

UNIVERZA V LJUBLJANI
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**UPORABA UMETNE INTELIGENCE ZA IZBOLJŠANJE
MANAGEMENTA OSKRBOVALNE VERIGE PRI IZBRANEM
PODJETJU**

Ljubljana, oktober 2025

MARKO VRHOVNIK

IZJAVA O AVTORSTVU

Podpisani Marko Vrhovnik, študent Ekonomske fakultete Univerze v Ljubljani, avtor predloženega dela z naslovom Uporaba umetne inteligence za izboljšanje managementa oskrbovalne verige pri izbranem podjetju, pripravljenega v sodelovanju z mentorjem doc. dr. Markom Budlerjem

IZJAVLJAM

1. da sem predloženo delo pripravil samostojno;
2. da je tiskana oblika predloženega dela istovetna njegovi elektronski obliki;
3. da je besedilo predloženega dela jezikovno korektno in tehnično pripravljeno v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani, kar pomeni, da sem poskrbel, da so dela in mnenja drugih avtorjev oziroma avtoric, ki jih uporabljam oziroma navajam v besedilu, citirana oziroma povzeta v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani;
4. da se zavedam, da je plagiatorstvo – predstavljanje tujih del (v pisni ali grafični obliki) kot mojih lastnih – kaznivo po Kazenskem zakoniku Republike Slovenije;
5. da se zavedam posledic, ki bi jih na osnovi predloženega dela dokazano plagiatorstvo lahko predstavljalo za moj status na Ekonomski fakulteti Univerze v Ljubljani v skladu z relevantnim pravilnikom;
6. da sem pridobil vsa potrebna dovoljenja za uporabo podatkov in avtorskih del v predloženem delu in jih v njem jasno označil;
7. da sem pri pripravi predloženega dela ravnal v skladu z etičnimi načeli in, kjer je to potrebno, za raziskavo pridobil soglasje etične komisije;
8. da soglašam, da se elektronska oblika predloženega dela uporabi za preverjanje podobnosti vsebine z drugimi deli s programsko opremo za preverjanje podobnosti vsebine, ki je povezana s študijskim informacijskim sistemom članice;
9. da na Univerzo v Ljubljani neodplačno, neizključno, prostorsko in časovno neomejeno prenašam pravico shranitve predloženega dela v elektronski obliki, pravico reproduciranja ter pravico dajanja predloženega dela na voljo javnosti na svetovnem spletu preko Repozitorija Univerze v Ljubljani;
10. da hkrati z objavo predloženega dela dovoljujem objavo svojih osebnih podatkov, ki so navedeni v njem in v tej izjavi.
11. da sem preveril verodostojnost informacij, ki izhajajo iz zapisov na podlagi uporabe orodij umetne inteligence.

V Ljubljani, dne 21. 11. 2025

Podpis študenta: 

POVZETEK

Magistrsko delo obravnava uporabo umetne inteligence za izboljšanje delovanja managementa oskrbovalne verige izbranega podjetja. Prvi del zajema teoretičen pregled ključnih področij uporabe umetne inteligence v managementu oskrbovalnih verig in predstavitev tehnologij, ki se na teh področjih uporabljajo, kot so strojno učenje, procesiranje naravnega jezika ter koncept interneta stvari. Temu sledi razvoj modela stopnje zrelosti uporabe umetne inteligence specifično za izbrano podjetje in analiza anketnega vprašalnika, ki je bil oblikovan na podlagi tega modela. Na podlagi rezultatov je ugotovljeno, da se podjetje nahaja v prehodni fazi med tretjo in četrto stopnjo zrelosti. V tretjem delu je predlagan večstopenjski načrt za implementacijo umetne inteligence v podjetje. Načrt zajema postavitev temeljev in ustanovitev centra odličnosti za umetno inteligenco, več projektov, ki bodo podjetju omogočali natančnejše napovedovanje povpraševanja, optimizacijo dela s kadri in končni prehod k popolni integraciji umetne inteligence v vse poslovne procese. Cilj načrta je umetno inteligenco upeljati kot ključno konkurenčno prednost in gonilo inovacij v celotnem podjetju.

KLJUČNE BESEDE: management oskrbovalne verige, umetna inteligenca, model zrelosti, optimizacija procesov

CILJI TRAJNOSTNEGA RAZVOJA



ABSTRACT

The master's thesis addresses the use of artificial intelligence to improve supply chain management of a selected company. The first part of this thesis includes a theoretical overview of key areas of its application in supply chain management and technologies used in these areas such as machine learning, natural language processing, and the concept of the Internet of Things. This is followed by the development of an artificial intelligence maturity model, specifically for the selected company, and an analysis of a survey questionnaire prepared in conjunction with the maturity model. Based on the results, it is found that the company is in a transitional phase between the third and fourth maturity stages. The third part of the thesis proposes a multi-stage plan for implementing artificial intelligence within the company. The plan involves laying the groundwork and establishing a center of excellence for artificial intelligence. It includes several projects that will enable the company more accurate demand forecasting, human resource management, and move towards the full integration of artificial intelligence into all business processes. The goal of the plan is to

establish artificial intelligence as a key competitive advantage and driver of all innovation throughout the company.

KEY WORDS: supply chain management, artificial intelligence, maturity model, process optimization

SUSTAINABLE DEVELOPMENT GOALS



KAZALO

1	UVOD	1
2	TEORETIČEN DEL	4
2.1	Področja uporabe umetne inteligence v managementu oskrbovalnih verig ...	4
2.1.1	Načrtovanje povpraševanja.....	5
2.1.2	Načrtovanje proizvodnje.....	6
2.1.3	Načrtovanje in zagotavljanje dobav izdelkov.....	7
2.1.4	Delovanje logistike	7
2.1.5	Izzivi pri implementaciji.....	8
2.2	Tehnološko ozadje umetne inteligence.....	8
2.2.1	Strojno učenje	9
2.2.2	Procesiranje naravnega jezika	10
2.2.3	Internet stvari.....	12
3	PREDSTAVITEV PODJETJA.....	14
3.1	Opis podjetja	14
3.1.1	Ponudba rešitev	15
3.1.2	Organizacijska struktura	16
3.2	Oskrbovalna veriga podjetja	16
3.2.1	Oskrbovalna veriga tretjega segmenta.....	17
3.2.2	Trenutna uporaba tehnologije in informacijskih sistemov	18
4	STOPNJA ZRELOSTI PODJETJA	18
4.1	Razvoj modela	19
4.2	Model.....	20
4.2.1	Stopnje zrelosti	20
4.2.2	Dimenzije zrelosti.....	21
5	EMPIRIČEN DEL	23
5.1	Uvodna vprašanja	24
5.2	Demografski podatki	25
6	PREDLOGI ZA IMPLEMENTACIJO UMETNE INTELIGENCE V MOV	30
6.1	Vzpostavitev strateških temeljev podjetja	30
6.1.1	Centralizirano vodstvo in strategija za umetno inteligenco.....	30

6.1.2	Razvoj pametnih kazalnikov uspešnosti	31
6.1.3	Razvoj kadrov	33
6.2	Specifični projekti.....	34
6.2.1	Napovedovanje povpraševanja.....	34
6.2.2	Razporejanje kadrov.....	35
6.2.3	Sistem za obdelavo naravnega jezika.....	36
6.3	Kontrolni stolp z umetno inteligenco	37
6.3.1	Popolna vidljivost podatkov	38
6.3.2	Integracija napovednih modelov	39
6.3.3	Podpora pri odločanju	39
6.3.4	Popolna avtonomija.....	40
7	OMEJITVE IN PREDLOGI ZA NADALJNJE RAZISKAVE	40
8	SKLEP	41
	SEZNAM KLJUČNE LITERATURE	43
	LITERATURA IN VIRI.....	43
	PRILOGE	52

KAZALO SLIK

Slika 1: Struktura oskrbovalne verige podjetja	16
Slika 2: Tok oskrbovalne verige podjetja.....	17
Slika 3: Model stopenj zrelosti.....	20
Slika 4: Dimenzije zrelosti uporabljene v modelu	22
Slika 5: Tabela deskriptivnih statistik trditev anketnega vprašalnika	23
Slika 6: Porazdelitev zaposlenih po delovnih mestih.....	24
Slika 7: Pogostost uporabe specializiranih sistemov in analitičnih orodij	25
Slika 8: Razporeditev zaposlenih po spolu	25
Slika 9: Razporeditev po starostnih skupinah	26
Slika 10: Korelacijska matrika med dimenzijami	29
Slika 11: Štiri faze razvoja kontrolnega stolpa za umetno inteligenco	38

KAZALO PRILOG

Priloga 1: Anketni vprašalnik.....	1
------------------------------------	---

Priloga 2: Graf primerjave povprečnih ocen trditev glede na delovna mesta	4
---	---

SEZNAM KRATIC

angl. – angleško

AI – (angl. Artificial Intelligence); umetna inteligenca

AIMM – (angl. Artificial Intelligence Maturity Model); model zrelosti umetne inteligence

IKT – informacijsko-komunikacijska tehnologija

IoT – (angl. Internet of Things); internet stvari

IT – informacijska tehnologija

ML – (angl. Machine Learning); strojno učenje

MOV – management oskrbovalnih verig

NLP – (angl. Natural Language Processing); procesiranje naravnega jezika

1 UVOD

Globalizacija, napredek informacijske tehnologije in spremembe v družbenem okolju so dejavniki, ki od podjetij zahtevajo prilagajanje. Uspešna podjetja torej v svetu, ki se stalno spreminja, potrebujejo ustrezen management oskrbovalne verige, močne strateške partnerje, dober poslovni model in medsebojno sodelovanje, ki vsem vpletenim dolgoročno zagotavlja dobičkonosnost in konkurenčnost (Francis in drugi, 2021). Tipična oskrbovalna veriga zajema več udeležencev, in sicer dobavitelje, proizvajalce, distributerje, prodajalce in kupce. Prav tako zajema vse postopke, ki se med njimi odvijajo (Mentzer in drugi, 2001). V vedno hitrejšem svetu te verige postajajo bolj kompleksne, kar pomeni, da je za njihov optimalen management potrebnih vedno več informacij (Hugos, 2018). Ni več dovolj, da v podjetju posamezne postopke poskušamo spremeniti kot ločene elemente, temveč je za optimalno delovanje treba prevzeti bolj celovit pogled na celotno verigo in jo obravnavati kot eno enoto. Ustrezen management oskrbovalne verige je ključnega pomena za nemoteno delovanje podjetja, saj je mogoče le s celovitim pregledom vseh dejavnosti in nemotenim pretokom informacij med njimi zagotoviti nemoteno delovanje (Christopher, 2016). Namen oskrbovalne verige je sistematično in strateško koordiniranje tradicionalnih funkcij podjetja ter taktik v podjetju in ostalih podjetjih, ki so vključena v verigo. Cilj je na dolgi rok izboljšati delovanje podjetja in ostalih delov verige (Mentzer in drugi, 2001).

Večja podjetja v svoji verigi niso sposobna analizirati vseh podatkov ali za analizo nimajo potrebnih orodij, zato je prehod na uporabo umetne inteligence (angl. artificial intelligence, v nadaljevanju AI) v oskrbovalni verigi zanje lahko koristen. Kljub pozitivnim lastnostim umetne inteligence pri vodenju oskrbovalnih verig morajo biti podjetja še vedno pozorna na nekatere pomanjkljivosti v poznavanju te tehnologije. Pri implementaciji se je treba zavedati, da tveganja, ki jih prinaša uporaba umetne inteligence za management oskrbovalnih verig, še niso popolnoma raziskana. Prav tako je treba upoštevati, da so raziskave, ki opazujejo učinkovitost umetne inteligence v managementu oskrbovalnih verig, še relativno nove in zato verjetno niso zajele vseh parametrov, kar lahko vpliva na njihovo kredibilnost (Kumar in drugi, 2022). Druge opažene pomanjkljivosti umetne inteligence vključujejo tveganja, ki jih uporaba te tehnologije predstavlja za poslovno uspešnost podjetja. Številne študije so že razvile smernice za implementacijo umetne inteligence v oskrbovalne verige, le malo pa se jih ukvarja s posledicami te implementacije. Druge skrbi glede umetne inteligence vključujejo zmanjšano varnost zasebnih podatkov, etična vprašanja in varnostne ranljivosti podjetja. V magistrskem delu bodo predstavljene koristi in izzive, ki jih podjetje lahko pričakuje pri implementaciji te tehnologije. Delo bo prav tako prispevala k literaturi, ki bo lahko uporabljena v praksi drugih podjetij.

Svet se že vrsto let premika proti digitalni prihodnosti. Tehnologije, ki so bile razvite v okviru Industrije 4.0, so postavljene v sam vrh te transformacije. Med temi tehnologijami izstopa umetna inteligenca, ki se je po letu 2010 začela uveljavljati kot ena izmed potencialnih inovacij pri managementu oskrbovalnih verig (Mohsen, 2023). Tradicionalne

metode za nadzor in optimizacijo verig ne dosegajo več željenih standardov, zato se vedno več podjetij odloča za prehod na avtonomne sisteme, ki temeljijo na umetni inteligenci. Umetna inteligenca omogoča hitrejšo in bolj učinkovito reševanje kompleksnih problemov, hitrejšo odločanje ter hitrejšo analizo večjih količin podatkov. To omogoča sprejemanje bolj informiranih odločitev in oblikovanje učinkovitejših strategij. V primeru managementa oskrbovalnih verig taki sistemi omogočajo večjo fleksibilnost, hitrejšo prilagoditev na spremembe na trgu in splošno izboljšanje učinkovitosti celotne verige (Mohsen, 2023). S preходом na avtonomne sisteme podjetja ne le povečujejo svojo učinkovitost, temveč ustvarjajo priložnosti za nadaljnji razvoj in rast. S tem preходом management oskrbovalnih verig postaja čedalje bolj usklajen, odziven in prilagodljiv sodobnemu poslovnemu okolju (Baryannis in drugi, 2018).

Kljub visoki prisotnosti v poslovnem in akademskem svetu, prispevki umetne inteligence še vedno niso popolnoma jasni, zato je treba biti pri implementaciji previden in jo uvajati postopoma (Toorajipour in drugi, 2021). Hitrost implementacije je prav tako odvisna od stopnje zrelosti podjetja (angl. maturity stage). Ta metrika subjekte razvršča glede na poznavanje tematike in primernost za hitro prilagoditev. Na eni strani lestvice so novinci, ki se v tehnologijo še niso poglobili in niso sprejeli ustreznih korakov za implementacijo. Ti se še odločajo o morebitni implementaciji. Na drugi strani so napredni uporabniki, ki so tehnologijo že implementirali in je ta postala del vsakdanje uporabe. Ti so tehnologijo implementirali v vse procese in se skupaj z njo razvijajo (Ellefsen in drugi, 2019). Dodatno področje, ki ga delo obravnava je optimizacija oskrbovalne verige s pomočjo umetne inteligence, pri čemer je poudarek na načinih, kako lahko ta izboljša učinkovitost verige in zmanjša stroške.

Podjetje, katerega primarna dejavnost je razvoj in implementacija naprednih IKT- in IoT-rešitev za poslovne naročnike, s poudarkom na telekomunikacijah, energetiki, transportu in varnostnih sistemih, se trenutno ukvarja z implementacijo umetne inteligence v svojo oskrbovalno verigo. Sprememba izhaja iz želje po boljši operativni učinkovitosti in odpravljanju trenutnih pomanjkljivosti, ki izhajajo iz prenizke stopnje digitalizacije. Podjetje pri poslovanju ne uporablja integriranih informacijskih sistemov, kar mu onemogoča centralizirano zbiranje informacij in dostop ključnih oseb do teh informacij. Posledično je pretok informacij za koordiniranje dejavnosti v različnih segmentih neoptimalen. To vodi do upočasnevanja verige. Poleg pomanjkanja digitalizacije se podjetje prav tako sooča s problemi, ki so posledica stroge hierarhične ureditve. Odločitve o ključnih procesih se sprejemajo na višjih ravneh organizacije, kar zavlačuje celoten proces odločanja in preprečuje izkoriščanje znanja zaposlenih. V poslovnem okolju, kjer sta hitrost in natančnost ključna, imajo majhna odstopanja od idealnih okoliščin lahko velike posledice za stranke. Zato si podjetje želi z implementacijo umetne inteligence odpraviti nekatere svoje pomanjkljivosti, izboljšati operativno učinkovitost in se učinkoviteje prilagoditi zahtevam trga. Cilja sta večja konkurenčna prednost in rast v digitalnem poslovnem okolju.

Cilji magistrskega dela so:

- ugotoviti, kako je mogoče umetno inteligenco izkoristiti za učinkovitejši management oskrbovalne verige
- ovrednotiti koristi in izzive implementacije umetne inteligence ter njene posledice za prihodnost podjetja (npr. stroški usposabljanja delovne sile, hitrejši odzivi na trg itd.)
- glede na stopnjo zrelosti podjetja podati smernice za implementacijo umetne inteligence
- s pomočjo ankete pridobiti informacije o trenutnem stanju odnosa zaposlenih do umetne inteligence
- analizirati podatke ankete in podati smiselne zaključke o tem, kako naj podjetje nadaljuje s tem preходом.

Glede na cilje so bila oblikovana naslednja raziskovalna vprašanja:

- Kakšne so ključne ugotovitve literature o uporabi umetne inteligence za izboljšanje managementa oskrbovalnih verig?
- Kako lahko umetna inteligenca v okviru managementa oskrbovalne verige prispeva k zmanjšanju stroškov, načrtovanju proizvodnje, napovedovanju povpraševanja, boljšemu strateškemu odločanju itd.?
- Na kateri stopnji zrelosti za implementacijo umetne inteligence se podjetje nahaja in kako to vpliva na pričakovane koristi ter izzive?
- Katere smernice za implementacijo umetne inteligence je mogoče predlagati glede na ugotovljeno stopnjo zrelosti podjetja?
- Kakšen je odnos zaposlenih do implementacije umetne inteligence in kakšna je njihova pripravljenost za delo z novimi tehnologijami?

Pregled literature bo služil kot sredstvo za doseg ciljev teoretičnega dela magistrskega dela. Predvsem bo že objavljena literatura služila kot podlaga za teoretični del magistrskega dela. Pregledana bo literatura domačih in tujih avtorjev s področja oskrbovalnih verig, umetne inteligence, managementa oskrbovalnih verig ter drugih povezanih področij, na podlagi katerih bodo pripravljene analize in podani zaključki. Teoretična podlaga bo pridobljena iz del ne glede na leto publikacije, konkretna priporočila za izboljšanje pa bodo izhajala iz literature, ki je izšla v zadnjih desetih letih, kar bo omogočilo uporabo aktualnih podatkov in podajanje natančnih predlogov. Literaturo bo pridobljena iz baz DKUM, RUL, Google Scholar, Scopus ter iz drugih znanstvenih revij in člankov, do katerih omogoča dostop Ekonomska fakulteta.

Model stopnje zrelosti bo razvit v povezavi z dostopno literaturo in bo individualno prilagojen izbranemu podjetju. Zajemal bo področja vizije in ciljev podjetja, izkoriščanje podatkov, orodja in sisteme, ki se trenutno uporabljajo, kompetence zaposlenih in praktično uporabo umetne inteligence. Ta področja so neposredno povezana z logistiko, organizacijo in managementom podjetja. Dodatno bo pripravljena anketa, ki bo razdeljena zaposlenim. Anketa bo služila kot podpora pri validaciji uvrstitve podjetja na ustrezno raven stopnje

zrelosti. Sestavljena bo iz približno dvajsetih vprašanj, odgovori bodo ocenjeni na Likertovi lestvici od 1 do 5. Vprašanja ankete bodo omogočila podrobnejši vpogled v posamezna področja modela stopnje zrelosti. Rezultati modela in ankete bodo služili kot smernice za nadaljnjo implementacijo umetne inteligence v management oskrbovalne verige podjetja.

2 TEORETIČEN DEL

2.1 Področja uporabe umetne inteligence v managementu oskrbovalnih verig

V današnjem hitro razvijajočem se svetu oskrbovalne verige ne morejo več delovati samostojno. Za ustrezno delovanje je potreben management oskrbovalnih verig (angl. supply chain management, v nadaljevanju MOV). MOV je lahko opredeljen kot pristop za učinkovito integracijo členov verige. Členi verige so dobavitelji, proizvajalci, skladišča in stranke. Cilj je natančna distribucija produktov na prave lokacije ob pravem času in s čim manjšimi stroški. MOV je danes ključni dejavnik uspešnosti številnih podjetij, saj se posledice učinkovite oskrbovalne verige izražajo v nižjih stroških in višji poslovni uspešnosti. MOV zajema vse aktivnosti in procese, ki končnemu uporabniku zagotavljajo dostop do storitev ali izdelkov in ga je mogoče razdeliti na naslednje dele (Kavčič in drugi, 2004):

- načrtovanje povpraševanja
- načrtovanje proizvodnje
- načrtovanje in zagotavljanje dobav izdelkov
- delovanje logistike.

