

Fakulteta za pravo in ekonomijo
Univerzitetni program Poslovne vede

DIPLOMSKA NALOGA

Adrian Maksimilian Bizjan

Vpliv umetne inteligence na zmanjšanje emisij v avtomobilski
industriji

Diplomska naloga

Mentor: Doc. dr. Simon Starček

Ljubljana, 2024

Zahvala

Iskreno se zahvaljujem svojemu mentorju, doc. dr. Simonu Starčku, za vso pomoč pri izdelavi diplomske naloge in čas, ki mi ga je posvetil. Zahvaljujem se staršema za podporo in nasvete, ter da sta mi omogočila ta študij.

Nalogo pa bi posvetil svojemu dedku, ki mi je v življenju pokazal kakšne so vrednote, ki naredijo dobrega človeka. Sam je zmerom bil pripravljen me razveseliti z zgodbami svoje mladosti ter z njimi podati ključne nasvete ter pomoč za življenje za katere mu bom zmeraj hvaležen in ga bom vedno globoko pogrešal.

UPORABLJENE KRATICE IN OKRAJŠAVE

ANN	umetna nevronska mreža (angl. Artificial Neural Network)
ATSP	asimetrični problem trgovskega potnika (Asymetric Traveling Salesman problem)
AGV	avtonomno vodena vozila (angl. Automatic Guided Vehicle)
ADAS	napredni sistemi za pomoč voznikom (angl. Advanced Driver Assistance Systems)
ABHA	hibridni algoritem na osnovi nevronske mreže (angl. Neural Network based Hybrid Algorithm)
BDP	bruto domači proizvod
CO ₂	ogljikov dioksid
CNN	konvolucijska nevronska mreža (angl. Convolutional Neural Network)
DL	globoko učenje (angl. Deep Learning)
EU	Evropska unija
GAN	generativna naprotniška mreža (angl. Generative Adversarial Network)
GE	General Electric Company
HRES	hibridni sistemi obnovljivih virov energije (angl. Hybrid Renewable Energy Systems)
IoT	internet stvari (angl. Internet of Things)
LiDAR	svetlobno zaznavanje in merjenje (angl. Light Detection and Ranging)
ML	strojno učenje (angl. Machine Learning)
NN	nevronska mreža (angl. Neural Network)
RNN	rekurentna nevronska mreža (angl. Recurrent Neural Network)
UI	umetna inteligenca

Naslov: Vpliv umetne inteligence na zmanjšanje emisij v avtomobilski industriji

Avtor: Adrian Maksimilian Bizjan

Zaradi vse večje zaskrbljenosti zaradi podnebnih sprememb so v središču pozornosti pomembni povzročitelji emisij, kot je avtomobilska industrija. Ta sektor je pretežno odvisen od fosilnih goriv in zato se sooča z dvojnimi izzivi, in sicer z zmanjšanjem ogljičnega odtisa in ohranjanjem dobičkonosnosti. Umetna inteligenca (UI) ponuja obetavne rešitve z analizo obsežnih podatkovnih nizov in sposobnostjo napovedovanja, za izboljšanje varnosti, učinkovitosti in celo razvoj avtonomnih vozil. V tej diplomski nalogi so preučeni trenutni prispevki UI k zmanjšanju emisij in morebitne nadaljnje izboljšave. Razvijajoče se regulativno okolje v Evropski uniji poleg tega kaže na prihajajočo zakonodajo, ki bo prilagojena napredku UI. Z obsežnim pregledom literature, zbiranjem in analizo podatkov ter s študijami primerov bo diplomska naloga poglobila razumevanje stanja in prihodnosti na obravnavanem področju. V diplomski nalogi se osredotočamo na glavne avtomobilske proizvajalce in njihov pristop k zmanjšanju emisij s pomočjo UI. Izvori so lahko vse od avtomobilov samih do njihove proizvodnje, še preden sploh zapeljejo na cesto. Drugi so v transportnem sektorju, kjer velikost vozil in teža njihovega tovora omejujeta klasične pristope k zmanjšanju porabe goriva in posledično tudi emisij. Treba pa je poznati tudi zakonsko podlago, ki je v trenutni rabi, ki bi lahko spodbudila industrijo k večjim spremembam s pomočjo spodbude v obliki subvencij in drugih spodbud, ki so na voljo. Diplomaska naloga želi ozavestiti, da se kljub trenutnim zelenim trendom lahko še veliko stori in da niso potrebne drastične spremembe zakonodaje ali industrije same. Pregled literature, znanstvenih člankov in industrijskih poročil kaže, da lahko UI znatno prispeva k zmanjšanju porabe goriva in posledično zmanjšanju emisij. To je potrdila tudi raziskava, kjer je bilo dokazano, da bi lahko v ZDA prihranili 24,1 milijarde litrov goriv nafte, kar je enako 1,1 % trenutnega njenega uvoza nafte, 2,7 milijarde sodov in 15,3 milijona ton CO₂. Prav tako je raziskava pokazala, da bi lahko z uvedbo nove smeri UI, imenovane zelena umetna inteligenca, zmanjšali proizvodnjo emisij od 13 % do 115 %.

Ključne besede: umetna inteligenca, emisije, avtomobilska industrija, avtonomna vožnja, optimizacija proizvodnje, zmanjšanje porabe goriva, zmanjšanje nepotrebnih odpadkov v industriji

Abstract

Title: The Impact of Artificial Intelligence on Reducing Emissions in the Automotive Industry

Author: Adrian Maksimilian Bizjan

With growing concerns about climate change, major emitters such as the automotive industry are in the spotlight. This sector is dependent on fossil fuels and therefore faces the dual challenge of reducing its carbon footprint and maintaining profitability. Artificial intelligence (AI) offers promising solutions by analyzing and predicting large data sets, improving safety, efficiency and even developing autonomous vehicles. This thesis examines the current contributions of AI to reducing emissions and possible further improvements. The evolving regulatory environment in the European Union also points to upcoming legislation that will be adapted to advances in AI. Through extensive literature review, data collection and analysis, and case studies, the assignment deepened our understanding of the future. In tackling emission reductions, the thesis focuses on the main manufacturers and tries to reduce emissions at their source with the help of AI. The origins can be anything from the cars themselves to their production before they even hit the road. Others are in the transport sector, where the sheer size of vehicles and the weight of their loads limit traditional approaches to reducing fuel consumption and, consequently, emissions. However, it is also necessary to know the legal basis that is currently in use, which could encourage the industry to make major changes by means of incentives in the form of subsidies and other incentives that are available. With this thesis, it is hoped that despite the current green trends, much can be done that would not require drastic changes in legislation or in the industry itself. A review of current literature, scientific articles and industry reports shows that AI can contribute significantly to reducing fuel consumption and consequently reduce emissions. This was made clear in one study where it was shown that the country could save 24.1 billion litres of fuel oil, equivalent to 1.1% of its current oil imports of 2.7 billion barrels and 15.3 million tons of CO₂. It also showed that the introduction of a new direction of AI called “green artificial intelligence” could reduce emissions from 13% to 115%.

Keywords: Artificial intelligence, emissions, automotive industry, autonomous driving, production optimization, reduction of fuel consumption, reduction of unnecessary waste in industry

Vsebina

1.	Uvod	8
1.1	Opredelitev obravnavanega problema in teoretična izhodišča	9
1.2	Raziskovalne metode	10
1.3	Predpostavke in omejitve	11
2.	Avtomobilska industrija	12
2.1	Stanje razvoja v avtomobilski industriji	13
2.2	Umetna inteligenca v avtomobilski industriji	15
2.3	Izboljšanje načrtovanja poti tovornega prometa	16
2.4	Vloga umetne inteligence pri zmanjševanju emisij	22
3.	Umetna inteligenca	27
3.1	Razumevanje delovanja umetne inteligence	32
3.2	Umetna inteligenca in njena uporabnost	33
3.2.1	Umetna inteligenca in optimizacija proizvodnje	37
3.2.2	Pregled zakonodajnih priporočil za uporabo umetne inteligence	40
3.3	Umetna inteligenca in zmanjšanje emisij	42
4.	Analiza izbranih podatkov in ugotovitve	44
4.1	Pregled izbranih podatkov	44
4.2	Vpliv umetne inteligence na zmanjšanje emisij	45
4.3	Ugotovitve študije primera	47
5.	Primerjava količine emisij z in brez uporabe umetne inteligence	49
6.	Sklep	52
7.	Literatura	53

Kazalo slik

Slika 1: Uporaba podatkovnega rudarjenja v prometnem inženirstvu.....	17
Slika 3: Globalni pregled ravnanja s trdnimi odpadki do leta 2050	24
Slika 4: Osnovni elementi nevronske mreže	30
Slika 5: Emisije naftne in naftne industrije po vrednostni verigi in prispevek k svetovnim emisijam	50

1. Uvod

Naraščajoča zaskrbljenost zaradi podnebnih sprememb je v središče pozornosti postavila določene industrije, ki znatno prispevajo k emisijam toplogrednih plinov, med katerimi je avtomobilska industrija eden glavnih dejavnikov. Ta je močno odvisna od fosilnih goriv in se sooča z izzivom zmanjšanja svojega ogljičnega odtisa ob ohranjanju učinkovitosti in donosnosti. Pojav umetne inteligence (UI) ponuja obetavne rešitve za ta kompleksni problem. UI se s svojo zmožnostjo analiziranja ogromnih količin podatkov in napovedovanja vedno pogosteje uporablja v različnih sektorjih za izboljšanje učinkovitosti in reševanje kompleksnih izzivov. V avtomobilski industriji je UI že naredila pomembne korake pri izboljšanju varnosti, povečanju učinkovitosti in celo razvoju avtonomnih vozil, vendar potencial UI za zmanjšanje emisij v tej industriji ostaja relativno neizkoriščen. Namen te diplomske naloge je raziskati, kako je uporaba UI že prispevala k zmanjšanju emisij in kaj lahko še izboljša v avtomobilski industriji. Algoritmi UI, kot je algoritem za avtonomne kolone, se lahko uporabljajo za določanje najučinkovitejših poti za prevoz s tovornjaki, s čimer se zmanjšajo čas potovanja, poraba goriva in posledično emisije. Poleg tega se regulativno okolje razvija, da bi se prilagodilo temu tehnološkemu napredku. Evropska unija (EU) aktivno ustvarja priporočila, ki urejajo uporabo UI v cestnem prometu, kar nakazuje, na novo zakonodajno ureditev na tem področju. S celovitim pregledom literature, zbiranjem in analizo podatkov ter raziskovanjem izbranih primerov, kjer je UI že pripomogla k zmanjšanju izpustov, bo ta diplomska naloga prispevala k boljšemu razumevanju, kako lahko UI prispeva k zmanjševanju izpustov v avtomobilski industriji.

Z nalogo želimo spodbuditi nadaljnje raziskave na tem področju. V naslednjih poglavjih v diplomski nalogi predstavimo trenutno stanje v avtomobilski industriji, vlogo UI na obravnavanem področju in potencial, ki ga lahko UI prispeva k trajnosti v avtomobilski industriji. Predstavimo tudi trenutni regulativni okvir in predviden prihodnji razvoj zakonodaje v zvezi uporabe UI pri zmanjševanju emisij. Diplomska naloga stoji na stičišču tehnologije, trajnosti in politike, njen cilj pa je prispevati k bolj zeleni in trajnostni prihodnosti avtomobilske industrije.

1.1 Opredelitev obravnavanega problema in teoretična izhodišča

Avtomobilska industrija, ena izmed temeljev svetovnega gospodarstva, se sooča s pomembnim izzivom. Kot ena izmed največjih povzročiteljev emisij toplogrednih plinov je pod vse večjim pritiskom zmanjšanja svojega ogljičnega odtisa. Ta pritisk ne prihaja samo od regulativnih organov, ampak tudi od potrošnikov, ki postajajo vse bolj okoljsko ozaveščeni. Vendar velika odvisnost industrije od fosilnih goriv predstavlja veliko oviro pri doseganju tega cilja. Pojav električnih vozil in hibridnih tehnologij je ponudil nekaj rešitev, vendar se tudi te soočajo z vrsto izzivi, vključno z visokimi stroški in infrastrukturnimi zahtevami. Poleg tega te tehnologije še ne morejo v celoti nadomestiti tradicionalnih vozil na fosilna goriva, zlasti v sektorju težkih tovornjakov. Optimizacija transportnih poti predstavlja del rešitve tega problema. Z iskanjem najučinkovitejših poti je mogoče zmanjšati potovalni čas, porabo goriva in posledično emisije. Vendar pa je določanje najučinkovitejših poti kompleksen problem, ki zahteva analizo ogromne količine podatkov in upoštevanje številnih spremenljivk.

UI ponuja obetaven pristop k reševanju tega problema. Algoritmi UI lahko analizirajo velike nabore podatkov in dajejo napovedi, zaradi česar so zelo primerni za iskanje optimalnih poti. Uporaba UI je na tem področju podprta s širšo teorijo digitalne transformacije, ki trdi, da integracija digitalne tehnologije v vsa področja podjetja temeljito spremeni njegovo delovanje in zagotavljanje vrednosti strankam. Vključuje tudi kulturno spremembo, ki od organizacij zahteva, da nenehno izzivajo *status quo* in eksperimentirajo ter uzvajajo proces stalnih izboljšav. Ta teorija je še posebej pomembna za avtomobilsko industrijo, saj si prizadeva za inovacije in prilagajanje izzivom, ki jih prinašajo podnebne spremembe. Poleg tega teorija trajnostnega razvoja podpira potrebo po zmanjšanju emisij v avtomobilski industriji. Ta teorija trdi, da mora razvoj zadovoljiti potrebe sedanjosti, ne da bi ogrozil sposobnost prihodnjih generacij, da zadovoljijo svoje potrebe. V kontekstu avtomobilske industrije to pomeni iskanje načinov za nadaljnje zagotavljanje prevoza ob zmanjšanju njegovega vpliva na okolje.

1.2 Raziskovalne metode

Raziskovalna metodologija za to diplomsko nalogo je zasnovana tako, da okrepi razumevanje, kako lahko uporaba UI prispeva k zmanjšanju emisij v avtomobilski industriji, zlasti z optimizacijo poti tovornega prometa. Metodologija vključuje večstranski pristop, ki združuje pregled obstoječe literature, zbiranje in analizo podatkov ter raziskovanje študije primera.

1.2.1 Pregled literature

Sistematičen pregled literature je temelj te diplomske naloge. Vključuje temeljito preučitev znanstvenih člankov, industrijskih poročil in regulativnih dokumentov, povezanih z uporabo UI v avtomobilski industriji, trajnostjo v industriji in optimizacijo tovornih poti. Pregled literature ima dva glavna namena. Prvič, zagotavlja teoretični okvir za diplomsko nalogo, ki jo opira na obstoječe znanje in teorije. Drugič, identificira vrzeli v trenutni literaturi, ki jih želimo v diplomski nalogi deloma odpraviti.

1.2.2 Zbiranje in analiza podatkov

Zbiranje in analiza podatkov sta ključni sestavini naše naloge. Zbrani podatki vključujejo tako kvantitativne kot kvalitativne podatke. Kvantitativni podatki, kot so ravni emisij in stopnje porabe goriva, zagotavljajo merljive dokaze o vplivu UI na emisije v avtomobilski industriji. Ti podatki so zbrani iz različnih virov, vključno z industrijskimi poročili in znanstvenimi študijami. Po drugi strani pa kvalitativni podatki zagotavljajo globlji vpogled v načine, na katere se UI uporablja v industriji, izzive, s katerimi se sooča, in možne rešitve.

1.2.3 Študije primerov

Študije primerov ponujajo primere iz resničnega sveta, kako se UI uporablja za optimizacijo poti in zmanjšanje emisij. Ponujajo uporaben vpogled v praktične uporabe UI v industriji, izzive, s katerimi se srečujejo, in razvite rešitve. Študije primerov so izbrane glede na njihovo pomembnost za raziskovalna vprašanja in njihov potencial za zagotavljanje pomembnih vpogledov.

1.3 Predpostavke in omejitve

Diplomska naloga temelji na več predpostavkah – hipotezah, in sicer:

H1: Prvič, predpostavlja, da avtomobilska industrija pomembno prispeva k emisijam toplogrednih plinov in da je zmanjšanje teh emisij prednostna naloga industrije in družbe na splošno.

H2: UI lahko prispeva k zmanjšanju emisij toplogrednih plinov, zlasti z optimizacijo poti..

H3: Regulativno okolje se bo še naprej razvijalo, da bi se prilagodilo vse večji uporabi UI v avtomobilski industriji, in da bo v prihodnosti verjetno uvedena nova zakonodaja v zvezi z uporabo UI pri zmanjševanju emisij.

Kakovost podatkov je ključnega pomena za veljavnost izsledkov naše naloge. Poleg tega menimo, da so študije primerov, obravnavane v naši nalogi, reprezentativne za širšo industrijo in da je mogoče vpoglede, pridobljene iz teh študij primerov, posplošiti na druga področja. Kljub uporabljeni strogi raziskovalni metodologiji ima ta naloga več omejitev. Ena glavnih omejitev je hiter razvoj področja UI, zaradi česar je težko zagotoviti, da raziskave temeljijo na najnovejših dognanjih in razvojnih dosežkih. Hitra narava tega področja pogosto prehiteva tradicionalno akademsko založništvo, zaradi česar je težko pridobiti celovite, posodobljene in zanesljive raziskave. Da bi odpravili to omejitev, se ta diplomska naloga ne opira le na akademske članke, temveč vključuje tudi literaturo in ugotovitve večjih podjetij, ki so na čelu razvoja, uporabe in analize UI. Cilj tega pristopa je zagotoviti bolj celovito in natančno razumevanje trenutnega stanja UI v avtomobilski industriji. Določeni viri zaradi zaščite industrijske, intelektualne in poslovne lastnine ter s tem konkurenčne prednosti niso dostopni. Ugotovitve iz teh študij primerov je zato treba razlagati previdno. Čeprav diplomska naloga temelji na več predpostavkah in ima nekatere omejitve, je njen cilj izboljšanje razumevanja potenciala UI za zmanjšanje emisij v avtomobilski industriji.

