

Primjena generativne umjetne inteligencije u proizvodnji

Rogić, Jakov

Undergraduate thesis / Završni rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:540004>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-12-09**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Jakov Rogić

Zagreb, 2024.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentori:

Izv. prof. dr. sc. Hrvoje Cajner,
Dr. Sc. Mihael Gudlin.

Student:

Jakov Rogić

Zagreb, 2024.

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se roditeljima i prijateljima na velikom strpljenju koje su pokazali tijekom svih ispitnih rokova, a posebno zahvaljujem svojoj boljoj polovici, koja je bila najveći motivator, kritičar i prva osoba koja je dijelila sve uspjehe te me tješila u trenucima manjih zastoja.

Jakov Rogić



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

Središnje povjerenstvo za završne i diplomske ispite

Povjerenstvo za završne i diplomske ispite studija strojarstva za smjerove:
 proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
 materijala i mehatronika i robotika



Sveučilište u Zagrebu	
Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa: 602 – 04 / 24 – 06 / 1	
Ur.broj: 15 – 24 –	

ZAVRŠNI ZADATAK

Student: **Jakov Rogić** JMBAG: **0035228564**

Naslov rada na hrvatskom jeziku: **Primjena generativne umjetne inteligencije u proizvodnji**

Naslov rada na engleskom jeziku: **Application of Generative Artificial Intelligence in Manufacturing**

Opis zadatka:

Generativna umjetna inteligencija (Generative AI) predstavlja segment umjetne inteligencije koji se fokusira na stvaranje novih sadržaja, rješenja ili podataka koji mogu imitirati stvarne uzorke. Takva tehnologija uključuje modele koji mogu generirati tekstove, slike, zvukove i druge tipove podataka, a temelje se na velikim skupovima podataka iz kojih uče. U proizvodnji, Generative AI ima potencijal transformirati procese od dizajna proizvoda do personalizacije korisničkog iskustva i optimizacije lanaca opskrbe.

U radu je potrebno:

1. Proučiti primjene generativnog AI-a u proizvodnji te istražiti kako generativni AI modeli, uključujući one za obradu prirodnog jezika, mogu biti primijenjeni za poboljšanje proizvodnih procesa.
2. Ocijeniti prednosti koje generativni AI donosi u proizvodnji kao što su povećanje efikasnosti, smanjenje troškova, poboljšanje kvalitete i fleksibilnosti proizvodnih procesa.
3. Raspraviti izazove i ograničenja te tehničke, etičke i ekonomske prepreke koje mogu utjecati na integraciju generativnog AI-a u proizvodne sustave.
4. Analizirati jedan primjer primjene generativnog AI-a u tvornici za učenje.
5. Na temelju razrađenog primjera generalizirati zaključke iz perspektive općenite proizvodnje.

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:

30. 11. 2023.

Datum predaje rada:

1. rok: 22. i 23. 2. 2024.
 2. rok (izvanredni): 11. 7. 2024.
 3. rok: 19. i 20. 9. 2024.

Predviđeni datumi obrane:

1. rok: 26. 2. – 1. 3. 2024.
 2. rok (izvanredni): 15. 7. 2024.
 3. rok: 23. 9. – 27. 9. 2024.

Zadatak zadao:

Izv. prof. dr. sc. Hrvoje Čajner

Komentor: Dr. sc. Mihael Gudlin

Predsjednik Povjerenstva:

Prof. dr. sc. Damir Gođec

SADRŽAJ

SADRŽAJ	II
POPIS SLIKA	IV
POPIS TABLICA.....	V
SAŽETAK.....	VI
SUMMARY	VII
1. UVOD.....	1
1.1. Proizvodnja	1
1.2. Industrija 4.0	2
2. OSNOVE GENERATIVNE UMJETNE INTELIGENCIJE	5
2.1. Umjetna inteligencija	5
2.1.1. Strojno učenje	5
2.1.2. Duboko učenje	6
2.2. Generativna umjetna inteligencija	7
2.2.1. Generativne kontradiktorne mreže (GANs).....	8
2.2.2. Veliki jezični modeli (LLMs)	9
3. PRIMJENA GENERATIVNE UMJETNE INTELIGENCIJE U PROIZVODNJI	11
3.1. Optimizacija dizajna na primjeru automobilske industrije	12
3.1.1. Hibridni način rada	13
3.2. Planiranje proizvodnih procesa korištenjem generativne umjetne inteligencije.....	13
3.3. Kontrola kvalitete primjenom generativne umjetne inteligencije.....	15
4. PREDNOSTI GENERATIVNE UMJETNE INTELIGENCIJE U PROIZVODNJI.....	17
4.1. Prednosti primjene generativne umjetne inteligencije u dizajnu	17
4.1.1. Smanjenje troškova i resursna efikasnost	19
4.2. Prednosti primjene generativne umjetne inteligencije u planiranju proizvodnih procesa	20
4.2.1. Digitalni blizanci i konvolucijske neuronske mreže	20
4.3. Prednost primjene generativne umjetne inteligencije u kontroli kvalitete.....	22
5. IZAZOVI I OGRANIČENJA GENERATIVNE UMJETNE INTELIGENCIJE	25
5.1. Tehnički izazovi.....	25
5.2. Etički izazovi.....	26
5.2.1. Privatnost, povjerenje i pristranost.....	26
5.2.2. Autorska prava i akademski integritet.	27
5.2.3. Dezinformacije i lažnjaci (eng. Deepfakes).....	27
5.2.4. Transparentnost i odgovornost.....	27
5.3. Ekonomski izazovi.....	28
6. PRIMJENA GENERATIVNE UMJETNE INTELIGENCIJE U TVORNICI ZA UČENJE	29
6.1. Tvornice za učenje.	29
6.2. Primjer primjene generativne umjetne inteligencije u željezničkoj industriji.	30
6.2.1. Prikupljanje i analiza podataka.	30
6.2.2. Rezultati primjene	32
7. ZAKLJUČAK.....	34

LITERATURA..... 35

POPIS SLIKA

Slika 1.	Proces proizvodnje	2
Slika 2.	Devet stupova industrije 4.0 [1].	3
Slika 3.	Povijesni razvoj umjetne inteligencije [5].	5
Slika 4.	GAN model [5].	8
Slika 5.	Inženjer pregledava varijacije generativnog dizajna jednog proizvoda [9].	12
Slika 6.	Koraci hibridnog dizajna.	13
Slika 7.	Prikaz digitalnog blizanca tvornice BMW-a. [10].	14
Slika 8.	Stari dio kućišta sačinjen od osam manjih dijelova (lijevo) i novi jedinstveni komad dobiven generativnim dizajnom (desno).	18
Slika 9.	Tijek nadzornih proizvodnih procesa u digitalnim blizancima [13].	21
Slika 10.	Visokorezolucijske kamere koje prikupljaju vizualne podatke za obradu u kontroli kvalitete [14].	23
Slika 11.	Karakteristike i zadaci tvornice za učenje.	29
Slika 12.	Proces predviđanja korištenjem Gen AI-a [18].	31
Slika 13.	Graf temperatura kugličnih ležaja s obzirom na broj dana u pogonu.	32

POPIS TABLICA

Tablica 1. Usporedba vrsti umjetne inteligencije [5] 7
Tablica 2. Analiza klasičnog održavanja i prediktivnog održavanja implementacijom generativne umijetne inteliegnacije [18]. 33

SAŽETAK

U radu je obrađena tema primjene generativne umjetne inteligencije u proizvodnji. Na početku je objašnjen pojam Industrije 4.0 te sam koncept umjetne inteligencije, nakon čega su predstavljeni modeli generativne umjetne inteligencije. Prikazana je primjena umjetne inteligencije u različitim granama proizvodnje, uključujući dizajn, kontrolu kvalitete i planiranje proizvodnih procesa. Poseban naglasak stavljen je na izazove s kojima se kompanije susreću prilikom implementacije generativne umjetne inteligencije. Na primjeru tvornice za učenje, detaljno je analizirana primjena umjetne inteligencije u proizvodnji kugličnih ležajeva za željezničku industriju, pri čemu je obrađena učinkovitost prediktivnog održavanja.

Ključne riječi: industrija 4.0, umjetna inteligencija, generativna umjetna inteligencija, proizvodni procesi, prediktivno održavanje, kontrola kvalitete.

SUMMARY

The subject of the paper addresses the topic of applying generative artificial intelligence in manufacturing. The study explains the concept of Industry 4.0 and artificial intelligence itself, followed by an introduction to generative artificial intelligence models. The application of artificial intelligence in various branches of manufacturing, including design, quality control, and production process planning, is presented. Special emphasis is placed on the challenges companies face when implementing generative artificial intelligence. Using a learning factory as an example, the study provides a detailed analysis of the application of artificial intelligence in the production of ball bearings for the railway industry, focusing on the effectiveness of predictive maintenance.