MOV torej odgovarja na vprašanja o tem, kaj ponuditi uporabnikom, kako produkt izdelati ali storitev opraviti ter kako in kdaj ju dostaviti uporabnikom. Ta vprašanja se odražajo v naslednjih kazalnikih uspešnosti: fleksibilnost, zanesljivost, pravočasne dobave in stopnja zalog (Kavčič in drugi, 2004).

Podjetja se zaradi hitrega napredka na področju umetne inteligence srečujejo z novimi izzivi implementacije te tehnologije v obstoječe poslovne procese. Uporaba AI je še posebej učinkovita v povezavi z drugimi tehnologijami v okviru Industrije 4.0. Da je mogoče določen prehod managementa oskrbovalne verige uvrstiti pod uporabo AI, morata biti izpolnjena dva ključna pogoja: sistem mora biti sposoben samostojnega in pravilnega odločanja ter delovati v neznanem oziroma nepredvidljivem okolju (Baryannis in drugi, 2018). Identificirati je mogoče štiri glavna področja, kjer se uporaba umetne inteligence izkaže za koristno: optimizacija, napovedovanje, modeliranje in simulacije ter podpora pri sprejemanju odločitev. Dodatna področja, kjer se pogosto uporablja strojno učenje in druge metode obdelave velikih količin podatkov, vključujejo predvidevanje, upravljanje skladišč, upravljanje prihodkov, oglaševanje, transport in analizo tveganj (Helo in Hao, 2022).

2.1.1 Načrtovanje povpraševanja

Sposobnost sprejemanja odločitev pri načrtovanju povpraševanja je ena ključnih veščin v managementu oskrbovalnih verig. Odločitve temeljijo na trenutno dostopnih informacijah in pričakovanjih glede prihodnosti, vendar zaradi nepredvidljivosti poslovnega in organizacijskega okolja nikoli ne nudijo popolne gotovosti. Zato je sposobnost natančnega predvidevanja prihodnosti ključnega pomena za sprejemanje pravih odločitev in učinkovito načrtovanje poslovanja (Alireza in drugi, 2018). Podjetja lahko na podlagi preteklih informacij in s pomočjo različnih metod obdelujejo svoje podatke ter glede na povratne informacije zanesljivo sprejemajo odločitve (Alegre in drugi, 2016).

Tradicionalne metode načrtovanja se delijo na formalne in neformalne. Neformalne večinoma temeljijo na intuiciji posameznikov ter njihovih izkušnjah. Formalne metode se naprej delijo še na kvantitativne ter kvalitativne. Pod kvantitativne metode se uvrščajo ocene managementa, ocene osebja, ankete kupcev itd. Te so manj zanesljive in se uporabljajo le v primeru, da ni dostopa do drugih vrst podatkov (Jones, 2025). Kvantitativne metode temeljijo na matematičnih modelih, kot so linearna in polinomska regresija, časovni modeli, povprečja itd. Delujejo na predpostavki, da je pretekle informacije možno združiti s sedanjimi podatki ter tako natančno napovedati prihodnost (Alireza in drugi, 2018). Te metode se srečujejo z nekaterimi pomanjkljivostmi, ki so opazne predvsem v obdelavi velikih količin podatkov, kakršne se pogosto pojavljajo v sodobnih oskrbovalnih verigah (Jones, 2025).

Bolj kompleksni modeli, kot so strojno učenje (angl. machine learning, v nadaljevanju ML), omogočajo odkrivanje skritih vzorcev in korelacij v velikih bazah podatkov. AI-sistemi so še posebej uporabni na področjih, za katere je značilno veliko število spremenljivk (Jones, 2025). Obdelava in razumevanje večjih količin podatkov v realnem času omogoča večjo natančnost načrtovanja in hitrejšo prilagodljivost razmeram na trgu (Malviya in Bhandari, 2023). Ti AI-sistemi imajo lahko pozitiven vpliv na druge dele managementa oskrbovalnih verig. Z bolj natančnim načrtovanjem povpraševanja se doseže višja operativna učinkovitost in se znižajo stroški. Zniža se lahko pogostost potreb po prevelikih zalogah, zmanjša se verjetnost premajhnih zalog, izboljša se lahko pretok denarja, kar vse vodi v nižjo ceno končnih izdelkov (Jones, 2025).

Praktičen primer uporabe umetne inteligence pri načrtovanju povpraševanja je mogoče najti pri eni največjih nemških drogerij – dm. Z več kot 4.000 poslovalnicami po vsej Evropi se podjetje sooča s številnimi logističnimi izzivi. Njegov sistem temelji na šestih distribucijskih centrih, ki so odgovorni za pravočasno in natančno dostavo izdelkov na posamezne lokacije. Glavni izziv je uskladitev kratkoročnih potreb trgovin po izdelkih in daljših dobavnih rokov dobaviteljev. Doslej je dm reševal to težavo z dolgoročnejšim načrtovanjem in z naročanjem večjih količin izdelkov, kar je vodilo do povečanih stroškov skladiščenja in zadrževanja kapitala. Kot odziv na te izzive se je podjetje odločilo za uporabo umetne inteligence pri pripravi tedenskih modelov napovedovanja povpraševanja za posamezne izdelke po enotah

(angl. stock keeping units) za obdobje šestih mesecev. Model temelji na podatkih zadnjih dveh in pol let, specifičnih za vsak distribucijski center, in prav tako upošteva sezonske dejavnike. Rezultati uvedbe AI-sistemov so pokazali znatno izboljšanje v natančnosti napovedovanja povpraševanja, kar omogoča bolj pravočasno in zanesljivo naročanje. Posledično se je povečala dostopnost izdelkov in zmanjšali so se skladiščni stroški. Partnerji podjetja dm lahko zdaj računajo na večjo zanesljivost naročil, medtem ko trgovine prejemajo bolj natančne zaloge izdelkov (Dressler, 2018).

2.1.2 Načrtovanje proizvodnje

Načrtovanje proizvodnje mora biti usklajeno z internimi zmogljivostmi podjetja. V načrtovanje je vključeno naročanje materialov, načrtovanje zmogljivosti ter logističnih procesov na vhodni strani verige. Pri načrtovanju proizvodnje je posebnega pomena izbira dobaviteljev. Podjetje se mora odločiti za specifične dobavitelje, ki bodo sposobni izpolnjevati potrebe proizvodnje (Chapman, 2006).

Industrija 4.0 in koncepti »pametne« proizvodnje (angl. smart manufacturing) so v preteklih letih pridobili na prepoznavnosti v svetu načrtovanja in nadzora proizvodnje (angl. production planning and control), saj nam omogočajo večjo agilnost, prilagodljivost in decentralizacijo proizvodnje (Elbasheer in drugi, 2022). Pametno proizvodnjo je mogoče opredeliti kot povezovanje vseh delov proizvodnje s senzorji in komunikacijsko tehnologijo za lažji nadzor in modeliranje predvidevanja potreb. Tehnologije, ki so pri tem uporabljene, so računalništvo v oblaku, umetna inteligenca, tehnologije interneta stvari itd. (Kusiak, 2018). Te tehnologije se lahko v povezavi s sistemi umetne inteligence, specifično strojnega učenja, uporabijo za optimizacijo proizvodnih del. ML-modeli lahko ob morebitnih napakah v realnem času razporejajo dela in s tem znižujejo morebitne stroške izpadov. Na podlagi preteklih in trenutnih informacij so AI-sistemi v povezavi s tehnologijami interneta stvari sposobni predvidevati potrebe po vzdrževanju strojev ali druge opreme in s tem zagotavljajo minimalne motnje proizvodnji. AI-sistemi lahko s pomočjo kamer v resničnem času izvajajo nadzor kakovosti izdelkov. Morebitne napake so hitro odkrite, o njih so obveščene ustrezne osebe in izdelki so samodejno odstranjeni (Elbasheer in drugi, 2022).

Kot konkreten primer uporabe umetne inteligence v praksi lahko služi raziskava, opravljena na japonskem trgu, kjer so raziskovalci preučevali, ali je mogoče z uporabo modelov strojnega učenja uspešno identificirati ustrezne partnerje v oskrbovalni verigi. V raziskavi je sodelovalo več kot 30.000 podjetij, pri čemer je bilo analiziranih več kot 34.000 parov partnerjev. Za pozitivne primere partnerjev so bila upoštevana podjetja s preverjenimi partnerji, medtem ko so bili negativni primeri ustvarjeni z naključnim parjenjem podjetij. S strojnim učenjem so iskali vzorce povezav med podjetji glede na 32 različnih dejavnikov, kot so kapital, število zaposlenih, industrijski sektor, izbira banke itd. Rezultati so pokazali, da je model v kar 85 % primerov pravilno identificiral ustrezne partnerje. Najpomembnejša dejavnika, ki sta vplivala na uspešnost napovedi, sta bila število zaposlenih v podjetju in

industrijski sektor podjetja. Avtorji so to pojasnili kot značilnost japonskega poslovnega okolja. Ta študija dokazuje, da je uporaba modelov strojnega učenja učinkovita pri prepoznavanju potencialnih poslovnih partnerjev v oskrbovalnih verigah (Mori in drugi, 2010).

2.1.3 Načrtovanje in zagotavljanje dobav izdelkov

Načrtovanje postopka dobav izdelkov zajema urejanje distribucijskih kanalov. V dobavni postopek so vključeni skladiščni in medskladiščni postopki, nadzor nad distribucijsko mrežo podjetja, spremljanje prodaje, izbira strank in izvajalcev ter določanje prodajnih pogojev (Kavčič in drugi, 2004).

Integracija umetne inteligence v sisteme upravljanja dobave je drastično spremenila številna področja oskrbovalnih verig, saj je povečala njihovo učinkovitost, zanesljivost in sposobnost sprejemanja odločitev. Pri načrtovanju dobave AI analizira kompleksne skupine podatkov, na osnovi katerih omogoča sprejemanje informiranih odločitev. Z analizo prodajnih podatkov, tržnih trendov in drugih relevantnih dejavnikov umetna inteligenca pomaga optimizirati zaloge. Na podlagi napovedanega povpraševanja in razpoložljivih zalog lahko AI-sistemi omogočajo avtomatizirano naročanje. AI je koristna pri izbiri partnerjev, saj z analizo njihove uspešnosti predlaga tiste, ki ustrezajo določenim standardom (Singh in Adhiktar, 2023).

2.1.4 Delovanje logistike

Med logistične procese sodijo postopki, s katerimi se izvaja distribucija izdelkov ali storitev. Za optimalno distribucijo je treba najti pravo razmerje med zadovoljevanjem potreb kupcev, stroški distribucije in kakovostjo načrtovanja. Omejitve pri zagotavljanju logistike so načini distribucije, postavljeni časovni okvirji, dostopnost finančnih sredstev in dogovorjeni pogoji nabave. Cilj logistike je zagotavljanje maksimalne kakovosti storitev s čim nižjimi stroški (Richey in drugi, 2023).

Pri načrtovanju in zagotavljanju logistike so AI-sistemi pogosto uporabljeni pri načrtovanju poti. Z njihovo pomočjo je mogoče znižati operativne stroške, optimizirati poti in uporabo vozil ter znižati porabo goriva. Tradicionalni sistemi po navadi uporabljajo dva ključna dejavnika pri načrtovanju poti: dolžina poti in omejitve na poti. S pomočjo umetne inteligence lahko sistemi vključijo še druge dejavnike, kot so gostota prometa, ki je odvisna od časa dneva, in vreme, ki lahko ustvarja zastoje. Optimalna pot je tako sestavljena iz številnih dejavnikov, ki jih pretekli napovedni sistemi niso bili sposobni vključiti. AI-sistemi so tako sposobni dinamičnega načrtovanja poti, kar pomeni, da lahko glede na zunanje dejavnike pot stalno prilagajajo (Wu-Chih in drugi, 2020).

Praktičen primer v nadaljevanju se delno nanaša na področje iz prejšnjega poglavja – skladiščenje. Gre za podjetje METRO Group Cash & Carry, ki je implementiralo tehnologije umetne inteligence za reševanje problema lažnih pozitivnih zaznav radio-frekvenčnih identifikacijskih signalov pri nadzoru izhodnih palet v skladišču. Specifično so bile uporabljene metode strojnega učenja v povezavi s tehnologijami koncepta interneta stvari. Portali za identifikacijo radio-frekvenc, ki so bili nameščeni na izhodih skladišča, so samodejno beležili gibanje palet, ki so bile prav tako opremljene z radio-frekvenčnimi oddajniki. Zaradi širokega zaznavnega območja portalov so ti pogosto zaznali palete, ki niso bile namenjene izvozu, kar je povzročilo napačne zapise v inventuri. V obdelavo so bile zajete lastnosti, kot so moč sprejetega signala, čas zaznave signala ter število zaznav po posameznih antenah. Analiza je pokazala razlike med statičnimi paletami in tistimi, ki so se dejansko gibale. Palete z močjo signala pod -58,1 dBm so bile označene kot statične (lažno pozitivne) in druge kot premikajoče. Za učenje modela je bilo potrebnih sedem mesecev zbiranja podatkov, pri čemer je bilo analiziranih več kot 50.000 palet. Po končanem učenju je bil model sposoben pravilno prepoznati kar 95 % palet, s čimer je bistveno izboljšal natančnost inventure (Keller in drugi, 2012).

2.1.5 Izzivi pri implementaciji

Med glavne ovire pri implementaciji umetne inteligence v oskrbovalne verige spadajo visoki stroški, ki vključujejo začetne investicije v prenovu sistemov, odpor zaposlenih do sprememb ter potrebe po specifičnih veščinah za učinkovito upravljanje AI-sistemov. Te ovire so še posebej izrazite v velikih podjetjih, kjer je pred implementacijo potrebna temeljita analiza trenutne situacije in previdnost pri sprejemanju odločitev, saj lahko stroški implementacije v določenih primerih hitro presežejo dolgoročne koristi, kot so višja operativna uspešnost in nižji stroški dela (Gaikwad, 2024). Varnost in zaščita podatkov sta prav tako ključnega pomena pri prehodu na AI-sisteme. Ker umetna inteligenca obdeluje velike količine podatkov, morajo podjetja nujno vlagati v ustrezne sisteme za kibernetsko varnost (Yampolskiy, 2016). Veliko podjetij že ima vzpostavljene sisteme za vodenje oskrbovalnih verig, zato je pri uvedbi novih AI-sistemov pomembno zagotoviti njihovo združljivost in zmožnost sočasnega delovanja. Ključnega pomena je dostop do natančnih in kakovostnih podatkov, ki jih AI potrebuje za delovanje (Gaikwad, 2024). Poleg teh tehničnih in finančnih izzivov prinaša uporaba umetne inteligence v management oskrbovalnih verig pomembna etična vprašanja, še posebej na področju sprejemanja odločitev. Podjetja morajo zagotavljati pregledno in odgovorno uporabo umetne inteligence ter se hkrati prilagajati zakonodaji, ki ureja uporabo te tehnologije (Baeza Yates, 2022).

2.2 Tehnološko ozadje umetne inteligence

Pojem umetna inteligenca se lahko uporablja kot krovni izraz za številne tehnologije, ki strojem omogočajo razmišljanje, podobno človeškemu. Na področju managementa oskrbovalnih verig so se kot pomembne uveljavile tri tehnologije (Garg in drugi, 2024):

- strojno učenje
- procesiranje naravnega jezika
- tehnologije koncepta interneta stvari v povezavi z umetno inteligenco.

2.2.1 Strojno učenje

Strojno učenje, kot tehnologija, omogoča bolj učinkovito in avtomatizirano obdelavo velikih količin podatkov, saj je iskanje vzorcev in njihova interpretacija v obsežnih podatkovnih nizih s tradicionalnimi metodami pogosto neizvedljivo. Zaradi vedno večje razširjenosti podatkovnih baz, s katerimi se podjetja srečujejo, postaja strojno učenje vse bolj priljubljeno. Uporaba sega preko številnih industrijskih panog od medicine do vojaške industrije z aplikacijami na področjih, kot so napovedovanje povpraševanja in prodaje, transport, distribucija, proizvodnja, upravljanje zalog, izbira dobaviteljev in njihova segmentacija (Tirkolaee in drugi, 2021).

V praksi ločimo več metod strojnega učenja. Med najbolj prepoznavne sodijo:

- Učenje pod nadzorom (angl. supervised learning), kjer se računalnik uči na podlagi označenih podatkov, kjer so pravilni odgovori že znani. Cilj je, da sistem prepozna vzorce oziroma pravila, ki povezujejo vhodne in izhodne podatke in da jih lahko uspešno uporabi za obdelavo novih, še neznanih podatkov. Ključne naloge pri tej metodi so klasifikacija in regresija (Cunningham in drugi, 2008).
- Učenje brez nadzora (angl. unsupervised learning) opisuje proces, kjer računalnik deluje brez vnaprej določenih ciljev ali označenih odgovorov. Sistem sam poišče podobnosti in vzorce v podatkih ter jih skuša razvrstiti ali strukturirati. Med pomembne naloge spadajo iskanje asociacij in samo-organizacijske mape (James in drugi, 2023).
- Učenje z okrepitevijo (angl. reinforcement learning) temelji na principu nagrajevanja uspešnih dejanj oziroma kaznovanja neuspešnih. Sistem ob začetku pozna pravilne odzive in se nato uči, kako jih ponoviti v različnih okolijskih pogojih, pri čemer lahko upošteva kompleksne vplive in primerno reagira (Wenzel in drugi, 2019).

Metode strojnega učenja se kljub številnim prednostim pri obdelavi velikih količin podatkov soočajo z določenimi izzivi. Pogostost napak se praviloma poveča zaradi dveh glavnih razlogov. Prvi razlog izhaja iz samih podatkov. Pridobivanje zadostne količine kakovostnih podatkov, potrebnih za učinkovito učenje algoritmov še vedno predstavlja velik izziv. Kadar podatki vsebujejo veliko napak, manjkajočih vrednosti ali odstopanj, lahko to bistveno zmanjša učinkovitost prepoznavanja vzorcev. Poleg tega lahko prisotnost velikega števila nerelevantnih informacij vodi v tako imenovan »šum«, ki ne prispeva k rezultatom učenja in le upočasni delovanje algoritma. Drugi pomemben izziv je neustrezna izbira modela. Napačna odločitev glede kompleksnosti modela lahko vodi do dveh ekstremov: če je model preveč kompleksen (angl. overfitting), bo preveč pozoren na napake in šum v podatkih, kar posledično vodi do slabih zaključkov. Po drugi strani pa preveč preprost model (angl.

underfitting) ne bo zaznal globljih vzorcev, kar bo zmanjšalo njegovo uporabno vrednost (Wenzel in drugi, 2019).

2.2.2 Procesiranje naravnega jezika

Procesiranje naravnega jezika (angl. natural language processing, v nadaljevanju NLP) je tehnologija umetne inteligence, katere cilj je strojem omogočiti razumevanje in obdelavo človeškega jezika. Temeljna gradnika NLP sta razumevanje naravnega jezika (angl. natural language understanding) in generiranje naravnega jezika (angl. natural language generation). Razumevanje jezika strojem omogoča interpretacijo in razumevanje besedil, vključno z nalogami, kot so analiza mnenj (angl. sentiment analysis), prepoznavanje imenovanih entitet (angl. named entity recognition) in sintaktična analiza (angl. syntactic parsing). Gre za naloge, ki vključujejo razumevanje pomenov, namenov in konteksta jezika. Na drugi strani generiranje jezika strojem omogoča tvorjenje smiselnih in razumljivih besedil. Med glavne naloge procesiranja sodijo generiranje povzetkov, strojno prevajanje in vodenje pogovorov. S kombinacijo generiranja in razumevanja jezika omogoča procesiranje naravnega jezika izvajanje kompleksnih jezikovnih nalog in napredno interakcijo med človekom in strojem (Khurana in drugi, 2023).