2. Avtomobilska industrija

Avtomobilska industrija, ki pomembno prispeva k svetovnemu gospodarstvu, je na razpotju. Poročilo Medvladnega odbora za podnebne spremembe (IPCC) navaja, da so se »emisije ogljika v prometni industriji od leta 1990 do leta 2019 postopoma povečevale. Leta 2019 je prometna industrija prispevala 25 % k svetovnim emisijam toplogrednih plinov, kar jo uvršča na drugo mesto med industrijami z največjimi emisijami« (IEA, 2021). Zaradi vse večje zaskrbljenosti zaradi podnebnih sprememb je industrija pod pritiskom zmanjšanja svojega ogljičnega odtisa. Ta izziv je še večji zaradi močne odvisnosti industrije od fosilnih goriv, vendar pa pojav UI ponuja nove možnosti in pristope k reševanju tega kompleksnega problema. UI se s svojo zmožnostjo analiziranja ogromnih količin podatkov in napovedovanja vedno pogosteje uporablja v različnih sektorjih za izboljšanje učinkovitosti in reševanje kompleksnih problemov. V avtomobilski industriji je UI že naredila pomembne korake pri izboljšanju prometne varnosti, povečanju transportne učinkovitosti in celo razvoju avtonomnih vozil (Yifang et al., 2020). Vloga UI pri izboljšanju varnosti je očitna v funkcijah, kot so samodejno zaviranje v sili, opozorila o nenamerni menjavi voznega pasu in prilagodljivem tempomatu. (Kristalnyi et al., 2022) Te funkcije se zanašajo na algoritme UI za analizo podatkov iz različnih senzorjev in sprejemanje odločitev v delu sekunde za preprečevanje nesreč. Po podatkih Globalnega poročila o stanju varnosti v cestnem prometu 2023 (Global status report on road safety 2023). Svetovne zdravstvene organizacije (World Health Organization, 2023) je bilo leta 2023 skupaj po vsem svetu 1,19 milijona smrtnih žrtev v prometnih nesrečah. Evropske komisije (2024) poroča, da je v državah EU leta 2023 v prometnih nesrečah umrlo 20.400 oseb, kar je sicer le 1 % manj kot leta 2022. Pri tem je bilo 52 % smrtnih žrtev na podeželskih cestah in 9 % na avtocestah, med najbolj tveganimi v cestnem prometu ostajajo kolesarji. Evropska komisija opozarja, da le malo članic EU dosega obdobjne cilje za doseg skupnega globalnega dogovora Združenih narodov, da se do leta 2030 prepolovi število smrtnih žrtev in resnih poškodb zaradi prometnih nesreč. Zato bi lahko uporaba rešitev, temelječih na umetni inteligenci, prispevala k povečanju varnosti v prometu (Tselentis, Papadimitriou, van Gelder, 2023; UNECE, 2022).

Na področju učinkovitosti se UI uporablja za optimizacijo proizvodnih procesov, zmanjšanje odpadkov in izboljšanje produktivnosti. (Bonada et al., 2020; Gounis in Bassiliades, 2022). Ti algoritmi lahko analizirajo podatke iz proizvodne linije v realnem času, prepoznajo ozka grla in predlagajo izboljšave. To ne zmanjša le stroškov, ampak tudi vpliv proizvodnega procesa na

okolje. Razvoj avtonomnih vozil je morda najbolj vidna uporaba UI v avtomobilski industriji. (Garikapati in Shetiya, 2024). Avtonomna vozila se pri navigaciji, izogibanju oviram in sprejemanju odločitev zanašajo na UI. Medtem ko popolnoma avtonomna vozila še niso običajna, imajo številna vozila na cestah danes delno avtonomne značilnosti in pričakuje se, da bodo popolnoma avtonomna vozila v prihodnosti postala bolj razširjena. Inštitut za elektrotehniko in elektroniko (IEEE) napoveduje, da bo do leta 2040 75 % avtomobilov avtonomnih, nekateri strokovnjaki menijo, da bi se to lahko zgodilo še prej, medtem ko drugi menijo, da bo trajalo še veliko dlje, preden bodo avtonomna vozila postala običajna. (Russel, Paul, 2015). Vendar potencial UI za zmanjšanje emisij v avtomobilski industriji ostaja relativno neizkoriščen. Eno od področij, na katero bi lahko UI pomembno vplivala, je optimizacija tovornih poti. Z iskanjem najučinkovitejših poti je mogoče zmanjšati potovalni čas, porabo goriva in posledično emisije. Algoritmi UI, kot je algoritem čebeljih kolonij (angl. Artificial Bee Colony - ABC algorithm), so zelo primerni za to nalogo, saj lahko analizirajo velike nabore podatkov in omogočajo napovedi (Bhattacharjee et al., 2011). Integracija UI v avtomobilsko industrijo ni le futurističen koncept, ampak sedanja realnost s pomembnimi posledicami za učinkovitost, varnost in, kar je najpomembneje, trajnost. Da bi v celoti cenili potencial UI pri zmanjševanju emisij, je ključno razumeti trenutno stanje avtomobilske industrije. V naslednjem poglavju se bo osredotočamo na stanje avtomobilske industrije, njene izzive in priložnosti.

2.1 Stanje razvoja v avtomobilski industriji

Avtomobilska industrija je dinamičen in kompleksen sektor, ki ga zaznamujeta hiter tehnološki napredek in spreminjanje zahtev in pričakovanj potrošnikov. To je industrija, ki so jo med drugim oblikovale inovacije, regulacije in tržno povpraševanje. Svetovna proizvodnja avtomobilov je dosegla približno 80 milijonov vozil letno v zadnjih letih. Kitajska je največji proizvajalec avtomobilov na svetu, sledijo ji ZDA, Japonska, Nemčija in Indija. Danes stoji avtomobilska industrija na stičišču tehnologije in trajnosti ter se spopada z izzivom zmanjšanja vpliva na okolje, hkrati pa se trudi še naprej zadovoljevati transportne potrebe družbe. Eden najpomembnejših izzivov, s katerimi se sooča avtomobilska industrija, je njen prispevek k zmanjšanju emisij toplogrednih plinov. Industrija kot velik porabnik fosilnih goriv pomembno prispeva k podnebnim spremembam. To je povzročilo vse večji pritisk vlad, potrošnikov in okoljskih skupin za zmanjšanje emisij. Komisija se je zavezala k sprejemanju ukrepov za

obvladovanje podnebnih in okoljskih izzivov, uzakonjajo zavezanost EU k doseganju cilja podnebne nevtralnosti do leta 2050 in krepitvi vmesnega cilja z določitvijo cilja zmanjšanja neto emisij za vsaj 55 % do leta 2030 v primerjavi z ravnmi iz leta 1990 (Evropski parlament in Svet, 2023). V odgovor je industrija vlagala v čistejša tehnologije, kot so električna in hibridna vozila. Leta 2020 je bilo prodanih približno 3 milijone električnih vozil. Po podatkih Statista (2024) naj bi leta 2024 prihodki na trgu električnih vozil po vsem svetu dosegli 623,3 milijarde ameriških dolarjev. Pri tem se pričakuje, da bo prodaja enot na trgu električnih vozil do leta 2028 dosegla 17,07 milijona enot vozil. Vendar tudi te tehnologije niso brez izzivov, vključno z visokimi stroški, infrastrukturnimi zahtevami in omejitvami dosega. Hkrati industrija doživlja tudi digitalno preobrazbo, ki jo poganja napredek v UI in drugih digitalnih tehnologijah. Tudi zakonodajno okolje se razvija, da bi se prilagodilo tem spremembam. Vlade po vsem svetu uvajajo predpise za zmanjšanje emisij iz vozil, spodbujajo sprejemanje čistejših tehnologij in zagotavljajo varno uporabo UI v vozilih. Ti predpisi krojijo smer industrije in vplivajo na strategije avtomobilskih podjetij. Kljub tem izzivom in spremembam pa avtomobilska industrija ostaja pomemben del svetovnega gospodarstva (Musoumi, Kazemi, Salwa Hanim, 2019). To je panoga, ki ni odgovorna le za proizvodnjo vozil, temveč tudi za zagotavljanje delovnih mest, spodbujanje tehnoloških inovacij in prispevanje h gospodarski rasti. Promet, ki ga ustvari avtomobilski sektor, predstavlja 7 % celotnega BDP EU (ACEA, 2023). Pred temi izzivi in priložnostmi je avtomobilska industrija na razpotju. Odločitve, ki jih sprejema danes, bodo oblikovale njeno prihodnost in pomembno vplivale na okolje. V ospredju so tehnološki izzivi. Medtem ko UI in druge digitalne tehnologije ponujajo ogromen potencial za izboljšanje učinkovitosti in zmanjšanje emisij, njihova implementacija ni brez ovir. Razvoj in integracija sistemov UI v vozila zahteva znatne naložbe v raziskave in razvoj. Poleg tega morajo biti ti sistemi zanesljivi in robustni, da zagotovijo varnost, o kateri se v industriji ne da pogajati. Veliko podatkov, ki se zbirajo v avtomobilski industriji, vsebuje občutljive podatke, zato so potrebni dodatni varnostni ukrepi (APPEN, 2020). Regulativni izzivi prav tako predstavljajo velike ovire. Medtem ko vlade po vsem svetu zaostrejejo emisijske standarde, so avtomobilska podjetja pod pritiskom, da razvijejo in proizvedejo vozila, ki ustrezajo tem strogim predpisom. Hkrati uporaba UI v vozilih odpira nova regulativna vprašanja glede varnosti, zasebnosti in odgovornosti. Krmarjenje po tem razvijajočem se regulativnem okolju je zapletena naloga, ki zahteva skrbno načrtovanje in strateško odločanje. Namen te diplomske naloge je raziskati eno možno pot naprej - uporabo UI za zmanjšanje emisij.

2.2 Umetna inteligenca v avtomobilski industriji


UI je revolucionirala avtomobilsko industrijo in ponuja inovativne rešitve za izzive, s katerimi se sooča. Integracija UI v tem sektorju je pripeljala do razvoja naprednih sistemov, ki izboljšajo zmogljivost vozila, varnost in splošno izkušnjo vožnje. Od izboljšanja varnosti do optimizacije proizvodnih procesov in razvoja avtonomnih vozil UI preoblikuje industrijo in utira pot k bolj trajnostni prihodnosti. Napredni sistemi za pomoč voznikom (ADAS) so eni izmed glavnih uporabnikov UI ter so razviti za avtomatizacijo, prilagajanje in izboljšanje sistemov vozila za varnost in boljšo vožnjo. Na splošno se ADAS delijo na pasivno in aktivno varnost. Pasivna varnost temelji na določenih napravah, kot so varnostni pasovi, zračne blazine in odbijači, ki varujejo potnike in zmanjšujejo škodo. Vendar pasivna varnost sama po sebi ne more izboljšati varnosti vožnje, saj je 93 % prometnih nesreč posledica voznikovega pomanjkanja zavedanja nevarnosti. Prav tako je bilo ugotovljeno, da bi se lahko 90 % nevarnih nesreč izognili, če bi bili vozniki opozorjeni le 1,5 sekunde prej. Zato je aktivna varnost, razvita za zaznavanje in predvidevanje nevarnih situacij, postala pomemben del sodobnih vozil (Wang et al., 2020). ADAS vključuje funkcije, kot so samodejno zaviranje v sili, opozorilo o nenamerni menjavi voznega pasu, prilagodljivi tempomat in pomoč pri parkiranju. UI v sistemih ADAS lahko obdeluje velike količine podatkov iz različnih senzorjev v realnem času, kar vozilu omogoča sprejemanje odločitev, na primer, kdaj naj pospeši, zavira ali krmili. To je privedlo do ustvarjanja samovozečih avtomobilov, ki lahko krmarijo v zapletenih okoljih z minimalnim človeškim posredovanjem. ADAS, ki jih poganja UI, postajajo vse pogostejši v vozilih. S preprečevanjem nesreč ti sistemi povečujejo varnost in prispevajo k trajnosti z zmanjšanjem energije in virov, potrebnih za popravilo poškodovanih vozil. Prav tako UI prispeva k učinkovitosti, saj se lahko uporablja za optimizacijo proizvodnih procesov v avtomobilski industriji (Wang et al., 2020). Algoritmi UI lahko analizirajo podatke iz proizvodne linije v realnem času, prepoznajo napake in predlagajo izboljšave. To ne zmanjša le stroškov, ampak tudi zmanjša vpliv proizvodnega procesa na okolje z zmanjšanjem odpadkov in porabe energije. UI je temeljito spremenila avtomobilsko industrijo, kar je privedlo do znatnega napredka v zmogljivosti vozil, varnosti in splošni izkušnji vožnje. Revolucionarni vpliv UI pa daleč presega osebna vozila. Celoten prometni sektor doživlja spremembo, ki jo spodbujajo zmogljivosti UI. V naslednjem poglavju se bomo posvetili še enemu ključnemu vidiku prometa, kjer UI dosega napredek, in sicer izboljšanju načrtovanja tovornih poti.

2.3 Izboljšanje načrtovanja poti tovrnega prometa

Zaradi vse večje uporabe avtomobilov se prometna industrija sooča z izzivi povečanih emisij, pomislekov glede varnosti voznikov, povpraševanja po potovanjih itd. Zato avtomobilska industrija izdeluje vozila, ki proizvajajo manj emisij, so učinkovita pri porabi goriva in zagotavljajo varnost za voznike. Nedavno je UI naredila velik preskok in ponuja priložnosti za izboljšanje tako v avtomobilskem kot v transportnem sektorju. UI kaže obetavne rezultate v transportni industriji s povečanjem produktivnosti, trajnosti, zanesljivosti in varnosti (Ismael, Esztergár-Kiss, Duleba, 2023). V primerjavi z osebnimi vozili se pri težkih tovornih vozilih pojavijo izzivi zaradi večjih dimenzij/teže in zahtevajo pozornost na dinamiko med delovanjem. Podatke, zbrane iz vozil, je mogoče uporabiti za testiranje emisij in porabe goriva, ti podatki predstavljajo dejanske značilnosti delovanja na podlagi njihovega delovanja in poklicnih uporab. Razumevanje profilov dejavnosti težkih vozil je pomembno za tovarna podjetja, da izpolnjujejo standarde porabe goriva in emisij, preprečujejo neželene izpade in zagotavljajo varnost voznikov. Z uporabo velike količine podatkov, ki se zbirajo z naprednimi računalniškimi metodami, kot je UI, lahko pomagajo pridobiti vpogled v krajšem času brez testiranja na cesti. Vendar pa ima sposobnost uporabe metod strojnega učenja na težkih vozilih še prostor za izboljšavo na področjih, kot so avtonomni tovornjaki, povezana vozila, prediktivno vzdrževanje in diagnostika napak. Ko se poglobimo v uporabo UI v avtomobilski industriji, postane jasno, da njen potencial daleč presega osnovne funkcionalnosti. V nadaljevanju predstavljamo nekaj področij, na katera UI pomembno vpliva. Ti vključujejo porabo goriva in ekonomičnost, kjer se UI uporablja za optimizacijo porabe goriva in zmanjšanje stroškov; ocenjevanje emisij, kjer UI pomaga pri natančnem napovedovanju in nadzoru emisij vozil; samovozeča vozila in »truck platooning«, kjer UI revolucionira koncept avtonomne vožnje in upravljanja voznega parka; ter prediktivno vzdrževanje in diagnostika na vozilu, kjer UI vpliva na življenjske dobe in varnosti vozila. Vsako od teh področij predstavlja izzive in priložnosti, UI pa prispeva k učinkovitejšemu reševanju teh izzivov.

Poraba goriva je ključni dejavnik pri delovanju vozil, zlasti v okviru težkih tovornih vozil. Pomen porabe goriva presega zgolj operativni vidik; ima tudi precejšnje finančne posledice. Na skupne operativne stroške vozil, zlasti težkih tovornjakov, močno vpliva poraba goriva. Zaradi finančnih posledic in zmanjšanja porabe goriva se je začela uporaba podatkovnega rudarjenja. Podatkovno rudarjenje je proces preučevanja in odkrivanja zakonitosti v podatkih. Podatki se preučujejo, da bi pridobili koristne informacije in nova znanja, na podlagi katerih je

mogoče sprejeti odločitve. Rezultate podatkovnega rudarjenja je vedno mogoče uporabiti za izdelavo modelov, ki pomagajo pri predvidevanju prihodnjega vedenja, prepoznavanju vedenja, ki ga ni bilo mogoče opazovati prej, razvijanju odnosov med dvema ali več udeleženci v procesu ali prilagajanju obstoječega načela, da bi izboljšali postopek (Narasimha, Sruvatsa, 2015).



Slika 1: Uporaba podatkovnega rudarjenja v prometnem inženirstvu (vir: Barau, Sudhir Kumar, 2003)

Tradicionalne metode za te modele so običajno temeljile na statističnih in fizikalnih pristopih. Čeprav so te metode zagotovile dragocene vpoglede, se pogosto izkažejo za dolgotrajne in manj natančne v primerjavi s sodobnimi tehnikami. Tukaj nastopi UI, ki s svojimi metodami strojnega in globokega učenja ponuja alternativo tradicionalnim metodam. Algoritmi strojnega učenja lahko analizirajo kompleksne vzorce in razmerja v velikih naborih podatkov, zaradi česar so še posebej primerni za naloge, kot je napovedovanje porabe goriva. Modeli za napovedovanje porabe goriva so zgrajeni z uporabo nevronske mreže z vzratnim širjenjem (angl. Backpropagation - BP), podpornih vektorjev (angl. Support Vector Machine - SVR) in naključnih gozdov (angl. Random Forests) (Zhao et al., 2023). Rezultati kažejo, da so povprečna hitrost, povprečna hitrost razen v prostem teku (ASEI), povprečni pospešek, povprečni pojemek, odstotek časa pospeševanja, odstotek časa pojemka in odstotek časa križarjenja pomembni kazalniki za oceno porabe goriva. Yao s sodelavci (2020) so v raziskavi z uporabo prej omenjenih kazalnikov napovedali porabo goriva z absolutno relativno napako, manjšo od 10 %. Model temelječ na metodi naključnega gozda se je izkazal za najbolj natančnega in najhitrejšega. Ta metoda je lahko tudi podlaga za izboljšanje podatkovne baze


za spremljanje in natančno upravljanje porabe goriva (Yao et al., 2020). Modele strojnega učenja je mogoče učiti na različnih podatkih, vključno s tehničnimi parametri vozil, podatki o vedenju pri vožnji in meritvami iz resničnega sveta. Ko so usposobljeni, lahko ti modeli predvidijo učinkovitost porabe goriva, pomagajo upravljati vozni park in služijo diagnostičnim namenom v primeru visoke porabe goriva. Prediktivne zmožnosti modelov strojnega učenja lahko transportnim podjetjem omogočijo, da optimizirajo svoje poslovanje, zmanjšajo stroške in izpolnjujejo regulativne standarde. UI predstavlja močno orodje za spopadanje z izzivi porabe goriva in ekonomičnosti pri težkih vozilih. Ker se tehnologija še naprej razvija, se pričakuje, da bo imela vse pomembnejšo vlogo pri oblikovanju prihodnosti avtomobilske industrije.

