, upravljanje kontejnerima i automatizacija procesa prijema,
- **Internet stvari (IoT)** - integracijom IoT-a, razni automatizirani i ručni elementi kontroliraju se unutar objedinjene mreže, poboljšavajući kontrolu zaliha, planiranje rada i korisničko iskustvo putem bržih stopa ispunjenja,
- **Proširena (AR) i virtualna stvarnost (VR)** - AR tehnologija, putem uređaja poput pametnih naočala, pruža pregled uputa ili informacija u realnom vremenu u skladišnom okruženju, pomažući u zadacima kao što su navigacija rutom i lociranje spremnika bez upotrebe ruku. VR se koristi za obuku i sigurnosne svrhe, kao što je obuka operatera viličara i poboljšanje ruta isporuke.



Berry (2021) navodi da je tržište WMS-a vrlo zrelo i da postoje mnoge poznate softverske tvrtke koje nude širok raspon značajki za pomoć čak i kod naj složenijih skladišnih zadataka. Mnogo vrhunskih WMS pružatelja sada nudi modele isporuke u oblaku. 40-50% novih korisnika WMS-a sada odabire isporuku u oblaku umjesto lokalnih implementacija. Neki od popularnih WMS dobavljača su (Gartner, n.d.): SAP Extended Warehouse Management (EVM), Oracle Warehouse Management (WMS Cloud), Microsoft Dynamics 365 Supply Chain, Manhattan WMS i Infor WMS.

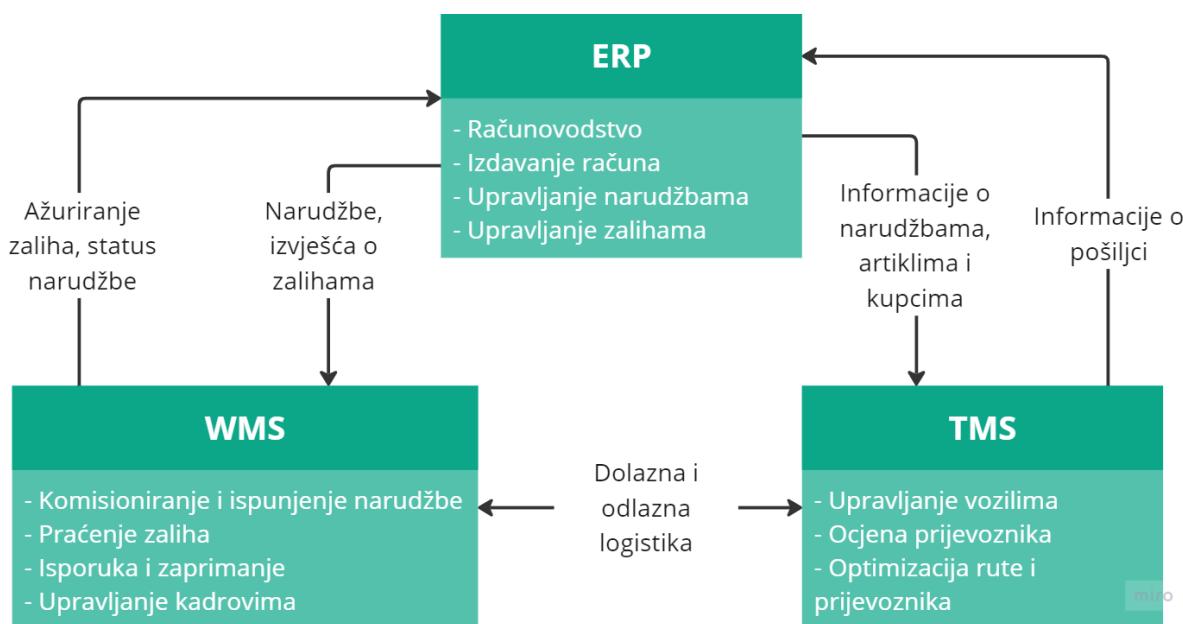
### 6.3. Sustavi za upravljanje transportom

Sustav za upravljanje transportom (TMS) ključan je softver u logistici koji optimizira kretanje robe različitim načinima prijevoza. Kao dio šireg sustava upravljanja opskrbnim lancem, TMS optimizira rute utovara i dostave, prati teret i automatizira zadatke poput usklađivanja s trgovinom i naplate tereta. Ovaj sustav ne samo da osigurava pravovremenu isporuku, već i smanjuje troškove, čime profitiraju i tvrtke i kupci. Nudi sveobuhvatan uvid u operacije prijevoza, pomaže u usklađenosti i pojednostavljuje proces dostave kopnom, zrakom ili morem (SAP, n.d.b; Oracle, n.d.b).

Prema Berryju (2021), postoji nekoliko načina kako TMS može smanjiti troškove prijevoza. Odjel isporuke može uštedjeti puno vremena i truda automatiziranjem procesa rezerviranja i praćenja pošiljaka. Mogućnosti usmjeravanja osiguravaju da se odabere metoda prijevoza koja košta najmanje za svaku pošiljku. Mnogi TMS sustavi mogu optimizirati pošiljke tako da se napuni cijeli kamion, što je mnogo jeftinije.

Neke od prednosti TMS-a su (SAP, n.d.b; Inbound Logistics, 2023):

- **Ušteda troškova** – TMS značajno smanjuje i administrativne troškove i troškove otpreme, optimizirajući upravljanje teretom,
- **Vidljivost u stvarnom vremenu** – pruža kritične uvide u transportni proces, poboljšavajući učinkovitost rute i praćenje,
- **Veće zadovoljstvo kupaca** – osigurava isporuku na vrijeme i poboljšava korisničko iskustvo boljim procesima praćenja i naplate,
- **Poboljšana učinkovitost** – TMS poboljšava ukupnu učinkovitost transportnih operacija,
- **Poboljšano donošenje odluka** – nudi vrijedne podatke za informirano donošenje odluka, poboljšavajući strateško planiranje u upravljanju prijevozom.



Slika 6.2 Veza između ERP-a, WMS-a i TMS-a

Izvor: Essex (2020).

Slika 6.2 prikazuje vezu između ERP, WMS i TMS sustava. Prema Essexu (2020), ERP sustav upravlja računovodstvom, fakturiranjem, narudžbama i zalihami. WMS pomaže pri ispunjavanju, otpremi i primanju zadataka u skladištu, kao što je komisioniranje i skladištenje robe te u modul upravljanja zalihami sprema podatke u stvarnom vremenu skeniranjem crtičnog koda i RFID-a. ERP sustav daje detalje narudžbe TMS-u za pripremu i izvršenje pošiljke. TMS vraća pojedinosti o pošiljci ERP-u za računovodstvo i upravljanje narudžbama i potencijalno ažurira module za upravljanje odnosima s kupcima (CRM) za ažuriranje statusa narudžbe za kupce.

U ovom poglavlju opisana je važna uloga ERP, WMS i TMS sustava za logistiku. Ovi sustavi, ključni u modernoj logistici, zajednički povećavaju učinkovitost, osiguravaju precizno upravljanje zalihami i optimiziraju transportne procese. Integracija ERP-a, WMS-a i TMS-a nije samo tehnološki napredak već i strateška nužnost, koja poduzeću omogućuje veću učinkovitost, točnost i zadovoljstvo kupaca u području logistike i upravljanja opskrbnim lancem.

## REFERENCE

- 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 [dostupno na: <https://softwareconnect.com/erp/top-vendors/>, pristupljeno January 15, 2024]
4. Esex, D. (2020). Transportation management system (TMS). TechTarget [dostupno na: <https://www.techtarget.com/searcherp/definition/transportation-management-system-TMS>, pristupljeno January 15, 2024]
5. Gartner (n.d.). Warehouse Management Systems Reviews and Ratings [dostupno na: <https://www.gartner.com/reviews/market/warehouse-management-systems>, pristupljeno January 17, 2024]
6. Hale, Z. (2019). What Factors Determine the Cost of ERP Software?. Software Advice [dostupno na: <https://www.softwareadvice.com/resources/erp-software-pricing/>, pristupljeno January 15, 2024]
7. Haranas, M. (2023). Oracle, Microsoft, SAP, Workday Lead Cloud ERP Market: Gartner. CRN [dostupno na: <https://www.crn.com/news/cloud/oracle-microsoft-sap-workday-lead-cloud-erp-market-gartner>, pristupljeno January 17, 2024]
8. Inbound Logistics (2023). Transportation Management System: Meaning, Importance, and Benefits [dostupno na: <https://www.inboundlogistics.com/articles/transportation-management-system/>, pristupljeno 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 [dostupno na: <https://www.netsuite.com/portal/resource/articles/erp/erp-trends.shtml>, pristupljeno 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 [dostupno na: <https://www.techtarget.com/searcherp/definition/warehouse-management-system-WMS>, pristupljeno January 15, 2024]
13. Oracle (n.d.a). What are the benefits of an ERP system? [dostupno na: <https://www.oracle.com/hk/erp/what-is-erp/erp-benefits/>, pristupljeno January 20, 2024]



14. Oracle (n.d.b). What Is a Transportation Management System? [dostupno na: <https://www.oracle.com/scm/logistics/transportation-management/what-is-transportation-management-system/>, pristupljeno January 15, 2024]
15. Paredes Hernandez, J. (2023). The advantages and disadvantages of ERP systems. IBM [dostupno na: <https://ibm.com/blog/enterprise-resource-planning-advantages-disadvantages/>, pristupljeno 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)? [dostupno na: <https://www.sap.com/products/scm/extended-warehouse-management/what-is-a-wms.html>, pristupljeno January 15, 2024]
18. SAP (n.d.b). What is a transportation management system (TMS)? [dostupno na: <https://www.sap.com/products/scm/transportation-logistics/what-is-a-tms.html>, pristupljeno January 15, 2024]
19. Saunders, P. (2022). Are ERP Projects Really The Stuff Of Nightmares?. Forbes [dostupno na: <https://www.forbes.com/sites/sap/2022/06/28/are-erp-projects-really-the-stuff-of-nightmares/>, pristupljeno January 20, 2024]
20. Scullin, Ch. (2023). 7 Smart Warehouse Technologies to Implement Today. Camcode [dostupno na: <https://www.camcode.com/blog/smart-warehouse-technologies/>, pristupljeno January 10, 2024]
21. Software Path (2022). What 1,384 ERP projects tell us about selecting ERP (2022 ERP report) [dostupno na: <https://softwarepath.com/guides/erp-report>, pristupljeno January 15, 2024]
22. Statista (2023). Enterprise Resource Planning Software – Worldwide [dostupno na: <https://www.statista.com/outlook/tmo/software/enterprise-software/enterprise-resource-planning-software/worldwide>, pristupljeno 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 [dostupno na: <https://softwareconnect.com/erp/pricing/>, pristupljeno January 22, 2024]



## 7. E-LOGISTIKA

Autor: Michał Adamczak

Ovo poglavlje posvećeno je najvažnijim pitanjima vezanim uz e-logistiku. Ono ne samo da definira ovaj koncept, već ga također predstavlja u širem kontekstu mogućnosti koje nudi analiza podataka za optimizaciju logističkih procesa. Poglavlje uključuje teme kao što su:



- kontekst u kojem e-logistika djeluje, uključujući koncept e-poslovanja,
- osnovne definicije e-logistike,
- razvoj e-logistike,
- suvremene e-logističke tehnologije i alati,
- praktična rješenja e-logistike.

### 7.1. Uvod

Razvoj digitalnih tehnologija ima dugu povijest. Stoga se ne može reći da su digitalna rješenja ili dijeljenje informacija u opskrbnim lancima moderno rješenje. Naprotiv, iz perspektive vremena i sa stajališta profesionalno aktivnih ljudi, digitalni aspekt je već zrelo rješenje koje je postalo stalni dio tijeka logističkih procesa. Drugim riječima, ne možemo više zamisliti, a kamoli djelovati u logistici bez paralelnog protoka digitalno snimljenih informacija.

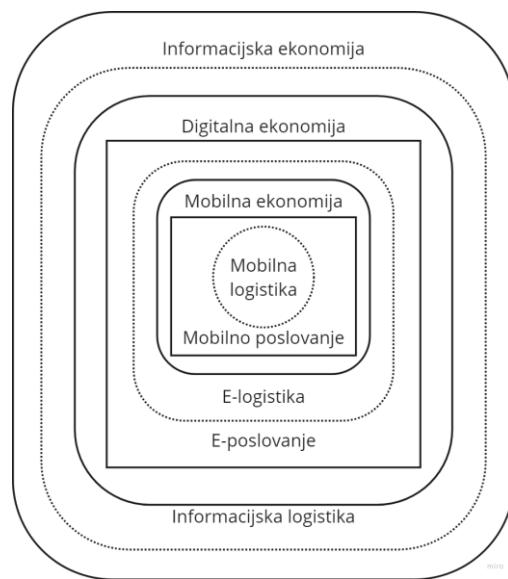
Moderno gospodarstvo naziva se postindustrijsko gospodarstvo ili digitalno gospodarstvo. No, to ne znači da je protok materijala potpuno zaustavljen ili napušten. Tok materijala je ključan za ekonomski promet i potrošnju. Tako će biti i dalje sve dok se potrebe ljudi zadovoljavaju materijalnim dobrima. Naravno, neke potrebe ljudi mogu se zadovoljiti digitalnim sadržajem, ali u dogledno vrijeme digitalnom robom neće biti moguće zadovoljiti sve potrebe ljudi. Čini se da će suživot materijalnih i digitalnih tokova sljedećih desetljeća činiti nerazdvojni tandem. Pojmom digitalna ekonomija želi se naglasiti uloga i opseg materijalnih i informacijskih tokova. Kao što će biti prikazano u ovom poglavlju, digitalni protok postaje sve važniji za izgradnju uvjeta koji poboljšavaju učinkovitost protoka materijala i time poboljšavaju konkurenčku poziciju pojedinih poduzeća i cijelih opskrbnih lanaca.



E-logistika je stoga rješenje koje se uklapa u glavne tokove modernog gospodarstva. To je ujedno i odgovor na zahtjeve suvremenog gospodarstva i rješenje koje pruža nove mogućnosti poslovanja.

## 7.2. E-poslovanje

E-logistika je rješenje koje djeluje unutar šireg koncepta e-poslovanja. E-poslovanje se može slobodno definirati kao poslovni proces koji koristi internet ili drugi elektronički medij kao kanal za obavljanje poslovnih transakcija (Jayashankar et al., 2003). Unutar e-poslovanja možemo razlikovati tako detaljne aktivnosti kao što su: e-trgovina, e-oglašavanje, e-marketing, elektroničko bankarstvo, elektroničke dražbe itd. U ovim vrstama poslovnih aktivnosti pridjev "elektronički" označava da se te aktivnosti obavljaju isključivo u elektroničkom (digitalnom) obliku putem interneta, mobilne veze i sl. (Skitsko, 2016). Položaj e-logistike unutar e-poslovanja i drugih koncepata koji koriste prijenos podataka putem Interneta prikazan je na slici 7.1.



Slika 7.1 E-logistika u konceptu e-poslovanja

Izvor: Skitsko (2016)

Unutar e-poslovanja postoji nekoliko osnovnih modela komunikacije između sudionika na tržištu (Shemet, 2012):

- B2B (*business-to-business*). U ovom modelu postoji interakcija između tvrtki (poduzeća, pravnih osoba) koje žele ostvariti različite pogodnosti.



- B2C (*business-to-customer*). U ovom modelu tvrtka komunicira sa svojim krajnjim potrošačem.
- C2C (*customer-to-customer*). U ovom modelu ljudi (fizičke osobe) međusobno komuniciraju uz pomoć različitih komunikacijskih sredstava i tehnologije.
- C2B (*customer-to-business*). U ovom modelu mišljenja ili ideje krajnjih potrošača izražene različitim sredstvima, posebice na raznim internetskim forumima, društvenim mrežama, e-poštom itd. značajno utječu na izradu proizvoda (njihove karakteristike, karakteristike, cijenu itd.) od strane proizvođača.
- B2G (*business-to-government*). U ovom modelu tvrtka je u interakciji s državnim upravnim tijelima.
- C2G (*customer-to-government*). U ovom modelu postoji interakcija između osobe i organa državne uprave.
- G2B (*government-to-business*), G2C (*government-to-customer*). U ovim modelima organi državne uprave društvima (poduzećima) i fizičkim osobama pružaju informacijske usluge putem Interneta.

Utjecaj razvoja tehnologija obrade podataka i interneta na opskrbne lance može se razlikovati u tri područja (Jayashankar et al., 2003.):

- razvoj sustava koji podržavaju upravljanje poduzećem (ERP) i planiranje protoka materijala (APS);
- razvoj sustava koji podržavaju proces poslovnog odlučivanja koji radi u stvarnom vremenu;
- dijeljenje informacija između poduzeća.

Sva navedena područja javljaju se i u kontekstu implementacije logističkih procesa koji su postali temelj za stvaranje koncepta e-logistike.

### 7.3. Definicija e-logistike

Teško je dati jednu definiciju e-logistike. To je zato što je riječ o pojmu koji je usko povezan s tehničkim mogućnostima prikupljanja, obrade i prijenosa podataka i informacija. Stoga su se definicije ovog pojma mijenjale tijekom vremena i vjerojatno će se nastaviti mijenjati.



„E-logistika je dinamičan skup komunikacijskih, računalnih i kolaborativnih tehnologija koje transformiraju ključne logističke procese tako da budu usmjereni na kupca, dijeljenjem podataka, znanja i informacija s partnerima u opskrbnom lancu.“ (Wang et al., 2004)



Još jednu zanimljivu definiciju, iako uskog opsega, donosi tim autora Quirk, Forder i Bentley. „E-logistika koristi internetske tehnologije za podršku nabavi materijala, skladištenju, transportu i omogućuje distribuciju kroz optimizaciju rutiranja s praćenjem zaliha“ (Quirk et al., 2003)

Obje gornje definicije usredotočuju se na aspekt podataka koji prate protok materijala u opskrbnim lancima. Zadatak e-logistike je, dakle, pratiti tijek materijala kako bi ga bolje kontrolirao i davao informacije o tom toku u stvarnom vremenu svim svojim dionicima, što će zauzvrat omogućiti sinkronizaciju tog toka u opskrbnom lancu (Mangiaracina i sur., 2015).



Prema drugoj definiciji, e-logistika su logistički procesi koji provode tijek proizvoda kupljenih u elektroničkim prodajnim kanalima (Erceg & Damoska Sekuloska, 2019). Ilustracija ovakvog načina razumijevanja e-logistike prikazana je na slici 7.2.



**Slika 7.2 E-logistika**

Source: Moroz et al. (2014)

Usporedbom oba pristupa definiranju e-logistike uspoređena su osnovna obilježja tradicionalne logistike i e-logistike koja podržava protok materijala u e-trgovini. Rezultati usporedbe prikazani su u tablici 1.