Za celovito razumevanje NLP je pomembno ločevanje med sintaktično in semantično analizo. Sintaktična analiza se osredotoča na prepoznavanje gramatične strukture stavkov, identificira posamezne stavčne člene (osebek, povedek, predmet itd.) in razmerja med njimi. Ne vključuje razumevanja pomena besed, ampak zagotavlja le formalni okvir za nadaljnjo obdelavo jezika (Sportiche in drugi, 2013). Semantična analiza se ukvarja z razumevanjem pomena jezika in konteksta, v katerem je bil jezik uporabljen. Omogoča zaznavanje bolj zapletenih jezikovnih pojavov, kot so ironija, sarkazem, dvoumnost ali emocionalni ton (Goddard in Schalley, 2011). Kombinacija obeh pristopov je ključna za učinkovito razumevanje jezika. Sintaktična analiza zagotavlja strukturo in semantična analiza omogoča vpogled v globlji pomen in namen sporočila. Skupaj predstavljata osnovo za sodobne NLP tehnologije, ki postajajo nepogrešljive pri projektih, kot so AI-agenti, avtomatizirano odgovarjanje, analitika družbenih omrežij in podobno (Vo in drugi, 2020).

Ena izmed najbolj osnovnih in prepoznavnih nalog NLP-tehnologij je klasifikacija besedil (angl. text classification). S pomočjo NLP-tehnologije se besedilom pripišejo vnaprej določene oznake glede na njihov kontekst ali vsebino. Ta naloga se široko uporablja v praksi pri filtriranju nezaželenih elektronske pošte, kategorizaciji novic, razvrščanju dokumentov po temah in zaznavanju mnenj (angl. sentiment analysis) (Razno, 2019). Na osnovi klasifikacije besedil deluje naloga iskanja ključnih besed (angl. keyword extraction), katere namen je prepoznati najpomembnejše besede ali besedne zveze v določenem besedilu. Takšna naloga je še posebej uporabna pri obnovi besedil, iskanju informacij, avtomatski kategorizaciji vsebin in pri optimizaciji iskalnikov (Nomoto, 2022). Še korak dlje gre naloga modeliranja vsebin (angl. topic modelling), ki je namenjena razkrivanju tematske strukture

v velikih korpusnih besedilih. S to nalogo se besedila lahko avtomatsko razvrščajo v skupine glede na njihove teme, kar močno olajša organizacijo, iskanje in povzemanje informacij iz obsežnih nestrukturiranih virov (Usmani in drugi, 2021).

Bolj napredne naloge so:

- Prepoznavanje imenovanih entitet (angl. named entity recognition), ki se osredotoča na iskanje in kategorizacijo pomembnih samostalnikov ter besednih zvez v besedilu. Tako imenovane »imenovane entitete« (angl. named entities) običajno vsebujejo ključne informacije stavkov, ki so uporabne pri drugih nalogah procesiranja jezika. Predstavljajo vir informacij pri odgovarjanju na vprašanja, strojnem prevajanju in iskanju informacij (Zitouni, 2014).
- Sentimentalna analiza je naloga, ki se osredotoča na zaznavanje polarnosti in prepoznavanje emocij glede oseb, tem ali dogodkov. Cilj sentimentalne analize je odkriti mnenja uporabnikov in pogledov, ki jih izražajo, ter jih nato klasificirati kot pozitivne, negativne ali nevtralne (Kastrati in drugi, 2021).
- Odgovarjanje na vprašanja temelji na želji uporabnika po novih informacijah. Glede na obliko postavljenega vprašanja je lahko vsaka naloga NLP-tehnologij formulirana v obliko odgovarjanja na vprašanja (npr. strojno prevajanje se lahko preoblikuje v obliko vprašanja: Kakšen je prevod X v angleščini?, prav tako se lahko sentimentalna analiza: Kaj je pomen X?). V takih primerih odgovarjanje na vprašanja postane naloga in format hkrati, kar pomeni, da vprašanja predstavljajo le način, kako stroju predstaviti specifično nalogo (Gardner in drugi, 2019). Formati odgovarjanja na vprašanja so pomembni za izboljšanje podpore uporabnikom, virtualno asistenco in brskalnike, saj nam omogočajo izpis natančnih in ustreznih odgovorov na njihova vprašanja (Van Otten, 2023). V MOV so vse te naloge uporabne pri analizi dokumentov in prepoznavanju njihovih vzorcev (Zadgaonkar in Agrawal, 2021), optimizaciji številnih operacij, analizi trgov in podpori uporabnikom (RevolveAI, 2025), analizi povratnih informacij strank (Wood, 2025) ter napovedovanje potreb po vzdrževanju (Mah in drugi, 2022).

Veliki jezikovni modeli (angl. large language model) delujejo tako, da med obdelavo teksta prepoznajo in identificirajo odnose med posameznimi besedami ne glede na pozicijo v besedilu. To je mogoče s postopkom predučjenja (angl. pre-training). Modelu je omogočen dostop do ogromne količine podatkov, po navadi internetnih baz, iz katerih si pridobi splošno razumevanje jezika. To znanje je nato mogoče usmeriti v specifične, prej omenjene naloge procesiranja naravnega jezika. Ti modeli so uporabni za številne naloge, kot so pisanje besedil, programiranje, povzemanje itd. Prednost velikih jezikovnih modelov leži v hitri prilagoditvi novega znanja v svoje delovanje. Ti modeli so popularni pri izdelavi AI-agentov, kot so ChatGPT, Copilot in drugi (Kasneci in drugi, 2023).

Pomanjkljivosti procesiranja naravnega jezika sta slaba reprezentacija različnih jezikov in dialektov ter težave na področju pojasnjevanja in razlaganja. To je poudarjeno v industrijah, kjer imajo lahko odločitve vezane na interpretacijo s pomočjo NLP-tehnologij velike

posledice (medicina in finance) (Rudin, 2019). S stalnim razvojem NLP-tehnologij te postajajo vedno bolj dovršene, pri čemer se pojavlja z etično vprašanjem potencialne pristranskosti. Zagotoviti je treba, da so NLP-tehnologije pregledne in njihova uporaba odgovorna (Mehrebi in drugi, 2021). Pogost vzrok težav je kompleksnost sodobnih oskrbovalnih verig. Uporaba nalog, prilagojenih reševanju specifičnih procesov v oskrbovalni verigi, bi bila bolj natančne in zanesljive (Bender in drugi, 2021).

2.2.3 Internet stvari

Internet stvari (angl. internet of things, v nadaljevanju IoT) se je v svetu pojavil kot transformativen koncept, ki spreminja način povezovanja in upravljanja s svetom okoli nas. Bistvo IoT je povezovanje vsakodnevnih objektov, naprav in senzorjev preko interneta, kar omogoča samostojno pridobivanje in izmenjavo podatkov. Mreža pametnih naprav uporabnikom omogoča nadzora, obdelavo podatkov in boljše sprejemanje odločitev. V kontekstu managementa oskrbovalnih verig internet stvari povečuje učinkovitost verig in operativno učinkovitost ter izboljšuje pregled nad dejavnostmi (Sallam in drugi, 2023).

Arhitektura interneta stvari je sestavljena iz treh plasti. Temeljno ali prvo plast sestavljajo naprave s svojimi senzorji in mikrokontrolerji. Naloga teh naprav je zbiranje in osnovna obdelava podatkov. Drugo plast predstavlja vstopna plast (angl. gateway layer), ki deluje kot most med napravami in zbirnim centrom podatkov. Ta plast se nahaja v platformi v oblaku (angl. cloud platform), kjer se podatki hranijo, analizirajo in obdelujejo. Zadnja plast je aplikacijska plast (angl. application layer), ki uporabnikom zagotavlja vpogled v podatke in omogoča dodatne obdelave. Obdelava podatkov v oblaku je namenjena večjim količinam podatkov, kompleksnim analizam in predvidevanju. V primerih, da so hitri odzivi na podatke iz resničnega sveta ključnega pomena, je obdelava podatkov možna že na napravah v prvi plasti, kar znižuje zamike pri prenosu podatkov med plastmi, vendar omogoča le bolj preproste analize (Sallam in drugi, 2023).

V konceptu interneta stvari se pojavljata dve pomembni lastnosti objektov (Sallam in drugi, 2023):

- sposobnost razširitve in
- interoperabilnost.

Ti dve lastnosti sta ključnega pomena za dolgotrajen uspeh in obstoj IoT-sistemov. Sposobnost razširitve se nanaša na povečanje števila naprav, ki so vključene v sistem. V dinamičnem okolju oskrbovalnih verig je taka prilagodljivost ključnega pomena za uspeh. Interoperabilnost se nanaša na združljivost različnih naprav različnih proizvajalcev. S tem je zagotovljeno, da naprave lahko med seboj učinkovito komunicirajo in da se podatki ne izgubljajo. Cilj je doseči hkratno rast in interoperabilnost brez zmanjšanja varnosti in zanesljivosti (Sallam in drugi, 2023).

Natančno in učinkovito vodenje zalog je ključnega pomena za zadovoljstvo strank in zmanjševanje stroškov. IoT pri vodenju zalog omogoči večji nadzor in višjo preglednost nad skladišči. Za uspešno vodenje se lahko izkoristijo številni senzorji, čipi in druge povezane naprave, ki ves čas sledijo lokaciji in statusu izdelkov skozi celotno oskrbovalno verigo. Podatki, kot so lokacija, stanje in hitrosti prodaje, povečajo preglednost organizacije in nam omogočijo hitrejša prilagoditve. Prednosti IoT pri vodenju zalog so višja vidljivost in natančnost, zniževanje stroškov, predvidevanje povpraševanja, natančnejše izpolnitve naročil itd. Tak sistem je mogoče dopolniti s sistemom avtomatičnega naročanja, kar nam zagotovi optimalne ravni zalog in še dodatno zniža stroške skladiščenja. Prav tako lahko senzorji nadzorujejo temperaturo in vlažnost ter ob odstopanjih od idealnih pogojev o tem pravočasno obvestijo osebe (Rejeb in drugi, 2019).

Sledenje in upravljanje s sredstvi sta temeljni funkciji oskrbovalnih verig, ki sta se po navadi izvajali ročno, kar poveča verjetnost napak in zahteva več časa. Napredki v IoT-tehnologijah, kot so globalni sistemi za določanje pozicije in radio-frekvenčna identifikacija, podjetjem omogočajo sledenje lokacije, statusa in stanja vozil, opreme ali produktov v resničnem času, s čimer dosežejo večjo operativno učinkovitost in si znižujejo stroške. Koristna uporaba je pri vodenju večjega števila vozil, saj je z IoT-tehnologijami mogoče pridobiti vpogled v podatke, kot so lokacija, hitrost, poraba goriva in način vožnje s čimer lahko podjetja izboljšajo varnost in optimizirajo poti. Prav tako so IoT-tehnologije koristne pri nadzoru nad vrednejšimi sredstvi, kot na primer zabojniki. S senzorji je mogoče odpraviti izgubo sredstev, optimizirati izkoriščenje prostora in zmanjšati potrebo po ročnem preverjanju zalog (Haddud in drugi, 2017).

Predvidevanje potrebnega vzdrževanja opreme je bilo prav tako izboljšano s pomočjo IoT-tehnologij. Predstavlja velik korak od tradicionalnih metod vzdrževanja, ko so bila ta opravljena po vnaprej določenih urnikih. Za predvidevanje vzdrževanj se IoT-tehnologije povežejo z ML-modeli in s tem podjetjem omogočajo pravočasno opraviti vzdrževalna dela, kar znižuje pogostost in trajanje izpadov, optimizira delovanje in podaljša življenjsko dobo opreme. Senzorji stalno zbirajo podatke o opremi, kot so stanje, temperatura, vibracije, pritisk in obraba. Te informacije so v realnem času poslane v oblak, kjer jih ML-modeli obdelajo in primerjajo s preteklimi podatki. V primeru odstopanj se posreduje signal vzdrževalnim ekipam, ki lahko pravočasno opravijo vzdrževanja in s tem zmanjšajo izpade (Majeed in Rupasinghe, 2017).

IoT-tehnologije lahko prav tako pomagajo pri trajnostnem razvoju, saj omogočijo nadzor nad porabo različnih virov in skrb za odpadke. Senzorji lahko sledijo porabi vode in energije ter surovih materialov skozi celotno verigo s čimer omogočajo temeljit nadzor. Z analizo podatkov lahko organizacije odkrijejo področja, kjer poraba ni optimalna in uvedejo ustrezne cilje ter ukrepe. IoT omogoča podjetjem preglednost in odgovornost za svoje verige, kar je nujno potrebno pri trajnostnem razvoju. S sledenjem celotni poti produktov lahko organizacije zagotovijo skladnost z vsemi predpisi in etičnimi standardi (Birker in Hartmann, 2020).

Pri implementaciji IoT-tehnologij se podjetja srečujejo z nekaterimi ovirami. Glavni pomisleki se pojavijo pri varnosti in zasebnosti podatkov. Za ustrezno delovanje potrebujejo IoT tehnologije dostop do velike količine podatkov, ki so po navadi občutljive narave. To so lahko stanja zalog, lokacije, podatki o transportu itd. V določenih primerih lahko obdelava takih podatkov podjetja naredi tarče kibernetских napadov, kar vodi do kraje intelektualne lastnine in finančnih izgub. Zato morajo biti baze podatkov ustrezno varovane in morajo slediti vsem regulacijam glede varstva osebnih podatkov (Omitola in Wills, 2018). Pri uvajanju IoT-tehnologij se podjetja pogosto srečujejo s pomisleki glede stroškov in donosnosti naložb. Pri odločanju je treba natančno opredeliti tako vidne kot nevidne koristi, saj lahko le tako opredelijo ovire, kot so zastarelost tehnologije in varnost (Li, 2011). Z dostopom do velike količine podatkov pride izziv obdelave. Vodenje velike količine hitro dostopnih in raznolikih podatkov od podjetij zahteva robustno in razširljivo infrastrukturo, učinkovite načine zbiranja podatkov in napredno obdelavo. S tem se zagotovita doslednost in kakovost. Analiza podatkov prav tako zahteva napredno analitiko in specializirane spretnosti analitikov, da lahko vzdržujejo te modele (Yadav in drugi, 2020). Ovire se pojavijo še pri regulacijah in potrebi po skladnosti z zakoni. Podjetja morajo delovati v skladu s kompleksno mrežo lokalnih, nacionalnih in mednarodnih regulacij, ki skrbijo za varnost podatkov (GDPR in HIPAA). Neskladnost s temi predpisi lahko vodi do visokih kazni (Shah in drugi, 2020).

3 PREDSTAVITEV PODJETJA

V magistrskem delu je za primer študije izbrano eno izmed vodilnih slovenskih podjetij na področju informacijsko-komunikacijske tehnologije (v nadaljevanju IKT). Podjetje je visoko specializirano na področju razvoja in uporabe naprednih informacijsko-komunikacijskih in IoT-tehnologij ter deluje izključno na poslovnem trgu. Svoje rešitve podjetje uspešno trži tako na slovenskem kot tujem trgu. Zaradi kompleksne oskrbovalne verige je podjetje primerno za analizo optimizacije managementa oskrbovalne verige z umetno inteligenco (Izbrano podjetje, 2025). V nadaljevanju bodo predstavljeni podjetje, njegova struktura, poslovne dejavnosti in oskrbovalna veriga, na podlagi česar bo temeljila nadaljnja analiza ter predlogi izboljšav.

3.1 Opis podjetja

Podjetje se je skozi desetletja poslovanja na preteklem jugoslovanskem in sedanjem evropskem trgu prislužilo ugled enega izmed zanesljivejših proizvajalcev telekomunikacijske opreme in izvajalcev IKT-storitev. Uspeh podjetja je že od samega začetka temeljil na močnem internem razvoju in kakovostnem inženiringu, kar je omogočilo rast podjetja skozi različna obdobja njegove zgodovine.

V začetkih enaindvajsetega stoletja je podjetje prepoznalo potrebo po preobrazbi. Pozicijo tradicionalnega proizvajalca strojne opreme je zamenjalo za novo pozicijo ponudnika

celovitih programskih rešitev. Ta preobrazba je bila podprta s širitvijo na evropske trge in trge Bližnjega vzhoda, s čimer je povečalo razpon svojih dejavnosti. Poleg telekomunikacije je vključilo še transport, energetiko, varnost in sodobne IKT-storitve. Ključna prelomnica je bila integracija z vodilnim mednarodnim tehnološkim podjetjem s sedežem v Srednji Evropi. S tem si je zagotovilo dostop do novih trgov in okrepilo svoje zmožnosti razvoja. To ga je znotraj organizacije pozicioniralo kot vodilne ponudnike rešitev na področju IoT in Industrije 4.0 (Izbrano podjetje, 2025).

Vizija podjetja je biti ključni strateški partner drugim organizacijam pri njihovi digitalni preobrazbi in digitalnih potrebah. Poudarek je na ponudbi zanesljive tehnologije in drugih rešitvah za infrastrukturo podjetja. Cilje dosega z razvojem in uvedbo individualno prilagojenih IKT-rešitev, ki strankam omogočajo višjo operativno učinkovitost in konkurenčnost ter izpolnjevanje trajnostnih ciljev podjetja. Uresničitev te vizije je podprta s tremi strateškimi stebri (Izbrano podjetje, 2025):

- Prvi steber predstavlja tehnologija. Konkurenčno prednost na področju tehnologije podjetje ohranja s stalnim vlaganjem v raziskave in razvoj (angl. research and development) novih tehnologij.
- Drugi steber predstavlja individualni pristop do strank. Podjetje razvija individualno prilagojene rešitve za svoje stranke, kar strankam omogoča boljše poslovanje.
- Tretji steber, ki je ključen za obravnavano temo magistrskega dela, je operativna odličnost. Podjetje stalno strmi k izboljšanju notranjih procesov in managementa oskrbovalne verige, kar vodi k višji agilnosti in učinkovitosti poslovanja.

3.1.1 Ponudba rešitev

Podjetje na trgu posluje izključno z drugimi podjetji in ne končnimi potrošniki. Njihova ponudba rešitev se deli na tri segmente (Izbrano podjetje, 2025):

- V prvem segmentu so zgodovinsko najpomembnejše rešitve. To so rešitve za telekomunikacijske operaterje, in sicer oprema za širokopasoven dostop do interneta in optična omrežja.
- V drug segment spadajo rešitve za javni in gospodarski sektor in zajemajo digitalizacijo poslovanja pri transportu, energetiki in javni varnosti. Sem spadajo rešitve za komunikacije, pametna omrežja in mesta.
- V tretji segment spadajo IoT-rešitve in velika izbira IKT-storitev. Tu podjetje razvija lastne rešitve za obdelavo podatkov v industrijskem okolju in jih dopolnjuje s storitvami, kot so integracija sistemov, svetovanje, vodenje projektov in vzdrževanje sistemov skozi celoten življenjski cikel. Značilnost tega segmenta je, da so rešitve sestavljene iz lastno razvitih komponent ter tuje strojne opreme. To lahko predstavlja velik izziv za management oskrbovalne verige, saj je treba usklajevati tempo lastnega razvoja in dobavo tujih komponent.

3.1.2 Organizacijska struktura

Organizacijska struktura podjetja je prilagojena dejavnostim in strateškim ciljem in je matrična. To pomeni, da so zaposleni na delovnih mestih razporejeni glede na področja dela, poslovne enote in tržne segmente. Ključne vloge posameznih oddelkov so potrebne za razumevanje managementa oskrbovalnih verig. Oddelek za raziskave in razvoj je zadolžen za pripravo novih idej in produktov. Prav tako sodeluje pri izbiri in nabavi novih komponent. Oddelek za nabavo je ključnega pomena, saj je odgovoren za urejanje odnosov z dobavitelji, izbiro materialov in programske opreme ter kupljenih storitev. V proizvodnji se izdelujejo in testirajo produkti, načrtujejo procesi in izvajajo testi kakovosti. Oddelek za logistiko skrbi za optimizacijo zalog. Skrbi za vse od prevzema materialov do distribucije končnih izdelkov. Oddelek za prodajo in marketing skrbi za predvidevanje povpraševanja in upravljanje z naročili. Vse oddelke med seboj povezuje oddelek za informacijske tehnologije, ki skrbi za sisteme in programsko opremo, ki jih podjetje uporablja za vodenje vsakodnevnih aktivnosti (Izbrano podjetje, 2025).

3.2 Oskrbovalna veriga podjetja

Posledično je zaradi kompleksne strukture podjetja oskrbovalna veriga zelo razčlenjena. Za lažjo predstavbo jo je mogoče razdeliti na več med seboj povezanih delov kar je prikazano na sliki 1.

Slika 1: Struktura oskrbovalne verige podjetja



Vir: lastno delo na podlagi Izbrano podjetje (2025).