S pojavom novih tehnologij industrije, vključno z globokimi nevronskimi mrežami, se je začela nova doba v avtomobilski industriji: doba avtonomnih ali samovozečih vozil (Jiang, Y., Hsiao, T. 2021). Pomembno je razumeti različne ravni avtonomije, ki jih ta vozila lahko dosežejo. Avtonomna vožnja je običajno razvrščena v pet ravni (SAE International, 2021). Raven 0 predstavlja vozila, ki jih v celoti upravlja človek. Vozila, razvrščena v stopnjo 1, imajo funkcije, kot sta prilagodljivi tempomat, ki hitrost vozila prilagaja hitrosti vozila pred njim, in pomoč pri ohranjanju voznega pasu, ki preprečuje, da bi vozilo zapeljalo s svojega voznega pasu. Lahko imajo tudi funkcijo samodejnega zaviranja v sili, ko se nenadoma pojavi pešec ali druga ovira. Raven 2, ki se včasih imenuje "delna avtomatizacija", je višja od stopnje 1. Voznik mora še vedno pozorno spremljati dogajanje na cesti, vendar so pomembnejše naloge vožnje avtomatizirane. Prilagodljivi tempomat, pomoč pri ohranjanju voznega pasu in samodejno zaviranje v sili so še vedno vključeni. Poleg njih so na voljo tudi prostoročno krmiljenje, prepoznavanje prometnih znakov, zaznavanje mrtvega kota in samodejno parkiranje. Tako kot pri ravni 1 so te funkcije omogočene s kamerami, infrardečimi senzorji in ultrazvokom. Nekatera vozila 2. ravni omogočajo celo nočni vid, ki s pomočjo toplotnega slikanja vidi ljudi ali stvari, ki bi bile sicer vozniku skrite v temi. Tretja raven avtonomije omogoča vozilu pospeševanje, zaviranje, krmiljenje, parkiranje, navigacijo po prometnih znakih in signalih, vstopanje na avtocesto in izstopanje z nje ter vzdrževanje varne hitrosti in razdalje do drugih vozil - torej vse naloge, ki jih običajno voznik sam. Vozila 3. ravni lahko s pomočjo zapletenega sistema senzorjev, procesorjev in algoritmov "sprejemajo lastne odločitve", kar jim omogoča upravljanje velikega dela vozne izkušnje. V nekaterih okoliščinah mora voznik posredovati, na primer na zapletenih gradbenih območjih, na krajih nesreče ali v drugih okoliščinah (Nine, 2023). Čeprav je tretja raven tehnološki preskok, je izhodišče za četrto stopnjo. Raven 4,

imenovana tudi "visoka stopnja avtomatizacije", zmanjšuje vlogo voznika, dokler ni skoraj popolnoma nepotreben. Vozila ravni 4 so bolj opremljena za obvladovanje nujnih okoliščin, zato vozniku ni treba posredovati, vendar lahko vozniki po želji prevzamejo nadzor. Prihodnost, proti kateri se giba razvoj avtomatizacije vozil, je stopnja 5 oziroma popolna avtomatizacija. Avtomatizacija pete ravni ali "popolna avtomatizacija" omogoča, da vozilo vozi samo v vseh okoliščinah. Človek je povsem nepotreben ne glede na zahtevnost in kompleksnost situacije, v katerih se vozilo nahaja (Nine, 2023). Pot do doseganja popolne avtonomije vozil je bila zaznamovana s pomembnimi napredki na različnih področjih. Ti vključujejo pomoč pri zaznavanju voznega pasu, zaznavanje pešcev, vozil, predmetov, prepoznavanje prometnih znakov in zmožnosti samostojne vožnje. Uspeh teh tehnologij v osebnih avtomobilih je spodbudil mnoga podjetja, da se osredotočijo tudi na avtonomna tovorna vozila. Vendar pa razvoj avtonomnih tovornjakov predstavlja posebne izzive. Tovornjaki morajo zaradi svoje velikosti in mase še prej zaznati razmere v okolju kot osebna vozila. Trenutna stopnja avtonomije pri tovornjakih je znotraj obsega sistema »truck platooning«, kjer tovornjaki potujejo skupaj, povezani z računalnikom in avtomatiziranim voznim sistemom. Ta vozila se prilagajajo in odzivajo glede na delovanje vodilnega vozila, kar povzroči pol avtonomni konvoj tovornjakov. Pri analizi tovornjakov se osredotočamo na tri glavna področja: porabo goriva, energijsko učinkovitost ter nadzor hitrosti in nadzora okoliščin v prometu. V raziskavi ameriškega raziskovalnega centra za obnovljive vire energije in energetske učinkovitost agencije (National Renewable Energy Laboratory - NREL) je bilo ugotovljeno, da so leta 2014 kombinirana tovorna vozila v ZDA prevozila 273.2 milijarde kilometrov, pri čemer so porabila 110.1 milijarde litrov goriva in izpustila približno 6.9 milijarde ton ekvivalenta ogljikovega dioksida (CO_2). ZDA bi lahko prihranile 24.1 milijarde litrov goriv iz nafte, kar je enako 1.1 % trenutnega uvoza nafte v ZDA: 2.7 milijarde sodov v letu 2015 in 15.3 milijona ton CO_2 (0.22% zmanjšanje emisij) (Muratori et al., 2017). Eden pomembnih napredkov na tem področju je razvoj proporcionalnega integralnega odvodnega krmilnika na osnovi nevronske mreže (angl. Proportional Integral Derivative - PID), ki temelji na metodi globokega determinističnega gradienta politik globokega determinističnega gradienta politik (angl. Deep Deterministic Policy Gradient - DDPG) za krmiljenje voznega sistema. Gre za algoritem globokega okrepljenega učenja (angl. Deep Reinforcement Learning), ki se uporablja za usmerjanje agentov v okoljih z neprekinjenimi akcijskimi prostori. Algoritem združuje elemente določevalnih politik in metod gradienta politik za optimizacijo odločanja agentov. Drug pomemben vpliv na razvoj je uporaba konvolucijskih nevronske mreže (angl. Convolutional Neural Network - CNN) in modelov za zaznavanje ovir,

ki temeljijo na svetlobnem zaznavanju in merjenju (angl. Light Detection and Ranging – LiDAR) za avtonomna tovorna vozila. Sistem zaznavanja uporablja en senzor kamere in en senzor LiDAR v eni ravnini. Kamera zaznava pasove za bočni nadzor, LiDAR pa meri vzdolžno razdaljo in bočno lego predhodnega priklopnika (Hyeongyu et al., 2022). Ti modeli so usposobljeni na različnih projekcijskih zemljevidih LiDAR in so pokazali obetavne rezultate pri odkrivanju ovir. Kljub tem napredkom so sistemi avtonomnih tovornjakov še vedno v zgodnjih fazah razvoja. V primerjavi z avtonomnimi avtomobili potrebujejo več senzorjev in več računske moči. Poleg tega se soočajo s tveganji, kot so izpad povezave med vozili, napadi na programsko opremo in težave z okvarami senzorjev zaradi slabega vremena. V prihodnosti je moč pričakovati, da bodo avtonomni tovornjaki običajen prizor na naših cestah, saj bodo ponujali večjo varnost in učinkovitost.

Vzdrževanje ima ključno vlogo pri upravljanju voznega parka, njegov glavni cilj pa je izboljšati zanesljivost in vzdržljivost vozil. Slabo izbrana ali slabo načrtovana strategija vzdrževanja katere koli opreme lahko med drugim privede do pridobivanja izdelkov vprašljive kakovosti, zmanjšanja energetske učinkovitosti na nekaterih področjih ali premajhne/prekomerne izkoriščenosti vzdrževalnega osebja (Werbinska-Wojciechowska, Winiarska, 2023). Prve študije o industriji 4.0 so se pojavile na začetku prejšnjega desetletja. Izpostavile so nove visokotehnološke dosežke kot so platforme interneta stvari (angl. Internet of Things - IoT), napredni vmesniki človek–stroj, pametni senzorji, analitika, ki temelji na velikih podatkih, rešitve, ki temeljijo na konceptu pametne tovarne, ki je postal del industrijske proizvodnje. Skupaj z opaženim hitrim tehnološkim razvojem svetovnega gospodarstva se je začela tako imenovana četrta industrijska revolucija šele 42 let po tretji revoluciji, kar je relativno krajše obdobje v primerjavi z 99 leti, zabeleženimi med drugo in tretjo industrijsko revolucijo.



Slika 2: Temeljni trendi industrijske revolucije (vir: Werbinska-Wojciechowska, Winiarska, 2023)

Razvoj vzdrževanja 4.0 je industriji omogočil prehod z reaktivnega vzdrževanja (angl. Reactive Maintenance - RM) na preventivno vzdrževanje (angl. Preventive Maintenance - PM) in zdaj na predvideno vzdrževanje (angl. Predictable Maintenance - PdM). Ta premik je bil mogoč z uporabo pristopov, ki temeljijo na aktualnih in zgodovinskih podatkih, metod statističnega sklepanja in tehnik strojnega učenja za zgodnje odkrivanje napak. Njegov cilj je čim bolj zmanjšati izpade, optimizirati porabo energije ter povečati razpoložljivost, stopnjo izkoriščenosti in življenjsko dobo strojev, hkrati pa zagotoviti ohranjanje okolja in varnost osebja (El Kihel, El Kihel, Bouyahrouzi, 2022). Pristop k vzdrževanju se spreminja iz reaktivnega in korektivnega pristopa v napovedovalnega in anticipacijskega. Ta premik zaznamuje prehod od vzdrževanja 1.0 (reaktivno), prek vzdrževanja 2.0 (preventivno) in vzdrževanja 3.0 (proaktivno) do vzdrževanja 4.0. Ta se močno opira na tehnologije, kot so UI, IoT in velikih podatkov. Te tehnologije so ključnega pomena za trajnostni razvoj vzdrževalnih praks. Eden od glavnih ciljev vzdrževanja 4.0 je zmanjšati negativne vplive na okolje, zlasti glede porabe energije. Z gospodarskega vidika vključuje zmanjšanje stroškov popravil, povečanje dobička podjetja ter izboljšanje kakovosti in stroškov izdelkov.

Hitra digitalizacija industrij v zadnjih nekaj letih je prinesla pomembne spremembe. UI, tehnologija, ki posnema človeško inteligenco, je v ospredju teh sprememb. Potencial UI v avtomobilski industriji je velik in spodbuja razvoj inteligentnih vozil. Integracija IoT in tehnologije v oblaku je omogočila obdelavo velikih količin podatkov, s čimer je utrla pot v prihodnost avtomobilske industrije. Povpraševanje po UI v avtomobilski industriji je spodbudilo naraščajoče povpraševanje po novih funkcijah, vključevanje novih tehnologij in pomanjkanje voznikov tovornjakov. Novejši avtomobili so sedaj opremljeni z inteligentnimi sistemi, ki imajo zmožnost odločanja brez voznika, izboljšanimi varnostnimi funkcijami, asistenco vozniku, učinkovitostjo porabe goriva in nižjimi emisijami. Tako UI postaja sestavni del avtomobilske proizvodnje, dobavne verige in vozil. V tem poglavju so bile predstavljene aplikacije UI v težkih vozilih, analize podatkov in tehnike strojnega učenja, ki lahko izboljšajo učinkovitost porabe goriva ter jo predvidijo, izračunajo emisije, prepoznajo nepravilnosti v delovanju vozila, predvidijo vzdrževanje, izračunajo preostanek uporabne dobe in čas med vzdrževanjem ter uporabo tovornjaka z avtonomno vožnjo. Celotno majhne izboljšave, kot so učinkovitost goriva, nižje emisije in preprečevanje izpadov, bodo prevozniki podjetjem pomagale ekonomsko in tudi pri zmanjšanju vpliva na okolje. Čeprav so električna vozila, hibridna vozila in avtonomna vozila glavni trendi, ki uporabljajo računalniški vid in odločanje, je pred težkimi tovornjaki še dolga pot, da to dosežejo. Razpoložljivost kakovostnih podatkov

je glavna zahteva za učinkovito strojno učenje in metode globokega učenja. Zbiranje podatkov iz različnih vozil, ki uporabljajo različne vrste goriva, kot so vozila na dizelsko gorivo, zemeljski plin in propan, bi lahko pomagalo novim študijam uporabiti strojno učenje za primerjavo učinkovitosti porabe goriva, emisij in vzdrževanja vozil. Ker je pričakovati razvoj UI in strojnega učenja, lahko pričakujemo nadaljnji napredek na tem področju, ki bo vodil do učinkovitejšega in zanesljivejšega upravljanja voznega parka in na koncu do bolj trajnostne prihodnosti za naš planet.

2.4 Vloga umetne inteligence pri zmanjševanju emisij

Podnebne spremembe, ki jih povzročajo predvsem emisije ogljika, so eno najbolj perečih vprašanj našega časa. Povečanje koncentracije CO₂ v ozračju je porušilo prvotno ravnovesje na Zemlji, kar je povzročilo ekološke in okoljske učinke, kot so spremembe podnebnih območij, razvoj kopenskih ekosistemov in zakisljevanje oceanov. Te spremembe vplivajo na socialne in okoljske dejavnike zdravja - čist zrak, varno pitno vodo, zadostno količino hrane in varno zavetje. Podnebne spremembe povečujejo uničujoče posledice neurij, požarov in suš, zato je jasno, da potrebujemo inovativne rešitve za napovedovanje, omejevanje in blaženje teh vplivov.

Ena takšnih rešitev je uporaba UI pri varčevanju z energijo, znana tudi kot »zelena umetna inteligenca«. Zelena umetna inteligenca se nanaša na razvoj in izvajanje tehnologij umetne inteligence s poudarkom na zmanjševanju njihovega vpliva na okolje. To vključuje prizadevanja za zmanjšanje porabe energije in ogljičnega odtisa, povezanega z usposabljanjem in uvajanjem modelov umetne inteligence, ki je lahko zaradi potrebne računske moči precejšen. Koncept zelene umetne inteligence zajema več ključnih načel in strategij:

- energetska učinkovitost, ki vključuje razvoj algoritmov in modelov, ki potrebujejo manj računske moči in energije. To lahko vključuje optimizacijo kode, uporabo učinkovitejše strojne opreme in razvoj novih arhitektur UI, ki so manj potratne;
- trajnostne prakse: uvajanje trajnostnih praks v celotnem življenjskem ciklu razvoja UI, od zbiranja in obdelave podatkov do usposabljanja in uporabe modelov. To vključuje uporabo obnovljivih virov energije za napajanje podatkovnih centrov in računskih virov;


- presoja vplivov na okolje: ocenjevanje in zmanjševanje okoljskih vplivov projektov UI. To vključuje izračun ogljičnega odtisa modelov UI in sprejetje ukrepov za izravnavo emisij, na primer z ogljičnimi dobropisi ali drugimi trajnostnimi pobudami;
- ozaveščanje in izobraževanje: ozaveščanje o okoljskih vplivih UI in spodbujanje izobraževanja o trajnostnih praksah umetne inteligence med raziskovalci, razvijalci in zainteresiranimi stranmi v tehnološki industriji.

Zelena UI je nastajajoče področje, ki veliko obeta za trajnostno prihodnost. Postala je učinkovito orodje, ki lahko pomaga optimizirati porabo energije, zmanjšati količino odpadkov in spodbujati uporabo obnovljivih virov energije. Nekatere raziskave kažejo obetavne rezultate s prihranki energije od 13 % do 115 % (Vardecchia, Sallou, Cruz, 2023). Zelena UI predstavlja ključno raziskovalno področje, ki se osredotoča na izboljšanje okoljske trajnosti tehnologij UI. Ključno spoznanje iz pregleda literature je opredelitev različnih strategij in raziskovalnih usmeritev na področju zelene UI, kot so optimizacija hiperparametrov, spremljanje porabe energije in primerjalna analiza modelov glede na njihov vpliv na okolje. Sistemi z UI lahko analizirajo velike količine podatkov iz senzorjev in drugih virov ter tako prepoznajo vzorce in trende pri porabi energije, kar omogoča informirane odločitve o tem, kako optimizirati porabo energije. Z UI je na primer mogoče v realnem času prilagajati sisteme ogrevanja, prezračevanja in klimatizacije ter tako zagotoviti, da se energija porabi le takrat in tam, kjer je potrebna. S tem se lahko znatno zmanjšata poraba energije in proizvodnja emisij. UI ima ključno vlogo tudi pri upravljanju električnih omrežij (Mira, Bugiotti, Morosuk, 2023). S prehodom na obnovljive vire energije, kot sta sončna in vetrna energija, postaja upravljanje ponudbe in povpraševanja po električni energiji vse bolj zapleteno.

UI lahko pomaga uravnotežiti omrežje s predvidevanjem nihanj v povpraševanju in ustrezno prilagoditvijo ponudbe. S tem se lahko preprečijo izpadi električne energije in zagotovi učinkovito porabo energije. Poleg tega je mogoče UI uporabiti za optimizacijo postavitve in delovanja infrastrukture za obnovljive vire energije, kot so vetrne turbine in sončne celice, da se čim bolj poveča njihova proizvodnja energije in čim bolj zmanjša njihov vpliv na okolje. Vključevanje tehnik UI v sisteme obnovljivih virov energije je obetavno izboljšalo učinkovitost delovanja in možnosti optimizacije, zlasti na področju hibridnih sistemov obnovljivih virov energije (angl. Hybrid Renewable Energy Systems - HRES) in shranjevanja energije. Tam je prišlo do dveh pomembnih napredkov, doseženih z uporabo UI: izboljšanje učinkovitosti delovanja HRES in optimizacija sistemov za shranjevanje energije, ki skupaj prispevata k zmanjšanju porabe energije in obratovalnih stroškov. Uporaba tehnik UI, zlasti z

razvojem hibridnih algoritmov temelječih na umetnih nevronskih mrežah (angl. Neural Network-based Hybrid Algorithm - ABHA), pomeni pomemben napredek v učinkovitosti delovanja samostojnih HRES. Sistem ABHA je v raziskavi Zhengxuan s sodelavci (2020) pokazal visoko natančnost in znatno skrajšal čas izračuna v primerjavi s tradicionalnimi metodami, kar kaže na sposobnost učinkovite racionalizacije postopka optimizacije HRES. Ta inovacija zagotavlja, da je proizvodnja energije bolj usklajena s potrebami po porabi, s čimer se povečujeta zanesljivost in učinkovitost sistema. Z vključitvijo UI v operativni okvir HRES se bistveno izboljša splošna učinkovitost sistema, kar vodi k učinkovitejšemu izkoriščanju obnovljivih virov energije. Vzporedno z napredkom na področju HRES so tehnike UI revolucionarno spremenile tudi upravljanje in optimizacijo sistemov za shranjevanje energije. Ključni primer tega je uporaba UI pri optimizaciji izmenjave električne energije med mikro omrežjem in glavnim omrežjem, ki je prinesla znatne gospodarske koristi. Z inteligentnimi strategijami nadzora in optimizacije je UI omogočila skoraj nič-energijski stavbni sistem, ki je občutno zmanjšal mesečne račune za elektriko za približno 87 % (Zhengxuan et al., 2020). Takšna raven optimizacije ne povečuje le ekonomske izvedljivosti sistemov obnovljivih virov energije, temveč spodbuja tudi bolj trajnosten in učinkovit vzorec porabe energije. Strateško upravljanje shranjevanja energije, ki ga omogoča UI, ima ključno vlogo pri stabilizaciji ponudbe in povpraševanja po energiji ter s tem povečuje odpornost in trajnost energetskega omrežja.

V avtomobilskem sektorju lahko UI z optimizacijo poti, zmanjšanjem zastojev in izboljšanjem pretočnosti prometa pomaga zmanjšati porabo energije in emisije. UI se prav tako lahko uporabi za razvoj učinkovitejših sistemov za polnjenje električnih vozil, ki zagotavljajo, da se električna vozila polnijo ob optimalnem času in z uporabo najučinkovitejših virov energije.