**Tablica 7.1 Osnovne razlike između tradicionalne i e-logistike**

Opseg	Tradicionalna logistika	E-logistika
Vrsta pošiljke	Velike količine	Pojedinačni paketi
Kupac	Strateški	Nepoznat
Usluga kupcima	Reaktivna, stroga	Responsivna, fleksibilna
Distribucijski model	„guranje“ na temelju ponude	„povlačenje“ na temelju potražnje
Zalihe/tok narudžbi	Jednosmjerno	Dvosmjerno
Destinacije	Koncentrirane	Visoko disperzirane
Potražnja	Stabilna	Sezonalna, fragmentirana
Narudžbe	Predvidljive	Varijabilne

Izvor: Song & Hou (2004)

Sumirajući gore navedene definicije, valja istaknuti njihove sličnosti. Logističke aktivnosti koje se provode za potrebe protoka materijala vrlo su slične jedna drugoj, bez obzira radi li se o tradicionalnom protoku ili o onima koje se provode u okviru e-trgovine. Kada se opisuje e-



logistika, treba napomenuti da se u oba pristupa ovaj koncept odnosi na tijek podataka koji opisuju tijek materijala. Osnovne funkcije e-logistike iste su za oba područja (Skitsko, 2016):

- formiranje informacijskog okruženja u kojem međusobno djeluju sudionici logističkog lanca opskrbe robom;
- definiranje karakteristika elektroničkih informacijskih tokova;
- formiranje zahtjeva i potreba prema tvrtkama koje pružaju informacijske i komunikacijske usluge i odgovarajuće veze;
- organizacija korištenja međunarodnih standarda identifikacije proizvoda;
- održavanje ispravnog i pouzdanog rada, razvoj informacijskog sustava poduzeća;
- prikupljanje, analiza, pohrana, transformacija i organizacija prijenosa informacija u elektroničkom obliku;
- izbor potrebnih podataka za donošenje upravljačkih odluka.

Implementacija ovih funkcija ne bi bila moguća bez digitalnih tehnologija koje omogućuju prikupljanje, prikupljanje i analizu podataka. Opis najvažnijih od njih, koji su imali najveći utjecaj na razvoj e-logistike, prikazan je u sljedećem podpoglavlju.

## 7.4. Razvoj e-logistike

Na temelju prikazanih definicija jasno se može ustvrditi da počeci e-logistike sežu u vrijeme kada su nastali prvi informatički sustavi koji podržavaju upravljanje protokom materijala, planiranje materijalnih potreba (MRP) i sustave za planiranje resursa distribucije (DRP). stvorio. Ti su se sustavi počeli razvijati 1960-ih. Bila su to prva rješenja za paralelni protok materijala i digitalno snimljenih informacija. Sljedećih godina bilježimo dinamičan razvoj ovih sustava, što je dovelo do stvaranja sustava za planiranje resursa poduzeća (ERP). Paralelno su se razvijali sustavi posvećeni pojedinim logističkim funkcijama: sustavi za upravljanje transportom (TMS) i sustavi za upravljanje skladištem (WMS) (Wang, 2016). Više detalja o ovim IT sustavima možete pronaći u poglavlju 6 ovog priručnika.

Razvoj ERP sustava, a posebno koncentracija podataka i višedimenzionalnost tih podataka, omogućili su stvaranje sustava za podršku odlučivanju (DSS) (Turbanet al., 2002). Razvoj interneta i mogućnost razmjene podataka između sustava pojedinačnih poduzeća pokrenuli su razvoj sustava ERPII koji omogućuju integraciju podataka između partnera u opskrbnim



lancima (Møller, 2005). Razmjena podataka između partnera moguća je zahvaljujući rješenju za elektroničku razmjenu podataka (EDI) (Huang, et al., 2008).

Još jedna prekretnica u razvoju e-logistike bilo je stvaranje elektroničkih tržišta (EM). Stvaranje platformi koje povezuju poduzeća izravno s kupcima (i druge konfiguracije predstavljene u pododjeljku o e-poslovanju) omogućile su stvaranje novih poslovnih modela, a time i zahtjeva za logistiku (Wang, et al., 2007.).

Paralelno s razvojem EM-a razvijali su se sustavi za prikupljanje i analizu velikih skupova podataka koji su omogućili implementaciju računalnih procesa u oblaku. Razvoj tehnologije prikupljanja velikih podataka i mogućnosti njihove analize te dijeljenja analitičkih alata i rezultata analize na daljinu putem interneta pružio je potpuno nove mogućnosti, posebice u području informatičke opskrbe DSS-a te, posljedično, mogućnosti optimizacije logističkih procesa, posebno u područjima kao što su: predviđanje, upravljanje zalihamama, upravljanje transportom i upravljanje ljudskim resursima (Waller & Fawcett, 2013). Kako bismo saželi razvoj digitalnih tehnologija koje se koriste u e-logistici, možemo se poslužiti zapažanjem autora Merali, Papadopoulos i Nadkarni (2012), koji su prikazali četiri koraka promjena u ICT-u od 1960-ih godina, koje su imale veliki utjecaj na razvoj e-logistike (Merali et al., 2012.):

- povezanost (između ljudi, aplikacija i uređaja);
- kapacitet za distribuiranu pohranu i obradu podataka;
- doseg i raspon prijenosa informacija;
- brzina (brzina i volumen) prijenosa informacija.

Nedvojbeno je da su navedeni koraci u razvoju ICT tehnologija utjecali na mogućnosti praktične primjene digitalnih rješenja u logističkim procesima. Ove promjene također jasno prikazuju smjer u kojem se digitalne tehnologije razvijaju. Tehnologije koje se trenutno koriste u e-logistici detaljnije su opisane u sljedećem potpoglavlju.

## 7.5. Suvremene tehnologije koje podupiru e-logistiku

Razvoj Industrije 4.0 i Logistike 4.0 pruža dodatne mogućnosti za proširenje rješenja i usluga koje se nude unutar e-logistike. Među glavnim tehnologijama koje podržavaju e-logistiku trenutno su:

- *Blockchain*;
- Internet stvari i senzori (IoT);
- Generativna umjetna inteligencija (AI);



*Blockchain* je distribuirani sustav baze podataka između svih sudionika u istoj mreži. Ovaj sustav bilježi i pohranjuje podatke u obliku povezanih blokova koji tvore zbirku zapisa. Oni su trajni i stoga se ne mogu izbrisati. Važno je znati da ne postoji mogućnost ažuriranja ili bilo kakvih izmjena. Međutim, moguće je dodati ili pročitati snimku (Dutta et al., 2020.).

*Blockchain* tehnologija omogućuje praćenje različitih transakcija duž cijelog opskrbnog lanca na siguran i sljedivi način. Dokumentirane transakcije i podaci nepovratno se pohranjuju u *blockchain* i ne mogu se koristiti ili čitati bez konsenzusa. Svaki put kada se pošiljka prevozi ili rukuje, transakcija se može dokumentirati, stvarajući trajnu povijest od proizvođača do trgovca ili potrošača (Aritua et al., 2021).

Internet stvari (IoT) omogućuje ne-računalnim uređajima da međusobno komuniciraju. Koncept se temelji na širokom rasponu tehnologija, od komunikacijskih protokola preko senzora koji prikupljaju podatke, infrastrukture koja omogućuje prijenos podataka do sustava koji analiziraju prikupljene podatke (Minerva, 2015). IoT rješenja često se kombiniraju s RFID (radiofrekvencijska identifikacija) senzorima, dajući mogućnost ne samo lokalne identifikacije robe ili tereta, već i prijenos tih podataka do bilo kojeg korisnika. IoT rješenja mogu se izraditi u dvije varijante (Idrissi et al., 2022.):

- Usmjeren prema internetu – glavni element sustava su usluge koje se nude u računalstvu u oblaku, a objekti sustava su pružatelji podataka;
- Usmjeren prema objektu – rješenje u kojem je središnja točka mreže objekt koji se može kontrolirati pomoću poruka koje se prenose preko Interneta.

IoT rješenja naširoko se koriste u logistici. IoT omogućuje praćenje različitih informacija za kontrolu kvalitete robe kao što su svjetlost, vlažnost, temperature, vibracije, udarci itd. (Dash et al., 2019.). Na primjer, u Maersku kontejnerski prijevoznik želi plasirati uslugu koja zahtijeva dodatno osiguranje na cijelom putovanju. Uvjeti transporta (vibracije, temperatura, vlažnost, magnetizam, položaj, itd.) mogu se pratiti u spremniku s instrumentima. Te se informacije također mogu prenijeti u *Blockchain* kako bi se pokrenula djelomična plaćanja tijekom otpreme. AI je simulacija procesa ljudske inteligencije pomoću strojeva i računalnih sustava. Generiranje znanja pomoću umjetne inteligencije provodi se u tri koraka (Samoili et al., 2020.):

- učenje – stjecanje informacija i njihova pravila korištenja;
- zaključivanje – korištenje pravila za zaključivanje;
- samoispravljanje.



AI aplikacija omogućuje sustavu da daje precizne indikacije svakom operateru za svaku narudžbu. Sustav to može učiniti kroz učenje temeljeno na povijesti. To pomaže u postizanju maksimalne učinkovitosti, posebno u skladištima s intenzivnim komisioniranjem, kao što je e-trgovina (Dash et al., 2019).

Predstavljene tehnologije ne čine zatvoreni katalog rješenja koja se koriste unutar e-logistike. Posebno je važna suradnja ovih tehnologija u akviziciji, prikupljanju i obradi podataka u svrhu stvaranja informacija koje podržavaju učinkovite upravljačke odluke.

## 7.6. E-logistika u praksi

Bez obzira na to kako se e-logistika definira, ova rješenja funkcioniraju u gotovo svakom aspektu logističke aktivnosti, bez obzira na funkciju ili fazu protoka materijala. Prema ranije predstavljenom pregledu literature pozornost treba usmjeriti na vezu između dobavljača i primatelja. Ovdje se razmjena podataka i povezivanje entiteta radi poboljšanja učinkovitosti protoka materijala čine posebno važnima. To je trenutno moguće zahvaljujući općepristupačnom internetu i automatskom prikupljanju podataka. Praktična e-logistička rješenja nude gotovo svi logistički operateri, a posebice oni koji djeluju na globalnom tržištu. Izvrstan primjer rješenja korištenih u e-logistici su ona koja nudi Dachser. Ovaj europski logistički operater svojim korisnicima omogućuje direktnu vezu sa sustavima za upravljanje transportom i skladištenjem, zahvaljujući čemu korisnici imaju nesmetan pristup podacima o provedbi logističkih procesa ovog operatera u stvarnom vremenu. Funkcije koje nudi Dachser (n.d.) unutar e-logistike uključuju:

- analiza proizvoda i usluga - ovaj alat omogućuje brzo određivanje optimalnog ili željenog vremena isporuke za pošiljke unutar Europe;
- online naručivanje - automatski uvoz podataka u narudžbe štedi vrijeme. Funkcija uvoza adresa iz ERP sustava nadopunjuje upravljanje adresama. Ova funkcionalnost vam također omogućuje slanje dokumenata, spremanje informacija o opasnoj robi, kao i slanje budućih narudžbi i korištenje vlastitih crtičnih kodova;



- kontrola svih troškova prijevoza - omogućuje brzo dobivanje informacija o cijeni prijevoza bez podnošenja opsežnih upita;
- praćenje zaliha - omogućuje praćenje procesa koji se odvijaju u skladištima - od provjere statusa primitka narudžbe do praćenja šarže. Ova funkcionalnost omogućuje da odmah odredite manjkove i razine zaliha;
- aktualne informacije o statusu pošiljke i njezinoj lokaciji - *Track & Trace* funkcija vam omogućuje da za svaku pošiljku kreirate pojedinačnu poveznicu koja će vas informirati o trenutnom statusu pošiljke. Ta se poveznica zatim može proslijediti kupcima ili partnerima;
- online upravljanje fakturama - online pristup svim podacima o pošiljci. Podaci su dostupni u PDF datotekama, Excel tablicama i CSV datotekama. Ove podatke možemo poslati i digitalno putem EDI centra.;
- elektroničko računovodstvo paleta - upravlja opremom za utovar koja zahtijeva praćenje, tj. euro paletama i regalima.

Još jedan globalni logistički operater koji u velikoj mjeri koristi rješenja e-logistike je DHL. Uz gore navedene vrlo slične funkcije za drugog operatera, DHL također u velikoj mjeri koristi rješenja iz područja strojnog učenja, proširene stvarnosti i umjetne inteligencije. Proširena stvarnost koristi se za optimizaciju skladišne infrastrukture i logističkih operacija koje se tamo provode. Strojno učenje i umjetna inteligencija koriste se za povećanje učinkovitosti poslovanja i povećanje otpornosti organizacije fokusiranjem poduzetih radnji na proaktivne umjesto na reaktivne radnje. Proaktivno djelovanje moguće je zahvaljujući analizi velikih skupova podataka i traženju odnosa između uzroka i posljedica u njima. Stoga je moguće predvidjeti formiranje budućih pojava na temelju proših događaja. Takve radnje također utječu na povećanje vrijednosti usluga usmjerenih DHL-ovim korisnicima i povećavaju njihovu konkurenčku poziciju (DHL, 2017). To pokazuje da logistički operater može ponuditi ne samo klasične logističke usluge u vidu transporta, skladištenja ili rukovanja narudžbama, već i napredne usluge u području analize podataka i preporuke rješenja proizašlih iz tih analiza. Rješenja e-logistike stoga postaju izvor konkurenčke prednosti, a usluge koje iz njih proizlaze prirodni su element suradnje između karika opskrbnog lanca.

## 7.7. Sažetak

Rješenja koja djeluju unutar e-logistike su raznolika kao i definicije ovog pojma. Mogu se razlikovati dva glavna trenda u definiranju ovog pojma. U širem smislu, e-logistika su sve vrste



digitalnih rješenja koja prate protok materijala. U užem smislu, e-logistika se definira kao provedba logističkih procesa koji prate e-trgovinu. Naravno, oba pristupa se međusobno ne isključuju. Prikazana povijest razvoja, prikazano širenje opsega u kojem funkcioniра e-logistika i očekivani pravci razvoja jasno pokazuju da će, bez obzira na način definiranja ovog koncepta, biti predmetom interesa kako poslovnih praktičara tako i istraživača.

Iako, kao što je navedeno u uvodu ovog poglavlja, protok materijala neće biti zamijenjen protokom informacija, protok informacija uvelike određuje učinkovitost protoka materijala. Podrška informacijskim procesima implementiranim unutar e-logistike metodama i alatima za analizu podataka čini se posebno važnom u tom smislu. Suvremena tehnička rješenja omogućuju prikupljanje velikih skupova podataka i traženje odnosa između tih podataka kako bi se pripremile informacije korisne za donošenje menadžerskih odluka.

Detaljna rješenja u području analize podataka, pripreme podataka za donošenje menadžerskih odluka obrađena su u ostalim poglavlјima ovog priručnika. Predstavljaju ne samo koncepte poslovne analitike već i ERP sustave koji omogućuju prikupljanje podataka, BI alate koji omogućuju analizu i vizualizaciju podataka, kao i suvremena pitanja vezana uz korištenje strojnog učenja u analizi podataka i sigurnosti podataka.

Nepostojanje jasnog konteksta za definiranje pojma e-logistike uzrokovano je brzim razvojem predmeta i brisanjem granica između pojedinih rješenja koja podržavaju provedbu protoka informacija.

## REFERENCE

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 logistiką [available at: [dachser.pl/pl/elogistics-116](http://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](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. Samoili, 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, Bejing, 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 U LOGISTICI

Autor: Dario Šebalj

Geografski informacijski sustavi (GIS) napravili su revoluciju u logističkoj industriji pružajući moćne alate za prostornu analizu i donošenje odluka. Kako poduzeća sve više posluju u globaliziranom okruženju, mogućnost vizualizacije i analize geografskih podataka ključna je za optimizaciju opskrbnih lanaca, upravljanje transportnim mrežama i povećanje ukupne učinkovitosti. GIS tehnologija omogućuje logističkim stručnjacima da mapiraju rute, prate pošiljke i analiziraju prostorne obrasce, što dovodi do donošenja informiranijih odluka i poboljšane raspodjele resursa. Ovo poglavlje istražuje integraciju GIS-a u logistiku, ističući njegove primjene, prednosti i budući potencijal. Razumijevanjem načina na koji se GIS može iskoristiti u logistici, tvrtke mogu stići konkurentsку prednost, smanjiti troškove i povećati zadovoljstvo kupaca.

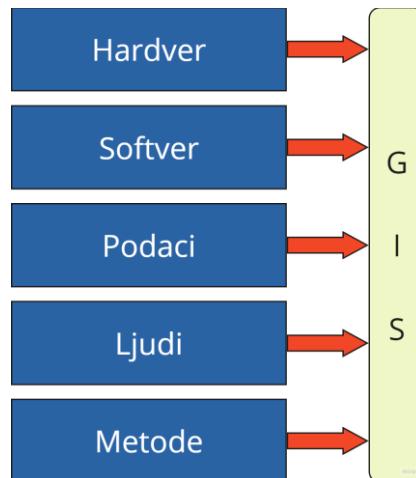
### 8.1. Geografski informacijski sustavi (GIS)

Geografski informacijski sustav (GIS) računalni je alat koji integrira, pohranjuje, analizira i vizualizira geografske podatke. Povezuje prostorne podatke s opisnim informacijama kako bi korisnicima pomogao razumjeti i protumačiti prostorne odnose, obrasce i trendove. GIS se koristi u raznim industrijama za mapiranje, analizu i donošenje odluka, pružajući dragocjene uvide u prostorne dimenzije podataka (Jonker, 2023; GisGeography, 2024a; Esri, n.d.a; National Geographic, n.d.).

Prema Esri (n.d.b) i GisGeography (2024b), povijest geografskih informacijskih sustava (GIS) seže u rane 1960-e kada je prvi računalni GIS razvio **Roger Tomlinson**, često nazivan "ocem GIS-a". Ovaj inicijalni sustav stvoren je za Kanadski zemljinski inventar kako bi pomogao u upravljanju korištenjem zemljišta i planiranju resursa. Tijekom 1970-ih i 1980-ih, napredak računalne tehnologije, daljinsko očitavanje i prostorna analiza doveli su do razvoja sofisticiranijeg GIS softvera. Godine 1969. osnovan je Esri - Institut za istraživanje sustava okoliša, koji je postao ključni igrač u GIS industriji, uvodeći ArcGIS platformu, koja je značajno poboljšala mogućnosti i dostupnost GIS tehnologije. Do 1990-ih, GIS tehnologija se razvila i uključila širi raspon primjena, od urbanog planiranja do upravljanja okolišem. Integracija GIS-a s GPS-om (eng. Global Positioning Systems) i pojava interneta dodatno su proširili njegovu



upotrebu. Danas je GIS sastavni alat u raznim sektorima, uključujući transport, logistiku, poljoprivredu i javnu sigurnost, pružajući kritične uvide i pomažući u procesima donošenja odluka.



Slika 8.1 Komponente GIS-a

Izvor: Autor, prema Kishore i Rautray (n.d.).