Prvi del predstavlja nabavna veriga. Ta je zadolžena za dobavo potrebnih materialov od številnih dobaviteljev iz celega sveta. V to je vključena dobava polprevodnikov, tiskanih vezij in drugih delov, potrebnih za sestavo in integracijo rešitev pri naročnikih. Pri tem je sodelovanje z dobavitelji zaradi dolgih dobavnih rokov in stalnih sprememb na trgu lahko zelo zahtevno. Informacije se v verigi prenašajo prek sistemov za načrtovanje virov in neposredne komunikacije. Med glavne izzive v tem delu verige sodijo upravljanje tveganj, zalog in zagotavljanje kakovosti.

Drugi del zajema vse interne procese podjetja, od skladiščenja do začetka distribucijskih postopkov. Glede na napovedano povpraševanje se ustvari načrt proizvodnje, ki usklajuje materialne zahteve in interne kapacitete. Proizvodni procesi vključujejo pripravo, testiranje in razvoj programske opreme. Upravljanje z zalogami skrbi za zmanjševanje stroškov in hitro odzivnost.

Distribucijski, tretji del, zajema končno dostavo rešitev strankam. Pri bolj kompleksnih rešitvah zajema ta del verige še sistemske integracije in namestitve pri strankah. Distribucija programske opreme pogosto poteka digitalno in vključuje licence ter samodejne posodobitve. Izzivi, ki se pojavljajo v tem delu verige, so optimizacija transporta, zniževanje stroškov in usklajevanje mednarodnega poslovanja. Poleg fizičnega dela verige je v podjetju prisotna še veriga razvoja programske opreme. Usklajevanje razvoja programske opreme z nabavo fizične strojne opreme je ključen strateški izziv podjetja.

3.2.1 Oskrbovalna veriga tretjega segmenta

Glede na širino in kompleksnost nabora produktov in storitev podjetja (poglavje 3.1.1) bi bila analiza oskrbovalnih verig vseh treh segmentov preobsežna. Zato se bo raziskava osredotočila le na oskrbovalno verigo tretjega segmenta: IoT-rešitve in IKT-storitve. Segment je bil izbran, ker predstavlja sodobne izzive v managementu oskrbovalne verige. Je drugačen od ostalih dveh bolj proizvodno usmerjenih segmentov. Oskrbovalna veriga tretjega segmenta ni linearna, temveč je sestavljena iz več prepletenih tokov, ki jih je treba ustrezno usklajevati za vsak projekt (Izbrano podjetje, 2025). Struktura je razvidna iz slike 2.

Slika 2: Tok oskrbovalne verige podjetja



Vir: lastno delo na podlagi Izbrano podjetje (2025).

Oskrbovalna veriga tretjega segmenta se začne s specifičnim naročilom stranke. To naročilo istočasno sproži več procesov. Začne se z materialnim tokom, ki vključuje nabavo komponent, senzorjev ali strojne opreme potrebne za implementacijo rešitev pri naročnikih. Ta proces pogosto spremljajo dolgi dobavni roki in sodelovanje z več različnimi globalnimi partnerji. Produkti pridejo v centralno skladišče, kjer se pojavi izziv upravljanja zalog. Zaloge niso vezane na splošno prodajo, temveč na individualne projekte. Skladiščni procesi v tej točki poskrbijo za dostopnost vseh materialov in komisioniranje blaga. Vzporedno poteka programski tok, ki poskrbi za razvoj in prilagoditev naročene programske opreme. Alokacija kadrov predstavlja tretji vzporedni tok. Ta je potreben za razvoj, integracijo,

uvvedbo in vzdrževanje opreme. Management te verige ima svoje izzive, saj je potrebno usklajevanje dobavnih rokov, razvoja programske opreme in alokacije kadrov. Ta kompleksnost ponuja priložnost za integracijo tehnologij umetne inteligence.

3.2.2 Trenutna uporaba tehnologije in informacijskih sistemov

Tok informacij se začne v fazi prodaje. Pri tem se uporablja Microsoft CRM, ki je program za vodenje odnosov s partnerji v oblaku. Po potrditvi projekta večino bremena prevzame sistem za načrtovanje virov projekta – SAP. Znotraj sistema se izvajajo ključne aktivnosti, kot so nabava, vodenje financ in načrtovanje zalog. Za vodenje projektov, alokacijo ljudi in spremljanje procesov se uporablja RcG Assist. RcG Assist se prav tako uporablja v centru za pomoč uporabnikom. Podatki, ki se pridobijo iz vseh sistemov, se uvozijo in analizirajo v programu PowerBI. To vodstvu nudi podporo pri odločanju in omogoča spremljanje kazalnikov uspešnosti (Izbrano podjetje, 2025).

Kljub močni tehnološki podlagi je uporaba napredne analitike in umetne inteligence v podjetju še v povojih. Analize podatkov, ki se odvijajo v programu PowerBI, so pretežno deskriptivne in bolj usmerjene v diagnostiko. Služijo za pregled nad preteklo uspešnostjo in iskanje vzrokov za odstopanja. V podjetju še ne obstaja formalna strategija za uvedbo umetne inteligence v vse poslovne operacije. Pojavljajo se posamezne pobude za postopno uvajanje umetne inteligence po oddelkih. Ideji, ki se trenutno razvijata, sta (Izbrano podjetje, 2025):

- Uporaba AI-agenta v centru za pomoč uporabnikom. Agent bo sposoben odgovarjati na pogosta vprašanja strank in tako razbremenil del ekipe.
- Uvedba lastno razvitega agenta po tipu »Copilot«. Ta bi služil kot orodje za iskanje dokumentov in pripravo povzetkov po eni celotni interni bazi podatkov. Sposoben naj bi bil pripraviti novo dokumentacijo, s čimer bi se povečala učinkovitost in hitrost prenosa informacij.

4 STOPNJA ZRELOSTI PODJETJA

Kot že omenjeno, ima umetna inteligenca velik vpliv na svetovne industrije. Zato podjetja iščejo strukturirane poti za uvedbo in izboljšanje svojih AI-zmogljivosti. Model zrelosti (angl. artificial intelligence maturity model, v nadaljevanju AIMM) služi kot sistemski pristop ali orodje, ki organizacijam pomaga oceniti trenutno stanje pripravljenosti na uvedbo AI v svoje poslovne procese in jih pri tem usmerja. Ti modeli služijo kot praktični standardi in organizacijam omogočajo kakovostno ali kvantitativno ovrednotenje svojih procesov. Nova podjetja lahko AIMM uporabljajo za prepoznavanje svojih pomanjkljivosti in tista, ki že bolj integrirano umetno inteligenco v svojih poslovnih procesih kot dodatno pomoč pri popolni integraciji umetne inteligence v vse svoje procese (Raghad in drugi, 2021).

AIMM lahko rezultate poda na tri različne načine (Raghad in drugi, 2021):

- kot opise, pri čemer gre le za opis trenutnega stanja podjetja,
- predpise, ki na podlagi že obstoječih smernic predstavijo optimalno pot naprej
- kot primerjavo, pri kateri gre za primerjavo z ostalimi podjetji in standardi v industriji.

Iz literature je razvidno, da je večina modelov zrelosti opisnih. Prednost opisnih modelov je, da se organizacijam omogoči vpogled v pomanjkljivosti in priprava strategij za napredovanje. Modeli zrelosti so sestavljeni iz več dimenzij. Pogosti primeri so strategija podjetja, odnos zaposlenih, tehnologija, dostop do podatkov in vodstvo. Dimenzije se ovrednotijo po stopnjah zrelosti od 1 do 5 (Raghad in drugi, 2021).

AIMM se kljub svoji naraščajoči popularnosti še vedno srečuje z izzivi pri raziskovanju in uporabi. Veliko število zrelostnih modelov je razvitih brez empirične in teoretične podlage. Razlog za to je, da jih razvijajo analitične organizacije za potrebe strank brez akademske podlage. Pomanjkanje validnosti modelov zato postavlja vprašanje, ali so modeli sploh praktično relevantni in natančni pri določanju stopenj zrelosti. Prav tako so številni modeli, ki so dostopni v akademskih bazah podatkov, še nepreizkušeni v resničnem svetu in sledijo modelu »eden za vse« (angl. one-size-fits-all). Posplošeni modeli ne morejo zajeti vseh relevantnih značilnosti različnih industrij, kar jih omejuje (Raghad in drugi, 2021). Ključnega pomena v prihodnosti bo razvoj AIMM, ki bodo jasno zastavili izvedljive cilje podjetjem (Fornasiero in drugi, 2024).


4.1 Razvoj modela

Pri zasnovi modela zrelosti za implementacijo umetne inteligence je bil najprej izveden pregled literature iz tega področja. Izhodišče je predstavljalo delo pregled literature zrelostnih modelov avtorja Gentsch (2018), ki je omogočilo vpogled v najpogostejše uporabljene strukture modelov, dimenzije zrelosti in števila stopenj zrelosti v številnih modelih. Na podlagi referenc iz izhodiščnega dela so bili nato prebrani in preučeni dodatni znanstveni članki te tematike, pri čemer je bila posebna pozornost namenjena člankom, ki obravnavajo uporabo ali razvoj modelov zrelosti v kontekstu managementa oskrbovalnih verig. Primerjalna analiza je omogočila identifikacijo najbolj relevantnih elementov za izbrano podjetje. Tako so bile iz obstoječih pristopov prevzete najbolj relativne dimenzije, stopnje in konceptualni poudarki, ki so se izkazali kot najbolj primerni glede na izzive, okolje in strateške cilje podjetja. Končni model je tako rezultat povezovanja uveljavljenih teoretičnih okvirjev in specifičnega konteksta podjetja. Tako je bila zagotovljena uporabnost modela za oceno trenutnega stanja zrelosti podjetja in načrtovanje nadaljnjega razvoja uporabe umetne inteligence v managementu oskrbovalne verige.

4.2 Model

Za oceno trenutnega stanja stopnje zrelosti na področju MOV v izbranem podjetju je bil v nadaljevanju razvit in pojasnjen AIMM (glej sliko 3). Kot že prej omenjeno, splošni modeli, ki so sestavljeni po principu »eden za vse«, ne zajemajo podrobnosti podjetja, zato je bil ta model specifično razvit za potrebe logistike ter organizacije in managementa v izbranem podjetju. Model je pripravljen po zgledu dostopne literature, ki poudarja pomen večdimenzionalnosti. Model poveže ključne dejavnike uspešnosti, kot so strategija, skrb za podatke, tehnologija in ljudje. Ti dejavniki so povezani s specifičnimi izzivi oskrbovalne verige podjetja. Namen ni le opis trenutnega stanja, temveč tudi podajanje smernice za razvoj v prihodnosti. Model se deli na dimenzije in stopnje zrelosti.

Slika 3: Model stopenj zrelosti



Vir: lastno delo na podlagi Gentsch (2018), Raghad in drugi (2021), Alsheiabni in drugi (2019) in Akbarighatar in drugi (2023).

4.2.1 Stopnje zrelosti

Stopnje zrelosti so pripravljene s pomočjo dostopne literature in so prilagojene individualnim potrebam podjetja. V naslednjem poglavju bodo predstavljene še dimenzije zrelosti, ki bodo ocenjene na petstopenjski lestvici. Končna ocena zrelosti bo podana glede na nadaljnjo klasifikacijo teh stopenj in bo podkrepjena s pomočjo rezultatov ankete, ki je bila razvita v povezavi z modelom. Pet stopenj zrelosti se klasificira na naslednji način:

Na prvi stopnji zrelosti podjetje še nima razvite formalne AI-strategije in kljub zavedanju še ne namenja sredstev za njen razvoj. Dostopni podatki so slabe kakovosti, se ne obdelujejo in so shranjeni na nepovezanih mestih. Obstoječa infrastruktura informacijske tehnologije (v nadaljevanju IT) je zastarela in ne omogoča povezave z novimi tehnologijami. Prav tako

primanjkuje osebja z naprednim tehnološkim znanjem, kar onemogoča uporabo naprednih analitičnih orodij za pomoč pri odločanju.

Na drugi stopnji se začnejo pojavljati posamezne razprave o potencialni uporabi umetne inteligence v podjetju. Vodstvo podpira posamezne, manjše projekte in eksperimentira z uvedbo. Kakovost podatkov ostaja slaba in analize teh podatkov so pretežno opisne. V podjetju se začnejo pojavljati prva namenska orodja za pomoč pri specifičnih izzivih, vendar ta niso standardizirana. V posameznih ekipah se pojavljajo specializirana znanja, vendar podjetje ne vlaga v dodatna izobraževanja zaposlenih.

Tretja stopnja je zaznamovana s pojavom dokumentirane AI-strategije. Vodstvo še ni popolnoma prepričano glede potenciala umetne inteligence v podjetju. V zgodnji fazi razvoja so prvi ključni kazalniki uspešnosti. Sistemi v podjetju so med seboj povezani, kar omogoča prenos podatkov, vendar kakovost podatkov ostaja podpovprečna. Izziv ostaja uporaba teh podatkov za natančno napovedovanje. Poslovna orodja postajajo standardizirana, IT-infrastruktura je zanesljiva in omogoča nadgradnje sistemov. V nekaterih ključnih poslovnih procesih se že uporablja sodobna tehnologija. Zaposleni v podjetju imajo jasno dodeljene vloge in odgovornosti, vse več zaposlenih pri delu razvija specifična znanja.


Četrta stopnja zrelosti zahteva jasno opredeljeno AI-strategijo, ki je popolnoma podprta s strani vodstva. Ključni kazalniki uspešnosti so razviti in se uporabljajo za merjenje uspešnosti podjetja. Podatki so nadpovprečne kakovosti, se primerno shranjujejo in omogočajo napredne napovedne analize. Napredne tehnologije so popolnoma integrirane v vse ključne poslovne procese. IT-infrastruktura ostaja visoko zmogljiva in omogoča dodatno rast ter v realnem času izmenjavo podatkov s partnerji. Podjetje sistematično vlaga v razvoj svojih zaposlenih in širjenje znanja znotraj podjetja.

Na peti stopnji je umetna inteligenca popolnoma integrirana v vse poslovne procese podjetja. AI je gonilo poslovne preobrazbe in inovacij v podjetju ter predstavlja ključno konkurenčno prednost podjetja. Uporaba umetne inteligence se stalno spreminja, nadgrajuje in optimizira. Vodstvo opravlja redne strateške naložbe za uporabo umetne inteligence in tako ohranja vodilno vlogo podjetja na trgu.

4.2.2 Dimenzije zrelosti

Dimenzije zrelosti predstavljajo pet področij podjetja, ki neposredno merijo sposobnost in pripravljenost podjetja na uvedbo umetne inteligence v MOV. Vsaka dimenzija bo glede na prej opisane stopnje dobila svojo oceno, te pa bodo nato združene v enotno oceno celotnega podjetja. Pet dimenzij je predstavljenih na sliki 4.

Slika 4: Dimenzije zrelosti uporabljene v modelu



Vir: lastno delo na podlagi Gentsch (2018), Fornasiero in drugi (2024), Tanajura Ellfefe in drugi (2019) in Raghad in drugi (2021).

Prva dimenzija zajema vizijo in cilje podjetja. Predstavljata vrh organizacijske strukture in preverjata, kako se umetna inteligenca povezuje v strateške cilje in MOV. Pri tem se preverja, ali so vizije in strategije za uvedbo ter uporabo sistemov umetne inteligence usklajene s poslovnimi cilji podjetja. Ta dimenzija je pomembna, saj usklajuje naložbe po vseh ravneh podjetja z njihovimi dolgoročnimi cilji.

Za drugo dimenzijo je bilo izbrano upravljanje s podatki in tehnologijo. Gre za shranjevanje in obdelavo podatkov ter uporabo ustrezne tehnologije, kar služi kot pogoj za učinkovito uvedbo in uporabo tehnologij umetne inteligence. Pri tem se ocenjujejo dostopnost, kakovost in način shranjevanja podatkov ter ustreznost tehnološke infrastrukture. Sposobnost integracije starih sistemov z novimi sistemi umetne inteligence je ključnega pomena.

Tretja dimenzija zajema orodja in sisteme, ki jih uporabljajo v podjetju. Gre za temelj tehnologije, ki se uporablja za analize, obdelave in zbiranje podatkov. Pomembno je, da so sistemi sodobni in dovolj zmogljivi, saj je le tako mogoče zagotoviti nemoteno integracijo s sistemi umetne inteligence. IT-infrastruktura mora biti sposobna obdelave velikih količin podatkov, ki so pomembni za učenje sistemov umetne inteligence. V to dimenzijo sta zajeti interna infrastruktura in povezava z različnimi partnerji v oskrbovalni verigi. Učinkovit pretok informacij med partnerji je ključen za preglednost skozi celotno verigo in njeno optimizacijo.

Četrto dimenzijo predstavljajo organizacija, znanje in procesi v podjetju. Ta dimenzija ocenjuje ljudi, njihova znanja in sposobnost upravljanja z novimi sistemi. Ključnega pomena so vlaganja v izobraževanja, jasno dodeljene vloge in odgovornosti ter postopno uvajanje novih procesov v načine dela. Brez ustrezne podpore s strani vodstva in ustreznega usposabljanja sistemi umetne inteligence sami po sebi ne morejo prinesiti dobrih rezultatov.

Peta dimenzija je vsakodnevna uporaba umetne inteligence in njena operativna vrednost. Gre za praktično uporabo umetne inteligence v vsakdanjih opravilih in vplivih, ki jih ima na

poslovne rezultate. To je dimenzija, ki preverja, kako uspešno podjetje uporablja svoje strateške sposobnosti in tehnologijo za doseganje poslovnih ciljev. Pri tej dimenziji opazujemo uporabo umetne inteligence pri dejavnostih, kot so predvidevanje povpraševanja, optimizacija skladišč in logistike ter vidljivosti celotne verige.

5 EMPIRIČEN DEL

Elektronska anketa je bila razdeljena vsem zaposlenim na področju komercialne, nabave in materialnega poslovanja, razvoja, logistike in skladiščenja ter osebam na vodstvenih pozicijah. Anketa je sestavljena iz treh delov. V prvem delu sta dve uvodni vprašanji, ki se nanašata na delovno mesto in pogostost uporabe specializiranih sistemov in analitičnih orodij pri delu. Drug del je sestavljen iz 19 trditev, ki bodo pomagale oceniti stopnjo zrelosti posameznih dimenzij. Nanje so anketiranci odgovarjali na Likertovi lestvici od 1 do 5. V zadnjem delu se pridobijo še podatke o starosti in spolu zaposlenih. Anketa je bila pripravljena z orodjem Ika in je bila med zaposlene razdeljena po elektronski pošti. Dostop do vseh zaposlenih je bil omogočen s strani kadrovske službe podjetja in dogovora z vodstvom. V podjetju je na prej omenjenih pozicijah zaposlenih med 200 in 250 ljudi, od tega je bilo prejetih 182 polno izpolnjenih vprašalnikov. Nadpovprečno število prejetih odgovorov na anketo je posledica predhodnega dogovora z vodstvom podjetja. Podjetje si aktivno prizadeva najti načine uvedbe umetne inteligence v procese, za kar so si želeli čim bolj natančne rezultate te raziskave. Vsi zaposleni so bili o raziskavi predčasno obveščeni in anketa je bila razdeljena med delovnim časom zaposlenih. Celotni anketni vprašalnik je v prilogi 1. V nadaljnjih poglavjih bodo posamezna vprašanja in trditve individualno predstavljeni ter opisani.

Slika 5: Tabela deskriptivnih statistik trditev anketnega vprašalnika

Dimenzija			Povprečje	Standardni odklon	Modus
Vizija in cilji	Trditev 1	Strategija_vloga_UI	2,65	0,70	3
Vizija in cilji	Trditev 2	Spodbujanje_vodstva	2,41	0,67	2
Vizija in cilji	Trditev 3	Kazalniki_uspesnosti	2,09	0,40	2
Vizija in cilji	Trditev 4	Eticna_tveganja	2,86	0,61	3
Podatki in način analize	Trditev 5	Dostop_do_podatkov	3,86	0,79	4
Podatki in način analize	Trditev 6	Povezanost_sistemov	3,73	0,85	3
Podatki in način analize	Trditev 7	Kakovost_podatkov	2,93	0,81	3
Podatki in način analize	Trditev 8	Napovedovanje_s_podatki	2,82	0,84	3
Orodja in sistemi	Trditev 9	Sodobnost_sistemov	3,52	0,84	3
Orodja in sistemi	Trditev 10	Zmogljivost_IT_infrastrukture	3,36	0,71	3
Orodja in sistemi	Trditev 11	Izmenjava_podatkov_s_partnerji	3,50	0,61	4
Znanje in način dela	Trditev 12	Izobrazevanje_zaposlenih	2,55	0,71	2
Znanje in način dela	Trditev 13	Razumevanje_analiz	3,85	0,69	3
Znanje in način dela	Trditev 14	Jasne_odgovornosti	3,53	0,73	3
Znanje in način dela	Trditev 15	Vkljucevanje_analiz_v_odlocanje	3,41	0,67	3
Uporaba v praksi in konkretni rezultati	Trditev 16	Napovedovanje_povprasevanja	3,34	0,86	4
Uporaba v praksi in konkretni rezultati	Trditev 17	Prepoznavanje_tveganj	3,48	0,59	3
Uporaba v praksi in konkretni rezultati	Trditev 18	Izboljsanje_logistike	3,10	0,90	4
Uporaba v praksi in konkretni rezultati	Trditev 19	Sledenje_posiljk	4,38	0,53	4

Vir: lastno delo.