Slika 3: Globalni pregled ravnanja s trdnimi odpadki do leta 2050 (vir: Kaza et al., 2018)

Kot je vidno iz Slike 3, industrijski odpad predstavlja največji delež odpadnega materiala, ki je globalno proizveden. Zato je pomembno, da se v industrijskem sektorju čim prej prične z uporabo UI za optimizacijo proizvodnih procesov in zmanjšanje porabe energije. Z analizo podatkov iz senzorjev in drugih virov lahko UI ugotovi neučinkovitost proizvodnih linij in priporoči prilagoditve za izboljšanje energetske učinkovitosti. To lahko podjetjem omogoči znatne prihranke pri stroških in zmanjša emisije ogljika. Skozi objektiv umetne inteligence lahko predvidimo ne le prihodnost vzdrževanja, temveč tudi prihodnost trajnostne industrije (Hao et al., 2022). To proizvajalcem omogoča, da v realnem času prilagodijo delovanje za optimalno rabo energije in zmanjšanje količine odpadkov. Ta zmožnost zajema tudi natančno prilagajanje proizvodnih urnikov, nastavitev strojev in logistike dobavne verige, kar zagotavlja, da je vsak vidik proizvodnje racionaliziran za doseganje največje učinkovitosti. Uporaba UI v industrijskih procesih presega tradicionalne metode, saj omogoča napovedno analitiko. Prediktivno vzdrževanje, ki ga poganja umetna inteligenca, spreminja nepredvidljivost v priložnost in zagotavlja, da je učinkovitost načrtovana in ne le pričakovana (Hao et al., 2022). Tradicionalne modele reaktivnega vzdrževanja, ki temeljijo na filozofiji popravljanja po okvari, nadomešča napovedno vzdrževanje, ki ga poganja UI. Ta inovativni pristop uporablja algoritme UI za spremljanje delovanja in zdravja opreme v realnem času ter prepoznavanje znakov morebitnih okvar, še preden se pojavijo. S predvidevanjem potreb po vzdrževanju lahko industrija načrtuje posege ob najprimernejšem času, s čimer se izogne nepričakovanim izpadom in podaljša življenjsko dobo strojev. Prediktivno vzdrževanje izkorišča moč UI za analizo podatkov iz senzorjev, vgrajenih v opremo, in uporablja strojno učenje za odkrivanje vzorcev ali anomalij, ki se pojavijo pred okvarami opreme. To ne zagotavlja le neprekinjenega delovanja, temveč tudi optimizira energetske učinkovitosti strojev, saj dobro vzdrževana oprema deluje učinkoviteje in porabi manj energije. Sinergija med industrijsko optimizacijo z UI in napovednim vzdrževanjem napoveduje novo obdobje odličnosti v proizvodnji. S hkratno racionalizacijo proizvodnih procesov in uvedbo proaktivnih praks vzdrževanja lahko industrija doseže višjo raven operativne učinkovitosti in trajnosti. Bistvo UI pri industrijski optimizaciji ni v tem, da nadomesti človeško delo, temveč da ga okrepi in usmeri k višji učinkovitosti. (Hao et al., 2022) Ta dvojni pristop zmanjšuje količino odpadkov, zmanjšuje porabo energije in povečuje produktivnost, kar je v skladu z globalnimi trajnostnimi cilji. Vključevanje UI na teh področjih spodbuja tudi kulturo nenehnih izboljšav in inovacij v proizvodnem sektorju. Z razvojem in izpopolnjevanjem tehnologij UI se povečuje njihov potencial za nadaljnje izboljšanje industrijskih procesov in strategij vzdrževanja, kar obeta še večje povečanje učinkovitosti, trajnosti in konkurenčnosti.

UI lahko hitro analizira dinamične podatke, na primer podatke iz sistemov za napovedovanje vremena, in ustvari simulacijo, ki jo lahko znanstveniki uporabijo za sprejemanje odločitev. Možnosti uporabe UI pri varčevanju z energijo in zmanjševanju emisij ogljika so obsežne in raznolike. Pri nadaljnjem razvoju in izpopolnjevanju tehnologij UI je ključnega pomena, da njihovo uporabo prednostno usmerimo v prizadevanje za bolj zeleno in trajnostno prihodnost. Z izkoriščanjem moči UI si lahko prizadevamo za svet, v katerem se energija uporablja učinkovito, odpadki so čim manjši in naša odvisnost od fosilnih goriv manjša.

3. Umetna inteligenca

Pojem umetna inteligenca je leta 1956 predlagal John McCarty v želji po nevtralnem poimenovanju hitro razvijajočega se raziskovalnega področja. Po McCartyju se definicija umetne inteligence v prevodu glasi: »študij naj bi temeljil na domnevi, da je mogoče vsak vidik učenja ali katerokoli drugo značilnost inteligence načeloma tako natančno opisati, da je mogoče na podlagi študije narediti stroj, ki to značilnost simulira« (Sutton, 2020). Definicijo UI podaja tudi Organizacija za ekonomsko sodelovanje in razvoj (angl. Organisation for Economic Co-operation and Development), in sicer je UI strojno temelječ sistem, ki lahko za določen nabor ciljev, ki jih določi človek, daje napovedi, priporočila ali odločitve, ki vplivajo na realna ali virtualna okolja. Definicija temelji na razdelitvi umetne inteligence na manjše obvladljive in smiselne dele, ki so ključni za razumevanje področja AI (OECD, 2024). Umetna inteligenca označuje zmožnost stroja opravljati naloge, ki jih človek izvaja z mišljenjem, učenjem, načrtovanjem, sklepanjem in kreativnostjo (Inštitut za slovenski jezik Frana Ramovša ZRC SAZU, 2021). Umetna inteligenca se nanaša na tehnologije, načrtovane za analizo sveta okoli sebe in ukrepanje za doseganje specifičnih ciljev (Evropska komisija, 2024). Umetna inteligenca omogoča tehničnim sistemom, da zaznavajo okolje, obdelajo, kar zaznajo, in rešijo problem, pri čemer ravnajo v skladu z določenim ciljem. Računalnik sprejema podatke, ki so predhodno pripravljeni, ali pa jih zbere sam s senzorji, denimo kamero, jih obdela in se odzove. Sistemi, ki delujejo na podlagi umetne inteligence, lahko na podlagi analize učinkov svojih predhodnih dejanj do določene mere samostojno prilagajajo svoje vedenje. Umetna inteligenca pomeni uporabo digitalne tehnologije za ustvarjanje sistemov, ki lahko opravljajo naloge, za katere običajno velja, da zahtevajo človeško inteligenco. Umetna inteligenca ni nova tehnologija. Nekatere tehnologije umetne inteligence obstajajo že desetletja, vendar so napredek na področju računalniške zmogljivosti, razpoložljivost velikih količin podatkov in nova programska oprema v kratkem času privedli do velikih prebojev (Evropski parlament, 2020; Evropski svet, 2024).

UI je transformativna tehnologija, ki je prežela različne sektorje svetovnega gospodarstva ter spodbuja inovacije in učinkovitost. UI je v svojem bistvu ustvarjanje strojev, ki lahko posnemajo človeško inteligenco in jim omogočajo učenje, razmišljanje, zaznavanje in sprejemanje odločitev. To poglavje ponuja splošen pregled UI ter povezuje njena načela in aplikacije s kontekstom avtomobilske industrije. UI lahko na splošno razdelimo v dve vrsti: ozko UI, ki je zasnovana za opravljanje določene naloge, kot je prepoznavanje glasu, in splošno

UI, ki lahko razume, se uči in uporablja znanje v širokem spektru nalog. Trenutno so aplikacije UI, ki jih vidimo v vsakdanjem življenju, vključno s tistimi v avtomobilski industriji, primeri ozke UI.

Umetno inteligenco lahko razdelimo na tri glavne ravni:

- ožja (ali šibka) umetna inteligenca,
- splošna umetna inteligenca in
- umetna super inteligenca

Ožja umetna inteligenca, pravimo ji tudi šibka umetna inteligenca, je ciljno usmerjena in načrtovana za izvajanje posameznih nalog. Tako stroji izgledajo inteligentni, vendar delujejo pod nekaterimi omejitvami. Ne oponašajo človeške inteligence, pač pa simulirajo človeško obnašanje na osnovi določenih parametrov. Za izvajanje nalog uporabljajo naravni jezik. To je vidno v tehnologijah, kot so klepetalni roboti (angl. chatbots) in sistemi za razpoznavo govora. Primeri ožje oziroma šibke UI so pametni asistenti v spletnih aplikacijah (npr. Siri, Alexa, Cortana), računalniški sistemi z odgovori na vprašanja v naravnem jeziku (IBM Watson), samovozeča vozila, razpoznavanje obraza, filtri neželene elektronske pošte, napovedna orodja idr.

Splošna umetna inteligenca, pravimo ji tudi močna ali globoka umetna inteligenca, so koncepti, s pomočjo katerega lahko stroji posnemajo človeško inteligenco, hkrati pa kažejo sposobnost uporabe svoje inteligence za reševanje problemov. Lastnosti globoke umetne inteligence prepoznavanje, spominjanje se česa (priklicanje), preizkušanje hipotez, domišljija, analogija, implikacija. Umetna super inteligenca je hipotetični pojem. To bi bila raven inteligence, ko bi stroj prekosil človeške zmožnosti in se zavedal samega sebe.

Generativna umetna inteligenca (angl. Generative Artificial Intelligence - GAI) je umetna inteligenca, ki je sposobna generirati besedilo, slike ali druge medije. Generativni modeli umetne inteligence se naučijo vzorcev in strukture iz svojih učnih vhodnih podatkov in nato ustvarijo nove podatke s podobnimi značilnostmi. V začetku leta 2020 je napredek globokih nevronske mreže omogočil številne generativne sisteme umetne inteligence. Sem spadajo klepetalni roboti z velikimi jezikovnimi modeli, kot npr. ChatGPT in drugi (Divjak, 2024).

Strojno učenje (angl. Machine Learning - ML) je podmnožica UI in je metoda analize podatkov, ki avtomatizira izdelavo analitičnih modelov. Uporablja algoritme, ki se iterativno učijo iz podatkov, kar računalnikom omogoča, da najdejo skrite vpoglede, ne da bi bili izrecno

programirani, kje naj iščejo. Ta pa vsebuje podmnožice, ki so nadzorovano učenje, nenadzorovano učenje in okrepljeno učenje.

Nadzorovano strojno učenje (angl. Supervised Machine Learning - SML) vključuje usposabljanje algoritma na naboru označenih podatkov, kjer se model nauči napovedovati rezultate iz vhodnih podatkov. Prediktivno vzdrževanje je eden izmed načinov, kako lahko modeli SML z analizo preteklih podatkov predvidijo morebitne okvare sestavnih delov vozila, preden se pojavijo. Algoritmi lahko na primer spremljajo zmogljivost motorja, življenjsko dobo baterije in druge kritične dele, da napovedujejo njihovo življenjsko dobo in predlagajo vzdrževanje, preden pride do okvar. V proizvodnji nadzorovani algoritmi učenja analizirajo dele in sklope za napake. Z usposabljanjem na slikah okvarjenih in neokvarjenih delov lahko sistem prepozna in označi napake, izboljša kakovost izdelkov in zmanjša prizadevanja za ročno pregledovanje.


Nenadzorovano strojno učenje (angl. Unsupervised Machine Learning - UML) vključuje algoritme, ki analizirajo in združujejo neoznačene nabore podatkov. Za segmentacijo oziroma razvrščanje strank lahko avtomobilska podjetja uporabljajo nenadzorovano učenje za segmentiranje oziroma razvrščanje svojih strank v različne skupine na podlagi njihovega nakupnega vedenja, preferenc in vzorcev uporabe. To pomaga pri ciljnem trženju in prilagojenih storitvah za stranke. Nenadzorovano učenje je ključnega pomena za prepoznavanje nenavadnih vzorcev ali nepravilnosti v podatkih o zmogljivosti vozila, ki lahko kažejo na morebitne težave ali napake. Na primer nenavadni vzorci temperature motorja ali vibracij vozila bi lahko opozorili na težave, ki zahtevajo nadaljnje preiskave.

Okrepljeno, okrepitevno oziroma spodbujevalno strojno učenje (angl. Reinforcement Machine Learning - RML) je vrsta strojnega učenja, ki vključuje algoritem, ki se uči z interakcijo z okolico in je nato kaznovan ali nagrajen, odvisno od tega, kako deluje (IPROM, 2024). Algoritmi okrepljenega učenja se uporabljajo tudi pri razvoju avtonomnih vozil. Ti algoritmi pomagajo vozilu, da se nauči optimalnih navigacijskih poti, prilagoditi hitrost in strategij za izogibanje oviram s poskusi in napakami v simuliranih okoljih. Prav tako omogoča prilagodljivi tempomat, ki samodejno prilagodi hitrost vozila, da ohrani varno razdaljo do spredaj vozečega vozila. Spodbujevalno učenje lahko optimizira ta proces z nenehnim učenjem iz voznega okolja in prilagajanjem nadzornih parametrov za bolj gladke in varnejše vožnje.

Globoko učenje (angl. Deep Learning - DL), podskupina ML, izkorišča nevronske mreže z več plastmi (zato se imenuje »globoko«) za analizo različnih oblik podatkov, vključno s slikami,

zvokom in besedilom. Njegove zmogljivosti presegajo tradicionalne modele ML, saj se lahko samodejno naučijo predstavitev iz podatkov, ne da bi potrebovali ročno ekstrakcijo funkcij. To je še posebej koristno pri nalogah, ki vključujejo velike količine podatkov in zapletene vzorce, ki jih ljudje težko artikulirajo.

Umetne nevronske mreže oziroma nevronske mreže so središče DL. Posnemajo biološke nevronske mreže v človeških možganih. Ta omrežja so sestavljena iz vozlišč (nevronov), povezanih z povezavami (sinapsami), ki prenašajo signale med vozlišči (nevroni).



Slika 4: Osnovni elementi nevronske mreže (vir: Tasič, Plesnik, 2018)

Sinaptične uteži - vrednosti $w_1, w_2, \dots, w_n$ so uteži povezane z vsakim vozliščem za določitev moči vhodnega vektorja $[x_1, x_2, \dots, x_n]^T$. Notranji prag nevrona Θ predstavlja vrednost, pri kateri se aktivira izhod nevrona y . Aktivacijska funkcija izvaja določeno matematično operacijo na izhodnem signalu. Za uporabo so možne tudi zahtevnejše aktivacijske funkcije, odvisno od vrste problema, ki ga rešuje mreža (Tasič, Plesnik, 2018).

Globoka nevronska mreža vsebuje več skritih plasti med vhodnimi in izhodnimi plastmi, kar ji omogoča, da se nauči kompleksnih vzorcev na različnih ravneh abstrakcije. V avtomobilski industriji se uporablja za prediktivno vzdrževanje. Nevronske mreže lahko v realnem času analizirajo ogromne količine operativnih podatkov senzorjev vozila, da predvidijo morebitne okvare, preden se pojavijo. Na primer s spremljanjem temperature motorja, tresljajev in drugih ključnih parametrov lahko nevronske mreže prepoznajo vzorce, ki kažejo na obrabo ali neposredno okvaro, kar omogoča preventivne vzdrževalne ukrepe, da se izognejo dragim popravilom in izpadom.

CNN so specializirane arhitekture DL, ki se uporabljajo za obdelavo mrežastih podatkov, kot so slike. Še posebej učinkovite so pri nalogah, kot sta prepoznavanje in razvrščanje slik, saj lahko zajamejo prostorske hierarhije v podatkih. Spodnje plasti lahko na primer zaznajo

robove, globlje plasti pa bolj zapletene oblike ali predmete. V avtomobilski industriji se uporabljajo za avtomatiziran nadzor kakovosti v proizvodnji. CNN se v veliki meri uporabljajo za sisteme vizualnega pregleda v avtomobilski proizvodnji. Ti analizirajo slike delov in sklopov vozil, da odkrijejo napake, kot so praske, udrtine ali nedoslednosti v kakovosti barve. Ta aplikacija zagotavlja višje standarde kakovosti in zmanjšuje potrebo po ročnem pregledu, kar vodi k učinkovitejšim proizvodnim procesom.

Rekurentne nevronske mreže (angl. Recurrent Neural Network- RNN) so zasnovane za obdelavo zaporednih podatkov, kot so časovne vrste ali naravni jezik. Za njih je značilno, da hranijo informacije iz prejšnjih vhodov, zaradi česar so primerne za naloge, kot sta prepoznavanje govora ali prevajanje jezika. V avtomobilski industriji se uporabljajo za obdelavo naravnega jezika za glasovne pomočnike v avtomobilu. RNN so zaradi svoje sposobnosti obdelave zaporednih podatkov idealne za razvoj naprednih glasovnih pomočnikov v avtomobilu. Ti sistemi lahko razumejo in obdelajo govorjene ukaze voznikov, kar omogoča prostoročni nadzor nad navigacijo, zabavnimi sistemi in nastavitvami vozila, kar izboljša vozno izkušnjo in hkrati spodbuja varnost.

Samodejni kodirniki so nenadzorovani učni modeli, katerih cilj je naučiti stisnjeno, kodirano predstavitev podatkov, nato pa jih dekodirati nazaj v prvotno obliko. Uporabni so za zmanjšanje dimenzionalnosti in učenje funkcij. V avtomobilski industriji se uporabljajo za zmanjšanje dimenzionalnosti telematskih podatkov vozil. Samodejni kodirniki lahko stisnejo visokodimenzionalne telematske podatke (kot so hitrost vozila, podatki o motorju in vzorci obnašanja voznika) v nižjo dimenzionalno in smiselno predstavitev. Te stisnjene podatke je mogoče učinkoviteje analizirati za vpogled v zmogljivost vozila in vedenje voznika, optimizacijo oblike vozila in izboljšanje prilagojenih storitev.

Generativne nasprotniške mreže (angl. Generative Adversarial Networks - GAN) so sestavljene iz dveh nevronske mreže, generatorja in diskriminatorja, ki se učita oziroma usposabljata hkrati. Generator ustvari podatke, ki so čim bolj realistični, diskriminator pa oceni, ali so ti podatki resnični (iz dejanskega nabora podatkov) ali ponarejeni (ki jih je ustvaril generator). GAN so še posebej znane po ustvarjanju realističnih slik, vendar se uporabljajo tudi v drugih primerih. V avtomobilski industriji se uporabljajo za simulacijo in testiranje sistemov avtonomnih vozil. GAN se uporabljajo za ustvarjanje realističnih scenarijev vožnje in okolij za usposabljanje in preskušanje sistemov avtonomnih vozil. Z ustvarjanjem raznolikih,

zahtevnih in realističnih prometnih situacij GAN pomagajo izboljšati robustnost in varnost algoritmov avtonomne vožnje, preden se uporabijo na resničnih cestah.