Slika 8.1 prikazuje pet osnovnih komponenti geografskog informacijskog sustava (GIS), prema Kishoreu i Rautrayu (n.d.):

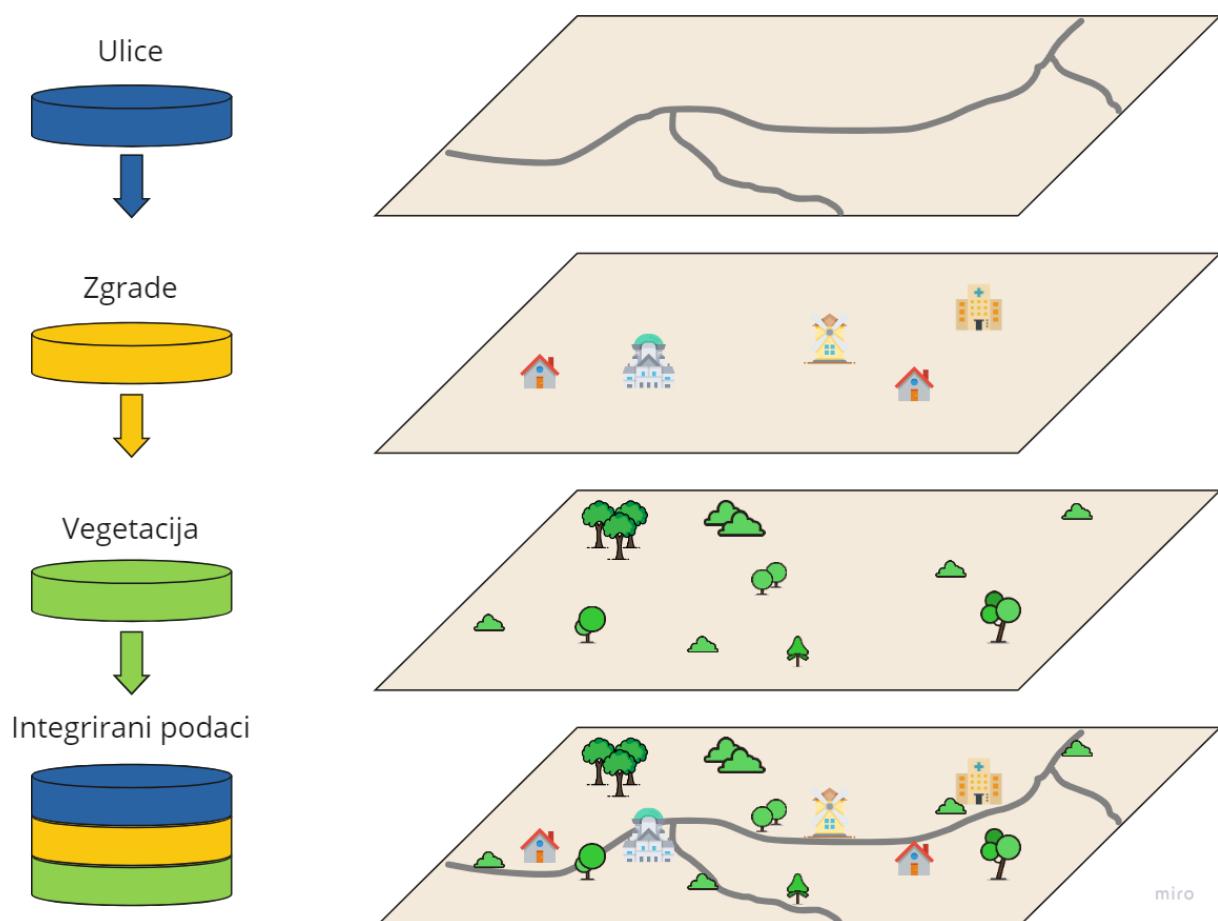
- **Hardver:** fizički uređaji koji se koriste za pokretanje GIS softvera i pohranu podataka, kao što su računala, poslužitelji, GPS uređaji i drugi periferni uređaji.
- **Softver:** programi koji izvode GIS funkcije, omogućujući korisnicima analizu i vizualizaciju prostornih podataka.
- **Podaci:** prostorne i neprostorne informacije koje GIS sustavi analiziraju, uključujući karte, satelitske slike i tablične podatke.
- **Metode:** tehnike i postupci koji se koriste za analizu GIS podataka, kao što su algoritmi i statistički modeli.
- **Ljudi:** profesionalci i korisnici koji rade i upravljaju GIS tehnologijom, od analitičara podataka do donositelja odluka.

Geografski informacijski sustavi imaju širok raspon primjena u raznim industrijama, što ih čini nezamjenjivim alatima za analizu prostornih podataka i donošenje odluka. U poslovnoj inteligenciji, GIS se koristi za analizu tržišta, odabir lokacije i optimizaciju logistike, pomažući tvrtkama da donose odluke vođene podacima na temelju geografskih trendova (Longley et al., 2015). Upravljanje okolišem koristi GIS za upravljanje prirodnim resursima, praćenje okoliša i odgovor na katastrofe, omogućujući učinkovitije napore za očuvanje i planiranje u hitnim



slučajevima (Goodchild et al., 2018). Integracijom i analizom prostornih podataka, GIS poboljšava procese donošenja odluka kroz precizne geografske uvide i vizualizacije, omogućujući organizacijama da identificiraju obrasce i odnose koji nisu odmah vidljivi u tradicionalnim formatima podataka (Longley et al., 2015).

Jedan od ključnih koncepata GIS tehnologije je koncept slojeva. Prema Esri (n.d.c), sloj je isječak geografske stvarnosti u određenom području. Svaki sloj u GIS-u odgovara određenoj vrsti podataka, kao što su ceste, zemljišta, nadmorska visina, vodene površine ili gustoća naseljenosti. Slika 8.2 prikazuje primjer različitih vrsta podataka na jednoj karti (ulice, zgrade i vegetacija), od kojih svaki odgovara jednom sloju.



Slika 8.2 GIS slojevi

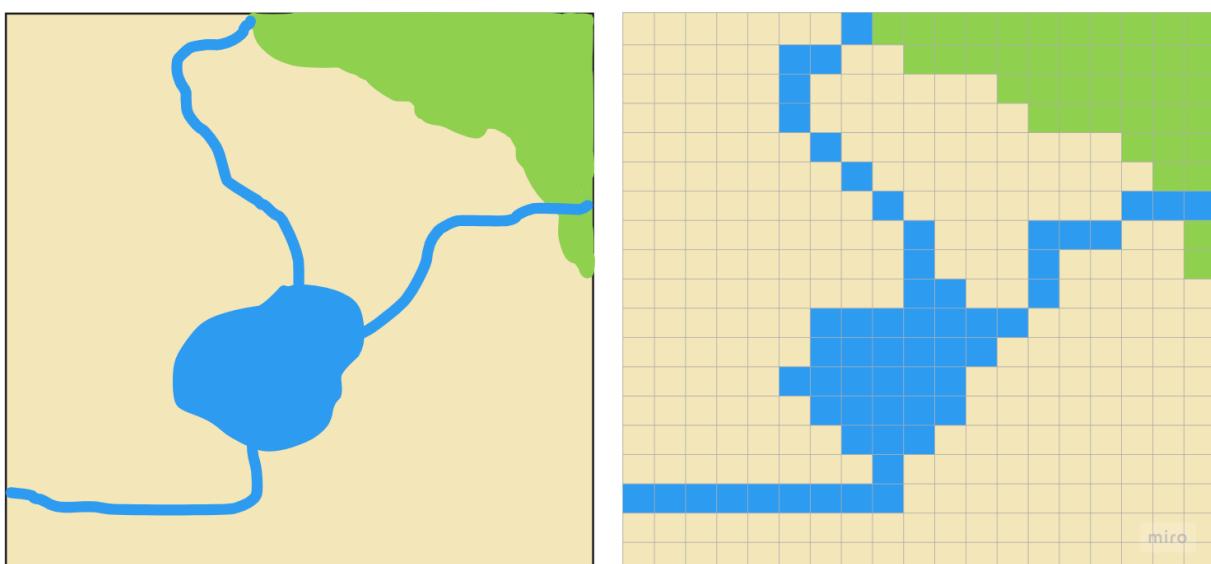
Izvor: Autor, prema National Geographic (n.d.).

Geografski informacijski sustavi oslanjaju se na različite vrste podataka za predstavljanje, analizu i vizualizaciju geografskih informacija. GIS podaci mogu se općenito kategorizirati u dvije glavne vrste: rasterski i vektorski podaci.



Prema Dempseyju (2024), prevladavajući oblik GIS podataka su **vektorski podaci**. Točke, linije i poligoni koji se koriste za predstavljanje geografskih podataka primjeri su vektorskog podataka. U vektorskome prikazu sve su linije prikazane kao točke povezane preciznim ravnim linijama (Longley et al., 2015). Točke predstavljaju diskretne podatkovne točke ili određene lokacije, poput škola, imena gradova ili zanimljivih točaka. Linijski podaci predstavljaju linearne značajke poput cesta i rijeka, a poligoni se koriste za značajke područja kao što su jezera, administrativne granice i šume (Dempsey, 2024).

**Rasterski podaci** predstavljaju strukturu podataka koja se temelji na mreži i sastoji se od piksela ili ćelija, od kojih svaka ima pridruženi atribut. Najčešći izvori rasterskih podataka su satelitske snimke, snimke iz zraka, podaci daljinske detekcije te podaci s osjenčanim reljefom i topografijom (Dempsey, 2024; Longley et al., 2015).



**Slika 8.3 Vektorski (lijevo) i rasterski (desno) podaci**

Izvor: Autor.

Slika 8.3 prikazuje dvije karte koristeći vektorske (lijevo) i rasterske (desno) podatke. Vektorski podaci uključuju poligone (jezera i šume) i linije (rijeku), a rasterski podaci uključuju mrežu gdje svaka ćelija predstavlja jednu boju (plavu, žutu ili zelenu).

Važno je razumjeti različite vrste GIS podataka kako bi se učinkovito koristili u poslovnoj inteligenciji. Vektorski podaci idealni su za precizno mapiranje i analizu diskretnih geografskih značajki, dok su rasterski podaci izvrsni za predstavljanje kontinuiranih podataka i velikih podataka vezanih uz okoliš.



## 8.2. GIS u logistici

Geografski informacijski sustavi (GIS) iz temelja su transformirali logistički sektor, pružajući alate koji omogućuju učinkovitije, troškovno učinkovitije i strateške procese donošenja odluka. Integracija GIS-a u logistiku omogućuje vizualizaciju, analizu i interpretaciju prostornih podataka, što je ključno za optimizaciju ruta, upravljanje opskrbnim lancima i povećanje ukupne operativne učinkovitosti.

Kako bi odgovorila na logističke izazove, GIS tehnologija kombinira najsuvremenije tehnike upravljanja podacima i geografiju. Logistički profesionalci mogu vidjeti uzorce, odnose i trendove koji nisu vidljivi u tradicionalnim formatima podataka koristeći ih za lakše preklapanje različitih skupova podataka na karti. Prema Esri (2017), strateško planiranje i operativna optimizacija imaju velike koristi od ove prostorne perspektive.

Jedna od primarnih primjena GIS-a u logistici je optimizacija ruta. Analizom prostornih podataka, logističke tvrtke mogu odrediti najučinkovitije rute za dostavu, smanjujući vrijeme putovanja, potrošnju goriva i ukupne operativne troškove. Na primjer, GIS može uzeti u obzir obrasce prometa, uvjete na cestama, ograničenja brzine kako bi optimizirao rutu u stvarnom vremenu (Ramzan, 2023). Ova mogućnost ne samo da poboljšava učinkovitost, već i povećava zadovoljstvo kupaca osiguravanjem pravovremenih isporuka.

Sureshkumar et al. (2017) proveli su studiju koja ističe brojne prednosti GIS-a i naglašava njegov transformativni potencijal u optimizaciji ruta za upravljanje prometom. GIS omogućuje primjenu podataka u stvarnom vremenu za dinamičke prilagodbe prometa i sveobuhvatnu prostornu analizu olakšavanjem integracije različitih vrsta podataka, uključujući GPS i satelitske snimke. Zbog ove integracije, postoje velike uštede vremena i troškova zbog kraćih udaljenosti putovanja i manje potrošnje goriva. Procesi donošenja odluka poboljšani su mogućnostima prostorne vizualizacije GIS-a, koje otkrivaju obrasce i trendove koji su skriveni u konvencionalnim formatima podataka. Kad se sve uzme u obzir, studija pokazuje da optimizacija ruta temeljena na GIS-u ne samo da smanjuje utjecaj na okoliš i povećava operativnu učinkovitost, već nudi i snažan okvir za rješavanje zamršenih problema gradskog prometa.

Primjena geografskih informacijskih sustava u optimizaciji ruta prikupljanja komunalnog krutog otpada (eng. *municipal solid waste* - MSW) pokazala se vrlo učinkovitom u povećanju operativne učinkovitosti i smanjenju troškova. Singh i Behera (2018) pokazali su da je integracija GIS-a i alata za mrežnu analizu u ArcGIS značajno smanjila udaljenosti prijevoza za



prosječno 27,78%, ističući značajna poboljšanja u logistici gospodarenja otpadom u Kanpuru u Indiji. Slično, Nguyen-Trong et al. (2016) upotrijebili su kombinirani pristup GIS-a, optimizacije temeljene na jednadžbama i modeliranja temeljenog na agentima za dinamičku optimizaciju ruta prikupljanja otpada u gradu Hagiang u Vijetnamu, postigavši smanjenje troškova od 11,3%. Ove studije naglašavaju transformativni potencijal GIS-a u rješavanju složenosti gospodarenja gradskim otpadom, posebice kroz integraciju podataka u stvarnom vremenu i naprednih tehnika modeliranja. Korištenjem GIS-a za prostornu analizu i optimizaciju ruta, općine mogu postići održivije i učinkovitije prakse gospodarenja otpadom, čime se poboljšava cjelokupno pružanje usluga i smanjuje utjecaj na okoliš.

Hemidat et al. (2017) proveli su studiju koja ima za cilj poboljšati učinkovitost prikupljanja komunalnog krutog otpada (MSW) u nekoliko jordanskih gradova korištenjem GIS tehnika. Istraživači su razvili optimizirane scenarije prikupljanja otpada pomoću alata ArcGIS Network Analyst, s ciljem smanjenja operativnih troškova, vremena rada vozila i utjecaja na okoliš. Optimizirani scenariji pokazali su značajne uštede u usporedbi s trenutnim stanjem (S0). Konkretno, Scenarij S1 rezultirao je uštemom troškova od 15%, 6%, odnosno 11% za Irbid, Karak i Mafraq. Scenarij S2 pokazao je uštemu troškova od 13%, 3% i 6% za iste gradove. Kombinirani scenarij (S3) donio je najveće uštede, sa smanjenjem ukupnih troškova od 23%, 8% i 13%. Ovi rezultati naglašavaju značajan utjecaj optimizacije rute temeljene na GIS-u na smanjenje operativnih troškova, vremena rada vozila i utjecaja na okoliš minimiziranjem potrošnje goriva i emisija.

Analitika temeljena na GIS-u značajno poboljšava upravljanje lancem opskrbe krvlju pružajući vidljivost u stvarnom vremenu i olakšavajući bolje donošenje odluka. Integracija GIS-a s rudarenjem podataka i drugim analitičkim tehnikama omogućuje učinkovito praćenje, upravljanje i optimizaciju izvora krvi, što dovodi do poboljšane operativne učinkovitosti i smanjenog rasipanja (Delen et al., 2011).

Također, GIS igra vitalnu ulogu u planiranju i upravljanju urbanom infrastrukturom pružajući robusnu platformu za integraciju i analizu prostornih podataka. Korištenje GIS-a u ovom kontekstu omogućuje informiranije donošenje odluka, što dovodi do optimiziranih ulaganja u infrastrukturu i poboljšanog pružanja usluga. Studija koju su proveli Irizarry et al. (2013) ističe učinkovitost GIS-a u upravljanju urbanom infrastrukturom i poboljšanju operativne učinkovitosti.



Korištenje GIS-a u optimizaciji ruta u različitim domenama, kao što je upravljanje komunalnim čvrstim otpadom, upravljanje lancem opskrbe krvlju i planiranje urbane infrastrukture, pokazalo je značajne prednosti. GIS poboljšava operativnu učinkovitost integracijom prostornih podataka s naprednim analitičkim alatima, olakšavajući donošenje odluka u stvarnom vremenu i optimizirajući korištenje resursa. Studije su pokazale značajna smanjenja troškova i poboljšanu isporuku usluga putem optimizacije rute temeljene na GIS-u, naglašavajući njegovu ključnu ulogu u upravljanju složenim logističkim operacijama. Korištenjem GIS tehnologije, organizacije mogu postići održive prakse, smanjiti utjecaj na okoliš i poboljšati ukupnu operativnu učinkovitost.

### 8.3. Budući trendovi vezani uz GIS

Geografski informacijski sustavi prolaze kroz značajne transformacije potaknute tehnološkim napretkom i sve većim zahtjevima za analizom prostornih podataka. Ovo će potpoglavlje istražiti buduće trendove u GIS-u, s fokusom na nove tehnologije, računalstvo u oblaku, integraciju velikih podataka i ulogu umjetne inteligencije (AI) i strojnog učenja (ML).

Budućnost GIS-a oblikuje nekoliko ključnih trendova i inovacija koje mijenjaju način na koji prikupljamo, analiziramo i koristimo prostorne podatke. Značajan trend je integracija naprednih tehnologija kao što su računalstvo u oblaku, AI, strojno učenje (ML) i prikupljanje podataka temeljeno na dronovima. Ove tehnologije poboljšavaju učinkovitost i mogućnosti GIS-a, omogućujući obradu podataka u stvarnom vremenu i sofisticiranje prostorne analize.

**Računalstvo u oblaku** revolucionira GIS pružajući skalabilne i pristupačne platforme za pohranu i obradu velikih skupova podataka. Ova promjena omogućuje organizacijama da iskoriste ogromne količine geoprostornih podataka bez potrebe za značajnom lokalnom infrastrukturom. Primjetan je rast GIS-a kao usluge (eng. *GIS as a service*), omogućujući korisnicima pristup moćnim GIS alatima i mogućnostima analize podataka putem platformi u oblaku. Ovaj trend čini GIS pristupačnijim i isplativijim, posebno za manje organizacije i industrije s ograničenim resursima. **AI i ML** igraju važnu ulogu u automatizaciji i poboljšanju analize prostornih podataka. Te tehnologije mogu identificirati obrasce, napraviti predviđanja i pružiti uvide iz složenih skupova podataka koje bi bilo teško ručno analizirati. Na primjer, algoritmi umjetne inteligencije mogu obraditi satelitske slike kako bi otkrili promjene u korištenju zemljišta, dok ML modeli mogu predvidjeti obrasce prometa na temelju povijesnih podataka. Integracija AI i ML s GIS-om omogućuje točnije i pravodobnije donošenje odluka u različitim sektorima, od urbanog planiranja do upravljanja katastrofama. Napredak u



**tehnologiji dronova** također je značajan trend u GIS-u. Dronovi opremljeni kamerama i senzorima visoke rezolucije sve se više koriste za prikupljanje podataka na teško dostupnim mjestima. Ovi alati daju podatke visoke točnosti u stvarnom vremenu koji se mogu integrirati u GIS za detaljno mapiranje i analizu. Ovaj trend posebno je koristan za praćenje okoliša, inspekciju infrastrukture i upravljanje poljoprivredom. Još jedan novi trend je korištenje **proširene stvarnosti** (AR) i **virtualne stvarnosti** (VR) u GIS-u. Ove tehnologije nude nove načine vizualizacije i interakcije s prostornim podacima, pružajući impresivna iskustva koja mogu poboljšati razumijevanje i donošenje odluka. Na primjer, AR može prikazati geoprostorne podatke kao sloj na prikazu stvarnog svijeta, pomažući korisnicima da vizualiziraju podzemne komunalne instalacije ili da se kreću kroz složena okruženja. VR može stvoriti detaljne simulacije urbanih krajolika, omogućujući planerima da istraže različite scenarije i njihove potencijalne utjecaje. **Analiza podataka u stvarnom vremenu** postaje sve važnija u GIS aplikacijama. Sposobnost obrade i analize podataka dok se prikupljaju omogućuje brže reagiranje i dinamičnije donošenje odluka. Ova je mogućnost poboljšana integracijom GIS-a s Internetom stvari (IoT), gdje se podaci s povezanih uređaja mogu kontinuirano pratiti i analizirati. GIS u stvarnom vremenu koristi se u aplikacijama kao što su upravljanje prometom, odgovor na hitne slučajeve i nadzor okoliša, gdje su pravovremene informacije ključne. Također treba spomenuti širenje GIS aplikacija u nove industrije i sektore. GIS se sada koristi u područjima kao što je zdravstvo, gdje pomaže u praćenju izbjivanja bolesti i optimizira pružanje zdravstvene skrbi. U maloprodaji GIS analizira demografiju kupaca i optimizira lokacije trgovina. Tehnologija je također ključna u inicijativama pametnih gradova, pružajući prostornu inteligenciju potrebnu za učinkovito upravljanje urbanom infrastrukturom i resursima (Kerski, 2022; MGISS, 2023).