Iz slike 5 je razvidno, da se povprečne vrednosti odgovorov prve dimenzije nahajajo med 2,09 in 2,86. Najnižje je ocenjena tretja trditev (2,09) in najvišje četrta (2,86). Standardni odklon je najnižji pri tretji trditvi (0,4), kar kaže, da se zaposleni pretežno strinjajo glede te trditve.

Povprečne vrednosti odgovorov druge dimenzije se gibljejo med 2,82 in 3,86. V tem sklopu je bila peta trditev najvišje ocenjena (3,86) in najnižje osma (2,82). Standardni odkloni vseh trditev so višji (med 0,79 in 0,85), kar kaže na višjo raznolikost med odgovori.


Vsa povprečja tretje dimenzije so višja od 3,3. Najvišje je ocenjena deveta trditev (3,52) in najnižje deseta (3,36). Standardni odklon se giblje med 0,61 in 0,84, kar kaže na zmerno porazdelitev odgovorov.

V četrti dimenziji je trditev trinajst najvišje ocenjena (3,85) in najnižje pa ocenjena dvanajsta trditev (2,55). Standardni odkloni se pri vseh trditvah gibljejo okoli 0,70.

Zadnja dimenzija je v povprečju najbolj ocenjena. Najvišjo oceno celotne ankete ima devetnajsta trditev (4,38) in najnižje je v tej dimenziji ocenjena osemnajsta (3,10). Trditev devetnajst ima nizek standardni odklon, kar kaže na pretežno strinjanje med zaposlenimi (0,53). Trditev osemnajst ima standardni odklon 0,90, kar pomeni, da odgovori zaposlenih pri tej trditvi niso tako enotni.

5.1 Uvodna vprašanja

Slika 6: Porazdelitev zaposlenih po delovnih mestih




Vir: lastno delo.

Vprašanje 1: Kateremu od spodnjih področij primarno pripada vaše delo? Iz slike 6 vidimo, da je 66 ljudi zaposlenih v sektorju logistike in skladiščenja, 50 pri razvoju programske

opreme, 29 ljudi je zaposlenih za nabavo in materialno poslovanje, 19 je komercialistov in 18 jih je na vodstvenih položajih.

Vprašanje 2: Ali pri svojem delu uporabljate specializirane sisteme (npr. SAP, RcG Assist) ali analitična orodja (npr. PowerBI) za podporo pri odločanju? Slika 7 pove, da 82 zaposlenih redno uporablja omenjene sisteme, 80 jih uporablja občasno, 18 jih ne uporablja in 2 osebi ne veda, če jih uporabljata pri delu.


Slika 7: Pogostost uporabe specializiranih sistemov in analitičnih orodij



Vir: lastno delo.

5.2 Demografski podatki

Slika 8: Razporeditev zaposlenih po spolu




Vir: lastno delo.

Vprašanje 3: Vaš spol? Slika 8 kaže razporeditev zaposlenih glede na spol. V podjetju je 132 zaposlenih moških, 48 žensk in 2 osebi sta kot spol izbrali opcijo »Drugo« ali se ne želita identificirati. V podjetju prevladujejo moški, kar je značilno za podjetja v tem sektorju.

Vprašanje 4: V katero starostno skupino spadate? Iz slike 9 je razvidno, da ima 12 zaposlenih 25 let ali manj, 74 jih spada v skupino od 26 do 35, 62 zaposlenih je starih med 36 in 45 let, 24 zaposlenih ima med 46 in 55 let ter 10 zaposlenih je starejših od 55 let. Starostna porazdelitev predstavlja sliko podjetja, kjer je večina zaposlenih v svojih najproduktivnejših letih.

Slika 9: Razporeditev po starostnih skupinah



Vir: lastno delo.

Rezultati anketnega vprašalnika omogočajo podrobnejšo interpretacijo in oceno stopnje zrelosti podjetja. Zasnovan vprašalnik neposredno sledi strukturi modela zrelosti, ki je bil predstavljen v poglavju 4.2, in vključuje vse ključne kazalnike dimenzij. Analiza tako omogoča sistematičen pregled in oceno vseh petih dimenzij. S kombinacijo modela in ankete je mogoče podati več kot le končne ocene zrelosti, temveč tudi jasno prepoznati pomanjkljivosti in prednosti podjetja. Na podlagi teh so v naslednjih poglavjih predstavljeni predlogi za nadaljnji razvoj.

Dimenzija »vizija in cilji« predstavlja najšibkejši člen v podjetju in je glavna ovira za napredovanje. Ocena kaže na to, da podjetje nima jasno opredeljene vizije in strateških ciljev. Nizki oceni pri trditvah o kazalnikih uspešnosti (2,09) in vlogi umetne inteligence v poslovni strategiji (2,65) potrjujeta dejstvo, da v podjetju še ne obstaja jasno začrtana strategija za uvedbo umetne inteligence v poslovanje. Nizka ocena pri trditvi o namenjanju sredstev za uvedbo umetne inteligence s strani vodstva (2,41) kaže na to, da zaposleni ne čutijo podpore in pobude s strani vodstva, kar je skladno s pomanjkanjem strateških ciljev.

Kljub temu da se v podjetju pojavljajo iniciative za razvoj rešitev, podprtih z umetno inteligenco, kot sta AI-agenta, te niso del širše strategije. Posamezne ideje o vključevanju umetne inteligence izhajajo iz oddelkov samih in niso del celovitega načrta za prehod. Glede na to je mogoče sklepati, da je podjetje preseglo prvo stopnjo zrelosti in se zaveda potenciala umetne inteligence. Pomanjkanje podpore vodstva in formalne strategije pa segment umeščata na drugo stopnjo zrelosti.

Dimenzija »podatki in način analize« kaže na to, da ima podjetje vzpostavljene osnovne temelje za upravljanje s podatki in njihovo analizo. Razvidne so priložnosti za nadgradnjo, še posebej pri analitiki. Trditvi o dostopu do kakovostnih podatkov (3,86) in povezanosti poslovnih sistemov (3,73) sta višje ocenjeni. To je skladno z dejstvom, da podjetje v svojem poslovanju že uporablja sisteme, kot so SAP in PowerBI. Nižje ocenjeni sta trditvi o kakovosti podatkov (2,93) in izkoriščanju podatkov za napovedovanje (2,82). Ti dve trditvi potrjujeta, da podjetje opravlja svoje analize podatkov, vendar so te pretežno deskriptivne in diagnostične. Iz ocene je razvidno, da ima podjetje urejen dostop do kakovostnih podatkov, vendar jih ne izkorišča v popolnosti. Zaradi tega se ta dimenzija uvršča na tretjo stopnjo zrelosti.

Dimenzijo »orodja in sistemi« se uvršča v tretjo stopnjo zrelosti. Trditev o sodobnosti sistemov (3,52) kaže na to, da trenutni sistemi niso zastareli in so primerni za povezovanje z novimi tehnologijami. Raven tehnologije ne bo predstavljala ovire za nadaljnji razvoj. IT-infrastruktura (3,36) je primerna za trenutne in prihodnje analize. Prav tako je dobro ocenjena trditev o izmenjavi podatkov (3,50), kar je pomembno za kompleksne oskrbovalne verige.

Dimenzija »znanje in način dela« ima svoje pomanjkljivosti. Podobno kot v prejšnji dimenziji ta ocena kaže na to, da obstaja neizkoriščen potencial pri razvoju kadrov. Trditev o znanju, potrebnem za opravljanje analiz (3,85), je v tem sklopu ocenjena najvišje. Vzrok je lahko, da večina ljudi že dela z naprednejšimi sistemi, kot sta SAP in PowerBI. Prav tako sta višje ocenjeni trditvi o dodeljevanju vlog in odgovornosti (3,53) ter o vključevanju rezultatov analiz v procese odločanj (3,41). Najslabše je ocenjena trditev o vlaganju v izobraževanje kadrov (2,55), kar kaže na to, da je znanje zaposlenih pridobljeno individualno in ne kot posledica strateškega razvoja kadrov. To kaže, da ima podjetje številne sposobne posameznike, ki so sposobni dela z novimi tehnologijami, ne vlaga pa se dovolj v nadaljnji razvoj teh ljudi in prenos njihovega znanja na druge. Glede na ugotovitve se dimenzija uvršča v tretjo stopnjo zrelosti.

Dimenzija »praktična uporaba in rezultati« je najvišje ocenjena, kar kaže na to, da podjetje kljub pomanjkljivostim na strateški ravni dosega dobre poslovne rezultate. Prisoten je močan »bottom-up« pristop, ki ustvarja vrednost neposredno v poslovnih procesih. Daleč najboljše je ocenjena trditev o sledenju pošiljk (4,38). Visok rezultat pri tej trditvi je logičen. Podjetje se ukvarja s ponudbo IoT-rešitev in IKT-storitev, kar zahteva usklajevanje nabave materialov, programiranje in logistiko. Visoka preglednost v celotni verigi je pri tem ključna.

Dobro sta ocenjeni trditvi o prepoznavanju tveganj (3,48) in sistemih za napovedovanje povpraševanja (3,34). Trditev o specializiranih sistemih za logistiko je ocenjena najslabše (3,10). Pri tem gre za sisteme, ki lahko pomagajo pri transportu ali vodenju skladišč. To kaže, da je podjetje bolj osredotočeno na preglednost verige kot na iskanje rešitev za optimizacijo logistike. Te po navadi zahtevajo bolj kompleksne rešitve. Na podlagi teh informacij je mogoče dimenzijo uvrstiti v prehodno fazo iz tretje na četrto stopnjo zrelosti.

Glede na zgoraj zapisano je mogoče ugotoviti, da se podjetje nahaja v »prehodni fazi« med tretjo in četrto stopnjo. Podjetje se že oddaljuje od stopnje eksperimentiranja, saj ima trdne tehnološke temelje. Na operativni ravni dosega konkretne rezultate. Prehod na četrto stopnjo, kjer bi bili sistemi umetne inteligence že integrirani v poslovne procese in predstavljali konkurenčno prednost, pa je še oddaljen. Od podjetja bi četrta stopnja zahtevala popoln strateški okvir, aktivno podporo vodstva in več naložb v razvoj kadra. Trenutna največja moč podjetja je inovativnost pri operativnih procesih in največji izziv predstavlja pomanjkanje strateškega vodenja.

V prilogah se nahaja graf (priloga 2), ki vizualizira razlike v povprečnih vrednostih odgovorov glede na posamezna delovna mesta. Iz grafa so razvidne majhne, vendar dosledne razlike med odgovori vodstva in operativnimi oddelki. Te so še posebej opazne pri trditvah o viziji in ciljih. Vzorec podpira ugotovitve, da v podjetju manjka jasno opredeljena in komunicirana strategija za uvedbo AI. Medtem ko vodstvo morda misli, da podpira uvedbo novih tehnologij in širi jasno vizijo, te informacije očitno ne dosežejo operativne ravni. To kaže na slabo komunikacijo in slabo uresničevanje strategij v prakso. Pri trditvah o dostopnosti podatkov in sledljivosti pošiljk so rezultati precej enotni, kar nakazuje, da so IT-infrastruktura, sledljivost pošiljk in dostop do podatkov močna točka podjetja. Soglasje prav tako obstaja pri pomanjkljivostih. Vsi oddelki se strinjajo, da obstaja pomanjkanje pri izobraževanju kadrov, kar le še poudarja idejo o osredotočenosti znanja pri posameznikih in zaviranju potencialnih napredkov v podjetju. Razlike so prav tako vidne pri odgovorih na trditve o napovedovanju povpraševanja in analizah za podporo odločanju. Opazno je, da so ocene višje pri komercialistih kot pri logistiki in nabavi. Razlika se zdi logična, saj komerciala za svoje potrebe prodaje morda ne potrebuje tako naprednih analiz kot logistika in nabava, ki se pri poslovanju srečujeta z zamudami in napačnimi zalogami. To potrjuje, da procesi za analize podatkov v podjetju še niso dovolj integrirani in dovolj napredni za celotno verigo.

Z namenom pridobivanja globljega vpogleda v medsebojne odnose izbranih dimenzij je bila dodatno pripravljena še korelacijska matrika. V prvem koraku je bila za vsakega anketiranca izračunana povprečna vrednost odgovorov po posameznih dimenzijah. Povprečje je bilo uporabljeno, ker se število trditev po posameznih dimenzijah razlikuje. Za izračun korelacij je bil uporabljen Spearmanov koeficient korelacije. Ta je bil izbran, ker so vsi podatki ordinalne narave. Koeficient korelacije je predstavljen na lestvici od -1 do +1. Popolna negativna povezava (-1) pomeni, da se, ko se prva spremenljivka povečuje, druga zmanjšuje

za točno in predvidljivo vrednost. Popolna pozitivna korelacija pomeni ravno obratno. Vrednost 0 pomeni, da spremenljivki nista povezani (Ali Abd Al-Hameed, 2022).

Slika 10: Korelacijska matrika med dimenzijami

Dimenzije	Vizija in cilji	Podatki in način analize	Orodja in sistemi	Znanje in način dela	Uporaba v praksi
Vizija in cilji	1	0,41	0,44	0,41	0,21
Podatki in način analize	0,41	1	0,69	0,64	0,6
Orodja in sistemi	0,44	0,69	1	0,82	0,74
Znanje in način dela	0,41	0,64	0,82	1	0,71
Uporaba v praksi	0,21	0,6	0,74	0,71	1

Vir: lastno delo.

Iz slike 29 je razvidno, da je analiza pokazala pozitivne korelacije med vsemi dimenzijami, kar pomeni, da se napredek v eni dimenziji pozitivno kaže pri drugih.

Dimenziji »orodja in sistemi« ter »znanje in način dela« sta najmočneje povezani (0,82). Zelo močna povezava kaže na tesno povezanost med tehnologijami, ki se uporabljajo v podjetju, in kompetencami zaposlenih. Iz predhodne analize je jasno, da se v podjetju že uporabljajo specializirani sistemi in analitična orodja. Kljub pomanjkanju izobraževanj so zaposleni ocenili, da imajo potrebna znanja za razumevanje analiz. Iz tega je mogoče sklepati, da sodobni sistemi sami po sebi vzpodbujajo širjenje in razvoj znanja, saj so zaposleni zavezani k njihovi uporabi. Prav tako je mogoče sklepati, da lahko zaposleni z višjo ravno znanja lažje izkoriščajo potencial naprednih sistemov.

Visoka korelacija je opazna med dimenzijama »orodja in sistemi« ter »uporaba v praksi« (0,74) in med dimenzijama »znanje in način dela« ter »uporaba v praksi« (0,71). Ti korelaciji potrjujeta, da so orodja in sistemi v povezavi s kompetentnimi zaposlenimi ključni pogoj za uspešno izvajanje operativnih dejavnosti. Iz predhodne analize je razvidno, da je dimenzija o praktični uporabi najvišje ocenjena. Iz tega je mogoče sklepati, da podjetje na področjih, kjer ima podjetje ustrezna znanja in sisteme, dosegata vidne, pozitivne rezultate. Zmogljivost IT-infrastrukture podjetja omogoča uporabo novih tehnologij, kar vodi do boljših rezultatov.

Zmerne korelacije so opazne med dimenzijami »podatki in način analize« ter »orodja in sistemi« (0,69) in med dimenzijama »znanje in način dela« ter »podatki in način analize« (0,64). Tu je poudarjena vloga kakovostnih podatkov kot glavnega gradnika za sprejemanje odločitev in uporabo novih tehnologij. Brez dostopnih in kakovostnih podatkov bi bilo opravljanje številnih nalog nemogoče. Iz teh korelacij je glede na prejšnjo analizo razvidno, zakaj podjetje še ne popolnoma izkorišča sodobnih tehnologij in umetne inteligence. V predhodni analizi je bilo razkrito, da kakovost podatkov in uporaba teh podatkov za napovedovanja nista optimalna.

Šibke korelacije se pojavljajo med dimenzijo »vizija in cilji« ter vsemi drugimi dimenzijami; še posebej šibka je povezava z dimenzijo »uporaba v praksi« (0,21). Te številke potrjujejo

glavno ugotovitev magistrskega dela, ki je, da obstaja razmak med strateško in operativno ravno podjetja. Analiza je razkrila, da v podjetju primanjkuje jasno opredeljene strategije, podpore s strani vodstva in kazalnikov uspešnosti. Iz korelacij je mogoče sklepati, da operativna uspešnost izhaja iz »bottom-up« pobud oddelkov in posameznikov. Pomanjkanje jasne vizije in ciljev predstavlja največjo oviro, saj uspehi posameznih oddelkov ne vodijo v načrtovan napredek podjetja.

6 PREDLOGI ZA IMPLEMENTACIJO UMETNE INTELLIGENCE V MOV

Analiza in interpretacija stopnje zrelosti uporabe umetne inteligence v MOV pri izbranem podjetju, ki sta predstavljeni v prejšnjem poglavju, sta razkrili jasno sliko stanja podjetja glede uvedbe umetne inteligence. V tem poglavju bo zato predstavljen specifičen načrt za nadaljnjo pot podjetja. Predlogi ne bodo le seznam tehnoloških rešitev, temveč bodo predstavljeni kot večstopenski načrt, ki bo zasnovan za dvig stopnje zrelosti podjetja. Načrt bo sestavljen iz treh korakov:

- V prvem koraku bodo obravnavane pomanjkljivosti strateškega okvirja, kot so usmeritev podjetja, merilniki uspešnosti in razvoj kadrov.
- V drugem koraku bodo predstavljeni med seboj povezani projekti, ki bodo usmerjeni v reševanje specifičnih izzivov oskrbovalne verige podjetja in so ključni za napredovanje do četrte stopnje zrelosti.
- V tretjem bo predstavljena še vizija, kako lahko podjetje doseže peto stopnjo zrelosti in začne uporabljati umetno inteligenco kot glavno gonilo poslovne preobrazbe in konkurenčne prednosti.

6.1 Vzpostavitev strateških temeljev podjetja

Iz analize je razvidno, da je največja pomanjkljivost podjetja pomanjkanje strateške usmeritve. Prvi korak za dvig stopnje zrelosti je zato vzpostavitev trdnega strateškega in organizacijskega okvirja. Podjetje brez jasno opredeljene vizije, ustreznih merilnikov uspešnosti in razvoja kadrov ne bo moglo izkoristiti celotnega potenciala sodobnih tehnoloških rešitev. Podani predlogi v nadaljevanju bodo služili kot temelj, na katerem bo podjetje lahko v prihodnosti gradilo svojo vizijo. Ideja o postavitvi trdnih temeljev temelji na pogostih praksah te industrije (Trax Technologies, 2025).