Te tehnologije skupaj optimizirajo trenutne proizvodne in operativne procese ter utirajo pot prihodnjim inovacijam na področju oblikovanja vozil, pomoči pri vožnji in avtonomnih sistemov. Nenehno vključevanje ML in DL v avtomobilsko industrijo omogoča izboljšanje vseh vidikov avtomobilske izkušnje, od proizvodnje do končne uporabniške izkušnje, s poudarkom na ključni vlogi UI pri oblikovanju prihodnosti mobilnosti.

3.1 Razumevanje delovanja umetne inteligence

UI je večplastna disciplina v računalniški znanosti, katere cilj je ustvariti stroje, ki bi lahko posnemali človeško inteligenco, in predstavlja mejo računalniške tehnologije. To ne pomeni ustvarjanja robotov s človeško zavestjo, temveč sistemov, ki se lahko učijo iz izkušenj, razumejo kompleksno vsebino, logično sklepajo in komunicirajo z ljudmi na naraven, intuitiven način. Sistemi UI so zasnovani za izvajanje nalog, ki običajno zahtevajo človeško inteligenco, kot so analiza in interpretacija podatkov, vizualno zaznavanje, prepoznavanje govora, odločanje in prevajanje jezika. Začetek umetne inteligence sega v sredino 20. stoletja s temeljnim delom pionirjev, kot je Alan Turing, ki je predlagal Turingov test kot merilo strojne inteligence (Russell, Norvig, 2016). Tehnologije UI so se zelo razvile, od ekspertnih sistemov, ki temeljijo na pravilih, do ML in algoritmov DL. ML, podskupina UI, omogoča sistemom, da se učijo in izboljšujejo iz izkušenj, ne da bi bili izrecno programirani. DL, podskupina ML, uporablja nevronske mreže z več plastmi za analizo različnih oblik podatkov na kompleksne načine, ki posnemajo nevronske mreže v človeških možganih. To je tehnologija, ki stoji za številnimi naprednimi aplikacijami UI, kot sta prepoznavanje slik in govora. UI ima v sodobnem svetu nešteto aplikacij. UI se uporablja v številnih sektorjih in je revolucionirala industrijo z izboljšanjem učinkovitosti, natančnosti in produktivnosti. V zdravstvu algoritmi UI analizirajo medicinske slike za natančnejše diagnoze (Esteva et al., 2019). Na področju financ UI izboljšuje odkrivanje goljufij in prilagaja bančne storitve (Chen, Mao, Liu, 2018).

Napredek v tehnologijah UI predstavlja le vrh ledene gore na hitro razvijajočem se področju. Okrepljeno učenje, GAN in razložljiva UI obljublajo preoblikovanje industrij z omogočanjem novih zmogljivosti, od izboljšanja procesov odločanja do ustvarjanja novih, ustvarjalnih vsebin. Vendar z napredkom teh tehnologij prinašajo tudi izzive, zlasti v smislu etične uporabe,

varnosti in zagotavljanja, da UI ostane orodje za pozitivno preobrazbo. Reševanje teh izzivov zahteva stalne raziskave, etični nadzor in zavezanost razvoju UI na način, ki bo koristil vsemu človeštvu.

Prihodnost UI obljublja nadaljnje inovacije, vključno z napredkom v kvantnem računalništvu in vključevanjem UI v vsakdanje življenje. Vendar izzivi, kot so zagotavljanje etične uporabe, izboljšanje razločljivosti in preprečevanje zlorab, ostajajo kritični. Potencial UI za preoblikovanje industrije in družbe je ogromen, vendar ga spremljajo precejšnje odgovornosti. Stalne raziskave, etični premisleki in razvoj politike so bistveni za izkoriščanje koristi UI in hkrati zmanjševanje tveganj.

3.2 Umetna inteligenca in njena uporabnost

UI je svoj odtis pustila v različnih sektorjih ter spremenila način življenja in dela. Vpliv UI je vsesplošen in transformativen, od zdravstva do financ, izobraževanja do zabave in avtomobilske industrije.

V zdravstvu se UI uporablja za napovedovanje bolezni, pomoč pri diagnozi in prilagajanje načrtov zdravljenja. UI je revolucionirala zdravstveno industrijo z zagotavljanjem inovativnih rešitev za diagnosticiranje bolezni in prilagajanje načrtov zdravljenja. Ena najpomembnejših aplikacij UI v zdravstvu je na področju diagnostike. Algoritmi UI lahko analizirajo radiološke slike za odkrivanje anomalij, kot so tumorji, kar znatno pospeši diagnostični postopek (Mustafa, 2018). Podjetje DeepMind Technologies Limited se je podalo na področje zdravstvenega varstva in obljublja napredek s podatkovno vodenimi orodji, zlasti UI. Projekt DeepMind Health je razvil sistem UI, ki lahko diagnosticira očesne bolezni z enako natančnostjo kot človeški zdravniki. Sistem umetne inteligence, ki ga je razvil DeepMind, lahko hitro analizira rutinske klinične preglede oči in identificira več kot 50 bolezni, ki ogrožajo vid, z izjemno natančnostjo (Mustafa, 2018). Ima sposobnost, da priporoči napotitev na zdravljenje tako natančno kot izkušeni oftalmologi. Takšna sposobnost ni le akademsko zanimiva, temveč lahko potencialno reši življenja in zagotavlja, da so bolniki, ki potrebujejo nujno oskrbo, hitro prepoznani in prednostno razvrščeni. Ta dosežek je poudarjen s pristopom sistema k eni najpomembnejših ovir UI v zdravstvu, ki je problem »črne skrinjice«. Sistem DeepMind uvaja pregled v svoj proces odločanja z novo kombinacijo dveh nevronske mreže. Prva, segmentacijska mreža, ponuja podroben zemljevid očesnega tkiva in značilnosti bolezni,

ki jih identificira iz skeniranja. Druga, klasifikacijska mreža, uporablja ta zemljevid za ponujanje diagnostičnih vpogledov in priporočil za napotitev skupaj z odstotkom zaupanja. Ta dvotirni pristop ne zagotavlja le natančnosti, temveč tudi vzbuja zdravnikom in bolnikom zaupanje in globlje razumevanje priporočil UI. Poleg tega prilagodljivost te tehnologije različnim vrstam skenerjev za oči povečuje njen potencialni globalni vpliv. Usposabljanje UI na določeni napravi ne omejuje njene uporabe, s čimer obljublja široko uporabnost in dostopnost. Takšna vsestranskost je ključnega pomena za sprejetje tehnologije v različnih kliničnih okoljih po vsem svetu, kar zagotavlja, da lahko napredek pri diagnosticiranju in zdravljenju doseže širšo populacijo bolnikov. Ko ta tehnologija napreduje v smeri izdelka, se sooča s strogimi potmi kliničnih preskušanj in regulativne odobritve. Končni cilj je spremeniti diagnozo, zdravljenje in obvladovanje očesnih bolezni po vsem svetu. Kljub tem napredkom je še vedno treba premagati izzive. To vključuje vprašanja, povezana z zasebnostjo in varnostjo podatkov, potrebo po velikih količinah visokokakovostnih podatkov za usposabljanje sistemov UI in potrebo po regulativnih okvirih za zagotavljanje varne in etične uporabe UI v zdravstvu. Vendar pa so potencialne koristi UI v zdravstvu ogromne.

UI je postala transformativna sila v proizvodni industriji in ponuja rešitve, ki povečujejo učinkovitost, izboljšujejo nadzor kakovosti in optimizirajo dobavne verige. Integracija UI v proizvodne procese je del širšega trenda, znanega kot industrija 4.0, ki predstavlja četrto industrijsko revolucijo, za katero sta značilni digitalizacija in avtomatizacija proizvodnih procesov. Ena od ključnih aplikacij UI v proizvodnji je predvideno vzdrževanje. Cilj tehnologij prediktivnega vzdrževanja je odkrivanje, diagnosticiranje in napovedovanje okvar in razgradenj strojnih komponent. Končni cilj je preprečiti izpade, prepoznati temeljne vzroke za nadaljnje ukrepanje in omogočiti učinkovito načrtovanje in optimizacijo vzdrževanja, ki temelji na dokazih (General Electric, 2024). Tradicionalni razporedi vzdrževanja temeljijo na ocenjeni življenjski dobi opreme, kar lahko povzroči nepotrebne izpade, če oprema nepričakovano odpove, ali nepotrebno vzdrževanje, če oprema še vedno dobro deluje. UI to spremeni tako, da analizira podatke senzorjev na opremi, da napove, kdaj bo potrebno vzdrževanje. To omogoča pravočasno načrtovanje vzdrževanja, s čimer se skrajšajo izpadi in prihranijo stroški. General Electric (GE) uporablja UI za napovedovanje, kdaj bodo industrijski stroji potrebovali vzdrževanje, s čimer skrajša čas izpadov in poveča učinkovitost. Uporablja se tudi pri kontroli kakovosti. Tradicionalne metode nadzora kakovosti so pogosto odvisne od ročnega pregleda, ki je lahko dolgotrajen in nagnjen k napakam. GE Research je v ospredju pionirskih tehnologij napovednega vzdrževanja, ki se osredotočajo na spremljanje in

upravljanje več kot sto tisoč sredstev v različnih sektorjih, kot so vesolje, proizvodnja električne energije, prevoz, iskanje nafte in zdravstveno varstvo. Te tehnologije so zasnovane tako, da preventivno prepoznajo in predvidijo okvaro in obrabo strojnih komponent, preden dosežejo kritično stanje, s končnim ciljem izogniti se izpadom, določiti osnovne težave za nadaljnje ukrepanje in olajšati učinkovite, podatkovno vodene strategije vzdrževanja in optimizacije. Pri pristopu zgodnjega opozarjanja gre za odkrivanje nenavadnih vzorcev v delovanju stroja takoj, ko se pojavijo, ne glede na trenutno stanje ali kontekst stroja. Cilj te metode je čim bolj povečati čas, ki je na voljo za vse potrebne posege, z uporabo kombinacije nenadzorovanih, delno nadzorovanih in v celoti nadzorovanih tehnik analize podatkov. Omogoča širok nabor zapletenosti rešitev, ki temeljijo na razpoložljivih podatkih o tem, kaj je normalno in nenormalno za poslovanje sredstva. Ključna raziskovalna prizadevanja vključujejo razvoj fuzijskih algoritmov za združevanje opozoril in različnih podatkov iz več modelov, da bi povečali natančnost napovedi in skrajšali čas za odkrivanje težav, s čimer bi zmanjšali tudi nepotrebna opozorila. Poleg tega je raziskava prinesla učinkovit postopek iskanja multivariabilnih časovnih vrst, ki pospešuje identifikacijo specifičnih podatkovnih vzorcev za diagnosticiranje in razumevanje temeljnih vzrokov.

Prognostika naredi to še korak dlje s ponudbo dolgoročnih napovedi o življenjski dobi in učinkovitosti komponent. Ti prognostični modeli, aktivirani po zgodnjem opozorilu, so izdelani za napovedovanje preostale življenjske dobe komponent, časovnice do zmanjšane funkcionalnosti in delitve vozniških parkov za ciljno pregledovanje, vzdrževanje in upravljanje zalog rezervnih delov. Prognostične tehnologije, ki jih je razvil GE, izkoriščajo kombinacijo tehnik modeliranja, ki vključujejo fiziko iz resničnega sveta in podatke iz dejanske uporabe sistema in simulacij. Ta pristop vključuje tudi učenje iz vedenja celotnih vozniških parkov z uporabo naprednih metod, kot je učenje prenosa, in uporablja orodja za samodejni pregled za nepristransko oceno stanja komponent, s čimer se poveča natančnost prognostičnih modelov s stalnim prilagajanjem in učenjem. SmartSignal je na voljo kot samostojen programski izdelek ali kot integrirana komponenta programske rešitve GE Digital Asset Performance Management (APM). Nove funkcije vključujejo edinstveno analitiko časa do ukrepanja za napovedovanje, kdaj lahko pride do okvare. Nova analitika časa za ukrepanje napoveduje, kdaj bo anomalija opreme dejansko dosegla mejo alarma in zahtevala takojšnjo odpravo. Te informacije omogočajo inženirjem zanesljivosti in vzdrževanja, da natančno določijo prednostne naloge in načrtujejo korektivne ukrepe, da ohranijo delovanje operacij in opreme. Poleg zagotavljanja

nič nenačrtovanih izpadov SmartSignal zdaj pomaga zmanjšati odzivnost dela in optimizirati načrtovanje operacij in vzdrževanja (O&M). (Ramon, 2021)

Optimizacija dobavne verige je še eno področje, na katero UI pomembno vpliva. UI lahko analizira velike količine podatkov, da napove povpraševanje, optimizira raven zalog in načrtuje najučinkovitejšo pot za dostavo. To lahko močno zmanjša stroške in izboljša zadovoljstvo strank. Amazon uporablja UI za optimizacijo dostavnih poti paketov in upravljanje obsežnega logističnega omrežja. V ta namen podjetje organizira tekmovanje "Last mile routing research challenge" v sodelovanju s Tehnološkim inštitutom v Massachusettsu. Cilj tega sodelovanja je spodbuditi udeležence k razvoju inovativnih pristopov, ki izkoriščajo UI, ML, DL, računalniški vid in druge nekonvencionalne metode za izdelavo rešitev problema sekvenciranja poti, ki presegajo tradicionalne, optimizacijsko usmerjene operativne raziskovalne metode v smislu kakovosti rešitev in računskih stroškov (Amazon Last mile routing, 2021). Vsaka od 6.112 poti je izvirala iz enega od 17 skladišč v ZDA in je sestavljena iz zbirke postajališč, ki jih voznik obišče na določen dan. Število postankov se giblje od najmanj 32 do največ 237. Povprečno število postankov je bilo 148. Za vsak postanek, ki ga je treba obiskati, podatki vključujejo čas potovanja v sekundah do vseh drugih postankov na poti, ID območja, časovno okno za čas dostave, zemljepisno širino in dolžino, informacije o velikosti paketov, ki jih je treba dostaviti, in še več. Potovalni časi od postajališča do konca so asimetrični, kar pomeni, da zaradi pretoka prometa predvideni čas potovanja od postajališča x do postajališča y morda ni enak času potovanja od y nazaj do x. Naloga iskanja optimalne (najhitrejše) poti za voznika je primer asimetričnega problema trgovskega potnika (angl. Asymmetric Traveling Salesman Problem - ATSP). Pomembno je, da podatki za 6.112 poti vključujejo tudi dejansko zaporedje postankov na poti, ki jim je sledil voznik kombija. Vsaka vožnja voznika je iz nerazkritih razlogov razvrščena kot »visoka« kakovost (2.718 primerkov), »srednja« kakovost (3.292 primerkov) ali »nizka« kakovost (102 primerka). Namesto standardnega cilja, ki je zmanjšanje skupnega časa potovanja, tekmovanje zahteva poti, ki se tesno ujemajo z »visokimi« kakovostnimi potmi, ki jih opravijo izkušeni vozniki. Čeprav neposredna optimizacija poti ni v središču izziva, bo amazonska knjižnica 6.112 praktičnih primerov ATSP dragocen vir za raziskovalno skupnost. Algoritem je tako izračunal visokokakovostne rešitve za te omejene primerke v manj kot sekundi. Tako izpolnjuje zahteve izračunavanja na tisoče potovanj v obdobju načrtovanja resnične logistične aplikacije. Zasnovan je tako, da obvladuje omejitve, kot je zahteva, da se voznik iz postaje A med vožnjo ustavi še pri postaji B do cilja C. Analiza večjih podatkovnih

nizov (s ponavljajočimi se obiski istih ulic) bi lahko izkoristila to možnost in zajela lokalne želje voznikov kombijev.

Raziskovanje večplastnih aplikacij UI v avtomobilski industriji razkriva preobrazbeno okolje, v katerem tehnologija ne le povečuje operativno učinkovitost, temveč tudi na novo opredeljuje možnosti vzdrževanja vozil, spremljanja stanja vozila in logističnih operacij. Skozi objektiv DeepMindovega prodora v stanje in GE diagnostiko vozil postanejo napovedne sposobnosti UI očitne in kažejo prihodnost, v kateri lahko vpogledi, ki temeljijo na UI, preventivno obravnavajo okvare vozil, s čimer se zmanjša čas izpadov in podaljša življenjska doba avtomobilskih delov. Ta proaktivni pristop k vzdrževanju, ki je značilen za industrijo 4.0, poudarja premik k inteligentnim, podatkovno vodenim procesom odločanja, ki obljublajo, da bodo znatno zmanjšali stroške in povečali zanesljivost. Poleg tega razprava o Amazonovi uporabi UI pri optimizaciji dostave in logistike ponazarja velik vpliv inteligentnih algoritmov pri racionalizaciji dobavne verige. Z izkoriščanjem moči ML in sofisticirane podatkovne analitike Amazon ponazarja, kako lahko UI izkoristimo za optimizacijo načrtovanja poti, upravljanja zalog in procesov dostave, s čimer se povečata učinkovitost in zadovoljstvo strank v avtomobilskem sektorju. S časom je jasno, da bo uspešna implementacija UI ključni dejavnik v sposobnosti industrije za prilagajanje, inovacije in uspeh v vse bolj digitalnem svetu.