Kao što se može vidjeti, integracija GIS-a u logistiku je revolucionirala industriju povećanjem operativne učinkovitosti, smanjenjem troškova i poboljšanjem zadovoljstva kupaca. Kako se GIS tehnologija nastavlja razvijati, njezine će se primjene u logistici proširiti, nudeći još sofisticirane alate za rješavanje složenih izazova. Iskorištavanjem ovih poboljšanja, logističke tvrtke mogu održati konkurenčku prednost i prilagoditi se dinamičnim zahtjevima globalnog tržišta.



## REFERENCE

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* [dostupno na: <https://www.geographyrealm.com/geodatabases-explored-vector-and-raster-data/>, pristupljeno 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? [dostupno na: <https://www.esri.com/en-us/what-is-gis/overview>, pristupljeno May 27, 2024]
5. Esri (n.d.b). History of GIS? [dostupno na: <https://www.esri.com/en-us/what-is-gis/history-of-gis>, pristupljeno May 27, 2024]
6. Esri (n.d.c). Layer. *GIS dictionary* [dostupno na: <https://support.esri.com/en-us/gis-dictionary/layer>, pristupljeno June 8, 2024]
7. GisGeography (2024a). The Remarkable History of GIS [dostupno na: <https://gisgeography.com/history-of-gis/>, pristupljeno May 27, 2024]
8. GisGeography (2024b). What is GIS? Geographic Information Systems [dostupno na: <https://gisgeography.com/what-is-gis/>, pristupljeno 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*, 4<sup>th</sup> 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 [dostupno na: <https://www.ibm.com/topics/geographic-information-system>, pristupljeno May 27, 2024]
14. Kerski, J. (2022). 5 Trends in GIS and How to Successfully Navigate Them. Esri [dostupno na: <https://community.esri.com/t5/esri-young-professionals-network-blog/5-trends-in-gis-and-how-to-successfully-navigate/ba-p/1169616>, pristupljeno June 9, 2024]
15. Kishore, P. & Rautray, S. (n.d.). The five essential components of GIS. Infosys BPM [dostupno na: <https://www.infosysbpmpm.com/blogs/geospatial-data-services/gis-five-essential-components.html>, pristupljeno June 8, 2024]
16. Longley, P. A., Goodchild, M. F., Maguire, D. J. & Rhind, D. W. (2015). Geographic Information Science and Systems, 4<sup>th</sup> edition. John Wiley & Sons.
17. MGISS (2023). The Future of Gis: Trends and Innovations in Geospatial Technology [dostupno na: <https://mgiss.co.uk/the-future-of-gis-trends-and-innovations-in-geospatial-technology/>, pristupljeno June 9, 2024]
18. National Geographic (n.d.). GIS (Geographic Information System) [dostupno na: <https://education.nationalgeographic.org/resource/geographic-information-system-gis/>, pristupljeno May 27, 2024]
19. Ramzan, H. (2023). Optimizing Route Planning with GIS: A Comprehensive Approach for GIS Engineers. Medium [dostupno na: <https://medium.com/@hadiaramzan.2199/optimizing-route-planning-with-gis-a-comprehensive-approach-for-gis-engineers-f12d94dd7a16>, pristupljeno 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 PODATAKA

Autor: Dario Šebalj

U današnjem svijetu temeljenom na podacima, sposobnost učinkovitog prevođenja složenih skupova podataka u jasne, intuitivne vizualizacije nužna je za organizacije koje žele učinkovito koristiti svoje podatke. Vizualizacija podataka nadilazi čisto estetski prikaz; to je temeljna komponenta poslovne inteligencije koja pomaže donositeljima odluka identificirati trendove, stršeće vrijednosti i obrasce skrivene u neobrađenim podacima. U ovom poglavlju bit će predstavljane različite vrste vizualizacija, od jednostavnih grafikona kao što su stupčasti i linijski dijagrami do komplikiranijih grafičkih prikaza kao što su toplinske karte i bullet grafikoni. Svaka vrsta vizualizacije služi različitim svrhama i prikladna je za različite skupove podataka, stoga je za analitičare podataka ključno odabrati odgovarajuću vizualizaciju kako bi se učinkovito prenijela željena poruka.

Vizualizacija podataka je proces pretvaranja informacija u vizualni kontekst, kao što je karta ili grafikon, a koristi se kako bi ljudski um olakšao razumijevanje podataka i izvlačenje zaključaka. Glavni cilj vizualizacije podataka je olakšati identifikaciju obrazaca, trendova i outliera u velikim skupovima podataka. Uobičajene vrste vizualizacije podataka uključuju grafikone, tablice, karte i nadzorne ploče (Brush, 2022; GeeksForGeeks, 2024).

Zbog sve veće popularnosti velikih podataka i projekata analitike podataka, vizualizacija je sada važnija nego ikada. Tvrte sve više koriste strojno učenje za prikupljanje ogromnih količina podataka, koje može biti teško i sporo obraditi, razumjeti i objasniti. To se može ubrzati uz pomoć vizualizacije, koja također čini informacije lakšima za razumijevanje dionicima i vlasnicima tvrtki (Brush, 2022.).

Prije odabira metode vizualizacije važno je razumjeti kontekst vizualizacije.

### 9.1. Razumijevanje situacijskog konteksta

Nussbaumer Knaflc (2015) navodi da je razumijevanje i kontekstualizacija prvi i najvažniji korak prije bavljenja tehnikama vizualizacije podataka i metodama pripovijedanja. Razumijevanje publike ključni je aspekt konteksta. Nussbaumer Knaflc ističe važnost



poznavanja publike, razine njihove stručnosti i shvaćanje što joj je važno. Ovo razumijevanje osigurava da su vizualizacija podataka i pripovijedanje prilagođeni potrebama i preferencijama publike, čineći informacije relevantnijima i zanimljivijima.

Prema IBM-u (n.d.), općenite pozadinske informacije pomažu publici da razumije važnost određenog podatka na vizualizaciji. Na primjer, ako je stopa otvaranja e-pošte u tvrtki ispod prosjeka, trebali bismo pokazati kakva je stopa otvaranja u usporedbi s industrijom u cjelini kako bismo ilustrirali da postoji problem s ovim marketinškim kanalom. Publika mora razumjeti kakva je trenutna izvedba u usporedbi s određenim ciljem, mjerilom ili drugim ključnim pokazateljima performansi (KPI) kako bi bila motivirana za poduzimanje određenih radnji.

Postoje tri važna pitanja na koja je potrebno odgovoriti (Nussbaumer Knaflc, 2015; IBM, n.d.):

- **Tko:** prepoznavanje publike i razumijevanje njihove perspektive kako bi se znalo kako bi priča trebala biti skrojena. Time se osigurava da je vizualizacija usmjerenica izravno na ciljanu publiku, što je čini učinkovitijom i privlačnijom. Na primjer, dok kvartalno godišnje izvješće može sadržavati samo sažete informacije (na visokoj razini detalja), finansijski analitičar može trebati detaljniju analizu trendova tijekom nekoliko godina. Odluka o složenosti, razini detalja i uvidima koje treba naglasiti ovisi o tome tko će gledati vizualizaciju.
- **Što:** ključna poruka ili uvid koji treba priopćiti publici. Radi se o jasnoj radnji ili odluci na koju vizualizacija podataka namjerava utjecati. Kontekst definira svrhu vizualizacije. Je li riječ o uvjeravanju, informiranju, istraživanju ili potvrđivanju? Svaka svrha može dovesti do različitih odluka o vrsti vizualizacije i podacima koje treba istaknuti. Na primjer, uvjerljiva vizualizacija koja je napravljena sa svrhom dobivanja potpore za pokretanje nekih novih inicijativa će se usmjeriti na drugačije podatke od vizualizacije kojoj je svrha prikaz jednostavnih informacija o nekim prošlim performansama.
- **Kako:** odabir najprikladnijeg i najučinkovitijeg načina priopćavanja priče ili uvida, uzimajući u obzir medij, format i tehnike vizualizacije koje će najbolje odjeknuti kod ciljane publike. Određene vrste skupova podataka također zahtijevaju posebnu vizualizaciju. Na primjer, dijagrami raspršenosti dobri su za prikaz odnosa između dviju varijabli, a linijski grafikoni dobar su način za prikaz podataka vremenske serije. Vizualni elementi trebaju pomoći publici da razumije glavnu poruku. Neispravan raspored grafikona i podataka može imati suprotan učinak i zbuniti, a ne prosvijetliti publiku.



Kada je riječ o vizualizaciji i analizi podataka, potrebno je napraviti razliku između eksploratorne i eksplanatorne vizualizacije. Eksploratorna vizualizacija motivira korisnika da samostalno dublje prodre u podatke ili temu kako bi došao do vlastitih otkrića. Eksplanatorna vizualizacija stavlja rezultate u prvi plan, prenoseći autorovu hipotezu ili argument čitatelju (Schwabish, 2021).

Nakon što smo istražili važnost razumijevanja situacijskog konteksta u kojem se koriste vizualizacije podataka, jasno je da ovo temeljno znanje određuje način na koji se informacije najbolje komuniciraju i percipiraju od strane publike.

Sljedeći kritični korak je učinkovito uključiti publiku. Iduće potpoglavlje opisuje strategije za angažiranje i održavanje interesa gledatelja. To uključuje odabir elemenata koji povećavaju vizualnu privlačnost i čitljivost vizualizacije podataka i osiguravaju da ključni uvidi ne prođu nezapaženo. Korištenjem tehnika privlačenja pozornosti i isticanja važnih podataka, vizualizacije mogu biti više od puke informacije - mogu biti zadivljujuće i uvjerljive.

## 9.2. Metode privlačenja pozornosti

Prilikom oblikovanja vizualizacija podataka vrlo je važno zaokupiti i usmjeriti pozornost publike. Međuodnos između mehanike vida i načela vizualne percepcije određuje koliko učinkovito vizualizacija prenosi željenu poruku. Razumijevanje načina na koji ljudsko oko opaža vizualne elemente prvi je korak u stvaranju uvjerljivih vizualizacija.



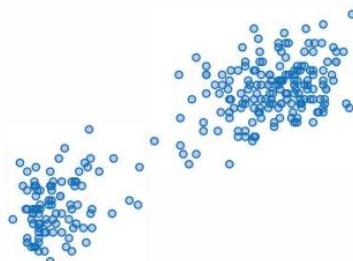
Otprilike 70% osjetilnih receptora u našem tijelu je posvećeno vidu (Few, 2012).

Oko gotovo trenutno uočava određene vizualne atribute, tj. ti se atributi brzo i automatski obrađuju u vizualnom sustavu bez svjesnog npora. Atributi kao što su boja, veličina, oblik i orijentacija mogu se koristiti za isticanje kritičnih podataka ili područja unutar vizualizacije i mogu odmah privući pozornost gledatelja.

Prema Schwabishu (2021), **Gestalt teorija** opisuje kako ljudi obično grupiraju vizualne elemente. Riječ *Gestalt* znači *uzorak* (Kairo, 2013). Razvili su ga njemački psiholozi početkom 20. stoljeća. Kada je riječ o stvaranju dijagrama i drugih vizualizacija, od velike pomoći mogu biti šest načela Gestalt teorije.



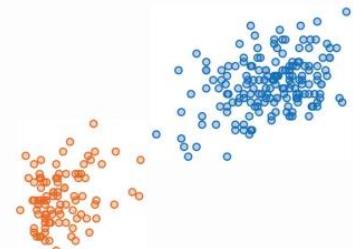
Načelo **blizine** kaže da naša percepcija grupira objekte zajedno kada su u neposrednoj blizini jedan drugome (npr. slika 9.1).



Slika 9.1 Blizina kao načelo Gestalt teorije

Izvor: Schwabish (2021).

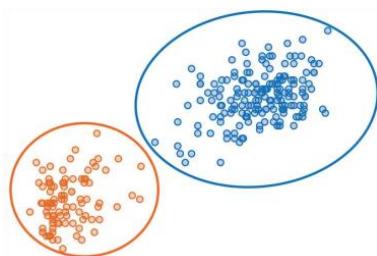
Načelo **sličnosti** kaže da ljudski mozak kategorizira objekte na temelju njihovih zajedničkih atributa kao što su boja, oblik ili smjer (npr. slika 9.2).



Slika 9.2 Sličnost kao načelo Gestalt teorije

Izvor: Schwabish (2021).

Prema principu **ograđenosti**, omeđeni objekti se percipiraju kao grupa (npr. slika 9.3).



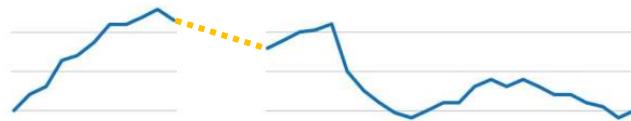
Slika 9.3 Ogradenost kao načelo Gestalt teorije

Izvor: Schwabish (2021).

Prema principu **zatvaranja**, naš mozak teži ignorirati praznine i popuniti informacije koje nedostaju kako bi formirao cjelovitu strukturu. Kada analiziramo linijski grafikon koji sadrži



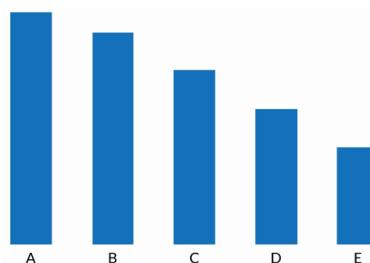
podatke koji nedostaju, skloni smo mentalno popuniti praznine koristeći najjednostavniji pristup (npr. slika 9.4).



Slika 9.4 Zatvaranje kao načelo Gestalt teorije

Izvor: Schwabish (2021).

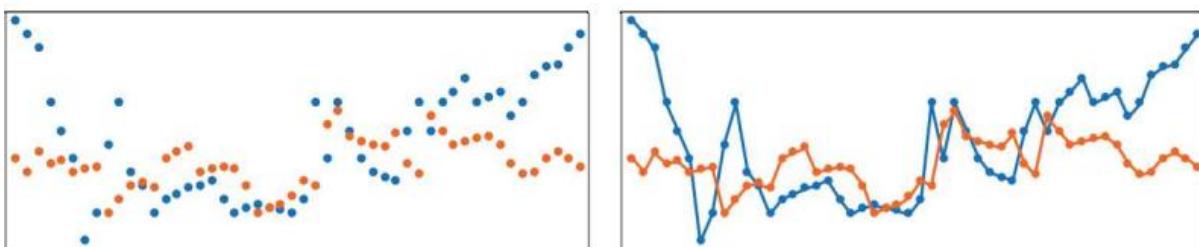
Načelo **kontinuiteta** sugerira da gledatelj percipira elemente poredane u ravnu liniju ili glatku krivulju kao da su više povezani od elemenata koji ne leže na liniji ili krivulji (npr. slika 9.5).



Slika 9.5 Kontinuitet kao načelo Gestalt teorije

Izvor: Schwabish (2021).

Na temelju načela **povezanosti**, naša percepcija kategorizira objekte koji su međusobno povezani kao da pripadaju istoj skupini (npr. slika 9.6).



Slika 9.6 Povezanost kao načelo Gestalt teorije

Izvor: Schwabish (2021).

Postoji vrlo važan koncept vizualizacije podataka, podskup Gestalt teorije koji se zove preattentivna obrada (eng. *preattentive processing*). Schwabish (2021) objašnjava da preattentivne značajke privlače našu pozornost na određeno područje grafikona ili slike. U nastavku ovog poglavlja, ove će se značajke nazivati „atributi za privlačenje pozornosti“.



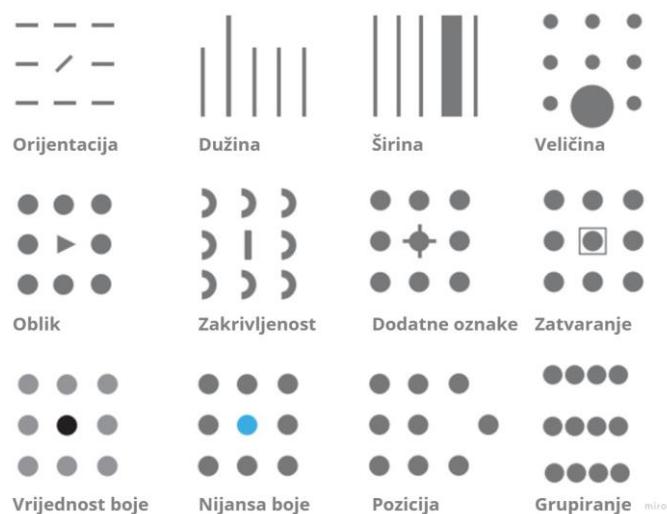
Ove značajke odnose se na vizualne kvalitete koje ljudski vizualni sustav može percipirati u ranim fazama vizualne obrade bez svjesne pažnje, a koje se obično mijere u milisekundama. Atributi koji se koriste u ovoj knjizi su boja (plava) i debljina (podebljani tekst). Sljedeći vrlo popularan primjer je pronalaženje određenog broja u matrici brojeva (npr. Wexler et al., 2017). Slika 9.7 prikazuje matricu s brojevima bez (lijevo) i s (desno) atributa za privlačenje pozornosti.