6.1.1 Centralizirano vodstvo in strategija za umetno inteligenco

Razvidno je, da je najšibkejša dimenzija v podjetju »vizija in cilji« s povprečno oceno 2,50. Kot že omenjeno, je vzrok pomanjkanje strategije, podpore vodstva in ključnih kazalnikov uspešnosti. Trenutne AI-pobude so posledice individualnih potreb specifičnih oddelkov in

ne spadajo v širši načrt. Kot baza nadaljnega razvoja bo deloval center odličnosti za umetno inteligenco. Ta bo poskrbel za jasno določene in komunicirane cilje ter vizijo. Center bi predstavljala formalna in centralizirana ekipa podjetja, ki bi izvajala nadzor, strateško usmerjala in pospeševala inovacije na področju umetne inteligence. Center odličnosti bi v izbranem podjetju opravljal štiri glavne naloge:

- Postavitev formalne strategije podjetja – dimenzija »vizija in cilji« se je izkazala za najšibkejšo v podjetju. Center tu rešuje problem z oblikovanjem nove strategije in skrbi za njeno izvajanje. Skrbi za skladnost te strategije z dolgoročnimi cilji podjetja. S tem preprečuje podvajanje dela, uvajanje nesmiselnih rešitev in zapravljanje virov.
- Zbiranje znanja – trenutna situacija nakazuje na specifično osredotočenost znanja pri posameznikih. Center naj bi deloval kot zbirališče znanja, prostor za razvoj znanja in medij za širjenje znanja med zaposlenimi. Vsem zaposlenim bi zagotavljal dostop do potrebnih orodij in podatkov.
- Skrb za varnost in etiko – umetna inteligenca prinaša določena nova tveganja. Center odličnosti bi skrbel, da so tveganja čim manjša in da podjetje sledi celotni zakonodaji. Uporaba umetne inteligence mora biti odgovorna in varna.
- Zagotavljanje poslovne vrednosti – novi projekti morajo biti formalno ocenjeni, saj je le tako mogoče zagotoviti, da so sredstva usmerjena v donosne naložbe. Center bo uvedel merilnike za ocenjevanje novih projektov glede na metrike, kot so donosnost naložb in vplivi na kazalnike uspešnosti.

Glede na pomembno vlogo centra odličnosti za umetno inteligenco mora biti ta sestavljen iz pravih ljudi in biti prepoznan kot ključ do uspeha s strani vodilnih v podjetju. Le tako si lahko zagotovi financiranje in avtoriteto za izvajanje svojih projektov. Vanj morajo biti vključeni ljudje iz ključnih področij podjetja (Curry in drugi, 2021):

- Vodje poslovanja iz ključnih področji MOV, kot so logistika, nabava, raziskave in razvoj ter komerciala. Njihova vključenost poveča možnost prepoznavanja priložnosti za uvedbo umetne inteligence.
- Inženirji, IT-specialisti in podatkovni znanstveniki, ki so sposobni razvoja in uvedbe novih rešitev.
- Pravniki, finančniki in drugi zaposleni, ki skrbijo za skladnost z zakonodajo.
- Predstavniki kadrovske službe, ki izvajajo usposabljanja in obveščajo zaposlene o spremembah v podjetju.

6.1.2 Razvoj pametnih kazalnikov uspešnosti

Iz analize je razvidno, da v podjetju primanjkuje ustreznih kazalnikov uspešnosti. To ga ovira pri vrednotenju vplivov tehnologij in upravljanju s temi tehnologijami (Parmenter, 2015). Trenutne analize s pomočjo orodja PowerBI so opisne in gledajo samo v preteklost, namesto da bi se osredotočale na prihodnost.

Podjetje mora v prihodnosti razviti svoje pametne kazalnike uspešnosti. To so kazalniki, ki s pomočjo umetne inteligence, specifično strojnega učenja, delujejo dinamično, razumejo kontekste in so napovedni ter predpisni. V nadaljevanju bodo predstavljene tri vrste kazalnikov uspešnosti in specifične značilnosti, ki naj bi jih ti merili.

Pametni opisni kazalniki uspešnosti presegajo osnovno prikazovanje števil. Ti so zmožni združevanja različnih podatkov iz več sistemov. Na podlagi teh podatkov podajajo globlje kontekste. Ti kazalniki ne poročajo le, da se je vrednost enega izmed kazalnikov spremenila za X %, ampak pojasnijo še vzrok te spremembe. Primer: Vrednost kazalnika točnosti dobav je padla za 6 % zaradi zamud dobaviteljev in povečanega povpraševanja po produktih (Parmenter, 2015).

Pametni napovedni kazalniki predstavljajo naslednji korak, ki bo podjetju omogočal predvidevanje prihodnosti. Podjetje lahko s strojnem učenjem izkoristi pretekle podatke za napoved prihodnosti. Kazalniki se tu spremenijo in glede na prejšnji primer poročajo o verjetnosti točnosti ali verjetnosti zamud. Primer: Obstaja 88 % verjetnost, da bo pošiljka prišla pravočasno. Kazalniki tako podjetju omogočajo proaktivno ukrepanje ob morebitnih težavah (Parmenter, 2015).

Pametni predpisni kazalniki so cilj pete stopnje zrelosti. S pomočjo naprednih algoritmov in strojnega učenja je mogoče težave predvideti in jih rešiti. Kazalnik uspešnosti je tako sposoben celovitega reševanja problemov. Primer: Čez dva tedna bo zmanjkalo zalog izdelka, zato je treba takoj naročiti nove. Pri popolni integraciji AI v podjetje bi se naročila izvajala samodejno (Parmenter, 2015).

Center odličnosti za umetno inteligenco mora skupaj z oddelki opredeliti specifične kazalnike uspešnosti. V nadaljevanju je pripravljenih nekaj potencialnih primerov (Parmenter, 2015):

- Stopnja popolnih naročil – specifična za posamezne projekte. Zajema pravočasno dostavo, skladnost s proračunom in izdelke brez napak. Kazalnik je namenjen merjenju uspešnosti celotne verige. Nizka vrednost tega kazalnika bi kazala na težave v materialnem toku, programskem toku ali pri razporejanju kadrov.
- Dobavni roki – spremljanje dobavnih rokov. Podjetje se srečuje z nepredvidljivimi dobavnimi roki, zato bi bil tak kazalnik ključen za uspešno usklajevanje vseh treh tokov oskrbovalne verige.
- Tok denarja – čas od plačila materialov do prejema plačila strank. Dolgi denarni toki lahko nepotrebno bremenijo podjetje. Kazalnik podjetju omogoči vpogled v zanesljivost strank in hitrost odvijanja projektov.
- Uspešnost prvega popravila – kazalnik za kakovost in sposobnost serviserjev. Visoka uspešnost popravil je ključna za zadovoljstvo strank in zniževanje stroškov.

- Stopnja izkoriščenosti kadra – kazalnik za merjenje produktivnosti in razporejanja ljudi. Razporejanje človeških virov je eden izmed treh ključnih tokov oskrbovalne verige podjetja. S tem kazalnikom se neposredno meri uspešnost podjetja pri tej nalogi.
- Čas na terenu – kazalnik za optimizacijo logistike, ki meri preživeti čas zaposlenih na poti do strank, delo pri strankah in pot nazaj. Pomemben je pri optimizaciji poti in določanju nalog.
- Točnost, natančnost in pogostost odpoklica modelov – standardizirane vrednosti ocenjevanja klasifikacijskih in napovednih modelov. Podjetje naj bi v svoje procese uvedlo modele strojnega učenja. Te tri metrike so ključne za vrednotenje njihove uspešnosti.
- Število napak napovedi – kazalnik, ki meri odstopanja med napovedanimi in dejanskimi vrednostmi in je koristen pri spremljanju napredka modelov za napovedovanje.
- Odzivni čas AI-sistemov – meri čas, ki ga sistemi umetne inteligence potrebujejo za obdelavo podatkov in predstavitev rezultatov. Za sisteme, ki delujejo v realnem času, je ključen kratek odziven čas. Počasni odzivi zmanjšujejo koristi avtomatizacije.

6.1.3 Razvoj kadrov

Analiza v prejšnjem poglavju je prav tako pokazala pomanjkanje vlaganja v razvoj kadrov. To vodi v osredotočenost znanja pri posameznikih in otežuje širjenje tega znanja med druge zaposlene. Uvajanje umetne inteligence v svoje podjetje predstavlja tehnološki in kulturni izziv. Zaposleni imajo lahko o umetni inteligenci napačne predpostavke. Bojijo se za svoja delovna mesta, ne zaupajo novi tehnologiji in v skrajnih primerih celo sabotirajo nove sisteme (Alhutelh in drugi, 2022). Za reševanje teh izzivov mora center odličnosti izvesti celovit program za razvoj kadrov in upravljanje s spremembami.

Program se mora začeti z jasno komunikacijo vizije in ciljev. S tem bo zaposlenim odgovoril na vprašanje: Zakaj? Jasno mora biti sporočen namen uvedbe umetne inteligence, ki je, da ta tehnologija služi le kot orodje za olajšanje in pospešitev dela. Namen je avtomatizacija ponavljajočih se procesov in drugih nalog nižjih vrednosti. To zaposlenim omogoča posvečanje več časa bolj kompleksnim nalogam, kot so reševanje problemov, strateško odločanje in odnosi s strankami. Pri teh operacijah človeška prisotnost prinaša dodatno vrednost (Shaw in drugi, 2019).

Program za razvoj kadrov mora biti sistematično zastavljen in prilagojen specifičnim oddelkom ter zaposlenim. Osnovno izobraževanje, ki bi ga prejeli vsi zaposleni, bi bilo usposabljanje za povečanje ozaveščenosti o umetni inteligenci. Zajemalo bi osnovno razumevanje tehnologije, njene zmožnosti in omejitve ter vključevanje v podjetje. Bolj specifično usposabljanje bi bilo namenjeno zaposlenim, ki pri delu že uporabljajo umetno inteligenco ali jo bodo uporabljali v prihodnosti. To usposabljanje bi obravnavalo delo z novimi sistemi. Zajeti bi bili interpretacija rezultatov, podajanje povratnih informacij sistemom in možnosti dopolnjevanja rezultatov s svojim znanjem. S tem bi se povečala

zaupanje in povezanost s sistemi umetne inteligence. Pod najvišjo raven usposabljanj bi spadalo strokovno izobraževanje. Namenjeno bi bilo ekipam, ki skrbijo za obdelavo podatkov in IT-oddelku. Udeleženci bi pridobili znanja glede zbiranja in priprave podatkov, vzdrževanja sistemov ter razvoja in uvedbe novih sistemov (Challoumis, 2024).

Vzporedno bi se spodbujal razvoj kulture sodelovanja in rasti, še posebej med poslovno in tehnično stranjo podjetja. Poslovna stran podjetja razume podatke in jih uporablja pri svojem poslovanju, medtem ko tehnična stran skrbi za uporabo ustreznih algoritmov. Povezava med tema področjema zagotavlja razvoj ustreznih poslovnih rešitev, ki so uporabne v praksi (Plotts in Gonzalez, 2024).

6.2 Specifični projekti

Po vzpostavitvi strateškega okvirja se podjetje lahko osredotoči na drugi korak načrta in začne izvajati specifične projekte, ki bodo reševali izzive oskrbovalne verige tretjega segmenta, ki so usklajevanje materialnega in programskega toka ter razporejanja kadrov. Projekti bodo temeljili na obstoječi infrastrukturi in bodo podjetje vodili proti četrti stopnji zrelosti po postavljenih kriterijih.

6.2.1 Napovedovanje povpraševanja

Prvi projekt obravnava izzive, ki se pojavljajo pri materialnem toku oskrbovalne verige. Spremembe bodo temeljile na prehodu iz reaktivnega tipa naročanja materialov na proaktivnega. Rešitev je napovedovanje povpraševanja s strojnimi učenjem. Oskrbovalna veriga tretjega segmenta se sooča s težavo, ki izhaja iz visoke stopnje specifičnosti IoT- in IKT-storitev. Pri tem je izziv natančno predvidevanje povpraševanja specifičnih komponent. V takem primeru tradicionalne metode napovedovanja povpraševanja niso dovolj zanesljive. S strojnimi učenjem je mogoče analizirati in povezati številne odnose med spremenljivkami, kot so številke iz prodaje, pretekla poraba materialov in specifične potrebe projektov. Na podlagi teh spremenljivk je mogoče s pomočjo ML-modelov občutno izboljšati natančnost predvidevanja (Feizabadi, 2020).

Projekt bi bil pripravljen v treh fazah. V prvi fazi bi se zbirali in obdelovali podatke iz trenutno obstoječih sistemov. Iz sistema SAP bi se pridobili podatke, kot so: poraba vseh komponent, naročilnice preteklih projektov, predvideni in dejanski dobavni roki materialov, stanje zalog itd. Iz Microsoft CRM sistema bi se pridobili v prihodnost usmerjeni podatki: potencialni projekti, vrednost projektov, vrste projektov, faze projektov itd. Iz RcG Assista bi se zajeli podatki, kot so tipi projektov in poraba materialov.

V drugi fazi bi bil predstavljen in dokazan koncept novega modela strojnega učenja. Za omejitev tveganj bi v tej fazi bi se začela priprava modela ožjega obsega. Primer bi bil napovedovanje povpraševanja le za eno vrsto materialov. Najprej bi se z uporabo trenutnih

metod napovedovanja vzpostavile izhodiščne vrednosti. Nato bi se razvil model strojnega učenja, ki naj bi bil sposoben preseči natančnost izhodišča. Glede na tip podatkov, ki naj bi se obdelovali, so primerni modeli:

- Prophet – ML-model, ki podatke obdeluje s pomočjo linearne ali logistične regresije (Meta, 2025).
- ARIMA/SARIMA – ML-modela, ki s pomočjo linearne regresije obdelujeta podatke nestacionarnih časovnih vrst (Sirisha in drugi, 2022).
- Modeli nevronske mreže, kot je »Long Short – Term Memory«, ki je še posebej učinkovit pri prepoznavanju dolgoročnih odvisnosti v podatkih (Hochreiter in Schmidhuber, 2012).

V tretji fazi bi bil model uveden v več funkcij napovedovanja. Pri tem je ključno razumevanje, da model ne nadomesti ljudi, temveč jim služi kot orodje za opravljanje napovednih analiz in pripravo natančnejših rezultatov. Nabava in logistika nato ta poročila oplemenitijo še s svojim znanjem, ki ga model morda ne more zajeti. Povezava med ljudmi in stroji tako prinaša najboljše rezultate.

Vplivi tega projekta na ključne kazalnike uspešnosti so: bolj natančne napovedi, zmanjšanje zalog, zmanjšanje zamud zaradi pomanjkanja materialov.

6.2.2 Razporejanje kadrov

Drug projekt obravnava izziv razpoložljivosti kadrov, saj neučinkovita porazdelitev podaljšuje izvajalne čase in stroške. Ročno razporejanje kadrov predstavlja kompleksen kombinatoričen problem. Dejavniki, kot so razpoložljivost, znanje, lokacija in stroški vplivajo na odločanje. Sistemi umetne inteligence lahko ta problem rešujejo hitreje in bolj učinkovito. To prinaša nižje stroške, hitreje dokončane projekte in višjo izkoriščenost kadrov. Ta projekt bo izveden v naslednjih dveh fazah.

V prvi fazi gre za centralizacijo vseh potrebnih podatkov. Potrebno bo ustvariti natančne profile zaposlenih, ki bodo zajemali znanja, izkušnje z različnimi programskimi ali strojnimi opremami, razpoložljivost delavcev, njihove lokacije ter njihovo uspešnost pri preteklih projektih.

V drugi fazi bo uveden model strojnega učenja, ki bi temeljil na metodi linearne regresije, odločitvenih dreves ali nevronske mreže. Ta sistem bo omogočil lažje napovedovanje trajanj nalog, ocenjevanje uspešnosti in izboljšanje kakovosti razporejanja zaposlenih. Ključnega pomena bo, da je sistem prilagodljiv, saj lahko vodstvo tako model prilagaja svojim trenutnim potrebam, na primer zmanjševanje potnih stroškov, zaključevanje nalog ali enakomerno razporejanje kadrov.

Ključne naloge tega AI-sistema bodo:

- Dodeljevanje nalog. Na podlagi vseh dostopnih informacij se bo sistem lahko sam odločil, kdo bo opravljal katero nalogo.
- Dinamično razporejanje. V primerih zamud, odpovedi ali drugih sprememb sistem lahko v realnem času prerazporedi preostale zaposlene tako, da je njihov čas čim bolj izkoriščen.
- Optimizacija poti. Sistem bo prav tako sposoben optimizacije poti, kar pomeni izračun najhitrejših poti, učinkovito razporeditev lokacij, ki jih moramo obiskati, pri čemer se upoštevajo vsi zunanji dejavniki. To vodi v nižjo porabo goriva in preživetega časa na poti.

Kazalniki uspešnosti, na katere bo tak sistem vplival, so: stopnja izkoriščenosti kadrov, uspešnost prvega popravila in čas na poti.

6.2.3 Sistem za obdelavo naravnega jezika

Kot tretji projekt bo pripravljen integriran sistem za obdelavo naravnega jezika. Cilj je priprava podlage za združitev trenutnih idej o AI-agentih v eno platformo. Naloge projekta bodo združevanje podatkov, ljudi in sistemov skozi celotni tretji segment podjetja. Trenutno se v podjetju pojavlja velika količina informacij brez strukturirane oblike. Podatki se pojavljajo v elektronski pošti, telefonskih klicih in drugi dokumentaciji. S pomočjo NLP-tehnologij bo omogočeno razumevanje, povezovanje in dodeljevanje vrednosti teh informacij na enem mestu. NLP-tehnologije bodo omogočile avtomatizacijo številnih administrativnih del in nadgradnjo ter povezovanje vrednosti projektov v poglavju 6.1 ter 6.2.

Pri tem projektu bi se razvil AI-agenta, ki bi bil namenjen podpori strankam in bi se povezoval z že obstoječimi sistemi, kot je RcG Assist. Primarna naloga bi bila analiza listkov (angl. ticket) strank z njihovimi težavami. Ob prijavi težave bi agent samodejno analiziral vsebino glede na ključne besede, kontekst in opravil sentimentno analizo. Prijavo bi nato klasificiral glede na vrsto problema (napaka v programski ali strojni opreми) in ji dodelil nujnost glede na ton sporočila (nevtrálnost, jeza). Agent temelji na specifičnih nalogah procesiranja naravnega jezika. Klasifikacija besedil služi kot naloga za določanje tipov problema, sentimentna analiza pomaga razumeti ton besedila ter prepoznavanje imenovanih entitet omogoča hitre izvlečke ključnih informacij (imena produktov, kode napak) (Agarwal in drugi,).

Po klasifikaciji besedila bi se prijava samodejno posredovala sistemu za razporejanje kadrov (poglavje 6.2.2). Glede na pridobljeno klasifikacijo nujnosti se lahko tu nalogo dodelimo ustreznim zaposlenim s potrebnim znanjem in dostopnostjo. S to povezavo se vzpostavi samodejna, neprekinjena pot od prijave do dodelitve tehnikov.

Razvit AI-agent bo lahko deloval še kot asistent. Uporaba bo možna tako za stranke kot za zaposlene. Na postavljena vprašanja bo agent sposoben odgovoriti s pomočjo celotne interne

baze podatkov, do katere bo imel dostop. Baza bo vključevala navodila, načine reševanja preteklih problemov in drugo relevantno dokumentacijo, kar strankam in zaposlenim omogoči hitrejši dostop do potrebnih informacij in posledično hitrejše reševanje problemov (Manseau, 2020).

Prav tako bo naloga agenta izboljšati delovanje nabavnega oddelka. AI-agent bo imel dostop do vseh sedanjih in prihodnjih partnerskih pogodb in jih bo sposoben sam analizirati. Iz njih bo sposoben prebrati vse ključne informacije, kot so datumi veljavnosti, pogoji plačil, obveznosti podpisnikov, storitve, ki naj bi bile opravljene, kazni za zamude itd. in jih analizirati. Ti podatki bodo nato zbrani v enotno bazo podatkov, ki bo dostopna vsem zaposlenim s pooblastili. AI-agent bo prav tako sposoben prepoznavanja tveganj in zagotavljanja skladnosti pogodb. S pomočjo predhodnih primerov standardnih pogodb bo tak model sposoben prepoznati nestandardne, dvoumne člene ali člene, ki prinašajo visoka tveganja. Sam bo sposoben prepoznati datume in dobavne roke ter o njih obveščati ustrezne oddelke. S tem se zmanjša verjetnost zamud pri podaljševanju in izboljša njihova skladnost. To je mogoče z nalogami prepoznavanja imenovanih entitet, iskanja ključnih besed in modeliranja vsebin (Linarelli, 2019).

Vpliv takega sistema bo izražen v višji uspešnosti prvih popravil in izkoriščenosti kadrov, zmanjšanju odzivnih časov, zmanjšanju časa pregledovanja pogodb, odpravi napak pri obnavljanju pogodb, možnosti prihrankov in odpravi visokih tveganj.

6.3 Kontrolni stolp z umetno inteligenco

Za doseg zadnje, pete stopnje zrelosti bo potrebna popolna preobrazba, kjer bo umetna inteligenca popolnoma integrirana v vse dele podjetja. Ne gre več za optimizacijo obstoječih projektov, temveč za popolno prenovu poslovnega okolja. Vzpostavljeno mora biti novo, dinamično okolje, kjer lahko umetna inteligenca služi kot vir konkurenčnih prednosti. Projekti, predstavljeni v prejšnjih korakih, so nujni gradniki za doseganje tega cilja. V nadaljevanju bo predstavljena ideja, kako lahko izbrano podjetje doseže to peto stopnjo.