3.2.1 Umetna inteligenca in optimizacija proizvodnje

V dinamičnem svetu proizvodnje je potreba po optimizaciji proizvodnih procesov ključnega pomena. Iskanje učinkovitosti, stroškovne učinkovitosti in kakovosti je privedlo do raziskovanja različnih inovativnih tehnik. V tem poglavju je predstavljen pristop, ki združuje UI, ML in simulacijske tehnike za optimizacijo proizvodnih procesov. Bistvo tega pristopa je koncept večnamenskih modelov. Ti modeli so zasnovani za različne vidike strojne obdelave. Algoritmi ML se uporabljajo za učenje iz podatkov in pripravo napovedi ali odločitev, ne da bi bili izrecno programirani za izvajanje naloge. Tehnike iskanja pa se uporabljajo za sistematično raziskovanje prostora problema. Rezultat kombinacije teh dveh tehnik so robustni in vsestranski modeli, ki lahko obravnavajo številne scenarije pri strojni obdelavi. Ključni element tega pristopa je blokovno usmerjen okvir. To ogrodje je namenjeno modeliranju in optimizaciji procesnih verig. Gre za modularni sistem, kjer vsak blok predstavlja drug vidik proizvodnega procesa. Bloki so med seboj povezani, kar omogoča celovit pregled celotne

procesne verige. Uporabnost okvira je prikazana z optimizacijo postopkov rezanja, kar kaže, da lahko bistveno izboljša učinkovitost in produktivnost. Blokovno usmerjeno ogrođje podpira tudi optimizacijo celotnih proizvodnih obratov na podlagi simulacije. To je pomemben napredek, saj omogoča optimizacijo proizvodnega procesa na makro ravni. Ena od glavnih prednosti tega pristopa je možnost nadomestitve zamudne simulacije z modeli umetnih nevronske mreže (angl. Artificial Neural Network - ANN). ANN so računalniški sistemi po vzoru bioloških NN, ki so del živalskih možganov, in so odlični pri prepoznavanju vzorcev in napovedovanju. Z uporabo ANN je postopek optimizacije po navadi veliko hitrejši in učinkovitejši. Za olajšanje postopka optimizacije se uporabi različno programsko orodje. Ena od metodologij, ki se uporablja, je večplasten pristop, zasidran z uporabo naprednih programskih programov, kot je "Tecnomatix Plant Simulation", podjetja Siemens, uporabnega za podrobno analizo proizvodnih sistemov in logističnih procesov s ciljem optimizacije pretoka materiala in uporabo virov za vse ravni načrtovanja proizvodnega procesa programov, kot je "Tecnomatix Plant Simulation", podjetja Siemens, uporabnega za podrobno analizo, modeliranje, simuliranje in vizualiziranje proizvodnih sistemov in logističnih procesov s ciljem optimizacije pretoka materiala in uporabo virov za vse ravni načrtovanja proizvodnega procesa (Siemens, 2024). Ta začetna faza je ključnega pomena pri razumevanju proizvodne dinamike različnih naložbenih možnosti, izpostavljanju potencialnih ozkih grl in oblikovanju strategij za povečanje produktivnosti linij. Naslednje faze vključujejo poglobljeno oceno z uporabo matrik. Ta obsežna metodologija poudarja vsestranskost programskih programov pri omogočanju celovitega preučevanja priložnosti za optimizacijo proizvodnje. Inženirji svetovno znanega nemškega avtomobilskega proizvajalca so iskali sodobno in optimizirano proizvodno linijo za zelo uspešen komercialni kombi podjetja. Z več kot 3,4 milijona dobav gospodarskih vozil iz različnih proizvodnih obratov je podjetje želelo orodje za optimizacijo, ki bi bilo prilagodljivo za uporabo v različnih tovarnah in ki bi upoštevalo tehnologije, kot so avtonomno vodena vozila (angl. Automated Guided Vehicle - AGV). V prvi fazi projekta je bilo doseženo 5 % povečanje učinkovitosti in ugotovljeni nadaljnji pomembni dobički za naslednjo fazo (Anylogic, 2023). Želeli so vedeti, kako bi ob upoštevanju učinkovitosti in optimizacije morali inženirji načrtovanja zagotoviti, da se soočijo z izzivi proizvodne linije komercialnih dostavnih vozil. Spremenljivke, ki so jim bile podane, so bile: uporaba opreme, združevanje delovne sile, izgubljeni čas zaradi prometa, čakanja, preparkiranja, prevožene razdalje, število pomanjkanj montažne linije, ravni ponovnega naročanja zalog, izkoriščenost dostave. Tradicionalne tehnike analize, ki temeljijo na preglednicah, ne morejo upoštevati kompleksnosti sodobne avtomobilske proizvodne linije, kot so procesi, ki so vključeni, in odnosi med njimi. Poleg tega

je treba za celovito obravnavo narave montažne linije upoštevati dinamično spremenljivost hitrosti transportnih vozil, prometne razmere, dostop do skupnih virov in povpraševanja. Simulacija ponuja način zajemanja kompleksnosti montažne linije in njene dinamične narave. S simulacijsko programsko opremo lahko inženirji proizvodnega procesa modelirajo svojo montažno linijo s knjižnico za ravnanje z materiali, se povežejo z zunanjimi knjižnicami programske opreme in razvijajo elemente po meri. Postavitev modela je konfigurirana kot parameter z razčlenitvijo datoteke DXF v proizvodnji. To pomeni, da lahko načrtovalec proizvodnje spremeni postavitev s svojo programsko opremo za oblikovanje tal, kot je AutoCAD, in jo hitro preizkusi v simulaciji. "Real data sourcing" pomeni, da se vsak del, lokacija, prevoznik in naročilo naloži in nastavi kot agent na začetku simulacije. Ta granularnost zagotavlja zelo nizko raven abstrakcije in visoko stopnjo podobnosti modela realnemu stanju. Da bi zagotovili prilagodljivost in se tako prilagodili hitrim spremembam, ki se dogajajo v sodobni proizvodnji, so razvijalci uporabili modularni pristop oblikovanja. To pomeni, da je mogoče nov razvoj in spremembe procesov modelirati neodvisno in enostavno vključiti v celoten model za analizo. Po pomoči pri potrditvi začetne izvedbe projekta AGV se model še naprej uporablja za preverjanje projektov pred izvedbo in optimiziranje proizvodnih procesov. Model pomaga oceniti učinkovitost ročnih procesov, podpira implementacije AGV in podpira delo, ki vodi v popolnoma avtomatizirano proizvodno telo. Kot primer uspešnosti modela lahko navedemo, da je že prvi korak ocenjevanja delovne sile z več kot 70 zaposlenimi prinesel 5 % povečanje učinkovitosti, drugi korak pa je pokazal še 5 % povečanje, ki ga je mogoče doseči z avtomatizacijo (Anylogic, 2023). V zvezi z namenom ocene učinkovitosti je treba omeniti, da simulacija zdaj zagotavlja 90 % izračunov, ki jih je načrtovalec prej moral opraviti ročno, kar pomaga prihraniti čas in zagotoviti dodatno preverjanje.

V tem poglavju je bil predstavljen pristop k optimizaciji proizvodnih procesov z uporabo kombinacije UI, ML in simulacijskih tehnik. Uspeh v praksi izvedenega projekta in praktična uporaba, kaže na uporabnost in potencial tega hibridnega pristopa. Ker se proizvodna industrija še naprej razvija, bodo takšne tehnike igrale ključno vlogo pri povečevanju učinkovitosti, produktivnosti in splošne uspešnosti.

3.2.2 Pregled zakonodajnih priporočil za uporabo umetne inteligence

V dinamičnem okolju UI je EU sprejela odločitev za pripravo zakonodaje, namenjeno usklajevanju razvoja, uvedbe in uporabe tehnologij UI. To poglavje predstavlja regulativni pristop EU in poudarja njeno zavezanost spodbujanju inovacij ob hkratnem zagotavljanju, da UI služi javnemu dobremu, spoštuje temeljne pravice in spoštuje etične standarde. V središču zakonodajnega okvira EU je Akt o umetni inteligenci (Evropski parlament, 2024), celovita uredba, namenjena vzpostavitvi enotnih pravnih standardov v vseh državah članicah. Akt o umetni inteligenci uvaja ključno spremembo s sistemom razvrščanja tehnologij UI na podlagi tveganja. Ta okvir razvršča sisteme UI glede na stopnjo tveganja, ki ga predstavljajo od minimalnega tveganja do nesprejemljivega tveganja in v skladu s tem določa stopnje skladnosti. Aplikacije z visokim tveganjem, ki so ključne v sektorjih, kot so kritična infrastruktura, biometrična identifikacija in različni institucionalni konteksti (kot sta izobraževanje ali zaposlovanje), bodo pred uvedbo zahtevale strogo oceno in certificiranje. V skladu z opredelitvijo ravni tveganja morajo uvajalci sistemov UI z visokim tveganjem izvesti temeljite ocene tveganja in vzpostaviti podrobne sisteme za upravljanje tveganja. Te ukrepe je treba nenehno posodabljati, da se odzovejo na spreminjajoče se grožnje, regulativni organi pa jih morajo zlahka revidirati, da zagotovijo stalno spoštovanje pravnih standardov. Za zaščito etičnih standardov in javne blaginje akt postavlja jasne meje, tako da nekatere prakse UI popolnoma prepoveduje. Te prepovedi vključujejo manipulativno UI, ki izkorišča ranljivosti za spodkopavanje avtonomije uporabnika, sisteme UI, ki uporabljajo podzavestne tehnike za neopazno vplivanje na posameznikova dejanja, in mehanizme socialnega točkovanja, ki bi lahko povzročili diskriminacijo. Zaradi "črne skrinjice" UI Akt uvaja zahteve po preglednosti. Upravitelji sistemov UI morajo zagotoviti izčrpno dokumentacijo, v kateri so podrobno opisani postopki usposabljanja podatkov-ozroma učenja, zmogljivosti sistema in načini odločanja. Ta preglednost ne olajšuje le postopka certificiranja, temveč tudi krepi zaupanje javnosti, saj je delovanje UI razumljivo in odgovorno. Namen Akta o umetni inteligenci Evropskega parlamenta oziroma uredbe Evropskega parlamenta in Sveta o določitvi harmoniziranih pravil o umetni inteligenci (akt o umetni inteligenci) in spremembi nekaterih zakonodajnih aktov Unije je izboljšati delovanje notranjega trga z določitvijo enotnega pravnega okvira, zlasti za razvoj, dajanje na trg, začetek uporabe in uporabo sistemov UI v Uniji v skladu z vrednotami Unije, spodbujati uvajanje na človeka osredotočene in zaupanja vredne UI ob zagotavljanju visoke ravni zaščite zdravja, varnosti, temeljnih pravic iz Listine, vključno z demokracijo in pravno državo, ter varstva okolja pred škodljivimi učinki sistemov

UI v Uniji in podpirati inovacije (Evropski parlament, 2024). Glavni cilj Akta je izboljšati delovanje notranjega trga z zagotavljanjem, da se sistemi UI razvijajo in uporabljajo v skladu z vrednotami EU, temeljnimi pravicami in varstvom okolja. Zakonodaja poudarja pomen UI, osredotočene na človeka in zaupanja vredne. Opisuje vizijo UI, ki ne spodbuja le inovacij in gospodarske rasti, temveč daje prednost tudi varstvu pravic posameznikov in družbenih vrednot. EU se zavzema za varno, pregledno in odgovorno UI ter postavlja svetovna merila za etični razvoj in uporabo UI. Temelj akta je sprejetje pristopa k ureditvi UI, ki temelji na tveganju. Ta pristop razlikuje med aplikacijami UI na podlagi njihovega morebitnega tveganja za javne interese in temeljne pravice, kar omogoča prilagojene regulativne ukrepe.

V zakonodaji so opredeljene posebne prakse in aplikacije UI, ki veljajo za nesprejemljive, poudarjeno pa je stališče EU glede zaščite državljanov pred škodljivimi tehnologijami UI. Te prepovedi obravnavajo manipulativne tehnike, ki spodkopavajo avtonomijo, diskriminatorno družbeno točkovanje s strani javnih ali zasebnih akterjev in nepooblaščen biometrično identifikacijo na javno dostopnih mestih. Preglednost in odgovornost sta ključni za zakonodajni okvir EU, saj zagotavljata, da so sistemi UI razumljivi in pod strogim nadzorom. Zakon navaja jasne prakse dokumentiranja, vodenja evidenc in razkritja za razvijalce UI, s čimer se krepijo pravice posameznikov in odgovornosti upravljavcev UI. Čeprav se uredba osredotoča na varovanje pravic in varnosti, priznava tudi ključno vlogo inovacij in raziskav pri spodbujanju UI. EU si prizadeva najti ravnovesje med regulativnim nadzorom ter spodbujanjem znanstvenega raziskovanja in tehnološkega napredka. Sprejete so posebne določbe za spodbujanje ekosistema, ki podpira zagonska podjetja in raziskovalne ustanove pri vodenju etičnega razvoja UI. Da bi omogočili izvrševanje te uredbe in ustvarili enake konkurenčne pogoje za izvajalce ter upoštevali različne oblike dajanja na voljo digitalnih proizvodov je, kot navaja Akt o umetni inteligenci, pomembno zagotoviti, da lahko oseba s sedežem v Uniji v vseh okoliščinah organom zagotovi vse potrebne informacije o skladnosti sistema UI. Zato ponudniki s sedežem zunaj Unije, preden dajo svoje sisteme UI na voljo Uniji, s pisnim pooblastilom imenujejo pooblaščenega zastopnika s sedežem v Uniji.

3.3 Umetna inteligenca in zmanjšanje emisij

V dobi hitrega tehnološkega napredka je preplet UI in skrbnega ravnanja z okoljem postal ključna osrednja točka. Globalni izziv spremljanja in upravljanja emisij toplogrednih plinov je še vedno zapleteno in nerešeno vprašanje. Vendar je pomemben preboj dosegla koalicija z imenom Climate TRACE (angl. Tracking Real-Time Atmospheric Carbon Emissions). Climate TRACE združuje strokovnjake s področja UI, podatkovne znanstvenike, raziskovalce in nevladne organizacije, ki so objavili prvi popis največjih znanih posameznih virov onesnaževanja s toplogrednimi plini na ravni objektov. Ta popis predstavlja kar 162 milijonov ton onesnaževanja s toplogrednimi plini, ki se dnevno sproščajo v troposfero. Skupno prizadevanje koalicije je namenjeno celovitemu razumevanju izvora onesnaževanja, ki je v 30 letih od začetka svetovnih pogajanj o zmanjšanju emisij toplogrednih plinov ostalo večinoma brez odgovora. Ta pobuda je še posebej aktualna, saj se je na tisoče podjetij, bank, vlagateljev in 88 držav zavezalo, da bodo do leta 2050 zmanjšali emisije na ničelno vrednost. Spremljanje napredka pri doseganju tega cilja je ključnega pomena, zlasti glede na poročila, ki kažejo, da svet močno zaostaja pri hitrosti, ki je potrebna za doseganje ciljev zmanjšanja emisij do leta 2030. To poglavje obravnava vlogo UI pri tej pomembni nalogi ter osvetljuje inovativne pristope in skupna prizadevanja, ki oblikujejo prihodnost zmanjševanja emisij. Združitev tehnologije in okoljske odgovornosti je obetavna pot v trajnostno prihodnost, delo Climate TRACE pa ponazarja potencial UI pri prispevanju k tem globalnim prizadevanjem.

V sodobnem času je izziv zmanjšanja emisij postal svetovna prednostna naloga. Prometni sektor, zlasti v pristaniških mestih, pomembno prispeva k emisijam toplogrednih plinov in zastojem. V tem poglavju je obravnavano, kako se UI in analiza podatkov uporabljata za reševanje teh izzivov, s posebnim poudarkom na študiji primera Valencie v Španiji. Pristaniška mesta pogosto trpijo zaradi prometnih zastojev, kar vodi do povečanja emisij toplogrednih plinov in negativnih vplivov na kakovost življenja, zdravje in lokalno gospodarstvo. Uporaba UI in ML ponuja obetavno rešitev za te izzive. V pristanišču Valencia se je obseg tovara stalno povečeval, kar je povzročilo večje zastoje v času prometnih konic. Stroški zastojev v velikih gospodarstvih, kot so ZDA, Združeno kraljestvo in Nemčija, so leta 2017 znašali skoraj 461 milijard dolarjev (Lehmacher, 2022). V Valencii je bil razvit sistem UI za napovedovanje pretoka kontejnerjev med pristaniščem in mestom. Ta sistem združuje informacije iz več virov podatkov vzdolž multimodalne dobavne verige od globalnih informacijskih sistemov za plovila do sistemov lokalnih pristaniških skupnosti. (The Maritime Executive, 2022) To omogoča

oceno natančnosti napovedi več sestavnih modelov in omogoča simulacijo sprememb parametrov, kot so ure delovanja, ne da bi bilo treba model ponovno usposobiti. Primer v Valencii je pokazal, da lahko podatki, izmenjava podatkov in sistemi UI prispevajo k zmanjšanju zastojev in emisij toplogrednih plinov. Analiza in simulacija, ki ju poganja UI, sta pripomogli k izravnavi konic, povečanju produktivnosti infrastrukture. Pametni koncept v kontekstu pristaniškega mesta poudarja digitalno povezovanje na več ravneh, vključno s pristaniščem, mestom, zaledjem, obalo in globalnim omrežjem pristanišč. Ta digitalna povezljivost je ključnega pomena za optimizacijo pretoka blaga in ljudi, zmanjšanje zamud, stroškov in emisij. Preobrazba v pametna mesta in pristanišča zahteva obsežno digitalizacijo, izmenjavo podatkov in celostno uporabo podatkov. Uporaba UI pri zmanjševanju emisij v pristaniških mestih pomeni pomemben napredek na področju trajnostnega razvoja. Z uporabo podatkov, napovednega modeliranja in inovativnih tehnologij so mesta, kot je Valencia, pionirji novih načinov upravljanja zastojev in zmanjševanja emisij. Spoznanja iz tega poglavja poudarjajo potencial UI kot močnega orodja v globalnih prizadevanjih za doseganje bolj trajnostne in okoljsko odgovorne prihodnosti.

4. Analiza izbranih podatkov in ugotovitve

Avtomobilska industrija je že dolgo pod drobnogledom zaradi svojega znatnega prispevka k svetovnim emisijam toplogrednih plinov. Zaradi vse večje nujnosti boja proti podnebnim spremembam so se začela usklajena prizadevanja za iskanje inovativnih rešitev za zmanjšanje emisij. UI je v tem pogledu obetavna tehnologija, ki ponuja številne aplikacije, ki lahko prispevajo k bolj trajnostnemu avtomobilskemu sektorju. Nekaj učinkovitosti, ki jih poganja UI, je naštetih v nadaljevanju:

- optimizacija porabe goriva: algoritmi UI lahko analizirajo vzorce vožnje, prometne razmere in zmogljivost vozila ter tako optimizirajo porabo goriva. S predvidevanjem najboljših poti in svetovanjem o učinkovitem načinu vožnje lahko UI znatno zmanjša porabo goriva in s tem tudi emisije.
- Prediktivno vzdrževanje: omogoča pomoč napovedne analitike, s katero lahko UI predvidi, kdaj bodo deli vozila odpovedali ali potrebovali vzdrževanje. Pravočasno vzdrževanje zagotavlja optimalno učinkovitost vozila in preprečuje nepotrebne emisije.
- Upravljanje energije v električnih vozilih: UI lahko upravlja porabo energije v električnih vozilih z optimizacijo uporabe baterije in urnikov polnjenja. To zagotavlja učinkovito rabo energije iz omrežja, spodbuja uporabo obnovljivih virov energije in zmanjšuje skupne emisije.
- Avtonomna vožnja in avtonomna vozila: UI lahko z učinkovitejšo vožnjo zmanjša emisije. Z usklajevanjem z drugimi vozili in prometnimi sistemi lahko avtonomna vozila zmanjšajo zastoje in omogočijo bolj tekoč promet, kar vodi k manjšim emisijam.
- Optimizacija proizvodnega procesa: vpliv UI ni omejen le na vozila, temveč se razteza tudi na proizvodni proces. Z optimizacijo proizvodnih linij in zmanjšanjem količine odpadkov lahko UI poveča energetske učinkovitost in prijaznost do okolja pri proizvodnji vozil. Vključevanje obnovljivih virov energije je še ena področje, na katero lahko vpliva UI.