2 2 5 6 7 1 1 6 9 1	2 2 5 6 7 1 1 6 <b>9</b> 1
9 1 7 5 5 5 6 2 5 9	<b>9</b> 1 7 5 5 5 6 2 5 <b>9</b>
4 5 2 9 6 9 7 6 4 6	4 5 2 <b>9</b> 6 <b>9</b> 7 6 4 6
8 1 5 7 8 5 6 6 6 7	8 1 5 7 8 5 6 6 6 7
7 2 3 6 8 9 1 7 9 1	7 2 3 6 8 <b>9</b> 1 7 <b>9</b> 1
3 8 6 8 4 5 6 9 4 5	3 8 6 8 4 5 6 <b>9</b> 4 5
4 9 9 2 3 7 1 9 1 2	4 <b>9</b> <b>9</b> 2 3 7 1 <b>9</b> 1 2
3 7 8 1 6 1 5 6 1 6	3 7 8 1 6 1 5 6 1 6
5 6 6 8 6 6 9 1 2 6	5 6 6 8 6 6 <b>9</b> 1 2 6
3 2 4 2 6 9 4 2 7 1	3 2 4 2 6 <b>9</b> 4 2 7 1

Slika 9.7 Korištenje atributa za privlačenje pozornosti u vizualizaciji podataka

Izvor: Wexler et al. (2017).

Ako gledamo lijevu matricu potrebno je dosta vremena da se pogodi koliko ima devetki. Ali samo jedna promjena u matrici čini veliku razliku. Promijenjena je samo boja – brojevi 9 su crveni, a svi ostali brojevi su svijetlo sivi. Boja (u ovom slučaju, nijansa) jedan je od nekoliko atributa za privlačenje pozornosti. Slika 9.8 prikazuje primjere nekih tributa koji se često koriste u vizualizaciji podataka.



Slika 9.8 Vrste atributa za privlačenje pozornosti u vizualizaciji podataka

Izvor: Wexler et al. (2017).



Atributi za privlačenje pozornosti omogućuju gledateljima da gotovo trenutačno prepoznaaju obrasce, stršeće vrijednosti ili neke druge važne podatke. Upotrebom strategija koje usmjeravaju oko gledatelja prema najvažnijim informacijama, vizualizacije podataka mogu značajno poboljšati komunikaciju i razumijevanje složenih skupova podataka.

U sljedećem potpoglavlju bit će prikazano kako različite vrste podataka i uvida koje trebaju pružiti utječu na izbor metoda vizualizacije. Od jednostavnih stupčastih grafikona do složenijih toplinskih karti ili bullet grafikona, odabir prave metode vizualizacije ključan je kako bi se osiguralo da podaci ne samo da privuku pažnju, već i učinkovito i točno prenesu željenu poruku.

### 9.3. Odabir ispravne metode vizualizacije

Prvi korak u odabiru odgovarajuće metode je temeljito razumijevanje podataka. Koje su ključne poruke koje želimo prenijeti? Koju vrstu podataka imamo na raspolaganju? Radimo li s podacima vremenskih serija, geografskim informacijama ili hijerarhijskim strukturama? Vrsta korištenih podataka može značajno utjecati na odabranu metodu vizualizacije. Koropletne karte su, na primjer, najprikladnije za prikaz geografskih podataka, dok su linijski grafikoni prikladniji za podatke vremenskih serija.

Pozadinski kontekst i očekivanja publike također igraju važnu ulogu u odabiru metode vizualizacije. Publika koja je više tehnički usmjerena može cijeniti detaljne i složene vizualizacije kao što su toplinske karte ili mrežni dijagrami. Općoj publici, s druge strane, jednostavniji grafikoni, kao što su stupčasti ili linijski grafikoni, mogu biti pristupačniji i zanimljiviji.

Interaktivnost je još jedan važan aspekt koji treba uzeti u obzir. Interaktivni vizualni elementi, kao što su dinamički dashboardi, omogućuju korisnicima istraživanje različitih razina podataka filtriranjem, zumiranjem i odabirom određenih elemenata. Ova interaktivnost može dovesti do dubljih uvida jer korisnici mogu prilagoditi vizualizaciju svojim specifičnim pitanjima.

Metoda vizualizacije ne mora uvijek biti grafikon. To također može biti tablica ili čak jednostavan tekst. Kao što Few (2012) navodi, svrha tablica i grafikona je učinkovito prenijeti važne informacije i pružiti čitatelju važne, smislene i korisne uvide.

U sljedećih nekoliko potpoglavlja ukratko će biti objašnjene najpopularnije metode vizualizacije..



### 9.3.1. Jednostavan tekst

Nussbaumer Knaflc (2015) predlaže korištenje jednostavnog teksta kada postoji samo jedan ili dva broja koja želite podijeliti (slika 9.9).



Slika 9.9 Jednostavan tekst u vizualizaciji

Izvor: Autor.

Prema Schwabishu (2021), ovaj jednostavan tekst često se naziva BAN (eng. *Big Ass Numbers*). Obično se koriste za privlačenje pozornosti na ključnu metriku ili pokazatelje učinka i daju gledatelju neposredan pristup važnim informacijama. Iстicanjem područja koja zahtijevaju pozornost ili djelovanje, BAN-ovi obično pomažu u donošenju odluka pomažući korisnicima da usmjeri svoju pozornost na važne aspekte podataka (Tay, 2024). Iako su BAN-ovi jednostavni, mogu se poboljšati suptilnim vizualnim elementima kao što su kodiranje u boji ili korištenjem ikona za označavanje performansi u odnosu na ciljeve ili promjene tijekom vremena. Na primjer, crvena strelica prema dolje pored broja koji označava prodaju može odmah ukazivati na pad, dok zelena strelica prema gore signalizira rast.

### 9.3.2. Tablica

Tablice su bitan dio vizualizacije podataka jer pružaju strukturiran i jasan način prezentiranja numeričkih podataka. Tablice su nevjerojatno korisne kada je u pitanju prezentiranje detaljnih informacija s preciznošću i jasnoćom, iako možda nemaju isti vizualni učinak kao grafikoni ili karte. Prema Schwabishu (2020), u većini slučajeva nisu namijenjene brzom vizualnom prikazu podataka. Umjesto toga, tablice su korisne kada je potrebno prikazati točne vrijednosti podataka. Iako nisu idealna opcija za prikaz puno podataka ili na malom prostoru, dobro dizajnirana tablica može pomoći čitatelju pronaći određene brojke, kao i uočiti trendove i odstupanja. Few (2012) naglašava da su tablice korisne za referencu i usporedbe jedan na jedan zbog svoje jednostavne strukture i činjenice da su kvantitativne vrijednosti izražene kao tekst koji možemo odmah razumjeti bez potrebe za prevođenjem.

Tablice trebaju biti oblikovane na sljedeći način (Schwabish, 2020; Nussbaumer Knaflc, 2015):

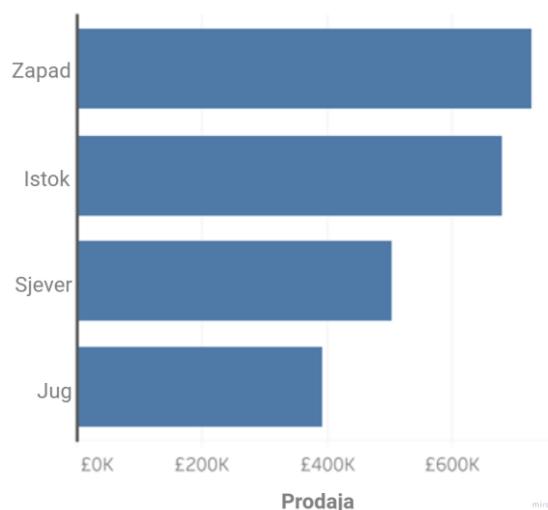
- uklonite sve obrube oko tablice



- što je više moguće posvijetlite linije između redova i stupaca ili ih u potpunosti uklonite
- jasno odvojite zaglavje od tijela tablice
- poravnajte tekst u tablici i zaglavlju ulijevo, a brojeve udesno
- koristite odgovarajuću razinu detalja podataka (npr. koristite brojeve s jednim decimalnim mjestom ako je to dovoljno za razumijevanje podataka)

### 9.3.3. Stupčasti grafikon

Stupčasti grafikon je idealan za prikaz numeričkih vrijednosti po grupama ili kategorijama (npr. ako želimo prikazati broj zaposlenih po odjelima). Može se prikazati okomito ili vodoravno. Horizontalni prikaz (kao na slici 9.10) preporuča se ako su nazivi kategorija preduži ili ako ima previše kategorija. Stupčasti dijagram na slici 9.10. prikazuje prodaju (kvantitativni podaci) po regijama (kvalitativni podaci).



Slika 9.10 Stupčasti grafikon u vizualizaciji

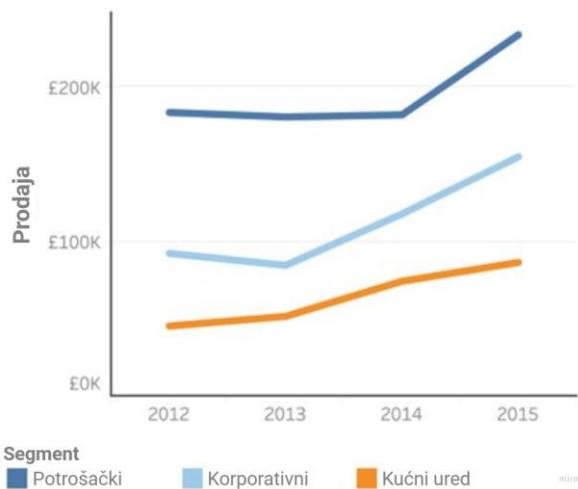
Izvor: Wexler et al. (2017).

Prema Fewu (2013), najučinkovitiji način predstavljanja mjera povezanih s diskretnim stavkama na nominalnoj ili ordinalnoj ljestvici je stupčasti grafikon. Lako je usporediti pojedinačne vrijednosti jednostavnom usporedbom visine stupaca. Os Y na stupčastom grafikonu mora počinjati od nule. Ako os počinje na vrijednosti različitoj od nule, to može prenaglasiti razliku između stupaca i iskriviti našu percepciju vrijednosti u stupčastom grafikonu, koja se temelji na duljini stupaca (Schwabish, 2021).



### 9.3.4. Linijski grafikon

Linijski grafikon koristi se za prikaz promjena kvantitativne vrijednosti, koja leži na y-osi, tijekom vremena, koje se nalazi na vodoravnoj x-osi. Yi (n.d.a) predlaže da linijski grafikon ne bi trebao sadržavati više od pet linija. Također, nije nužno da os Y počinje s nulom. Prihvatljivo je da os Y započinje nekom drugom vrijednosti ako će se tako fokus staviti na promjene između vrijednosti koje će biti najkorisnije čitatelju.

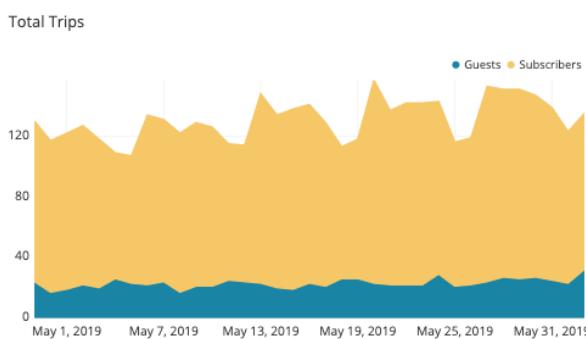


Slika 9.11 Linijski grafikon u vizualizaciji

Izvor: Wexler et al. (2017).

Linijski grafikon na slici 9.11 prikazuje prodaju (kvantitativni podaci) u razdoblju od 4 godine te je raščlanjen po segmentima.

Površinski grafikon (slika 9.12), koji je varijanta linijskog grafikona, dodaje sjenu između linije i nulte osnovne linije (Yi, n.d.a).



Slika 9.12 Area chart in visualization

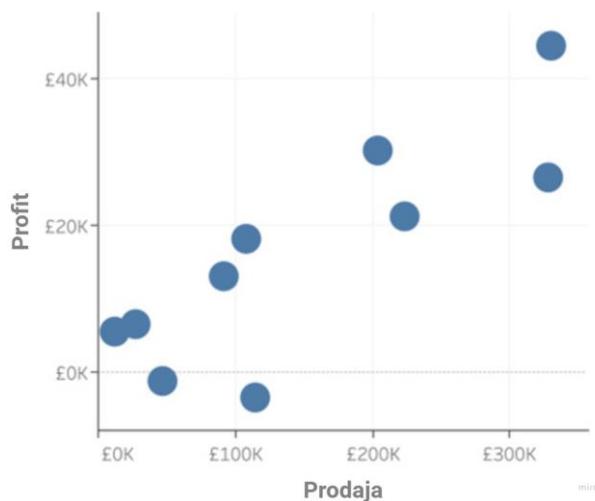
Source: Yi (n.d.)



Površinski grafikon može se promatrati kao hibrid između linijskog i stupčastog grafikona, budući da se vrijednosti mogu tumačiti, ne samo njihovim okomitim položajima, već i područjem osjenčanim između svake točke i osnovne linije (Yi, n.d.).

### 9.3.5. Dijagram raspršenosti

Dijagram raspršenosti koristi se kada želimo vidjeti postoji li odnos između dviju kvantitativnih varijabli. Prema The Data Visualisation Catalogue (n.d.), obrasci koji se vide na dijagramu raspršenosti mogu se koristiti za tumačenje prirode korelacije. To su: pozitivna (vrijednosti rastu zajedno), negativna (jedna vrijednost opada, a druga raste) ili nulta (nema korelacije).



Slika 9.13 Dijagram raspršenosti u vizualizaciji

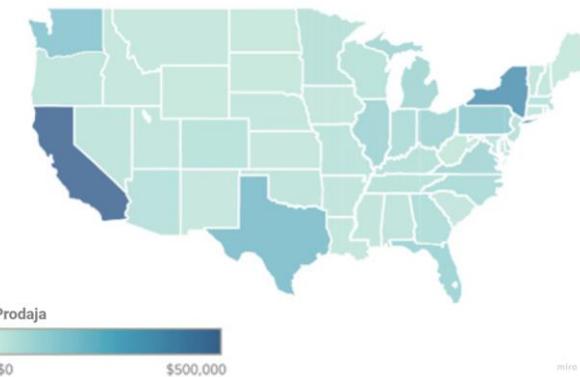
Izvor: Wexler et al. (2017).

Dijagram raspršenosti na slici 9.13 prikazuje odnos između profita i prodaje (obje kvantitativne varijable).

Prema Yiju (n.d.), vrlo je važno spomenuti da u dijagramu raspršenosti, samo zato što vidimo odnos između dvije varijable, to ne znači da promjene u jednoj varijabli uzrokuju promjene u drugoj. To dovodi do široko korištene fraze u statistici: "korelacija ne implicira uzročnost."

### 9.3.6. Koropletna karta

Koropletna karta koristi razlike u sjenčanju ili bojama unutar unaprijed definiranih područja kako bi označila vrijednosti ili kategorije u tim područjima (Wexler et al., 2017). Prema Schwabishu (2021), paleta boja na koropletnoj karti je laka za razumijevanje, manje vrijednosti odgovaraju svjetlijim bojama, a veće vrijednosti tamnjim bojama.



**Slika 9.14 Koropletna karta u vizualizaciji**

Izvor: Wexler et al. (2017).

Koropletna karta na slici 9.14 prikazuje ukupnu prodaju u različitim državama SAD-a.

### 9.3.7. Toplinska karta

Toplinska karta je vizualizacija podataka u tabličnom formatu, gdje obojene ćelije predstavljaju relativnu veličinu brojeva (Nussbaumer Knaflc, 2015).

Budući da je boja ključni element ove vrste grafikona, morate biti sigurni da paleta boja koju odaberete odgovara podacima. Najčešća vrsta boje je sekvencijalna boja, gdje su tamnije boje u korelaciji s višim vrijednostima, a svjetlijе s nižim vrijednostima ili obrnuto (Yi, n.d.b).

	Regija A	Regija B	Regija C
Kategorija 1	Dark Blue	Medium Blue	Light Blue
Kategorija 2			Light Blue
Kategorija 3		Dark Blue	Light Blue
Kategorija 4		Medium Blue	Dark Blue
Kategorija 5		Light Blue	Medium Blue

**Slika 9.15 Toplinska karta u vizualizaciji**

Izvor: Autor, prema Nussbaumer Knaflc (2015).

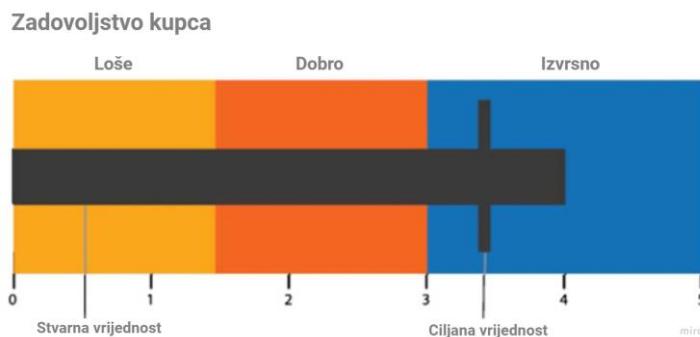
Toplinska karta na slici 9.15 prikazuje različite vrijednosti nekih kvantitativnih podataka (npr. prodaja) po kategoriji (u redovima) i regiji (u stupcima).

### 9.3.8. Bullet grafikon

Stephen Few je 2005. izumio bullet grafikon (Few, 2013). To je u osnovi stupčasti grafikon s jednom crnom vodoravnom trakom koja predstavlja stvarnu vrijednost, dodatnom (okomitom)



oznakom za ciljanu vrijednost (koju želimo postići) i osjenčanim područjima u pozadini koja predstavljaju ljestvicu uspjeha (npr. loše, dobro, izvrsno).



Slika 9.16 Bullet grafikon u vizualizaciji

Izvor: Schwabish (2021).

Bullet grafikon na slici 9.16 pokazuje da želimo postići ocjenu zadovoljstva korisnika od 3,4 (od 5). Naša trenutna ocjena zadovoljstva je 4, što je iznad ciljane vrijednosti. U pozadini su tri područja zadovoljstva kupaca – loše, dobro i izvrsno.

Odabir prave metode vizualizacije vrlo je važan za učinkovitu komunikaciju, ali načela dizajna koja vode ove tehnike također igraju ključnu ulogu u jasnoći i učinkovitosti prezentacije podataka. U sljedećem potpoglavlju razmotrit će se važnost izgleda, tipografije, sheme boja i strateškog korištenja prostora, koji su ključni za izradu vizualizacija, ne samo estetski ugodnih, već i lакih za razumijevanje i tumačenje.

## 9.4. Smjernice dobrog vizualizacijskog dizajna

Učinkovit dizajn vizualizacije odnosi se na povećanje sposobnosti gledatelja da razumije podatke i komunicira s njima. To uključuje ravnotežu između estetskih elemenata i funkcionalnosti, pri čemu odabir boje, fonta i izgleda igra ključnu ulogu u jasnom i učinkovitom prenošenju informacija. Jednostavnost bi također trebala biti vodeći princip. Ali prema Cairu (2013), grafika ne bi trebala pojednostaviti poruke. Trebali bi ih razjasniti, istaknuti trendove, razotkriti obrasce i otkriti stvarnosti koje prije nisu bile vidljive.

Česta zamka je prekomplikiranje vizualizacije s previše elemenata koji zbumuju umjesto da pojašnjavaju. Cilj je podatke učiniti dostupnima i razumljivima ciljanoj publici te osigurati da vizualizacija služi svojoj svrsi, a to je informiranje i podrška donošenju odluka.