Ideja za doseg pete stopnje bo postopen prehod k razvoju kontrolnega stolpa za management oskrbovalne verige. Z njim bo upravljal AI-agent in bo deloval kot aktivni center za nadzor nad celotno oskrbovalno verigo podjetja. Stolp podjetju omogoča popolno preglednost nad vsemi procesi, natančnejše predvidevanje in hiter pretok informacij med posameznimi deli verige. Stolp bo povezal vse prej omenjene projekte, ki jih je podjetje moralo razviti in uvesti za doseg četrte stopnje zrelosti. Z razvojem kontrolnega stolpa se podjetje premika iz reaktivnega sprejemanja odločitev k popolni avtomatizaciji. AI-agent znotraj stolpa bo sposoben samodejno usklajevati vse tri tokove oskrbovalne verige in predvidevati njihove motnje (Patsavellas in drugi, 2021). Razvoj kontrolnega stolpa bo v podjetju potekal v štirih fazah. V prvi fazi bo zagotovljena popolna vidljivost podatkov iz celotnega podjetja. V drugi fazi se bodo v stolp integrirali napovedni modeli. V tretji fazi bo AI-agent, razvit v poglavju

6.2.3, prevzel še dodatno vlogo podpore pri odločanju in v zadnji. V zadnji četrti fazi bo AI-agent sposoben avtonomnega delovanja v infrastrukturi kontrolnega stolpa (glej sliko 30).

Slika 11: Štiri faze razvoja kontrolnega stolpa za umetno inteligenco



Vir: lastno delo.

6.3.1 Popolna vidljivost podatkov

Prva faza predstavlja temelj delovanja kontrolnega stolpa. Združuje vse podatke iz že obstoječih in novih sistemov v eno samo bazo ter vključuje vse informacije iz vseh treh obstoječih tokov oskrbovalne verige (Vlachos, 2023):

- podatke iz materialnega toka, kot so naročila novih komponent, dobavni roki, stanje zalog, transport, potencialne reklamacije itd.
- podatke iz programskega toka, kot so stanje razvoja novih produktov, programske opreme, zaključne roke, porabljene vire itd.
- podatke iz toka usklajevanja človeških virov, kot so razpoložljivost inženirjev, trenutne naloge, trenutne lokacije, večšine zaposlenih itd.
- druge dodatne informacije iz zunanjega sveta, kot so statusi dobaviteljev, vreme, gostota prometa, cene materialov, spremembe na trgu itd.

Ta faza omogoča celovit vpogled v vse potrebne informacije iz vseh tokov oskrbovalne verige. S pomočjo kontrolnega stolpa je tako zagotovljen nadzor nad celotnim projektom in ne le specifičnim delom verige.

6.3.2 Integracija napovednih modelov

Druga faza v kontrolni stolp poveže vse prej razvite modele strojnega učenja, namenjene napovedovanju prihodnosti. Podatki so tako združeni, kar omogoča bolj natančno, nenehno napovedovanje prihodnih stanj in tveganj podjetja. Vključeni bi bili naslednji modeli:

- model za napovedovanje povpraševanja iz poglavja 6.2.1
- model za razporejanje kadrov iz poglavja 6.2.2
- model za oceno zanesljivosti dobaviteljev
- model za napovedovanje tveganj pri projektih.

Dodatno bi bil razvit model za oceno zanesljivosti dobaviteljev. S pomočjo strojnega učenja bi podjetje analiziralo pretekle podatke glede uspešnosti dobaviteljev, velikosti naročil, razpoložljivosti specifičnih komponent itd. in tako uspelo napovedati morebitne zamude posameznih naročil. Model za napovedovanje tveganj pri projektih bi na podlagi podatkov iz zgornjih modelov in preteklih podatkov o specifičnih projektih s strojnem učenjem omogočal uspešno napovedovanje morebitnih zamud in prekoračitve proračuna.

Z dostopnostjo verjetnostnih napovedi teh modelov lahko podjetje uspešno simulira vplive potencialnih prihodnjih dogodkov. V primeru, da je treba preveriti vpliv zamud pri nabavi novih materialov, je mogoče skozi kontrolni stolp spremeniti vhodne podatke (npr. zamuda pri nabavi) in jih poslati skozi vse modele napovedovanja. Izhodni podatek je tako specifičen za potencialno situacijo in natančno obvešča o možnih zamudah, povečanju stroškov in drugih potencialnih motnjah (von Rueden in drugi, 2020).

6.3.3 Podpora pri odločanju

V tretji fazi se kontrolni stolp preoblikuje iz orodja za predstavljanje podatkov v interaktivni sistem za podporo pri odločanju. To je mogoče z integracijo že prej razvitega AI-agenta, ki v arhitekturi stolpa prevzema vlogo kognitivnega elementa. AI-agenta in kontrolni stolp sta sedaj povezana na naslednji način:

- Kontrolni stolp deluje kot enotni vir vseh preteklih in trenutnih informacij. To AI-agentu omogoča poenoten dostop do vseh podatkov v podjetju. Informacije so agentu dostopne iz projektov prve in druge faze.
- AI-agent deluje na samem vrhu te infrastrukture. Uporabnik lahko svoja vprašanja zastavlja neposredno AI-agentu. Odgovor na vprašanje agent pridobi v štirih korakih. V prvem koraku pregleda celotno bazo podatkov in najde ustrezne podatke. V drugem koraku podatke analizira in ustvari celotno sliko stanja. V tretjem koraku odgovarja na vprašanja. Odgovor vključuje analizo tveganj, simulacijo potencialnih scenarijev in priporočila za ukrepanje, ki so podprta z najdenimi podatki.

AI-agent tako postane partner zaposlenih, ki omogoča interaktivno analizo podatkov in scenarijev. To omogoča bolj natančno strateško odločanje zaposlenih, saj so vse odločitve podprte s podrobnimi analizami vseh relevantnih dejavnikov (Phillips-Wren, 2012).

6.3.4 Popolna avtonomija

To predstavlja sam vrh razvoja kontrolnega stolpa. AI-agent je tu sposoben avtonomnega delovanja znotraj vnaprej določenih okvirjev. AI-agent ni več le svetovalec, temveč prevzame vlogo glavnega izvajalca. Sam opravlja rutinske in operativne naloge:

- samodejno oddajanje nabavnih naročil, skrb za zaloge
- razdeljevanje novih nalog, obveščanje strank o potencialnih zamudah in prilagajanje urnikov
- samostojno ukrepanje v primeru motenj sistema (npr. izguba dobavitelja), kot je iskanje novih dobaviteljev, razporejanje virov in obveščanje ustrezne oseb, s čimer zmanjša negativne posledice.

S tem se razbremenijo zaposleni, saj agent sam opravlja rutinske naloge. Zaposleni se lahko posvečajo bolj kompleksnim nalogam, kot so ohranjanje odnosov z dobavitelji in strankami ter reševanje specifičnih zahtevnih problemov, ki zahtevajo prisotnost ljudi (Candrian in Scherer, 2022).

7 OMEJITVE IN PREDLOGI ZA NADALJNJE RAZISKAVE

Omejitve raziskave izhajajo iz metodoloških pomanjkljivosti. Kljub temu, da je bilo z vprašalnikom pridobljenih kar 182 veljavnih odgovorov, se raziskava sooča s težavo neenakomerne porazdelitve zaposlenih. Iz slike 6 je razvidno, da je delež zaposlenih v logistiki in skladiščenju ter razvoju precej večji kot delež komercialistov in vodstva. Enaka pomanjkljivost se pojavlja pri porazdelitvi glede na spol, ki je razvidna iz slike 8. Te razlike v raziskavi niso naslovljene. Ob bolj poglobljeni analizi bi lahko te razlike vplivale na porazdelitev rezultatov, saj mnenja manjših skupin nimajo enake teže kot mnenja drugih, večjih skupin.

Rezultati prav tako temeljijo na samoporočanju. Čeprav gre za anonimno anketo, so lahko odgovori pristranski. Mnenja zaposlenih o strateških dejavnikih, kot je na primer podpora vodstva, so odvisna od delovnega mesta in ni nujno, da natančno prikazujejo dejansko stanje. Prav tako AIMM kljub utemeljitvi z literaturo, ni bil predhodno veljavnostno preverjen. AIMM, ki je bil uporabljen v tem magistrskem delu, je bil razvit specifično za izbrano podjetje, kar pomeni, da ponovitve raziskave z istim modelom pri drugih podjetjih morda ne bi bile najbolj primerne.

Dodatna pomanjkljivost izhaja iz narave kvantitativne analize. Povprečne vrednosti in korelacije med dimenzijami so pokazale jasne trende in uspešno predstavile ključna področja za izboljšave. Kljub temu je z analizo vseh podatkov skupaj morda prišlo do izgube globljega vpogleda. Skupna obdelava vseh podatkov lahko tako zakrije specifične, praktično pomembne izzive med posameznimi oddelki. Izbira kvantitativne analize sicer omogoča odgovarjanje na vprašanje »kaj se dogaja« ne odgovori pa na vprašanje »zakaj se nekaj dogaja«. S tem se izgubi možnost razumevanja, zakaj se pojavljajo razlike med mnenji pri določenih skupinah.

Glede na odkrite pomanjkljivosti raziskave se za nadaljnjo raziskavo priporočata dve smeri:

- Podrobnejša kvantitativna raziskava: izvedba statističnih analiz za odkrivanje pomembnosti razlik pri odgovorih med različnimi delovnimi mesti. S tem bi se natančneje opredelila področja, kjer se pojavljajo razlike, kar bi omogočilo uvedb bolj ciljno usmerjenih ukrepov.
- Kvalitativna raziskava: izvedba intervjujev z vodstvom in drugimi ključnimi kadri. Na podlagi teh podatkov bi bilo mogoče pridobiti globlji vpogled v obstoječe pomanjkljivosti podjetja pri doseganju višje stopnje zrelosti in pridobiti podrobnejši vpogled v kontekst za razlike med različnimi skupinami.

8 SKLEP

V magistrskem delu je obravnavan izziv uvedbe umetne inteligence v management oskrbovalne verige izbranega podjetja. Delo se je osredotočilo na specifične izzive tretjega segmenta podjetja, ki se ukvarja s ponudbo IoT-rešitev in IKT-storitev, pri čemer so bile uspešno prepoznane največje pomanjkljivosti. Pomanjkljivosti so razvidne v odstopanjih med operativno uspešnostjo in pomanjkanjem smernic za uvedbo umetne inteligence v poslovne procese podjetja. Glavni cilj dela je bil tako ugotoviti, kako lahko podjetje s pomočjo uvedbe umetne inteligence odpravi te pomanjkljivosti, oceniti pripravljenost podjetja na to uvedbo in oblikovati načrt za uspešen prehod.

V teoretičnem delu magistrskega dela so bile uspešno prepoznane tehnologije umetne inteligence in ključna področja njihove uporabe. Prepoznana so bila štiri področja, kjer lahko umetna inteligenca ponudi rešitve. V managementu oskrbovalnih verig so ta področja napovedovanje povpraševanja, načrtovanje proizvodnje, upravljanje dobave izdelkov in optimizacija logistike. Te rešitve omogočajo tehnologije, kot so:

- Strojno učenje omogoča natančnejše napovedovanje številnih metrik z analizo preteklih podatkov in s prepoznavanjem skritih vzorcev
- Procesiranje naravnega jezika omogoča obsežne analize dokumentov in gradnjo AI-agentov, kar lahko olajša administrativna dela

- Tehnologije interneta stvari omogočajo sledenje sredstev, predvidevanje potreb po vzdrževanj in optimizacijo logistike.

Teoretični del tako potrjuje, da umetna inteligenca ni le nova tehnologija, temveč služi kot strateško orodje pri optimizaciji celotne oskrbovalne verige.

V osrednjem delu magistrskega dela je bil razvit specifičen model zrelosti. S pomočjo razvitega modela zrelosti in ankete je bilo ugotovljeno, da se podjetje nahaja v prehodni fazi med tretjo in četrto stopnjo zrelosti. Podjetje ima dobro postavljeno tehnološko infrastrukturo in je operativno učinkovito, vendar se spopada s pomanjkanjem strateškega okvirja in podpore pri razvoju kadrov s strani vodstva. Delo dokazuje svojo vrednost z večstopenjskim načrtom za prehod podjetja k višjim stopnjam zrelosti. Načrt zajema tehnološke rešitve in obravnava potrebe po postavitvi novih strateških temeljev, ki bodo v prihodnosti služili kot podlaga pri uvedbi novih sistemov umetne inteligence. Prav tako se ne ustavi le pri doseganju ene višje stopnje zrelosti, temveč poda predloge za doseg zadnje, pete stopnje zrelosti.

Načrt za prehod je sestavljen iz treh delov. V prvem delu je obravnavana postavitve temeljev. Ustanovljen bi bil center odličnosti za umetno inteligenco, ki bi oblikoval strategijo in cilje, pripravil ključne kazalnike uspešnosti, skrbel za razvoj kadrov in centraliziral vodenje prehoda. V drugem delu bi bili izvedeni trije specifični projekti:

- Prvi bi bil razvoj modela strojnega učenja, ki bi podjetju pomagal pri napovedovanju povpraševanja in bil s časom razširjen še na druge napovedne naloge.
- Drugi projekt bi bil razvoj drugega modela strojnega učenja, ki bi optimiziral razporejanje kadrov.
- Tretji projekt bi bil razvoj AI-agent, ki bi podjetju služil kot orodje za dostop do informacij in nadzor nad njimi.

Tretji del prehoda zajema dolgoročno vizijo kontrolnega stolpa, ki bi podjetju omogočil popolno preglednost nad vsemi operacijami, napredno analitiko in postopno popolno avtonomijo procesov. S tem bi podjetje doseglo zadnjo stopnjo zrelosti.

Raziskava te teme je pokazala, da se podjetja pri uvedbi umetne inteligence v poslovne procese srečujejo s kulturnimi, strateškimi in tehnološkimi izzivi. Uspešna uvedba umetne inteligence v management oskrbovalnih verig zajema avtomatizacijo procesov, nadgradnjo načina zbiranja in obdelave podatkov, podporo pri sprejemanju odločitev, optimizacijo vodenja kadrov ter prilagoditev poslovnega modela. Za doseg pete stopnje zrelosti je potrebna celostna preobrazba podjetja.

SEZNAM KLJUČNE LITERATURE

1. Jones, J. (2025, 20. januar). *AI-driven demand forecasting in supply chains: A qualitative analysis of adoption and impact*. [Preprint] <https://www.preprints.org/manuscript/202501.1349/v1>
2. Kavčič, A., Jaklič, J., Indihar Štemberger, M. in Groznik A. (2004). *Prenova in informatizacija poslovanja*. Ekonomska fakulteta Univerze v Ljubljani
3. Mentzer, J. T., De Witt, W., Keebler, J. S., Min, S., Nix, N. W., Zacharia, Z. G. in Smith, C. D. (2001). Defining supply chain management. *Journal of Business Logistics*, 22(2), 1–25. <https://doi.org/10.1002/j.2158-1592.2001.tb00001.x>
4. Mohsen, B. M. (2023). Impact of artificial intelligence on supply chain management Performance. *Journal of Service Science and Management*, 16(1), 44–58. <https://doi.org/10.4236/jssm.2023.161004>
5. Raghad, S. B., Nurhizam, S., Abdul Hadi, R. A. in Shidrokh, G. (2021). Artificial intelligence maturity model: a systematic literature review. *PeerJ Computer Science*, 7, 4–27. <https://doi.org/10.7717/peerj-cs.661>

LITERATURA IN VIRI

1. Agarwal, S., Agarwal, B. in Gupta R. (2022) Chatbots and virtual assistants: a bibliometric analysis. *Library hi tech*, 40(4). <https://doi.org/10.1108/LHT-09-2021-0330>
2. Akbarighatar, P., Pappas, I. in Vassilakopoulou, P. (2023). A sociotechnical perspective for responsible AI maturity models: Findings from a mixed-method literature review. *International Journal of Information Management Data Insights*, 3(2), 100193–100212. <https://doi.org/10.1016/j.jjime.2023.100193>
3. Alegre, U., Augusto, J. C. in Clark, T. (2016). *Engineering context-aware systems and applications: A survey*. Middlesex University.
4. Alhutelh, F. A., Alghubari, H. M., Alyami, H. H., Alyami, A. M., Alalhareth, M. H., Alsaad, K. O. in AL Yami, N. S. (2022). The fear of artificial intelligence among healthcare workers: A narrative review. *Advances in Clinical and Experimental Medicine*, 9(4), 3975–3983.
5. Ali Abd Al-Hameed, K. (2022). Spearman's correlation coefficient in statistical analysis. *International journal of nonlinear analysis and applications*, 13(1), 3249–3255. <http://dx.doi.org/10.22075/ijnaa.2022.6079>

6. Alireza, G., Khademi, Z. H., Tavakkoli, M. R. in Ahmad, S. (2018). A comprehensive model of demand prediction based on hybrid artificial intelligence and metaheuristic algorithms: A case study in dairy industry. *Journal of Industrial and Systems Engineering*, 11(4), 190–203. <https://mp.ra.ub.uni-muenchen.de/101727/>
7. Alsheiabni, S., Cheung, Y. in Messom, C. (2019). Towards an artificial intelligence maturity model: From science fiction to business facts. V *Pacific Asia Conference on Information Systems* (str. 46–55). Association for Information Systems.
8. Baeza Yates, R. (2022). Ethical challenges in AI. V *Proceedings of the fifteenth ACM international conference on web search and data mining* (str. 1–2). ACM. <https://doi.org/10.1145/3488560.3498370>
9. Baryannis, G., Validi, S., Dani, S. in Antoniou, G. (2018). Supply chain risk management and artificial intelligence: state of the art and future research directions. *International Journal of Production Research*, 57(7), 2179–2202. <https://doi.org/10.1080/00207543.2018.1530476>
10. Bender, E. M., Gebru, T., McMillan-Major, A. in Shmitchell, S. (2021). On the dangers of stochastic parrots: Can language models be too big? V *2021 ACM conference on fairness, accountability, and transparency* (str. 610–623). ACM Digital Library. <https://doi.org/10.1145/3442188.3445922>
11. Birker, H. S. in Hartmann, E. (2020). Internet of things - the future of managing supply chain risks. *Supply Chain Management and Logistics*, 25(5), 535–548. <https://doi.org/10.1108/SCM-09-2019-0356>
12. Candrian, C. in Scherer, A. (2022). Rise of the machines: Delegating decisions to autonomous AI. *Computers in Human Behavior*, 134, 107308. <https://doi.org/10.1016/j.chb.2022.107308>
13. Challoumis, C. (2024). The Imperative of skill development in an AI revolution. V *XIX International Scientific Conference* (str. 132–168). Researchgate.
14. Chapman, S. N. (2006). *The fundamentals of production planning and control*. Prentice Hall.
15. Christopher, M. (2016). *Logistics and supply chain management*. Pearson UK.
16. Cuevas, A., Febreco, M. in Fraiman, R. (2004). An anova test for functional data. *Computational Statistics & Data Analysis*, 47(1), 111–122. <https://doi.org/10.1016/j.csda.2003.10.021>