4.1 Pregled izbranih podatkov

Leta 2019 je prometna industrija prispevala približno 25 % svetovnih emisij toplogrednih plinov, kar jo uvršča na drugo mesto med sektorji z največ proizvedenimi emisijami. To poglavje obravnava ključno vlogo avtomobilskega sektorja pri teh emisijah, raziskuje in

razpravlja o znatni učinkovitosti, ki jo je mogoče doseči z UI, in podaja pregled podatkov. Avtomobilski sektor je glavno gonilo gospodarske dejavnosti, saj prispeva 7 % celotnega BDP EU. Leta 2014 so kombinirana tovorna vozila v ZDA prevozila 273,2 milijarde kilometrov, porabila 110,1 milijarde litrov goriva in izpustila približno 6,9 milijarde ton ekvivalenta CO₂. Z boljšimi strategijami optimizacije bi lahko dosegli znatno zmanjšanje porabe goriva in emisij CO₂, s čimer bi lahko prihranili 24,1 milijarde litrov goriva in 15,3 milijona ton CO₂ na leto. Do leta 2040 bo predvidoma 75 % vseh vozil avtonomnih, morda celo prej. Ta sprememba naj bi zmanjšala število prometnih nesreč, saj trenutni statistični podatki 93 % prometnih nesreč pripisujejo človeški napaki. Sistemi zgodnjega opozarjanja, ki voznikom dajejo dodatnih 1,5 sekunde časa za odziv, bi lahko preprečili do 90 % možnih scenarijev prometnih nesreč. Prehod na avtonomna vozila je ključna točka za povečanje varnosti v cestnem prometu in zmanjšanje izgub, povezanih z nesrečami. UI je postala ključno orodje za povečanje energetske učinkovitosti v avtomobilski industriji. Trenutne raziskave kažejo, da je potencialni prihranek energije od 13 % do 115 % z inteligentnimi strategijami nadzora in optimizacije. Uporaba UI v skoraj ničenergijskih stavbnih sistemih je pokazala, da lahko mesečne račune za elektriko zmanjša za približno 87 % (Zhengxuan et al., 2020). Sposobnost UI, da obvladuje zapletene logistične operacije, se kaže v njeni uporabi pri načrtovanju na tisoče potovanj za logistiko v realnem času. Učinkovito upravlja omejitve, kot so obvezni postanki, in optimizira poti na podlagi ponavljajočih se lokalnih vzorcev, s čimer povečuje učinkovitost delovanja in zmanjšuje emisije. Dvostopenjska ocena delovne sile, ki je štela več kot 70 oseb, je pokazala, da se je učinkovitost sprva povečala za 5 %, z naslednjo fazo avtomatizacije pa se je sprostilo dodatnih 5 %. Ta študija primera poudarja potencial avtomatizacije za povečanje učinkovitosti poslovanja in tudi za prispevanje k širšim okoljskim ciljem z učinkovitejšim izkoriščanjem virov. Vključevanje UI v avtomobilski sektor bo spremenilo podobo uporabe vozil, porabe energije in emisij. Avtonomne tehnologije in UI postajajo vse bolj razširjene, zato so možnosti za velike okoljske in gospodarske koristi ogromne. Podatki, predstavljeni v tem poglavju, poudarjajo, da so za uresničitev teh koristi nujno potrebne stalne naložbe v tehnologijo in infrastrukturo ter da je UI komaj začela prispevati k napredku zmanjševanja emisij.

4.2 Vpliv umetne inteligence na zmanjšanje emisij

UI je postala transformativna tehnologija, ki lahko revolucionarno spremeni različne panoge, vključno z varčevanjem z energijo, proizvodnjo in varstvom okolja. Eden najpomembnejših učinkov UI je njena vloga pri zmanjševanju emisij in optimizaciji proizvodnih procesov. V tem

poglavju so obravnavani večplastni načini, na katere UI prispeva k tem področjem. Poudarjen je potencial UI za spodbujanje trajnostne prihodnosti.

- Blažitev podnebnih sprememb

Zmožnosti napovedovanja UI omogočajo natančno napovedovanje prihodnjih emisij ogljika na podlagi trenutnih podatkov, kar omogoča proaktivne ukrepe za zmanjšanje ogljičnega odtisa. Z analizo preteklih podatkov lahko UI prepozna vzorce in trende, ki vodijo k učinkovitejši porabi energije in zmanjšanju emisij.

- Varčevanje z energijo

Uporaba UI pri varčevanju z energijo je obsežna in raznolika. Optimizacija porabe energije v stavbah, upravljanje električnih omrežij in spodbujanje obnovljivih virov energije UI prispevajo k znatnemu zmanjšanju emisij ogljika. Orodja, kot sta napovedno vzdrževanje in spremljanje v realnem času, omogočajo energetska učinkovitost, zmanjšanje količine odpadkov in splošno trajnost.

- Trajnostno okolje

Vključevanje UI v prizadevanja za varstvo okolja je privedlo do inovativnih rešitev za zmanjšanje emisij ogljika. UI ima ključno vlogo pri ustvarjanju trajnostnega okolja od napovedovanja podnebnih dogodkov do obvladovanja podnebnih sprememb z zmanjšanjem emisij in večjo absorpcijo ogljika.

UI pri optimizaciji proizvodnje in proizvodnje:

- Farmacevtska in kemična proizvodnja

V panogah, kot sta farmacevtska in kemična proizvodnja, UI analizira kompleksne podatke za optimizacijo produktivnosti in učinkovitosti. Z razumevanjem osnovnih vzorcev lahko sistemi UI preprečijo premajhno proizvodnjo, zmanjšajo količino odpadkov in izboljšajo splošno učinkovitost ter s tem zmanjšajo emisije.

- Proizvodna industrija

Vloga UI v proizvodni industriji je vse večja, saj se uporablja za različne aplikacije od predvidljivega vzdrževanja do zmanjševanja odpadnega materiala. Z avtomatizacijo procesov in uporabo inteligentnih algoritmov UI povečuje produktivnost, zmanjšuje

količino odpadkov in optimizira proizvodno linijo, kar vodi v okolju prijaznejši proizvodni proces.

- Optimizacija dobavne verige

Z uporabo UI lahko proizvajalci optimizirajo procese, zmanjšajo stroške in izboljšajo produktivnost. Poleg tega vloga UI pri optimizaciji dobavne verige zagotavlja učinkovito dodeljevanje virov, kar še dodatno zmanjšuje emisije.

Učinek UI na emisije je večplasten in globok. Njena uporaba pri zmanjševanju emisij, varčevanju z energijo ter optimizaciji proizvodnih in proizvodnih procesov dokazuje njen potencial za spodbujanje trajnostne prihodnosti. Z uporabo napovednih zmožnosti, analitičnih vpogledov in optimizacijskih tehnik UI lahko industrija znatno zmanjša emisije in prispeva k svetovnim prizadevanjem za boj proti podnebnim spremembam. Nadaljnje raziskovanje in vključevanje UI v različne sektorje obeta veliko za doseganje okoljske trajnosti in zmanjšanje globalnega ogljičnega odtisa. Primeri in spoznanja iz tega poglavja poudarjajo preobrazbeni potencial UI pri oblikovanju bolj zelene in odgovorne prihodnosti.

4.3 Ugotovitve študije primera

V tem poglavju so združene ugotovitve obravnavanih primerov, ki preučujejo vpliv UI na zmanjšanje emisij v avtomobilski industriji. S pregledom empiričnih analiz ugotavljamo zmogljivosti UI za povečanje učinkovitosti porabe goriva, optimizacijo logističnih operacij in prispevanje k splošnemu zmanjšanju emisij toplogrednih plinov. Vključevanje UI v sisteme vozil je bistveno izboljšalo porabo goriva. Študije so pokazale, da lahko UI predvidi porabo goriva z absolutno relativno napako manj kot 10 %. Takšna natančnost napovedi omogoča učinkovitejše delovanje vozila in načrtovanje poti, kar neposredno prispeva k manjši porabi goriva in zmanjšanju emisij. V ZDA bi na primer z optimizacijo UI prihranili 24,1 milijarde litrov goriva na leto, kar pomeni zmanjšanje emisij CO₂ za 15,3 milijona ton. To kaže na potencial UI pri doseganju znatnega vpliva na okolje samo zaradi večjega izkoristka goriva. Pričakuje se, da bo prehod na avtonomna vozila, podprt z UI, drastično zmanjšal število prometnih nesreč in posledično tudi emisije zaradi mirujočih vozil, ki so obtičala v prometu. Avtonomna vozila naj bi do leta 2040 predstavljala 75 % avtomobilskega trga, zato so možnosti za zmanjšanje emisij velike (IEEE, 2023). UI izboljšuje varnostne funkcije vozil, zmanjšuje

število nesreč zaradi človeških napak, ki so odgovorne za 93 % nesreč, ter tako zmanjšuje zastoje in s tem povezane emisije pri prostem teku. Vloga UI v logističnih aplikacijah še dodatno poudarja njeno zmožnost zmanjšanja emisij. Sistemi UI, zasnovani za logistično načrtovanje v realnem času, lahko optimizirajo poti in zmanjšajo število nepotrebnih potovanj ter tako učinkovito zmanjšajo ogljični odtis prevoznih dejavnosti. Analiza obsežnih zbirk podatkov, kot je primer podatkov o dostavah v mestih, omogoča UI prepoznavanje in izvajanje najučinkovitejših poti, s čimer se prihrani gorivo in zmanjšajo emisije. Podrobne študije primerov, vključno z izvajanjem UI v skoraj ničenergijskih stavbnih sistemih, dokazujejo zmanjšanje porabe energije do 87 % s pomočjo inteligentnih sistemov za upravljanje energije. Takšni sistemi ne optimizirajo le svojega delovanja, temveč prispevajo tudi k širšemu zmanjšanju povpraševanja po energiji v omrežju in posledično k zmanjšanju emisij. Pregledani podatki in študije potrjujejo, da UI pomembno prispeva k zmanjšanju emisij v avtomobilski industriji. UI se je z izboljšanjem učinkovitosti goriva, omogočanjem širjenja avtonomnih vozil in optimizacijo logističnih operacij izkazala za ključno orodje v boju proti podnebnim spremembam. Nadaljnji napredek na področju tehnologije UI obeta še večje zmanjšanje emisij, kar poudarja pomen naložb in inovacij na tem področju.


5. Primerjava količine emisij z in brez uporabe umetne inteligence

S prihodom UI so se v različnih panogah začele korenite spremembe, ki imajo pomembne posledice za okoljsko upravljanje in trajnost. Namen tega poglavja je preučiti različne vplive sistemov, ki vključujejo tehnologije UI, na emisije v primerjavi s sistemi, ki teh tehnologij ne vključujejo, zlasti v avtomobilskem in energetske sektorju. Poudarek je na tem, kako lahko rešitve, ki jih poganja UI, optimizirajo operativno učinkovitost in zmanjšajo ogljični odtis na teh področjih. UI zajema vrsto tehnologij, ki strojem omogočajo zaznavanje, razumevanje, delovanje in učenje s človeku podobno stopnjo inteligence. Za avtomobilski ter naftni in plinski sektor so najbolj pomembni ML, NN in okrepljeno učenje. Vsi ti so temelji tehnologije za razvoj sistemov, ki se lahko dinamično učijo in optimizirajo vedenje za zmanjšanje emisij. Avtomobilski sektor se je tradicionalno spopadal z obvladovanjem emisij zaradi neučinkovitosti pri delovanju vozil in upravljanju prometa. Podobno se naftna in plinska industrija srečujeta z izzivi, kot so sežiganje ter izpuščanje in uhajanje, ki znatno prispevajo k onesnaževanju okolja. UI ponuja nove priložnosti za ublažitev teh težav z izboljšano analizo podatkov in zmožnostmi napovedovanja.

V študiji iz leta 2022, ki so jo izvedli raziskovalci z univerze MIT, je bila raziskana nova aplikacija UI, katere namen je bil skrajšati čas mirovanja avtonomnih vozil na semaforjih. Tradicionalna vozila in avtonomni sistemi pogosto porabijo veliko količino goriva, ko stojijo v prostem teku pri rdeči luči, kar prispeva k nepotrebnim emisijam. S simulacijami so ugotovili, da njihov pristop zmanjšuje porabo goriva in emisije ter hkrati povečuje povprečno hitrost vozila. Tehnika daje najboljše rezultate, če so vsi avtomobili na cesti avtonomni, vendar tudi, če le 25 % avtomobilov uporablja njihov algoritem za nadzor, to še vedno pomeni znatno zmanjšanje porabe goriva in emisij (Zewe, 2022). Avtonomna vozila se lahko z uporabo algoritmov učenja z ojačitvijo naučijo in prilagodijo svoje obnašanje pri ustavljanju in zagonu, da zmanjšajo čas mirovanja. Takšne izboljšave ne pomenijo le zmanjšanja porabe goriva, temveč tudi občutno zmanjšanje emisij mestnih vozil. »V primerjavi z drugimi metodami optimizacije, ki so prav tako zasnovane za preprečevanje prometa z ustavljanjem in speljevanjem, je njihova tehnika prinesla večje zmanjšanje porabe goriva in emisij. Če bo vsako vozilo na cesti avtonomno, lahko njihov nadzorni sistem zmanjša porabo goriva za 18 % in emisije CO₂ za 25 %, hkrati pa poveča potovalne hitrosti za 20 % (Zewe, 2022). Takšna uporaba UI bi lahko revolucionarno spremenila mestne prometne sisteme z izboljšanjem

pretočnosti in zmanjšanjem onesnaževal iz izpušnih plinov ter tako zagotovila bolj zeleno in učinkovito mestno okolje.

Medtem je skupina Boston Consulting Group (BCG) leta 2021 poudarila uporabo UI v naftni in plinski industriji ter se osredotočila na njeno sposobnost učinkovitega upravljanja emisij (Lyons et al., 2021) Industrija, ki je ključni dobavitelj goriv za avtomobile, je znana po visokih ravneh emisij zaradi sežiganja, izpuščanja in puščanja. Z uporabo UI lahko podjetja zdaj bolje spremljajo in optimizirajo delovanje, povečajo učinkovitost in zmanjšajo nenamerne emisije. Orodja UI omogočajo napovedno vzdrževanje, ki preprečuje okvare opreme, ki bi lahko povzročile velike emisije. BCG je v publikaciji podrobno opisala, kako so ti sistemi UI izboljšali skladnost z zakonodajo, saj hitreje odkrivajo in odpravljajo operativne težave ter tako zmanjšujejo vplive na okolje. Podjetja za izkoriščanje in pridobivanje nafte lahko za zmanjšanje ogljičnega odtisa uporabijo šest vzvodov. Kljub temu večini še ni uspelo bistveno zmanjšati emisij iz področij 1 in 2, za katere so odgovorne. Le redkim je uspelo natančno izračunati količino emisij iz področja 3, ki jih ustvarijo stranke, kaj šele, da bi si močno prizadevali za njihovo zmanjšanje.



Source: BCG analysis.

Note: CCUS = carbon capture, utilization, and storage; GHG = greenhouse gas emissions; O&G = oil and gas; O&M = operations and maintenance.

Slika 5: Emisije naftne in naftne industrije po vrednostni verigi in prispevek k svetovnim emisijam (vir: Lyons et al., 2021)

Vendar pa lahko podjetja s popolnim vključevanjem teh vzvodov v vse svoje dejavnosti dejansko učinkovito zmanjšajo svoje neposredne in posredne emisije. V ta namen bodo morala podjetja čim natančneje opredeliti in izmeriti svoje emisije, določiti optimalna sredstva za njihovo zmanjšanje, izvesti zmanjšanje ter nato zagotoviti popolno in natančno poročilo o svojih prizadevanjih za razogljčenje. Ta industrija je odgovorna za 10 % svetovnih emisij toplogrednih plinov z neposrednimi emisijami iz dejavnosti v okviru področja 1 in še 31 % s posrednimi emisijami v okviru področij 2 in 3. Glede na obseg emisij te industrije pa zgolj diverzifikacija na nizkoogljične energetske alternative ne bo zadostovala za zmanjšanje emisij na sprejemljivo raven. Tudi emisije iz področja 3 je treba znatno omejiti, če naj industrija resnično prispeva k zmanjšanju skupnih svetovnih emisij ogljika. Vendar pa je le malo podjetij oblikovalo cilje za zmanjšanje emisij iz področja 3 ali pa so se lotila izziva, da bi razumela njihov obseg in kako jih razogljčiti. Ta orodja lahko skupaj z UI in ML podjetjem pomagajo pri ugotavljanju virov in gonilnih sil emisij (lastnih ter dobaviteljev in strank), zmanjšanju porabe energije in optimizaciji energetske učinkovitosti lastnih dejavnosti. Prav takšno prizadevanje je na primer enemu operaterju O&G (Oil and Gas) omogočilo, da je opredelil načine za zmanjšanje 500 milijonov ton emisij ekvivalenta CO₂ iz področij 1 in 2, kar predstavlja 30 % njegovih skupnih emisij. Od tega bi lahko 15 % zmanjšali z izboljšanjem operativne in energetske učinkovitosti, 60 % s preходом na opremo in vire energije in toplote z nižjimi emisijami ogljika, 5 % pa z manjšim številom sežiganja, izpustov in nezajetih emisij. Podjetje je pridobilo tudi večjo preglednost nad kompromisi med različnimi pobudami za zmanjšanje emisij (Lyons et al., 2021).

Tradicionalni prometni sistemi in prakse upravljanja energije se ne prilagajajo dinamično spreminjajočim se razmeram, kar pogosto povzroči neoptimalno delovanje in večji vpliv na okolje. Vključevanje tehnologij UI je pokazalo obetavne rezultate pri zmanjševanju emisij. Kot je prikazano v študijah primerov, lahko avtonomna vozila z UI ter optimizirane naftne in plinske operacije znatno zmanjšajo nepotreben prosti tek in naključne emisije. Ta proaktivni pristop ne koristi le okolju, temveč tudi povečuje splošno gospodarsko učinkovitost.

UI ima z izboljšano učinkovitostjo in inovativnimi rešitvami velik potencial za zmanjšanje emisij v avtomobilskem ter naftnem in plinskem sektorju. Čeprav izzivi ostajajo, pa pot naprej vključuje usklajena prizadevanja za raziskave, razvoj in premišljeno vključevanje tehnologij UI za doseganje globalnih okoljskih ciljev.