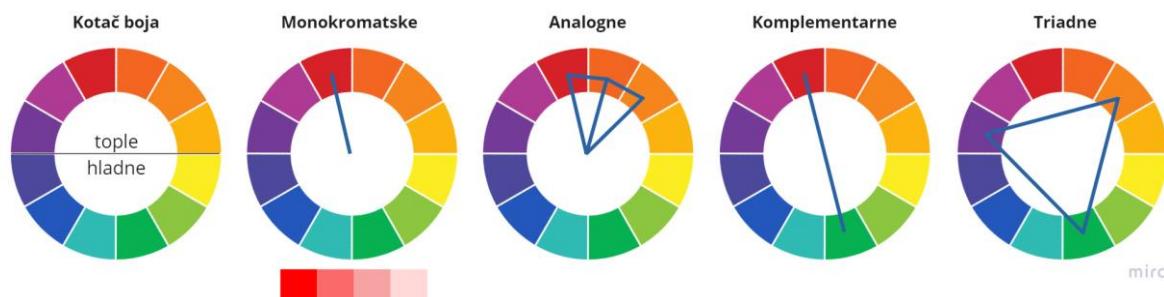


Jasnoća i učinkovitost vizualizacije podataka može se poboljšati uklanjanjem nepotrebnih elemenata. Nussbaumer Knaflc (2015) naglašava da se svaki element koji ne dodaje vrijednost ili izravno ne koristi razumijevanju podataka smatra **neredom**. To uključuje nepotrebne linije u tablicama, pretjerane boje, nevažne podatkovne točke i pretjerani „ukrasi“ na grafikonima. Ti elementi mogu odvratiti pozornost od ključnih poruka koje podaci trebaju prenijeti. Nussbaumer Knaflc preporučuje tehnike kao što su jednostavne sheme boja, minimiziranje teksta i korištenje bijelog prostora. Strateškim korištenjem bijelog prostora može se stvoriti vizualna hijerarhija koja ističe ključne podatkovne točke i čini cjelokupnu prezentaciju jasnijom i lakšom za razumijevanje. Osim toga, učinkovito korištenje bijelog prostora može pomoći u stvaranju uravnoteženog rasporeda koji je manje pretrpan i organizirani.

Boja je vrlo važan dio svake vizualizacije podataka. Služi ne samo za privlačenje pažnje, već i za organiziranje informacija i učinkovito prenošenje značenja. Kada se pravilno koristi, boja može uvelike poboljšati jasnoću i učinak vizualizacije. Postoji nekoliko prijedloga za učinkovitu upotrebu boja u vizualizacijama (Few, 2012; Cairo, 2013; Few, 2013; Nussbaumer Knaflc, 2015; Wexler et al, 2017; Schwabish, 2021; Lidwell, 2023; Interaction Design Foundation, n.d.) :

- **Odaberite odgovarajuću kombinaciju boja:** pomoću tzv. kotača boja moguće je kreirati vizualizacije koje su vizualno uravnotežene i ugodne oku. Postoji nekoliko uobičajenih kombinacija boja (slika 9.17):
  - **Monokromatske** – jedna boja u različitim nijansama.
  - **Analogne** – tri boje jedna pored druge na kotaču boja. Ove boje su ugodne oku i stvaraju skladan dizajn.
  - **Komplementarne** – dvije suprotne boje na kotaču boja. Ove boje su kontrastne boje i treba ih koristiti za naglašavanje nečega (npr. povećanje - zeleno/smanjenje - crveno).
  - **Trijadne** – tri jednakom udaljene boje na kotaču boja. Ove boje su dinamične i privlače pozornost.

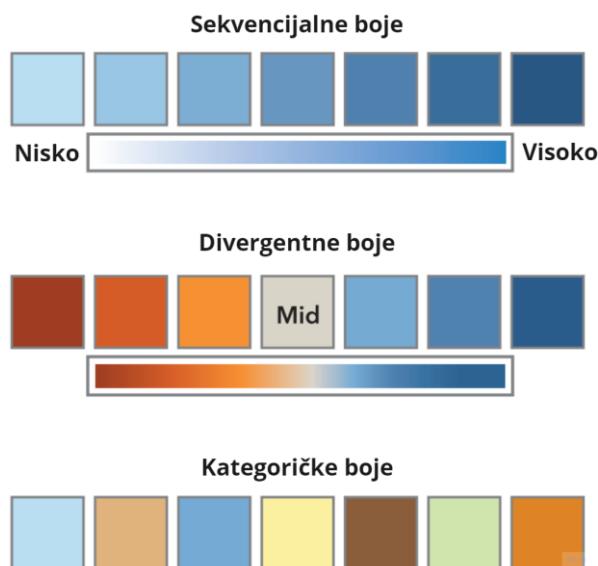
Osim toga, toplije boje treba koristiti za prednje elemente i hladnije boje za pozadinske elemente.



Slika 9.17 Kombinacije boja

Izvor: Autor, prema Lidwell (2023).

- Odaberite odgovarajuću shemu boja:** izbor sheme boja ovisi o vrsti podataka koji se vizualiziraju. Sekvencijalna shema boja je korištenje jedne boje od svijetle do tamne i idealna je za prikaz numeričkih podataka koji se kreću od niske do visoke vrijednosti (npr. prodaja po državi). Divergentna shema boja korisna je za isticanje vrijednosti iznad ili ispod srednje točke (npr. dobit/gubitak). Kategorična shema boja najbolja je za kategoričke podatke gdje boje trebaju razlikovati različite skupine bez impliciranja redoslijeda ili vrijednosti (npr. kategorije proizvoda). Slika 9.18 prikazuje različite sheme boja koje se koriste u vizualizacijama.



Slika 9.18 Scheme boja

Izvor: Wexler et al. (2017).

- Koristite boje štedljivo:** pretjerana upotreba boja može izazvati zabunu i učiniti grafikon težim za razumijevanje. Paleta boja trebala bi biti ograničena na ono što ljudsko oko može brzo razlikovati, oko pet različitih boja.



- **Uzmite u obzir sljepoću na boje:** oko 8% muškaraca i 0,5% žena je slijepo za boje. Izbjegavajte kombinacije boja koje su daltonistima teške za razlikovanje, poput crvene i zelene. Umjesto ovih boja, bolja kombinacija je narančasta i plava.
- **Boje trebaju biti dosljedne:** dosljedna upotreba boja u različitim vizualizacijama omogućuje čitatelju jednostavno razumijevanje i usporedbu podataka. Nakon što se uspostavi shema boja za određene vrste podataka ili kategorije, treba je održavati u svim povezanim vizualizacijama.
- **Koristite boje za naglašavanje važnih podataka:** boja može biti snažan pokazatelj gdje nešto gledati. Korištenje svijetle ili kontrastne boje može privući pozornost na ključne podatke, dok se neutralnije boje mogu koristiti za manje kritične informacije. Neki autori sugeriraju da stvaranje jasne, razumljive vizualizacije treba započeti sivom bojom. Svi podatkovni elementi u grafikonu (npr. stupci u stupčastom grafikonu ili linije u linijskom grafikonu) trebaju biti sivi. Zatim dodajte oznake i boju samo za elemente koje želite istaknuti.
- **Pojednostavite:** u području vizualizacije podataka, princip KISS, akronim za "Keep It Simple, Stupid", vrlo je relevantan i koristan. Odnosi se na upotrebu jednostavnih grafikona, budući da složeni grafikoni ili pretjerano detaljni vizualni elementi mogu preopteretiti korisnike i otežati prepoznavanje ključnih poruka ili podataka. To također znači da biste trebali izbjegavati vizualni nered i smanjiti nepotrebne vizualne komponente kao što su pretjerano svijetle boje, fontovi i linije unutar grafikona i tablica. Prilikom primjene KISS principa, fokus bi trebao biti na samim podacima, a ne na dekorativnim ili pretjerano složenim elementima dizajna.

Ova su načela presudna da vizualizacije podataka postignu svoj primarni cilj komuniciranja složenih informacija na način koji je pristupačan i razumljiv svakoj publici.

Iz ovog je poglavlja jasno da je učinkovita vizualizacija podataka ključna komponenta u procesu donošenja odluka na temelju podataka. Na temelju razumijevanja situacijskog konteksta, istaknuta je važnost prilagođavanja vizualizacija specifičnim potrebama ciljane publike. Iz detaljnog pregleda različitih metoda vizualizacije i principa dizajna vidljivo je da je promišljen vizualni prikaz podataka važan za bolje razumijevanje i komunikaciju složenih informacija.



# REFERENCE

1. Brush, K. (2022). Data visualization. TechTarget [dostupno na: <https://www.techtarget.com/searchbusinessanalytics/definition/data-visualization>, pristupljeno 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 [dostupno na: <https://datavizcatalogue.com/methods/scatterplot.html>, pristupljeno 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? [dostupno na: <https://www.geeksforgeeks.org/data-visualization-and-its-importance/>, pristupljeno April 15, 2024]
7. IBM (n.d.). What is data visualization? [dostupno na: <https://www.ibm.com/topics/data-visualization>, pristupljeno April 15, 2024]
8. Interaction Design Foundation (n.d.). Color Theory [dostupno na: <https://www.interaction-design.org/literature/topics/color-theory>, pristupljeno 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 [dostupno na: <https://medium.com/@e0373084/eye-catching-bans-88d29632e4fa>, pristupljeno 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 [dostupno na: <https://www.atlassian.com/data/charts/line-chart-complete-guide>, pristupljeno April 17, 2024]
16. Yi, M. (n.d.b). A complete guide to heatmaps. Atlassian [dostupno na: <https://www.atlassian.com/data/charts/heatmap-complete-guide>, pristupljeno April 17, 2024]



# 10. PODATKOVNA ETIKA I INFORMACIJSKA SIGURNOST

Autor: Dario Šebalj

U eri digitalne transformacije, etičko postupanje i sigurnost podataka pojavili su se kao glavni problemi za pojedince i organizacije. Budući da se svakodnevno prikupljaju i obrađuju goleme količine osobnih i osjetljivih podataka, vrlo je važno osigurati da se tim podacima upravlja na odgovoran i siguran način.

Ovo poglavlje ispituje načela etike podataka, naglašavajući moralna razmatranja i najbolje prakse za rukovanje podacima te istražuje različite prijetnje informacijskoj sigurnosti. Razumijevanjem i rješavanjem ovih problema možemo zaštитiti privatnost, održati povjerenje i poticati sigurnije digitalno okruženje.

## 10.1. Važnost podatkovne etike

**Podatkovna etika** odnosi se na moralna načela i prakse koji se uzimaju u obzir prilikom prikupljanja, obrade, dijeljenja i korištenja podataka kako bi se osiguralo poštivanje prava pojedinaca, društveno blagostanje i povjerenje. Ona obuhvaća transparentnost, odgovornost, pravednost i privatnost, osiguravajući da su prakse podataka uskladene s etičkim standardima i pravnim okvirima kako bi se spriječila šteta i promicale odgovorne inovacije (Cognizant, n.d.; Gov.uk, 2020; Knight, 2021; McKinsey, 2022; Cepelak , 2023).

U današnjem digitalnom okruženju etičko postupanje podacima ključno je za održavanje povjerenja i osiguranje konkurentske prednosti. McKinsey (2022) je objavio članak o etici podataka u kojem naglašava važnost integriranja etičkih razmatranja u prakse upravljanja podacima. Istiće tri uobičajene pogreške: pretpostavku da je etika podataka nevažna, oslanjanje isključivo na pravne timove i timove za usklađenost te davanje prioriteta kratkoročnim finansijskim dobitcima u odnosu na etičke prakse. Za rješavanje ovih problema preporučuju nekoliko strategija. Prvo, tvrtke bi trebale uspostaviti jasne, specifične smjernice za etiku podataka. Ove smjernice trebaju služiti kao temelj za etičko upravljanje podacima i pomagati u postavljanju standarda u cijeloj organizaciji. Drugo, formiranje različitih timova za rješavanje problema povezanih s podacima osigurava niz perspektiva i smanjuje rizik od



pristranog donošenja odluka. Treće, uključivanje višeg rukovodstva kao zagovornika inicijativa za etiku podataka ključno je za provođenje tih praksi u cijeloj organizaciji.



**Slika 10.1 5C podatkovne etike**

Izvor: Autor, prema Atlan (2023).

Slika 10.1 prikazuje 5C podatkovne etike, koju je opisao Atlan (2023), a koja predstavlja bitna načela za etičko rukovanje podacima:

- **Privola:** prije prikupljanja njihovih podataka pribavite informirani, dobrovoljni pristanak pojedinaca, čime se osigurava transparentnost upotrebe podataka.
- **Prikupljanje:** prikupljajte samo podatke koji su potrebni za točno određene svrhe, izbjegavajući prekomjerno prikupljanje podataka.
- **Kontrola:** dopustite pojedincima pristup, pregled i ažuriranje svojih podataka, osiguravajući da imaju kontrolu nad njihovim korištenjem.
- **Povjerljivost:** zaštitite podatke od neovlaštenog pristupa i probaja kroz snažne sigurnosne mjere.
- **Sukladnost:** pridržavajte se zakonskih i regulatornih zahtjeva, provodeći redovite revizije kako biste osigurali stalnu usklađenost.

Slično Atlanovim načelima, Cote (2021) identificira pet temeljnih načela etike podataka koja su ključna za poštivanje poslovnih stručnjaka:

- **Vlasništvo** naglašava da pojedinci zadržavaju vlasništvo nad svojim osobnim podacima. Protuzakonito je i neetično prikupljati osobne podatke bez izričitog pristanka.



Tvrtke moraju dobiti privolu kroz jasne ugovore ili politike digitalne privatnosti, osiguravajući da su korisnici upoznati s praksama prikupljanja podataka i da se slažu s njima.

- **Transparentnost** uključuje jasnu komunikaciju o tome kako će se podaci prikupljati, pohranjivati i koristiti. Poduzeća moraju informirati pojedince o metodama i svrsi prikupljanja podataka. Ova transparentnost gradi povjerenje i omogućuje korisnicima da donose informirane odluke o svojim podacima. Obmanjujuće prakse ili uskraćivanje informacija o korištenju podataka su i neetični i nezakoniti.
- **Privatnost** se fokusira na odgovornost poduzeća da zaštite privatnost osobnih podataka. Čak i uz privolu, osobni podaci ne bi trebali biti javno dostupni bez izričitog dopuštenja pojedinca. Tvrtke moraju primijeniti snažne sigurnosne mjere kako bi zaštitile osobne podatke od neovlaštenog pristupa ili kršenja.
- **Namjera** se odnosi na etičke motive koji stoje iza prikupljanja i korištenja podataka. Podatke treba prikupljati i koristiti u svrhe koje su korisne, a ne štetne za pojedince ili društvo. Etička praksa podataka uključuje korištenje podataka za poboljšanje korisničkog iskustva i poboljšanje usluga bez iskorištavanja ili nanošenja štete.
- **Ishod** razmatra šire utjecaje korištenja podataka na pojedince i društvo. Poduzeća moraju procijeniti moguće posljedice svojih postupaka s podacima i nastojati izbjegći negativne ishode. Ovo načelo naglašava potrebu za etičkim predviđanjem i odgovornošću u donošenju odluka na temelju podataka.

Guzman i Dyer (2020) naglašavaju da etički izazovi vezani uz podatke nisu jednostavni i da im često nedostaju jasna rješenja. Naveli su da postoji razlika između etičkih očekivanja online i offline. Mnogi pojedinci percipiraju oblik iznimnosti u online prostorima, gdje se čini da se tradicionalna etička pravila ne primjenjuju. Ovakav način razmišljanja može dovesti do opravdanja online radnji koje bi se izvan mreže smatrале neetičnim. Autori predlažu etički pristup koji premošćuje oba područja, naglašavajući da etička načela trebaju ostati dosljedna bez obzira na medij.

Rad o etici podataka koji su objavili Basl et al. (2021) istražuje složeni proces prelaska s apstraktnih etičkih načela na konkretna, provediva obećanja u kontekstu velikih podataka i umjetne inteligencije (AI). Zaključili su da je teško, ali vrlo važno napraviti ovaj pomak kako bi se zajamčilo da etičko ponašanje nije samo teoretsko već i praktično i značajno.

Prema O'Reillyju (2018), Princetonov centar za politiku informacijske tehnologije i Centar za ljudske vrijednosti razvili su četiri anonimizirane studije slučaja kako bi potaknuli etički diskurs.



Jedna od studija slučaja istražuje etičke dileme koje postavlja automatizirana aplikacija za zdravstvenu skrb koja koristi AI, a dizajnirana je za pomoć pacijentima s dijabetesom u odrasloj dobi. Istiće potrebu za uravnoteženjem tehnoloških prednosti s etičkim načelima kao što su autonomija, pravednost i odgovornost. Rješavanje ovih etičkih izazova ključno je za odgovornu integraciju umjetne inteligencije u zdravstvu, osiguravajući da ona služi najboljim interesima svih pacijenata. Postoje neka ključna pitanja kojima se treba pozabaviti:

- **Paternalizam:** cilj aplikacije je potaknuti zdravije ponašanje među pacijentima potičući ih na bolje izbore. Iako to može poboljšati zdravstvene ishode, postavlja etička pitanja o autonomiji i paternalizmu. Je li etično da aplikacija utječe na ponašanje pacijenata ili bi pacijenti trebali imati potpunu autonomiju u donošenju zdravstvenih odluka?
- **Pristanak i transparentnost:** aplikacija prikuplja osjetljive zdravstvene podatke kako bi učinkovito funkcionalala. Osiguravanje informiranog pristanka i transparentnosti o prikupljanju, korištenju i dijeljenju podataka je ključno. Pacijenti moraju biti potpuno svjesni koji se podaci prikupljaju, kako će se koristiti i tko će im pristupiti.
- **Privatnost i sigurnost podataka:** rukovanje osjetljivim zdravstvenim podacima zahtijeva stroge mjere privatnosti i sigurnosti. Studija slučaja naglašava potrebu za robusnim protokolima za zaštitu podataka kako bi se podaci o pacijentu zaštitali od kršenja i neovlaštenog pristupa.
- **Odgovornost i odgovornost:** određivanje tko je odgovoran za odluke i radnje aplikacije još je jedan ključni aspekt. Ako aplikacija daje netočnu preporuku koja nepovoljno utječe na zdravlje pacijenta, identificiranje odgovorne strane (programeri, pružatelji zdravstvenih usluga ili sama aplikacija) je složeno, ali neophodno za odgovornost.

Suvremeno upravljanje podacima temelji se na etici podataka, koja jamči poštene, transparentne, odgovorne prakse podataka koje poštuju privatnost. Organizacije mogu poticati odgovorne inovacije, izbjegći pravne zamke i povećati povjerenje pridržavanjem etičkih standarda. Nije samo najbolja praksa, već i zahtjev za održiv i odgovoran rast uključiti jake etičke okvire u prakse upravljanja podacima jer podaci postaju sve bitniji za operacije i donošenje odluka.

Drugi važan aspekt je informacijska sigurnost jer su etika podataka i informacijska sigurnost suštinski povezane. Osiguravanje etičke prakse u vezi s podacima postavlja temelj za snažne mjere sigurnosti informacija. Zaštita podataka od neovlaštenog pristupa, proboja i drugih



sigurnosnih prijetnji ne samo da čuva privatnost i povjerljivost, već također podržava etička načela o kojima se govori u ovom poglavlju.