17. Cunningham, P., Cord, M. in Delany, S. J. (2008). Supervised learning. V P. Cunningham, M. Cord in S. J. Delany (ur.), *Machine learning techniques for multimedia: case studies on organization and retrieval* (str. 21–49). Springer.
18. Curry, E., Osagie, E., Pavlopoulou, N., Salwala, D. in Ojo, A. (2021). A best practice framework for centres of excellence in big data and artificial intelligence. V E. Curry, A. Metzger, S. Zillner, J. C. Pazzaglia in A. G. Robles (ur.), *The Elements of Big Data Value* (str. 177–210). Springer.
19. Dressler, T. (2018). *Erfolgreicher einsatz von bedarfsprognosen bei dm - Wie Machine-Learning-Algorithmen bei der Drogeriemarktkette Mehrwert schaffen*. BlueYonder.
20. Elbasheer, M., Longo, F., Nicoletti, L., Padovano, A., Solina, V. in Vetrano, M. (2022). Applications of ML/AI for decision-intensive tasks in production planning and control. *Procedia Computer Science*, 200, 1903–1912. <https://doi.org/10.1016/j.procs.2022.01.391>
21. Ellefsen, A. P., Oleśków-Szłapka, J., Pawłowski, G. in Toboła, A. (2019). Striving for excellence in AI implementation: AI maturity model framework and preliminary research results. *Scientific Journal of Logistics*, 15(3), 363–367. <https://doi.org/10.17270/J.LOG.2019.354>
22. Feizabadi, J. (2020). Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Application*, 25(2), 119–142. <https://doi.org/10.1080/13675567.2020.1803246>
23. Fornasiero, R., Kiebler, L., Falsafi, M. in Sardesai, S. (2024). Proposing a maturity model for assessing artificial intelligence and big data in the process industry. *International Journal of Production Research*, 63(4), 1235–1255. <https://doi.org/10.1080/00207543.2024.2372840>
24. Francis, J. R., Mairose, B. M. in Tichy E. M. (2021). 2020–The Year the World was awakened to the importance of Supply Chain Management. V *Mayo Clinic Proceedings: Innovations, Quality & Outcomes 5.1* (187-192). ScienceDirect. <https://doi.org/10.1016/j.mayocpiqo.2020.10.006>
25. Gaikwad, P. P. (2024). Integration of artificial intelligence in supply chain management: Challenges and opportunities. *MigrationLetters*, 21(4), 989–999.
26. Gardner, M., Berant, J., Hajisharizi, H., Talmor, A. in Min, S. (2019). Question answering is a format; When is it useful?. *arXiv*. <https://doi.org/10.48550/arXiv.1909.11291>

27. Garg, R., Kiwelekar, A. W. in Netak, L. D. (2021). Logistics and Freight Transportation Management: An NLP based Approach for Shipment Tracking. *Pertanika Journal of Science and Technology*, 29(4). <https://doi.org/10.47836/pjst.29.4.28>
28. Gentsch, P. (2018). AI business: framework and maturity model. V P. Gentsch, *AI in marketing, sales and service: How marketers without a data science degree can use AI, big data and bots* (str. 27–78). Springer.
29. Goddard, C. in Schalley, A. C. (2011). Semantic analysis: A practical introduction. V C. Goddard in A. C. Schalley (ur.), *Handbook of natural language processing* (str. 92–120). Taylor & Francis.
30. Haddud, A., DeSouza, A., Khare, A. in Lee, H. (2017). Examining potential benefits and challenges associated with the Internet of Things integration in supply chains. *Journal of Manufacturing Technology Management*, 28(8), 1055–1085. <https://doi.org/10.1108/JMTM-05-2017-0094>
31. Helo, P. in Hao, Y. (2022). Artificial intelligence in operations management and supply chain management: an exploratory case study. *Production Planning & Control*, 33(16), 1573–1590. <https://doi.org/10.1080/09537287.2021.1882690>
32. Hochreiter, S. in Schmidhuber, J. (2012). Long-short term memory. V A. Graves (ur.), *Supervised sequence labelling with recurrent neural networks* (str. 37–45). Springer.
33. Hugos, M. (2018). *Essentials of supply chain management*. John Wiley & Sons.
34. Izbrano podjetje. (2025). *Interni podatki o poslovanju in strukturi podjetja*. Izbrano podjetje.
35. James, G., Witten, D., Hastie, T. in Tibshirani, R. (2023). *An introduction to statistical learning: With applications in Python*. Springer.
36. Jones, J. (2025, 20. januar). *AI-driven demand forecasting in supply chains: A qualitative analysis of adoption and impact*. [Preprint] <https://www.preprints.org/manuscript/202501.1349/v1>
37. Kasneci, E., Seßler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F. in Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
38. Kastrati, Z., Dalipi, F., Imram, A. S., Nuci, K. P. in Wani, M. A. (2021). Sentiment analysis of students' feedback with NLP and deep learning: A systematic mapping study. *Applied Sciences*, 11(9), 3986. <https://doi.org/10.3390/app11093986>

39. Kavčič, A., Jaklič, J., Indihar Štemberger, M. in Groznik A. (2004). *Prenova in informatizacija poslovanja*. Ekonomska fakulteta Univerze v Ljubljani
40. Keller, T., Thiesse, F., Kungl, J. in Fleisch, E. (2012). Using low-level reader data to detect false-positive RFID tag reads. V *2010 Internet of Things (IOT)* (str. 1–8). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/IOT.2010.5678439>
41. Khurana, D., Koli, A., Khatter, K. in Singh, S. (2023). Natural language processing: state of the art, current trends and challenges. *Multimedia tools and applications*, 82(3), 3713–3744. <https://doi.org/10.1007/s11042-022-13428-4>
42. Kumar, M., Agarwal, V. in Agarwal, A. (2022). A Quantification of Supply Chain Management Factors Using Artificial Intelligence. V *International Conference on Advancement in Manufacturing Engineering* (109–116). Springer Nature Singapore. https://doi.org/10.1007/978-981-99-1308-4_9
43. Kusiak, A. (2018). Smart manufacturing. *International Journal of Production research*, 56(1), 508–517. <https://doi.org/10.1080/00207543.2017.1351644>
44. Li, L. (2011). Application of the internet of thing in green agricultural products supply chain management. V *Fourth International Conference on Intelligent Computation Technology and Automation* (str. 1022–1025). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/ICICTA.2011.256>
45. Linarelli, J. (2019). Advanced artificial intelligence and contract. *Uniform Law Review*, 1–25.
46. Mah, P. M., Skalna, I. in Muzam, J. (2022). Natural language processing and artificial intelligence for enterprise management in the era of industry 4.0. *Applied Sciences*, 12(18), 9207. <https://doi.org/10.3390/app12189207>
47. Majeed, A. A. in Rupasinghe, T. D. (2017). Internet of things (IoT) embedded future supply chais for industry 4.0: An assessment from an ERP-based fashon apperal and footwear industry. *International Journal of Supply Chain Management*, 6(1), 25–40.
48. Malviya, P. in Bhandari, V. (2023). A systematic study on effective demand prediction using machine learning. *Journal of Integrated Science & Technology*, 12(1), 711–718.
49. Manseau, J. (2020). AI in the workplace: A qualitative analysis of intelligent employee assistants. V *African Management Sciences International Conference*. AIS eLibrary.
50. Mehrebi, N., Morstatter, F., Saxena, N., Lerman, K. in Galstyan, A. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys*, 54(6), 115–150. <https://doi.org/10.1145/3457607>

51. Mentzer, J. T., De Witt, W., Keebler, J. S., Min, S., Nix, N. W., Zacharia, Z. G. in Smith, C. D. (2001). Defining supply chain management. *Journal of Business Logistics*, 22(2), 1–25. <https://doi.org/10.1002/j.2158-1592.2001.tb00001.x>
52. Meta. (2025, 30. julij). *Prophet*. <https://facebook.github.io/prophet/>
53. Mohsen, B. M. (2023). Impact of artificial intelligence on supply chain management performance. *Journal of Service Science and Management*, 16(1), 44–58. <https://doi.org/10.4236/jssm.2023.161004>
54. Mori, J., Kajikawa, Y., Sakata, I. in Kashima, H. (2010). Predicting customer-supplier relationships using network-based features. V *2010 IEEE International Conference on Industrial Engineering and Engineering Management* (str. 1916–1920). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/IEEM.2010.5674626>
55. Nomoto, T. (2022). Keyword extraction: A modern perspective. *SN Computer Science*, 4(1), 92–111. <https://doi.org/10.1007/s42979-022-01481-7>
56. Omitola, T. in Wills, G. (2018). Towards mapping the security challenges of the internet of things (IoT) supply chain. *Procedia Computer Science*, 126, 441–450. <https://doi.org/10.1016/j.procs.2018.07.278>
57. Parmenter, D. (2015). *Key performance indicators: Developing, implementing, and using winning KPIs*. John Wiley & Sons.
58. Patsavellas, J., Kaur, R. in Salonitis, K. (2021). Supply chain control towers: Technology push or market pull—An assessment tool. *IET Collaborative Intelligent Manufacturing*, 3(3), 290–302. <https://doi.org/10.1049/cim2.12040>
59. Phillips-Wren, G. (2012). AI tools in decision making support systems: a review. *International Journal on Artificial Intelligence Tools*, 21(2), 1240005. <https://doi.org/10.1142/S0218213012400052>
60. Plotts, C. in Gonzalez, L. (2024, 12. februar). *Creating a culture around AI: Thoughts and decision-making*. <https://www.proquest.com/openview/6d02a5dc1d29ccc91b9aea7884e26dc1/1?pq-origsite=gscholar&cbl=7213897>
61. Raghad, S. B., Nurhizam, S., Abdul Hadi, R. A. in Shidrokh, G. (2021). Artificial intelligence maturity model: a systematic literature review. *PeerJ Computer Science*, 7, 4–27. <https://doi.org/10.7717/peerj-cs.661>
62. Razno, M. (2019). Machine learning text classification model with NLP. V *International Conference for Computational Linguistics And Intelligent Systems* (str. 71–73). Kharkiv Polytechnic Institute.

63. Rejeb, A., Keogh, J. G. in Treiblmaier, H. (2019). Leveraging the internet of things and blockchain technology in supply chain management. *Future Internet*, 11(7), 1–22. <https://doi.org/10.3390/fi11070161>
64. RevolveAI. (2025, 25. maj). *Which Industries Are Making the Most of NLP Applications?* <https://revolveai.com/nlp-applications-in-different-industries/>
65. Richey Jr, R. G., Chowdhury, S., Davis-Sramek, B., Giannakis, M. in Dwivedi, Y. K. (2023). Artificial intelligence in logistics and supply chain management: A primer and roadmap for research. *Journal of Business Logistics*, 44(4), 532–549. <https://doi.org/10.1111/jbl.12364>
66. Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206–215. <https://doi.org/10.1038/s42256-019-0048-x>
67. Sallam, K. M., Mohamed, A. W. in Mohamed, M. (2023). Internet of things (IoT) in supply chain management: Challenges, opportunities, and best practices. *Sustainable Machine Intelligence Journal*, 2(2), 1–32. <https://doi.org/10.61185/SMIJ.2023.22103>
68. Shah, S., Bolton, M. in Menon, S. (2020). Study of internet of things (IoT) and its impacts on global supply chains. V *International Conference on Computation, Automation and Knowledge Management* (str. 245–250). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/ICCAKM46823.2020.9051474>
69. Shaw, J., Rudzicz, F., Jamieson, T. in Goldfarb, A. (2019). Artificial intelligence and the implementation challenge. *Journal of medical Internet research*, 21(7). <https://doi.org/10.2196/13659>
70. Singh, N. in Adhiktar, D. (2023). AI in inventory management: Applications, challenges and opportunities. *International Journal for Research in Applied Science and Engineering Technology*, 11(11), 2049–2053. <https://doi.org/10.22214/ijraset.2023.57010>
71. Sirisha, U. M., Belavagi, M. C. in Girija, A. (2022). Profit prediction using ARIMA, SARIMA and LSTM models in time series forecasting: A comparison. *IEEE Access*, 10, 124715–124727. <https://doi.org/10.1109/ACCESS.2022.3224938>
72. Sportiche, D., Koopman, H. in Stabler, E. P. (2013). *An introduction to syntactic analysis and theory*. John Wiley & Sons.
73. Tanajura Ellfese, A. P., Oleśków-Szłapka, J., Pawłowski, G. in Toboła, A. (2019). Striving for excellence in AI implementation: AI maturity model framework and preliminary research results. *Scientific Journal of Logistics*, 15(3), 363–376. <https://doi.org/10.17270/J.LOG.2019.354>

74. Tirkolaei, E. B., Sadeghi, S., Mooseloo, F. M., Vandchali, H. in Amini, S. (2021). Application of machine learning in supply chain management: A comprehensive overview of the main areas. *Mathematics Problems in Engineering, 1*, 1476043. <https://doi.org/10.1155/2021/1476043>
75. Toorajipour, R., Sohrabpour, V., Nazarpour, A., Oghazi, P. in Fischl, M. (2021). Artificial intelligence in supply chain management: A systematic literature review. *Journal of Business Research, 122*, 502–517. <https://doi.org/10.1016/j.jbusres.2020.09.009>
76. Trax Technologies. (2025, 21. julij). *The three-layer AI strategy that actually works for supply chain leaders*. <https://www.traxtech.com/ai-in-supply-chain/the-three-layer-ai-strategy-that-actually-works-for-supply-chain-leaders>
77. Usmani, U. A., Haron, N. S. in Jaafar, J. (2021). A natural language processing approach to mine online reviews using topic modelling. V *International conference on computing science, communication and security* (str. 82–98). Springer. https://doi.org/10.1007/978-3-030-76776-1_6
78. Van Otten, N. (2023, 20. januar). *Top 5 Ways To Implement Question-Answering Systems In Natural Language Processing (NLP)*. <https://medium.com/@neri.vvo/top-5-ways-to-implement-question-answering-systems-in-natural-language-processing-nlp-1440eda3e402>
79. Vlachos, I. (2023). Implementation of an intelligent supply chain control tower: a socio-technical systems case study. *Production planning & control, 34*(15), 1415–1431. <https://doi.org/10.1080/09537287.2021.2015805>
80. Vo, A. D., Nguyen, Q. P. in Ock, C. Y. (2020). Semantic and syntactic analysis in learning and representation based on a sentiment analysis model. *Applied Intelligence, 50*(3), 663–680. <https://doi.org/10.1007/s10489-019-01540-2>
81. von Rueden, L., Mayber, S., Sifa, R., Bauckhage, C. in Garcke, J. (2020). Combining machine learning and simulation to a hybrid modelling approach: Current and future directions. V *International Symposium on Intelligent Data Analysis* (str. 548–560). Springer. https://doi.org/10.1007/978-3-030-44584-3_43
82. Wenzel, H., Smit, D. in Sardesai, S. (2019). A literature review on machine learning in supply chain management. V K. Wolfgang, T. Blecker in C. M. Ringle (ur.), *Artificial intelligence and digital transformation in supply chain management* (str. 414–441). Econstore.

83. Wood, T. (25. maj 2025). *Business uses of natural language processing - the 2024 capabilities of NLP*. <https://fastdatascience.com/natural-language-processing/business-uses-nlp/>
84. Wu-Chih, H., Hsin-Te, W., Hsin-Hung, C. in Fan-Hsun, T. (2020). Optimal route planning systems for logistics vehicles based on artificial intelligence. *Journal of Internet Technology*, 21(3), 757–764. <https://doi.org/10.3966/160792642020052103013>
85. Yadav, S., Garg, D. in Luthra, S. (2020). Analysing challenges for internet of things adoption in agriculture supply chain management. *International Journal of Industrial and Systems Engineers*, 36(1), 73–97. <https://doi.org/10.1504/IJISE.2020.109121>
86. Yampolskiy, R. V. (2016). *Artificial intelligence safety and cybersecurity: A timeline of AI failures*. arXiv. <https://arxiv.org/abs/1610.07997>
87. Zadgaonkar, A. V., & Agrawal, A. J. (2021). An overview of information extraction techniques for legal document analysis and processing. *International Journal of Electrical & Computer Engineering* (2088-8708), 11(6). <https://doi.org/10.11591/ijece.v11i6.pp5450-5457>
88. Zitouni, I. (2014). *Natural language processing of semitic languages*. Springer. <https://doi.org/10.1007/978-3-642-45358-8>

PRILOGE

Priloga 1: Anketni vprašalnik

Pozdravljeni,

sem Marko Vrhovnik, študent Ekonomske fakultete v Ljubljani. V okviru magistrskega dela sodelujem z vodstvom vašega podjetja in pripravljam raziskavo o trenutnem stanju in prihodnjih ciljih na področju umetne inteligence. Anketa v nadaljevanju je sestavljena iz treh delov. Namen raziskave je pridobiti vpogled v strategijo pristopa k umetni inteligenci, razumevanje te tehnologije, odnos zaposlenih ter njene etične vidike. Reševanje vam bo vzelo med 5 in 7 minut.

Anketa je v celoti anonimna in prostovoljna, odgovori pa bodo uporabljeni izključno v namene te raziskave.

V primeru dodatnih vprašanj se lahko obrnete na:

Marko Vrhovnik: marko.vrhovnik00@gmail.com

Kadrovsko službo vašega podjetja

Z nadaljevanjem se strinjate z namenom raziskave in vašim sodelovanjem.

1. UVODNA VPRAŠANJA

Kateremu od spodnjih področij primarno pripada vaše delo?

- Komerciala
- Nabava in materialno poslovanje
- Razvoj programske opreme (R&D)
- Logistika in skladiščenje
- Vodstvo

Ali pri svojem delu uporabljate specializirane sisteme (npr. SAP, RcG Assist) ali analitična orodja (npr. PowerBI) za podporo pri odločanju?

- Da, redno
- Da, občasno
- Ne
- Ne vem

2. OCENA ZRELOSTI UPORABE UMETNE INTELIGENCE V OSKRBOVALNI VERIGI

Za vsako od spodnjih trditev označite, v kolikšni meri po vašem mnenju drži za naše podjetje. Uporabite lestvico od 1 do 5, kjer:

- 1 = Sploh ne drži
- 2 = Večinoma ne drži
- 3 = Delno drži / Niti drži niti ne drži
- 4 = Večinoma drži
- 5 = Popolnoma drži

Vizija in cilji

- Naša poslovna strategija jasno opredeljuje vlogo, ki jo imata obdelava podatkov in umetna inteligenca pri doseganju strateških ciljev oskrbovalne verige.
- Vodstvo aktivno spodbuja in namenja sredstva (finančna, kadrovska) za projekte, ki vključujejo izboljšave delovnih procesov s pomočjo moderne tehnologije.
- Imamo jasno določene kazalnike uspešnosti, s katerimi merimo vpliv tehnoloških rešitev na uspešnost oskrbovalne verige (npr. znižanje stroškov, čas dostave).
- Pri uvajanju novih sistemov sistematično ocenjujemo tudi etična tveganja in vprašanja, povezana z odločitvami, ki jih ti sistemi sprejemajo.

Podatki in kako jih analiziramo

- V podjetju imamo enostaven dostop do zanesljivih in ažurnih podatkov iz različnih delov oskrbovalne verige (npr. podatki o zalogah, transportu, naročilih).
- Podatki iz ključnih poslovnih sistemov (npr. SAP, RcG Assist) so med seboj povezani, kar nam omogoča celovit vpogled v poslovanje.
- Vzpostavljene imamo postopke, ki samodejno skrbijo za kakovost podatkov (npr. preverjanje točnosti, odpravljanje napak), preden se ti uporabijo za analize.
- Uporabljamo analitične sisteme za napovedovanje prihodnjih dogodkov v oskrbovalni verigi (npr. napovedovanje povpraševanja, časov dobav itd.).

Orodja in sistemi

- Naši obstoječi sistemi so dovolj sodobni, da omogočajo povezovanje z drugimi naprednejšimi tehnologijami.
- Naša IT infrastruktura je dovolj zmogljiva za obdelavo velikih količin podatkov.

- S ključnimi partnerji v oskrbovalni verigi (npr. prevozniki, dobavitelji) imamo vzpostavljene učinkovite načine za izmenjavo podatkov.

Znanje in način dela

- V podjetju sistematično vlagamo v izobraževanje zaposlenih za delo z novimi sistemi in tehnologijami.
- Zaposleni na ključnih funkcijah v oskrbovalni verigi imamo dovolj znanja za razumevanje informacij, ki jih dobimo iz analiz podatkov.
- Naše vloge in odgovornosti so jasno opredeljene glede na to, kdo je odgovoren za upravljanje s podatki in kdo za uporabo informacij iz analiz za odločanje.
- Vpogledi, pridobljeni iz analiz, so redno vključeni v procese odločanja.

Uporaba v praksi in konkretni rezultati

- Za napovedovanje povpraševanja uporabljamo napredne sisteme za analize podatkov.
- Sistemi za analize podatkov nam pomagajo pravočasno prepoznavati operativna tveganja (npr. možnost zamud pri dobavi, izpadi opreme).
- Za izboljšanje logističnih procesov (npr. planiranje transportnih poti, razporejanje dela v skladišču) uporabljamo specializirane sisteme.
- Sledimo pošiljkam in materialom skozi ključne faze oskrbovalne verige.

3. DEMOGRAFSKI PODATKI

Vaš spol:


- Moški
- Ženska
- Drugo / Ne želim odgovoriti

V katero starostno skupino spadate?

- Do 25 let
- 26–35 let
- 36–45 let
- 46–55 let
- 56 let ali več

Hvala za vaše sodelovanje.

Priloga 2: Graf primerjave povprečnih ocen trditev glede na delovna mesta



Vir: lastno delo.