6. Sklep

V diplomski nalogi je bila poglobljeno raziskana vloga UI v avtomobilski industriji s posebnim poudarkom na optimizaciji poti tovornih vozil, splošni uporabi UI pri optimizaciji proizvodnih procesov in morebitni prihodnji zakonodaji na to temo. Avtomobilska industrija doživlja pomembno preobrazbo, ki jo poganja vključevanje tehnologij UI. Te tehnologije ne povečujejo le učinkovitosti in produktivnosti industrije, temveč prispevajo tudi k zmanjšanju emisij in s tem spodbujajo trajnost. UI je ključnega pomena pri optimizaciji poti tovornih vozil, kar vodi k manjši porabi goriva, nižjim stroškom in boljšim dobavnim časom. To optimizacijo je industrija dosegla z naprednimi algoritmi, ki upoštevajo različne dejavnike, kot so promet, vremenske razmere in cestna infrastruktura. Na področju proizvodnje je prav tako prepoznana pomembna vloga UI. Omogočila je avtomatizacijo zapletenih procesov, kar je povečalo učinkovitost in zmanjšalo količino odpadkov. Sistemi UI se med drugim uporabljajo za napovedovanje in preprečevanje okvar opreme, optimizacijo proizvodnih urnikov in izboljšanje nadzora kakovosti. Uporaba UI v proizvodnji ni prinesla le večje produktivnosti, temveč je prispevala tudi k zmanjšanju celotnega ogljičnega odtisa industrije. V prihodnosti bo vloga UI v avtomobilski industriji verjetno oblikovala prihodnja zakonodaja. Ker se vlade po vsem svetu spopadajo z izzivi podnebnih sprememb, se vse bolj osredotočajo na spodbujanje trajnostnih praks v vseh sektorjih, tudi v avtomobilski industriji. Zakonodaja bo verjetno spodbujala uporabo tehnologij UI, ki prispevajo k zmanjšanju emisij in spodbujajo trajnost. Na koncu lahko rečemo, da je ta diplomska naloga potrdila hipoteze, ki so bile postavljene. Uporaba UI v avtomobilski industriji lahko bistveno zmanjša emisije. Uporaba sistemov UI v avtomobilski industriji lahko izboljša trajnost, ne da bi pri tem ogrozila učinkovitost ali produktivnost. Vključevanje UI v postopke načrtovanja in proizvodnje v avtomobilski industriji lahko privede do zmanjšanja celotnega ogljičnega odtisa industrije. Ugotovitve poudarjajo transformacijski potencial UI v avtomobilski industriji. Če bomo še naprej izkoriščali moč UI, se lahko veselimo prihodnosti, v kateri avtomobilska industrija ne bo le učinkovitejša in produktivnejša, temveč tudi bolj trajnostna.

7. Literatura

Accident Analysis & Prevention, 186: 107034. <https://doi.org/10.1016/j.aap.2023.107034>.

Amazon. 2021. Amazon Last Mile Routing, 2021: <https://routingchallenge.mit.edu/>

Anylogic. 2023. Automotive Production Process Optimization: Avon-Fontainebleau, Anylogic <https://www.anylogic.com/resources/case-studies/automotive-production-process-optimization/>

Appen. 2020. Five Challenges of Artificial Intelligence for Automotive Applications. Sydney, Appen. <https://appen.com/blog/challenges-artificial-intelligence-for-automotive-applications/>

Barai, K. 2003. Data mining applications in transportation engineering. Transport 18(5): 216–223.

https://www.researchgate.net/publication/26526470_Data_mining_applications_in_transportation_engineering

Bhattacharjee, P., Rakshit, P., Goswami, I., Konar, A., Nagar, A. K. 2011. Multi-robot path-planning using artificial bee colony optimization algorithm. Salamanca, Third World Congress on Nature and Biologically Inspired Computing: 219–224. <https://doi.org/10.1109/NaBIC.2011.6089601>

Bhatti, U. A. (ur.), Hashmi, M. Z. (ur.), Nizamani, M. M. (ur.), Masud, M. (ur.). 2023 Artificial Intelligence Applications in Reduction of Carbon Emissions: Step Towards Sustainable Environment. Editorials. Frontiers. <https://www.frontiersin.org/research-topics/40836/artificial-intelligence-applications-in-reduction-of-carbon-emissions-step-towards-sustainable-environment>

CARILEC. 2023. Green AI: The Role of Artificial Intelligence in Energy Conservation. St. Lucia, Caribbean Electric Utility Services Corporation. <https://www.carilec.org/green-ai-the-role-of-artificial-intelligence-in-energy-conservation/>

Divjak, S. 2024. Kaj je umetna inteligenca. Ljubljana, Univerza v Ljubljani, Fakulteta za računalništvo in informatiko.

El Kihel, Y., El Kihel, A., Bouyahrouzi, E. M. 2022: Contribution of Maintenance 4.0 in Sustainable Development with an Industrial Case Study. Sustainability: 14(17): 11090. <https://www.mdpi.com/2071-1050/14/17/11090>

Elcher, P. 2021. Going Beyond the Tailpipe for Automaker Sustainability Using AI. Pure Storage. <https://blog.purestorage.com/perspectives/going-beyond-the-tailpipe-for-automaker-sustainability-using-ai/>

Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., Dean, J. 2019. A guide to deep learning in healthcare. Nature Medicine, 25(1), 24–29:

European Automobile Manufacturers' Association. 2023. Facts about the automobile industry. <https://www.acea.auto/fact/facts-about-the-automobile-industry/>

European Commission. 2023. Reducing CO2 emissions from heavy-duty vehicles. EU Climate Action. Brussels, European Commission. https://climate.ec.europa.eu/eu-action/transport/road-transport-reducing-co2-emissions-vehicles/reducing-co2-emissions-heavy-duty-vehicles_en

European Commission. 2024. 2023 figures show stalling progress in reducing road fatalities in too many countries. Brussels, European Commission, Directorate-General for Mobility and Transport. https://transport.ec.europa.eu/news-events/news/2023-figures-show-stalling-progress-reducing-road-fatalities-too-many-countries-2024-03-08_en

Evropska komisija. 2024. Umetna inteligenca. Bruselj, Evropska komisija. <https://digital-strategy.ec.europa.eu/en/policies/artificial-intelligence>

Evropski parlament in Svet. 2023. Corrigendum to Regulation (EU) 2019/1242 of the European Parliament and of the Council of 20 June 2019 setting CO2 emission performance standards for new heavy-duty vehicles and amending Regulations (EC) No 595/2009 and (EU) 2018/956 of the European Parliament and of the Council and Council Directive 96/53/EC (Official Journal of the European Union L 198 of 25 July 2019). OJ L 39, 9.2.2023, p. 67–67.

Evropski parlament. 2024. Artificial intelligence act. Bruselj, Evropski parlament. [https://www.europarl.europa.eu/RegData/etudes/BRIE/2021/698792/EPRS_BRI\(2021\)698792_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/BRIE/2021/698792/EPRS_BRI(2021)698792_EN.pdf)

Evropski svet. 2024. Umetna inteligenca. Bruselj, Evropski svet. <https://www.consilium.europa.eu/sl/policies/artificial-intelligence/>

Garikapati, D., Shetiya, S. S. 2024. Autonomous Vehicles: Evolution of Artificial Intelligence and the Current Industry Landscape. Big Data and Cognitive Computing, 8(4): 42. <https://doi.org/10.3390/bdcc8040042>

General Electric. 2024. Project Predictive Maintenance. Cincinnati, General Electric <https://www.ge.com/research/project/predictive-maintenance#-1>

Gheorghe, G., & Cristea, G. 2020. Performance Evaluation for a Sustainable Supply Chain Management System in the Automotive Industry Using Artificial Intelligence. *Processes*, 8(11): 1384. <https://doi.org/10.3390/pr8111384>

Guo, A., Yuan, C. 2021. Network Intelligent Control and Traffic Optimization Based on SDN and Artificial Intelligence. *Electronics*, 10(6): 700. <https://doi.org/10.3390/ELECTRONICS10060700>

Haraldson S. 2022. How AI Could "Flatten the Curve" of Port Infrastructure Utilization. <https://maritime-executive.com/editorials/how-ai-could-flatten-the-curve-of-port-infrastructure-utilization>

Hashikami, H., Kobayashi, R., Li, Y., Nakano, Y., Shigeno, M. 2023. Safe Route Carpooling to Avoid Accident Locations and Small-Scale Proof of Concept in Japan. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 53(7): 4239–4250. <https://doi.org/10.1109/TSMC.2023.3243720>

Heflich, A., & Evas, T. 2021. Artificial intelligence in road transport - Cost of non-Europe report. Brussels, European Parliament, European Parliamentary Research Service. [https://www.europarl.europa.eu/RegData/etudes/STUD/2021/654212/EPRS_STU\(2021\)654212_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2021/654212/EPRS_STU(2021)654212_EN.pdf)

Inštitut za slovenski jezik Frana Ramovša ZRC SAZU. 2021. Umetna inteligenca. Ljubljana, Inštitut za slovenski jezik Frana Ramovša ZRC SAZU. <https://isjfr.zrc-sazu.si/sl/terminologisce/svetovanje/umetna-inteligenca>

IPROM. 2024. Okrepljeno učenje. Ljubljana, IPROM. <https://iprom.si/slovar/okrepljeno-ucenje/>

Ismael, K., Esztergár-Kiss, D., Duleba, S. 2023. Evaluating the quality of the public transport service during the COVID-19 pandemic from the perception of two user groups. *European Transport Research Review*, 15(5): 1–18. <https://doi.org/10.1186/s12544-023-00578-1>

Jensen, S. 2016. Follow the Leader. OEM off highway. <https://www.oemoffhighway.com/electronics/sensors/proximity-detection-safety->

[systems/article/12233087/truck-platooning-for-improved-efficiency-safety-and-emissions-reduction](#)

Jiang, Y., Hsiao, T. 2021. Deep Learning in Perception of Autonomous Vehicles. Proceedings of the 2021 International Conference on Public Art and Human Development (ICPAHD 2021). Advances in Social Science, Education and Humanities Research, 638. Dordrecht, Atlantis Press: 561–565.

Kristalniy, S. R., Popov, N. V. Ivanov, A. M., Dyakov, K., Andreev, A. N. 2022. Evaluation of the Joint Interaction of Automatic Emergency Braking and Adaptive Cruise Control Systems. Systems of Signals Generating and Processing in the Field of on Board Communications. Moscow, 15–17 March 2022. IEEE: 1–5. <https://doi.org/10.1109/IEEECONF53456.2022.9744297>

Lee, H., Park, J., Koo, C., Kim, J.-C., Eun, Y. 2022. Cyclops: Open Platform for Scale Truck Platooning. IEEE International Conference on Robotics and Automation (ICRA), Philadelphia, 23–27 May 2022: 8971–8977. <https://arxiv.org/pdf/2202.05385.pdf>

Lehmacher, W., Lind, M., Poikonen, J., Meseguer, J. Cárcel Cervera, J. L. 2022. Reducing port city congestion through data analysis, simulation, and artificial intelligence to improve the well-being of citizens. Journal of Mega Infrastructure & Sustainable Development: 65–82.

Lehmacher, W., Lind, M., Poikonen, J., Meseguer, J., Cárcel Cervera, J. C. 2022. Reducing port city congestion through data analysis, simulation, and artificial intelligence to improve the well-being of citizens. Journal of Mega Infrastructure & Sustainable Development, 2(sup1): 65–82. <https://doi.org/10.1080/24724718.2022.2133524>

Li, X. & Zhang, Y. 2022. The Innovation Ecological Model of Chinese Automotive Industry Based on Artificial Intelligence and Big Data Technology. Mathematical Problems in Engineering, 2022. <https://dx.doi.org/10.1155/2022/4328187>

Lv, H., Shi, B., Li, N., Kang, R. 2022. Can Artificial Intelligence Improve the Energy Efficiency of Manufacturing Companies? Evidence from China. International Journal of Environmental Research and Public Health, 19(4): 2091. <https://doi.org/10.3390/ijerph19042091>

Lyons, M., Appathurai, S., Vasquez, M., Bolikowski, L., Alcalá, P., Carducci, F., Tarabelloni, N. 2021. The AI Angle in Solving the Oil and Gas Emissions Challenge. Boston, Boston

Consulting Group. <https://www.bcg.com/publications/2021/ai-in-oil-and-gas-emissions-challenge>

Mira, K., Bugiotti, F., Morosuk, T. 2023. Artificial Intelligence and Machine Learning in Energy Conversion and Management. *Energies*, 16(23): 1–36. <https://doi.org/10.3390/en16237773>

Mohammed, G. P., Alasmari, N., Alsolai, H., Alotaibi, S. S., Alotaibi, N. Mohsen, H. 2022. Autonomous Short-Term Traffic Flow Prediction Using Pelican Optimization with Hybrid Deep Belief Network in Smart Cities. *Applied Sciences*, 12(21): 10828. <https://doi.org/10.3390/app122110828>

Monostori, L., Viharos, Z. J. 2001. Hybrid, AI- and simulation-supported optimisation of process chains and production plants. *CIRP Annals – Manufacturing Technology*, 50(1): 353–356. http://old.sztaki.hu/~viharos/homepage/Publications/2001_CIRP_ANNALS/cirp_2001_GAc.pdf

Muratori, M., Holden, J., Lammert, M., Duran, A., Young, S., Gonder, J., 2017. Potentials for Platooning in U.S. Highway Freight Transport. *SAE International Journal of Commercial Vehicles*, 10(1): 1–5. <https://www.nrel.gov/docs/fy17osti/67618.pdf>

Musoumi, S. M., Kazemi, N., Salwa Hanim, A.-R. 2019. Sustainable Supply Chain Management in the Automotive Industry: A Process-Oriented Review. *Sustainability*, 11(14): 3945. <https://doi.org/10.3390/su11143945>

Narasimha, S. B. 2015. Predictive Modeling of Fuel Efficiency of Trucks. Binghamton, Binghamton University. https://orb.binghamton.edu/cgi/viewcontent.cgi?article=1017&context=dissertation_and_theses

Nine, A. 2024. The 5 Levels of Autonomous Driving Explained. <https://www.extremetech.com/cars/the-5-levels-of-autonomous-driving-explained>

OECD. 2024. OECD AI Principles overview. Paris, OECD.

Porsche AG. 2021. Earth Day 2021: Seven Ways Porsche is Leading the Sustainability Charge. Zuffenhausen, Porsche AG. <https://www.porsche.com/stories/culture/earth-day-2021-seven-ways-porsche-is-leading-the-sustainability-charge>

Russell, P. 2015. How Autonomous Vehicles Will Profoundly Change The World. Loughborough, Loughborough University.
<https://myaidrive.com/dcjdtYNt22gunvUT/HowAutonomou.pdf> . 40-43

Russell, S. J., Norvig, P. 2016. Artificial Intelligence: A Modern Approach. Harlow, Pearson Education.
<https://ds.amu.edu.et/xmlui/bitstream/handle/123456789/10406/artificial%20intelligence%20%20a%20modern%20approach%20%283rd%2C%202009%29.pdf?sequence=1&isAllowed=y>

SAE International. 2021. SAE J3016 Levels of Driving Automation. Washington, SAE International. <https://www.sae.org/blog/sae-j3016-update>

San, R. 2021. A new perspective. Cambridge, GE Vernova. <https://www.ge.com/news/press-releases/ge-digitals-smartsignal-predictive-maintenance-software-features-time-to-value>

Siemens. 2024. Plant Simulation. München, Siemens. <https://plm.sw.siemens.com/en-US/tecnomatix/products/plant-simulation-software/>

Statista. 2024. Electric Vehicles – Worldwide. Statista.
<https://www.statista.com/outlook/mmo/electric-vehicles/worldwide>

Stephen, P. 2021. How AI can solve manufacturing's waste problem. Geneva, World Economic Forum. <https://www.weforum.org/agenda/2021/04/how-ai-can-cut-waste-in-manufacturing/>

Suleyman, M. 2018. A major milestone for the treatment of eye disease. London, DeepMind Technologies Limited. <https://deepmind.google/discover/blog/a-major-milestone-for-the-treatment-of-eye-disease/>

Sutton, R. S. 2020. John McCarthy's Definition of Intelligence. Journal of Artificial General Intelligence, 11(2): 66-67. <https://doi.org/10.2478/jagi-2020-0003>

Tasič, J. F., Plesnik, E. 2018. Nevronske mreže. Ljubljana, Univerza v Ljubljani, Fakulteta za elektrotehniko.

Tselentis, D. I., Papadimitriou, E., van Gelder, P. 2023. The usefulness of artificial intelligence for safety assessment of different transport modes. Accident Analysis & Prevention, 186(June 2023): 107034. <https://doi.org/10.1016/j.aap.2023.107034>

- Verdecchia, R., Sallou, J., Cruz, L. 2023. A Systematic Review of Green AI. Journal WIREs Data Mining and Knowledge Discovery, 13(4): 1–26. <https://arxiv.org/abs/2301.11047>
- Wang, L., Sun, P., Xie, M., Ma, S., Li, B., Shi, Y., Su, Q. 2020. Advanced Driver-Assistance System (ADAS) for Intelligent Transportation Based on the Recognition of Traffic Cones. Advances in Civil Engineering, 2020: 1–8.
- Wang, L., Sun, P., Xie, M., Ma, S., Li, B., Shi, Y., Su, Q. 2020. Advanced Driver-Assistance System (ADAS) for Intelligent Transportation Based on the Recognition of Traffic Cones. Advances in Transportation Geotechnics, 2020: 8883639. <https://doi.org/10.1155/2020/8883639>
- Werbinska-Wojciechowska, S., Winiarska, K. 2023. Maintenance Performance in the Age of Industry 4.0: A Bibliometric Performance Analysis and a Systematic Literature Review. Sensors, 23(3): 1409. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9919563/>
- World Health Organization. 2023. Global status report on road safety 2023. Geneva, World Health Organization. <https://www.who.int/publications/i/item/9789240086517>
- Yao, Y., Zhao, X., Liu, C., Rong, J., Zhang, Y., Dong, Z., Su, Y. 2020. Vehicle Fuel Consumption Prediction Method Based on Driving Behavior Data Collected from Smartphones. Journal of Advanced Transportation, 2020: 1–11. <https://doi.org/10.1155/2020/9263605>
- Yifang, M., Zhenyu W., Hong Y., Yang, L. 2020. Artificial Intelligence Applications in the Development of Autonomous Vehicles: A Survey. IEEE/CAA Journal of Automatica Sinica, 7(2): 315-329. <https://doi.org/10.1109/JAS.2020.1003021>
- Zainal, N. A., Ghani, J. A., Nuawi, M. Z., Haron, C. H. C., Case, K. 2022. Energy Optimization for Milling 304L Steel using Artificial Intelligence Methods. International Journal of Automotive and Mechanical Engineering, 19(3): 7691. <https://doi.org/10.15282/ijame.19.3.2022.05.0765>
- Zewe, A. 2022. On the road to cleaner, greener, and faster driving. Cambridge, Massachusetts Institute of Technology. <https://news.mit.edu/2022/ai-autonomous-driving-idle-0517>
- Zhang, P., Zhang, H., Sun, X., Li, P., Zhao, M., Xu, S., Jiao, X., Sun, Z., Zhang, T. 2023. Research on carbon emission standards of automobile industry in BRI participating countries. Cleaner and responsible consumption, 8: 1.

Zhang, Y., Li, X. 2021. Artificial Intelligence and Its Roles in the R&D of Vehicle Powertrain Products. *International Journal of Advanced Manufacturing and Materials*, 1(1): 6.
<https://doi.org/10.53941/ijamm0101006>

Zhang, Y., Zhang, Y., Zhang, Y. 2021. Artificial Bee Colony Algorithm for Fresh Food Distribution without Quality Loss by Delivery Route Optimization. *Journal of Food Quality*, 2021: 4881289.

Zhang, Y., Zhang, Y., Zhang, Y. 2022. Route Control and Behavior Decision of Intelligent Driverless Truck Based on Artificial Intelligence Technology. *Wireless Communications and Mobile Computing*, 2022: 7025081.

Zhao, D., Li, H., Hou, J., Gong, P., Zhong, Y., He, W., Fu, Z. 2023. A Review of the Data-Driven Prediction Method of Vehicle Fuel Consumption. *Energies*, 16(14): 5258.
<https://doi.org/10.3390/en16145258>