## 10.2. Temelji informacijske sigurnosti

**Informacijska sigurnost** odnosi se na sveobuhvatan skup praksi i načela usmjerenih na zaštitu informacija i informacijskih sustava od neovlaštenog pristupa, korištenja, otkrivanja, ometanja, modifikacije ili uništenja. Osigurava povjerljivost, cjelovitost i dostupnost podataka kroz implementaciju zaštitnih mjera, politika i tehnologija. Ove mjere uključuju kontrolu pristupa, enkripciju, oporavak od katastrofe i usklađenost sa pravnim i regulatornim standardima za ublažavanje rizika i zaštitu od potencijalnih prijetnji (Fruhlinger, 2020; CISCO, n.d., NIST, n.d.).

Informacijska sigurnost je ključna za vjerodostojnost i integritet organizacije u digitalnoj eri. Njezina je važnost naglašena rastućom ovisnošću o digitalnim podacima i porastom kibernetičkih prijetnji koje ugrožavaju osjetljive podatke. Prije svega, informacijska sigurnost štiti osjetljive podatke od neovlaštenog pristupa, provale i krađe. To uključuje osobne podatke, finansijske podatke, intelektualno vlasništvo i povjerljive poslovne komunikacije. Kako kibernetički napadi postaju sve sofisticiraniji, rizik od povrede podataka raste, što može dovesti do ozbiljnih finansijskih gubitaka i reputacijske štete. Na primjer, curenje podataka Equifaxa 2017. razotkrilo je osobne podatke 147 milijuna ljudi, što je rezultiralo nagodbom do 425 milijuna dolara (Federal Trade Commission, 2022). Takvi incidenti naglašavaju strašne posljedice neadekvatnih mjera sigurnosti informacija.

Nadalje, sigurnost informacija ključna je za zadržavanje povjerenja potrošača. U doba kada je privatnost podataka ključna, korisnici postaju sve zabrinutiji o tome kako se postupa s njihovim podacima. Snažna informacijska sigurnosna arhitektura osigurava da su podaci potrošača sigurni, što potiče lojalnost i povjerenje. Prema anketi IBM-a, 75% kupaca ne bi kupilo proizvode od tvrtke kojoj ne vjeruju da će sačuvati njihove podatke (PR Newswire, 2018). Stoga je informacijska sigurnost i tehnološka potreba i strateški imperativ poslovanja.

Informacijska sigurnost također je ključna za ublažavanje operativnih smetnji. Kibernetički napadi, kao što je *ransomware*, mogu poremetiti korporativne operacije sprječavajući korisnike da pristupe osnovnim sustavima dok se ne plati otkupnina. *Ransomware* napad na Colonial Pipeline iz 2021. godine, koji je doveo do nestašice goriva u istočnom dijelu SAD-a, primjer je

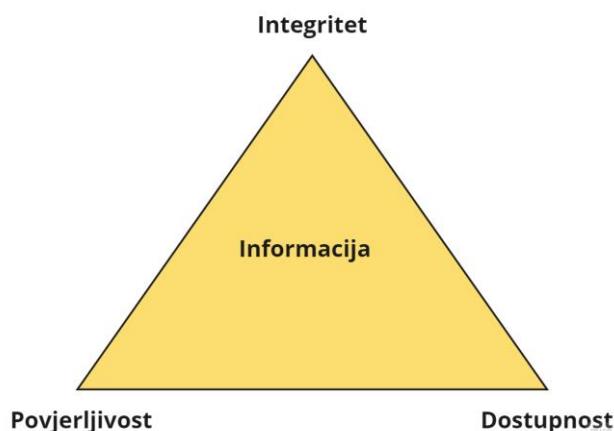


razornog potencijala takvih prijetnji (Kerner, 2022). Primjenom jakih sigurnosnih mjera organizacije mogu zaštititi svoj operativni kontinuitet i otpornost na takve poremećaje.

Prema Kimu i Solomonu (2018), informacije se smatraju sigurnima ako zadovoljavaju tri glavna načela:

- **Povjerljivost** (eng. *Confidentiality*): osjetljivim informacijama pristupaju samo ovlaštene osobe
- **Integritet** (eng. *Integrity*): podatke mogu mijenjati samo oni koji imaju dopuštenje
- **Dostupnost** (eng. *Availability*): informacije i resursi dostupni su ovlaštenim korisnicima kad god je potrebno.

Ta se načela često nazivaju CIA trokut, kao što je prikazano na slici 10.2.



**Slika 10.2 CIA trokut**

Izvor: Autor, prema Kim i Solomon (2018).

U informacijskoj sigurnosti, koncepti rizika, prijetnje i ranjivosti ključni su za razumijevanje i upravljanje sigurnošću. **Rizik** je vjerojatnost da će se nešto loše dogoditi imovini. U informacijskoj sigurnosti rizik je vjerojatnost štetnog događaja koji utječe na povjerljivost, integriteta ili dostupnost informacija. Na primjer, tvrtka može procijeniti rizik kibernetičkog napada na svoju mrežu uzimajući u obzir i vjerojatnost takvog napada i potencijalnu štetu koju bi mogao prouzročiti. **Prijetnja** je svaka radnja koja može uzrokovati štetu informacijskim sustavima ili podacima. Prijetnje mogu biti namjerne, poput kibernetičkog napada hakera, ili nemjerne, poput prirodnih katastrofa ili ljudske pogreške. **Ranjivost** se odnosi na slabosti ili praznine u obrani sustava koje prijetnje mogu iskoristiti za nanošenje štete. To mogu biti nedostaci u softveru, hardveru, organizacijskim procesima ili ljudskom ponašanju (Kim i Solomon, 2018).



Za učinkovitu zaštitu informacijskih sustava, organizacije moraju razumjeti kako rizici, prijetnje i ranjivosti međusobno djeluju. Na primjer, ranjivost u softveru (kao što je sigurnosni propust) može iskoristiti prijetnja (kao što je haker), što dovodi do povrede podataka, što predstavlja rizik za organizaciju. Prepoznavanjem i ublažavanjem ranjivosti, organizacije mogu smanjiti rizik od prijetnji koje uzrokuju značajnu štetu.

### 10.2.1. Curenja podataka

Curenja podataka postale su značajna prijetnja u digitalnom dobu, utječeći na organizacije u raznim sektorima. Ova kršenja ugrožavaju osjetljive informacije, što dovodi do finansijskih gubitaka, štete po ugled i pravnih posljedica. Razumijevanje veličine i utjecaja curenja podataka ključno je za razvoj učinkovitih sigurnosnih strategija za zaštitu od takvih incidenata. Prema Fortinetu (n.d.), curenje podataka "je događaj koji rezultira izlaganjem povjerljivih, privatnih, zaštićenih ili osjetljivih informacija osobi koja nije ovlaštena da im pristupi". Ta se kršenja mogu dogoditi na različite načine (Kaspersky, n.d.a):

- **Slučajni insajder:** zaposlenik nenamjerno pristupa osjetljivim informacijama bez odgovarajućeg ovlaštenja. Na primjer, korištenje računala kolege i pregledavanje povjerljivih datoteka.
- **Zlonamjerni insajder:** pojedinac s ovlaštenim pristupom namjerno zlorabi podatke u štetne svrhe. To može uključivati krađu ili curenje osjetljivih informacija.
- **Izgubljeni ili ukradeni uređaji:** nešifrirani i nezaštićeni uređaji poput prijenosnih računala ili vanjskih diskova koji sadrže osjetljive podatke izgubljeni su ili ukradeni, čineći informacije ranjivima na neovlašteno pristupanje.
- **Zlonamjerni vanjski kriminalci:** hakeri koriste različite metode za probijanje sustava, uključujući napade krađe identiteta, napade brutalnom silom i *malware*. Ovi kibernetički kriminalci iskorištavaju ranjivosti u softveru, mrežama i ponašanju korisnika kako bi dobili pristup osjetljivim podacima.

Prema Kasperskom (n.d.a), uobičajene metode koje se koriste u povredama podataka uključuju **phishing**, gdje se kibernetički kriminalci lažno predstavljaju kao određeni subjekti kako bi prevarili pojedince da otkriju osjetljive informacije. Druga metoda su **napadi brutalnom silom** (eng. *brute force attacks*), gdje hakeri koriste softver za opetovano pogađanje lozinki, iskorištavajući slabe ili ponovno korištene vjerodajnice kako bi dobili neovlašteni pristup računima. Osim toga, **zlonamjerni softver**, poput špijunskega softvera,



koristi se za infiltraciju u sustave i neotkrivenu krađu podataka. Ove metode bit će objašnjene kasnije u poglavlju.



Ljudske pogreške uzrok su **95%** svih curenja podataka(Cybernews, 2022).

U 21. stoljeću dogodile su se neka od najvećih curenja podataka, čime se naglašava ranjivost digitalnih sustava i kritična potreba za snažnim sigurnosnim mjerama. Prema Hillu i Swinhoeu (2022) i ESET-u (n.d.), neka od najznačajnijih curenja podataka:

- **Yahoo (2013.-2014.):** Yahoo je doživio jedno od najvećih curenja podataka u povijesti, sa svih tri milijarde njegovih korisničkih računa kompromitiranih u 2013. Ovo curenje otkrilo je imena, adrese e-pošte, datume rođenja te sigurnosna pitanja i odgovore. Još jedno curenje u 2014. utjecalo je na 500 milijuna računa, dodatno naglašavajući sigurnosne propuste tvrtke.
- **Marriott International (2018.):** Marriott je objavio curenje podataka koje je utjecalo na približno 500 milijuna gostiju. Hakeri su pristupili Starwood bazi podataka rezervacija gostiju, otkrivajući osobne podatke poput imena, adresa, telefonskih brojeva, e-mail adresa i brojeva putovnica. Ovo curenje bilo je rezultat neovlaštenog pristupa koji datira iz 2014. Ured povjerenika za informacije (ICO), regulatorno tijelo za podatke u Ujedinjenom Kraljevstvu, u konačnici je 2020. kaznio korporaciju s 18,4 milijuna funti jer nije zaštitila privatnost osobnih podataka svojih klijenata.
- **Adult Friend Finder (2016.):** curenje Adult Friend Finder razotkrilo je osobne podatke 412 milijuna računa, uključujući imena, adrese e-pošte i lozinke, od kojih su mnoge bile loše šifrirane. Ovaj je incident izazvao značajnu zabrinutost oko sigurnosnih praksi online platformi koje postupaju s osjetljivim osobnim podacima.
- **MySpace (2013.):** curenje podataka MySpacea, koja se dogodilo 2013., rezultiralo je izlaganjem više od 360 milijuna korisničkih računa. Podaci su uključivali imena, adrese e-pošte i lozinke. Hakeri su kasnije prodali te informacije na dark webu, što je istaknulo ranjivosti u sigurnosnim sustavima platformi društvenih medija tijekom tog vremena.
- **LinkedIn (2021.):** 2021. godine, osobni podaci 700 milijuna korisnika LinkedIna objavljeni su na forumu na dark webu. Haker je koristio tehniku skidanja podataka putem LinkedIn API-ja kako bi dobio adrese e-pošte, telefonske brojeve i druge osobne podatke. Iako ne spada u tradicionalno hakiranje, ovaj je incident izazvao ozbiljnu



zabrinutost u vezi s privatnošću podataka i mogućom zlouporabom podataka za napade društvenog inženjeringu.

- **Equifax (2017.):** ovo curenje razotkrilo je osobne podatke gotovo 148 milijuna Amerikanaca, 15,2 milijuna Britanaca i 19.000 Kanađana. Hakeri su iskoristili ranjivost u sklopu web aplikacije Apache Struts koju Equifax nije uspio zakrpati. Ukradeni podaci uključivali su brojeve socijalnog osiguranja, datume rođenja i adrese, što je dovelo do procijenjenih 1,7 milijardi dolara troškova za Equifax.
- **eBay (2014.):** eBay je otkrio curenje koje je utjecalo na 145 milijuna korisnika. Napad je potekao od kompromitiranih vjerodajnica za prijavu zaposlenika, što je dovelo do otkrivanja imena, adresa e-pošte, fizičkih adresa, telefonskih brojeva i šifriranih zaporki. Ovo kršenje ukazalo je na ranjivosti u pristupnim kontrolama zaposlenika i važnost snažnih mjera provjere autentičnosti.
- **Target (2013.):** curenje podataka koje je utjecalo na više od 41 milijun računa vezanih uz bankovne kartice i kontakt podatke više od 60 milijuna klijenata. Cyberkriminalci pristupili su korisničkim podacima, uključujući imena, telefonske brojeve, adrese e-pošte, brojeve kreditnih i debitnih kartica i šifrirane PIN-ove. Target se suočio sa znatnim pravnim troškovima i troškovima nagodbe, uključujući skupnu tužbu od 10 milijuna dolara i nagodbu u više država od 18,5 milijuna dolara.

Ova curenja podataka pokazuju dalekosežne posljedice kibernetičkih napada i kritičnu potrebu za snažnim praksama kibernetičke sigurnosti. Učeći iz ovih slučajeva visokog profila, organizacije mogu bolje zaštititi svoje podatke, poboljšati svoje sigurnosne protokole i minimizirati rizik od budućih provala. Povrede podataka često su rezultat niza prijetnji u pozadini. Razumijevanje ovih prijetnji ključno je za izgradnju uspješnih mjera informacijske sigurnosti. Kibernetičke prijetnje mogu proizaći iz raznih izvora, uključujući zlonamjerne insajdere, kibernetičke kriminalce pa čak i aktere koje sponzorira država. Osim toga, ranjivosti u sustavima i mrežama mogu se iskoristiti kako bi se neovlašteno pristupilo osjetljivim informacijama.

### 10.2.2. Prijetnje informacijskoj sigurnosti

Sigurnosna prijetnja zlonamjerna je radnja koja pokušava oštetiti ili ukrasti podatke, ugroziti sustave organizacije ili ugroviti tvrtku u cjelini (TechTarget, 2024). Mnogo je različitih prijetnji informacijskoj sigurnosti koje ozbiljno ugrožavaju dostupnost, cjelovitost i povjerljivost podataka.



Prema Kimu i Solomonu (2018) i Grubbu (2021), **malware** (maliciozni softver) dizajniran je za infiltraciju, oštećenje ili onesposobljavanje računala i mreža. Uobičajene vrste zlonamjernog softvera uključuju virusе, crve, trojance, ransomware i spyware. **Virus** je vrsta zlonamjernog softvera koji se pričvršćuje na legitiman program ili datoteku i širi se na druge programe i datoteke kada se zaraženi softver pokrene. Virusi mogu oštetiti ili izbrisati podatke, poremetiti rad sustava i proširiti se na druge sustave putem privitaka e-pošte, mrežnih veza ili prijenosnih medija. Za razliku od virusa, **crvi** su samostalni zlonamjerni softver koji se može samostalno umnožavati i širiti mrežama bez potrebe za spajanjem na glavni program. Crvi iskorištavaju ranjivosti u operativnim sustavima ili aplikacijama za širenje, često uzrokujući zagruženje mreže i preopterećenje sustava trošenjem propusnosti i resursa. **Trojanac** ili trojanski konj zlonamjerni je softver prerušen u legitimni softver. Korisnici ga instaliraju, vjerujući da je bezopasan ili koristan program. **Ransomware** je vrsta zlonamjernog softvera koji šifrira podatke žrtve, čineći ih nedostupnima dok se napadaču ne plati otkupnina. Ransomware napadi mogu biti razorni, dovesti do značajnog gubitka podataka i operativnih poremećaja ako se ne plati otkupnina ili ako nisu dostupne sigurnosne kopije. **Spyware** je zlonamjerni softver dizajniran za prikupljanje informacija o osobi ili organizaciji bez njihovog znanja. Može prikupljati različite vrste podataka, kao što su informacije o pritisnutim tipkama, navike pregledavanja i osobne informacije, te prenositi te podatke trećoj strani.

Druga vrsta prijetnje je **phishing**. Kosinski (2024) objašnjava da phishing napadi uključuju lažnu e-poštu, SMS-ove, pozive ili web-stranice osmišljene kako bi prevarili pojedince da otkriju osobne podatke ili preuzmu zlonamjerni softver. Ovi napadi iskorištavaju ljudsku pogrešku i povjerenje, što ih čini vrlo učinkovitim. Kako bi se borile protiv krađe identiteta, organizacije moraju koristiti napredne alate za otkrivanje prijetnji i osigurati snažnu obuku zaposlenika kako bi učinkovito prepoznali te prijevare i odgovorili na njih.



Phishing je vodeći uzrok curenja podataka, s udjelom od 16% i košta organizacije u prosjeku 4,76 milijuna dolara po štetnom događaju (Kosinski, 2024).

Četiri su osnovne vrste phishinga (Forbes, 2024):

- **E-mail phishing:** korištenje e-pošte za krađu osjetljivih informacija. Napadači mogu ciljati veliku publiku predstavljajući se kao renomirane organizacije.



- **Spear phishing:** slanje individualiziranih e-poruka, SMS-ova ili telefonskih poziva s namjerom pristupa računalnim sustavima ili osjetljivim informacijama. Kada koriste ovu tehniku, napadači obično koriste podatke iz otvorenih baza podataka, društvenih medija ili ranijih curenja, kako bi pojačali svoju legitimnost.
- **Whaling:** usredotočen je na visoko rangirano ili više osoblje, uključujući referente za financije i izvršne direktore. Napadači šalju vrlo uvjerljive, visoko prilagođene poruke kako bi dobili osjetljive podatke i informacije od poduzeća.
- **Vishing:** telefoniranje ili ostavljanje govorne pošte pod krinkom pouzdanog izvora. Cilj je doći do bankovnih računa, iskoristiti osobne podatke i ukrasti novac.

**Insajderske prijetnje** su sigurnosni rizici koji potječu unutar organizacije. To mogu biti zaposlenici, izvođači ili poslovni partneri koji imaju pristup sustavima i podacima organizacije. Ove prijetnje mogu biti osobito opasne jer insajderi često imaju legitiman pristup osjetljivim informacijama i sustavima, što otežava otkrivanje njihovih zlonamjernih aktivnosti (TechTarget, 2024).

Druga vrsta prijetnje su napadi **distribuiranog uskraćivanja usluge** (eng. Distributed Denial-of-Service - DDoS). Cilj im je poremetiti normalan promet ciljanog poslužitelja, usluge ili mreže preplavljujući ih internetskim prometom. To se postiže korištenjem više kompromitiranih računalnih sustava kao izvora prometa napada. Kada ti uređaji, često distribuirani globalno, istovremeno šalju brojne zahtjeve meti, troše njegovu dostupnu propusnost i resurse, što dovodi do prekida usluge i sprječava legitimne korisnike da pristupe usluzi (TechTarget, 2024).

Internetske sigurnosne prijetnje usko su povezane s djelovanjem hakera, koji iskorištavaju ranjivosti u sustavima u razne zlonamjerne svrhe. Prema Grubbu (2021), hakeri se često kategoriziraju na temelju njihovih namjera i metoda. Dvije osnovne kategorije su *white hat* hakeri i *black hat* hakeri. **White hat hakeri**, također poznati kao etički hakeri, koriste svoje vještine u obrambene svrhe. Rade na zaštiti organizacija od kibernetičkih prijetnji identificiranjem i popravljanjem sigurnosnih ranjivosti prije nego što ih zlonamjerni hakeri iskoriste. **Black hat hakeri**, nasuprot tome, sudjeluju u ilegalnim aktivnostima sa zlom namjerom. Iskorištavaju sigurnosne propuste za osobnu korist, što može uključivati krađu podataka, širenje zlonamjnog softvera ili izazivanje poremećaja.



Jedna ključna obrana od prijetnji informacijskoj sigurnosti je korištenje jake lozinke. Jake lozinke, koje bi trebale biti složene i jedinstvene za svaki račun, značajno smanjuju rizik od neovlaštenog pristupa.

Tablica 10.1 pokazuje vrijeme koje je potrebno hakeru da dođe do lozinke, prema istraživanju koje je proveo Hive Systems (2024).

**Tablica 10.1 Vrijeme potrebno hakeru da dođe do lozinke u 2024. godini**

Broj znakova	Samo brojevi	Mala slova	Velika i mala slova	Brojevi, velika i mala slova	Brojevi, velika i mala slova, simboli
4	Odmah	Odmah	3 sec	6 sec	9 sec
5	Odmah	4 sec	2 min	6 min	10 min
6	Odmah	2 min	2 sata	6 sati	12 sati
7	4 sec	50 min	4 days	2 tjedna	1 mjesec
8	37 sec	22 sata	8 mjeseci	3 god	7 god
9	6 min	3 tjedna	33 god	161 god	479 god
10	1 sat	2 god	1.000 god	9.000 god	33.000 god
11	10 sati	44 god	89.000 god	618.000 god	2 mil. god
12	4 dana	1.000 god	4 mil god	38 mil god	164 mil. god
13	1 mjesec	29.000 god	241 mil god	2mlrd god	11mlrd god
14	1 god	766.000 god	12mlrd god	147mlrd god	805mlrd god
15	12 god	19 mil god	652 mlrd god	9tn god	56tn god
16	119 god	517 mil god	33tn god	566tn god	3qd god
17	1.000 god	13 mlrd god	1qd god	35qd god	276qd god
18	11.000 god	350 mlrd god	91qd god	2qn god	19qn god

Izvor: Autor, prema Hive Systems (2014).

Razumijevanje različitih vrsta prijetnji informacijskoj sigurnosti, kao što su phishing napadi, zlonamjerni softver i DDoS napadi, naglašava kritičnu potrebu za snažnim mjerama kibernetičke sigurnosti. Ove prijetnje predstavljaju značajne rizike za osobne podatke, finansijske informacije i organizacijski integritet. Zbog toga postaje neophodno usvojiti sveobuhvatne sigurnosne strategije. Sljedeće potpoglavlje predstavlja prijedloge za održavanje jake internetske sigurnosti, uključujući praktične savjete koje ljudi i institucije mogu koristiti za zaštitu svojih digitalnih izvora.

### 10.2.3. Smjernice za informacijsku sigurnost

Velik broj sigurnosnih rizika, poput krađe identiteta i zlonamjernog softvera, mogu se uvelike minimizirati njihovim razumijevanjem i primjenom u praksi. Postoji nekoliko najvažnijih preporuka za osiguranje informacijske sigurnosti (Rubenking i Duffy, 2023; NSW Government, n.d.; Kaspersky, n.d.b):



- **Koristite jake lozinke:** koristite složene lozinke kombinirajući slova, brojke i simbole za svaki korisnički račun. Izbjegavajte korištenje informacija koje je lako pogoditi poput rođendana. Koristite upravitelj zaporki za sigurno pohranjivanje i upravljanje zaporkama.
- Ako je moguće, **omogućite multifaktorsku autentikaciju** (MFA): dodajte dodatni sloj sigurnosti zahtijevajući dvije ili više metoda verifikacije za pristup vašim računima, poput lozinke i jednokratnog koda poslanog na vaš telefon.
- **Održavajte softver ažuriranim:** redovito ažurirajte svoje operativne sustave, preglednike i aplikacije kako biste zakrpali sigurnosne propuste. Omogućite automatsko ažuriranje kad god je to moguće kako biste bili sigurni da ste uvijek zaštićeni od najnovijih prijetnji.
- **Budite svjesni phishing prijevara:** nemojte klikati na poveznice ili preuzimati privitke iz nepoznatih ili sumnjivih poruka e-pošte. Provjerite podatke pošiljatelja i potražite znakove krađe identiteta, kao što su pravopisne pogreške ili hitni zahtjevi za osobnim podacima.
- **Koristite sigurne veze:** osigurajte da je vaša internetska veza sigurna korištenjem virtualnih privatnih mreža (VPN) i izbjegavajte javni Wi-Fi za osjetljive aktivnosti poput internetskog bankarstva. U URL adresu uvijek tražite "https://", što ukazuje na sigurnu vezu.
- **Redovito sigurnosno kopirajte podatke:** redovito sigurnosno kopirajte svoje podatke na vanjske diskove ili usluge pohrane u oblaku. Ova praksa osigurava da možete vratiti svoje podatke u slučaju kvara hardvera, krađe ili napada ransomwarea.
- **Instalirajte antivirusni softver:** koristite renomirani sigurnosni softver za otkrivanje, sprječavanje i uklanjanje zlonamjernog softvera. Redovno ažurirajte antivirusni softver i redovito skenirajte kako biste bili sigurni da je vaš sustav čist.
- **Redovito nadzirite račune:** često provjeravajte svoje finansijske račune kako biste na vrijeme uočili bilo kakve neovlaštene aktivnosti. Postavite upozorenja za neobične transakcije i odmah prijavite bilo kakvo sumnjičivo ponašanje svom pružatelju usluga.

Razumijevanjem etičkih implikacija rukovanja podacima i prepoznavanjem sigurnosnih prijetnji koje postoje, pojedinci i organizacije mogu razviti učinkovite strategije za zaštitu osjetljivih informacija. Od uspostavljanja etičkih smjernica i korištenja jakih, jedinstvenih zaporki do implementacije naprednih sigurnosnih mjera i informiranja o potencijalnim prijetnjama, ove prakse zajedno osiguravaju integritet, povjerljivost i dostupnost podataka. Davanjem prioriteta



etici podataka i robusnim sigurnosnim protokolima može se stvoriti sigurnije i pouzdanije digitalno okruženje.

## REFERENCE

1. Atlan (2023). Data Ethics Unveiled: Principles & Frameworks Explored [dostupno na: <https://atlan.com/data-ethics-101/>, pristupljeno 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 [dostupno na: <https://www.atlanticcouncil.org/in-depth-research-reports/report/specifying-normative-content/>, pristupljeno May 17, 2024]
3. Cepelak, C. (2023). What is Data Ethics? Datacamp [dostupno na: <https://www.datacamp.com/blog/introduction-to-data-ethics>, pristupljeno May 14, 2024]
4. CISCO (n.d.). What Is Information Security? [dostupno na: <https://www.cisco.com/c/en/us/products/security/what-is-information-security-infosec.html>, pristupljeno May 20, 2024]
5. Cognizant (n.d.). Data ethics [dostupno na: <https://www.cognizant.com/us/en/glossary/data-ethics>, pristupljeno May 14, 2024]
6. Cote (2021). 5 Principles of Data Ethics for Business. Harvard Business School Online [dostupno na: <https://online.hbs.edu/blog/post/data-ethics>, pristupljeno May 17, 2024]
7. Cybernews (2022). World Economic Forum finds that 95% of cybersecurity incidents occur due to human error [dostupno na: <https://cybernews.com/editorial/world-economic-forum-finds-that-95-of-cybersecurity-incidents-occur-due-to-human-error/>, pristupljeno May 21, 2024]
8. ESET (n.d.). 5 scary data breaches that shook the world [dostupno na: <https://www.eset.com/in/about/newsroom/corporate-blog/corporate-blog/eset-5-scary-data-breaches-that-shook-the-world/>, pristupljeno May 21, 2024]
9. Federal Trade Commission (2022). Equifax Data Breach Settlement [dostupno na: <https://www.ftc.gov/enforcement/refunds/equifax-data-breach-settlement>, pristupljeno May 20, 2024]



10. Forbes (2024). Cybersecurity Stats: Facts And Figures You Should Know [dostupno na: <https://www.forbes.com/advisor/education/it-and-tech/cybersecurity-statistics/>, pristupljeno May 24, 2024]
11. Fortinet (n.d.). What Is A Data Breach? [dostupno na: <https://www.fortinet.com/resources/cyberglossary/data-breach>, pristupljeno May 21, 2024]
12. Fruhlinger, J. (2020). What is information security? Definition, principles, and jobs. CSO [dostupno na: <https://www.csoonline.com/article/568841/what-is-information-security-definition-principles-and-jobs.html>, pristupljeno May 20, 2024]
13. Gov.uk (2020). Data Ethics Framework: glossary and methodology [dostupno na: <https://www.gov.uk/government/publications/data-ethics-framework/data-ethics-framework-glossary-and-methodology>, pristupljeno 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 [dostupno na: <https://citizenevidence.org/2020/11/10/ethics-data-open-source/>, pristupljeno May 17, 2024]
16. Hill, M. & Swinhoe, D. (2022). The 15 biggest data breaches of the 21st century. CSO Online [dostupno na: <https://www.csoonline.com/article/534628/the-biggest-data-breaches-of-the-21st-century.html>, pristupljeno May 21, 2024]
17. Hive Systems (2024). Are Your Passwords in the Green? [dostupno na: [https://www.hivesystems.com/blog/are-your-passwords-in-the-green?utm\\_source=tabletext](https://www.hivesystems.com/blog/are-your-passwords-in-the-green?utm_source=tabletext), pristupljeno May 24, 2024]
18. Kaspersky (n.d.a). How Data Breaches Happen & How to Prevent Data Leaks [dostupno na: <https://www.kaspersky.com/resource-center/definitions/data-breach>, pristupljeno May 21, 2024]
19. Kaspersky (n.d.b). Top 15 internet safety rules and what not to do online [dostupno na: <https://www.kaspersky.com/resource-center/preemptive-safety/top-10-preemptive-safety-rules-and-what-not-to-do-online>, pristupljeno May 25, 2024]
20. Kerner, S. M. (2022). Colonial Pipeline hack explained: Everything you need to know. TechTarget [dostupno na: <https://www.techtarget.com/whatis/feature/Colonial-Pipeline-hack-explained-Everything-you-need-to-know>, pristupljeno 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 [dostupno na: <https://www.dataversity.net/what-are-data-ethics/>, pristupljeno May 14, 2024]
23. Kosinski, M. (2024). What is a phishing attack? IBM [dostupno na: <https://www.ibm.com/topics/phishing>, pristupljeno May 24, 2024]
24. McKinsey (2022). Data ethics: What it means and what it takes [dostupno na: <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/data-ethics-what-it-means-and-what-it-takes>, pristupljeno May 14, 2024]
25. National Institute of Standards and Technology (NIST) (n.d.). Information security [dostupno na: [https://csrc.nist.gov/glossary/term/information\\_security](https://csrc.nist.gov/glossary/term/information_security), pristupljeno May 20, 2024]
26. NSW Government (n.d.). 10 Tips for Cyber Security [dostupno na: <https://www.digital.nsw.gov.au/sites/default/files/2022-09/top-10-cyber-security-tips.pdf>, pristupljeno May 25, 2024]
27. O'Reilly (2018). Case studies in data ethics [dostupno na: <https://www.oreilly.com/content/case-studies-in-data-ethics/>, pristupljeno May 17, 2024]
28. PR Newswire (2018). New Survey Finds Deep Consumer Anxiety over Data Privacy and Security [dostupno na: <https://www.prnewswire.com/news-releases/new-survey-finds-deep-consumer-anxiety-over-data-privacy-and-security-300630067.html>, pristupljeno May 20, 2024]
29. Rubenking, N. J. & Duffy, J. (2023). 12 Simple Things You Can Do to Be More Secure Online. PC mag [dostupno na: <https://www.pc当地.com/how-to/12-simple-things-you-can-do-to-be-more-secure-online>, pristupljeno May 25, 2024]
30. TechTarget (2024). Top 10 types of information security threats for IT teams [dostupno na: <https://www.techtarget.com/searchsecurity/feature/Top-10-types-of-information-security-threats-for-IT-teams>, pristupljeno May 24, 2024]



## POPIS TABLICA

Tablica 1.1 Primjeri kardinalnosti .....	12
Tablica 5.1 Vrste događaja .....	59
Tablica 5.2 Primjer dnevnika događaja .....	65
Tablica 10.1 Vrijeme potrebno hakeru da dođe do lozinke u 2024. godini.....	133

## POPIS SLIKA

Slika 1.1 DIKW piramida .....	5
Slika 1.2 Osnovni tipovi podataka .....	8
Slika 1.3 Arhitektura podataka kao temelj uspješne poslovne inteligencije .....	9
Slika 1.4 Primjer tablice u RDBMS .....	10
Slika 1.5 Primjeri odnosa među entitetima .....	11
Slika 1.6 Primjer ERD-a za sustav prodaje .....	12
Slika 2.1 Evolucija logistike, SCM-a i BDA.....	22
Slika 2.2 Trendovi, alati i koristi SCA .....	23
Slika 2.3 Evolucija logistike i opskrbnog lanca .....	25
Slika 2.4 Potražnja za unaprijed narezanim salama u razdoblju od 2015.-2022. ....	26
Slika 2.5 Agregacija potražnje kroz različite vremenske periode .....	27
Slika 2.6 Empirijska distribucija potražnje .....	28
Slika 3.1 Međuindustrijski standardni proces za rudarenje podataka (CRISP-DM) .....	33
Slika 3.2 Principi izvlačenja znanja iz podataka.....	35
Slika 3.3 Koraci u provođenju Delphi metode .....	37
Slika 3.4 Zadaci rudarenja podataka.....	39
Slika 3.5 Koraci koji čine KDD proces .....	39
Slika 4.1 Klasično programiranje vs. treniranje sustava pomoću ML-a.....	44
Slika 4.2 Arhitektura Microsoft business intelligence .....	46
Slika 4.3 Koraci za analizu podataka pomoću ML-a u R Serveru .....	46
Slika 4.4 Cjevodod ML podataka i znanja za tvrtku Equilibrium AI .....	48
Slika 4.5 Tipični dio vizualizacije ML platforme u opskrbnim lancima.....	49



Slika 4.6 Prikaz kompromisa između fleksibilnosti i interpretabilnosti, korištenjem različitih ML metoda.....	50
Slika 4.7 Statističke karakteristike proizvoda u lancu opskrbe hranom (sažeto za sve proizvode) .....	51
Slika 5.1 BPM životni ciklus.....	57
Slika 5.2 Oznake za početni, intermedijarni i završni događaj .....	59
Slika 5.3 Zadatak i potproces.....	60
Slika 5.4 Odluke OR, XOR i AND .....	61
Slika 5.5 Primjer korištenja OR odluke.....	61
Slika 5.6 Sekvencijski tok, tok poruka i asocijacija .....	62
Slika 5.7 Bazen i staze .....	63
Slika 5.8 Podatkovni objekti.....	63
Slika 5.9 Spremiste podataka.....	64
Slika 5.10 Anotacija .....	64
Slika 5.11 Upravljanje poslovnim procesima vs. Rudarenje procesa.....	65
Slika 6.1 Razlika između neovisnih odjela i odjela koji dijele zajedničku centralnu bazu podataka .....	69
Slika 6.2 Veza između ERP-a, WMS-a i TMS-a .....	78
Slika 8.1 Komponente GIS-a.....	95
Slika 8.2 GIS slojevi .....	96
Slika 8.3 Vektorski (lijevo) i rasterski (desno) podaci .....	97
Slika 9.1 Blizina kao načelo Gestalt teorije .....	107
Slika 9.2 Sličnost kao načelo Gestalt teorije .....	107
Slika 9.3 Ograđenost kao načelo Gestalt teorije.....	107
Slika 9.4 Zatvaranje kao načelo Gestalt teorije .....	108
Slika 9.5 Kontinuitet kao načelo Gestalt teorije.....	108
Slika 9.6 Povezanost kao načelo Gestalt teorije .....	108
Slika 9.7 Korištenje atributa za privlačenje pozornosti u vizualizaciji podataka.....	109
Slika 9.8 Vrste atributa za privlačenje pozornosti u vizualizaciji podataka.....	109
Slika 9.9 Jednostavan tekst u vizualizaciji .....	111
Slika 9.10 Stupčasti grafikon u vizualizaciji.....	112
Slika 9.11 Linijski grafikon u vizualizaciji .....	113
Slika 9.12 Area chart in visualization .....	113
Slika 9.13 Dijagram raspršenosti u vizualizaciji .....	114



Slika 9.14 Koropletna karta u vizualizaciji.....	115
Slika 9.15 Toplinska karta u vizualizaciji.....	115
Slika 9.16 Bullet grafikon u vizualizaciji.....	116
Slika 9.17 Kombinacije boja.....	118
Slika 9.18 Scheme boja.....	118
Slika 10.1 5C podatkovne etike.....	123
Slika 10.2 CIA trokut.....	127



### Dario Šebalj, PhD

Assistant Professor at the Faculty of Economics and Business in Osijek, Department of Quantitative Methods and Informatics. He is a lecturer in a field of business process management, ICT project management, business analysis and e-logistics. He has published more than 20 scientific papers in journals and international conference proceedings. He was an executive editor of the journal Ekonomski vjesnik from 2020 to 2023, and secretary of the Alumni EFOS association from 2017 to 2019. He worked as a researcher on two Erasmus+ projects as well as a Croatian Science Foundation project.

ORCID: 0000-0002-8295-7847



### Dejan Mirčetić, PhD

Research Associate, Institute for Artificial Intelligence Research and Development of Serbia Assistant Professor, Faculty of Technical Sciences, University of Novi Sad. Dr Dejan Mirčetić earned his PhD in the field of demand forecasting and supply chain analytics and is the author of more than 60 scientific papers, with research primarily focused on solving real-world business and industrial challenges. At the Institute for Artificial Intelligence of Serbia, Dr Mirčetić is responsible for the design and development of AI solutions for business and industry. He currently leads the ISIOP project, part of the AIPlan4EU platform within the Horizon 2020 research and innovation programme. In addition to his work in supply chain management, Dr Mirčetić makes significant contributions to the application of artificial intelligence in healthcare and the food industry, focusing on innovative approaches to process optimisation and efficiency enhancement.

ORCID: 0000-0002-1602-7908



**Michał Adamczak, PhD Eng.**

Research and teaching employee at the Poznan School of Logistics. Head of the Department of Logistics at this university. Member of the Board of the Polish Logistics Association. Specializes in management, inventory, supply chain management and production management. In his work, he uses logistics data analysis tools, statistical analysis, modeling and process simulations, including the Ms Excel spreadsheet. Author of open and closed training programs on the above-mentioned topics. Implementer of several dozen consulting projects for commercial and manufacturing companies. Lead scientist in many projects implemented under the ERASMUS+ program. Author of over 100 scientific publications in recognized domestic and foreign journals. Participant of many international conferences.

ORCID: 0000-0003-4183-7264

# BUSINESS ANALYTICS SKILLS FOR THE FUTURE-PROOF SUPPLY CHAINS