Key words: industry 4.0, artificial intelligence, generative artificial intelligence, Production processes, predictive maintenance, quality control

1. UVOD

S obzirom na brzi razvoj tehnologije i transformaciju industrijskih praksi kroz koncept Industrije 4.0, generativna umjetna inteligencija (GAI) postaje sve važnija tema. Ne samo da će ova vrsta tehnologije automatizirati mnoge proizvodne procese, već će i omogućiti dizajn i inovacije i optimizaciju proizvodnih linija. Industrijska proizvodnja, jedan od ključnih sektora globalne ekonomije, prolazi kroz velike promjene zahvaljujući napretku u području umjetne inteligencije. Industrija 4.0 označava četvrtu industrijsku revoluciju, koja se temelji na digitalizaciji i povezanosti proizvodnih sustava [1]. U ovom kontekstu, umjetna inteligencija, a posebno generativni modeli, igraju ključnu ulogu u povećanju efikasnosti i inovativnosti unutar proizvodnih pogona [2]. Generativna umjetna inteligencija predstavlja specifičan aspekt AI tehnologije, koja je usmjerena na stvaranje novih sadržaja ili rješenja na temelju postojećih podataka. Ova tehnologija koristi se u različitim područjima, od dizajna novih proizvoda do optimizacije proizvodnih procesa [2]. Ovaj rad stavlja naglasak na procese proizvodnje u novoj industriji 4.0 i kako primjena generativnih AI modela može povećati učinkovitost cijelog procesa proizvodnje.

1.1. Proizvodnja

Kada govorimo o proizvodnji, podrazumijevamo složeni proces koji uključuje transformaciju sirovina u gotove proizvode putem različitih tehnoloških postupaka. Ovaj proces nije samo temelj svakodnevnog života, već i ključni pokretač ekonomskog rasta i inovacija. Proizvodnja se proteže od jednostavnih ručnih tehnika do sofisticiranih industrijskih operacija koje koriste napredne tehnologije poput automatizacije i umjetne inteligencije.

What is Manufacturing?



Slika 1. Proces proizvodnje

Cilj svakog proizvodnog procesa je kreiranje proizvoda koji zadovoljava specifične potrebe potrošača te ostvarivanje ekonomske vrijednosti kroz prodaju tih proizvoda na tržištu. U suvremenom svijetu svjedočimo značajnoj revoluciji poznatoj kao digitalizacija, koja je duboko transformirala i olakšala svakodnevni život. Ovaj trend snažno utječe i na industrijske procese, što je dovelo do razvoja koncepta poznatog kao Industrija 4.0.

1.2. Industrija 4.0

Industrija 4.0 predstavlja novu fazu industrijske revolucije koja se temelji na digitalnim tehnologijama. Od parne energije koja je pokretala tvornice u 19. stoljeću, preko elektrifikacije koja je omogućila masovnu proizvodnju u 20. stoljeću, te automatizacije koja je postala dominantna u 1970-ima, tehnološki napredak kontinuirano povećava industrijsku produktivnost [1]. Međutim, prethodni tehnološki napreci bili su uglavnom inkrementalni u usporedbi s dramatičnim promjenama koje su transformirale IT, mobilne komunikacije i e-trgovinu u posljednjim desetljećima.

Danas smo svjedoci četvrtog vala tehnološkog napretka poznatog kao Industrija 4.0. Ova transformacija, vođena napretkom u devet ključnih tehnologija [1], omogućava stvaranje pametnih tvornica u kojima su senzori, strojevi i IT sustavi međusobno povezani duž cijelog lanca vrijednosti, često unutar jedne organizacije. Ovi povezani sustavi, poznati i kao

kibernetičko-fizički sustavi, mogu međusobno komunicirati koristeći standardne internetske protokole, analizirati podatke kako bi predvidjeli kvarove, sami se konfigurirati i prilagođavati promjenama.



Slika 2. Devet stupova industrije 4.0 [1].

Kroz Industriju 4.0 moguće je prikupljati i analizirati podatke s različitih strojeva kako bi se omogućili brži, fleksibilniji i učinkovitiji proizvodni procesi koji rezultiraju visokokvalitetnim proizvodima uz smanjene troškove. U ovoj transformaciji, umjetna inteligencija (AI) igra ključnu ulogu kao katalizator inovacija i optimizacije proizvodnih procesa. AI omogućava analizu velikih količina podataka u stvarnom vremenu, prediktivno održavanje opreme, te optimizaciju lanca opskrbe, što rezultira povećanjem produktivnosti i smanjenjem troškova [3]. Primjena AI u okviru Industrije 4.0 ne samo da poboljšava operativnu učinkovitost, već i omogućava personalizaciju proizvoda, brzu prilagodbu promjenama na tržištu, i razvoj novih poslovnih modela. Ovaj spoj AI i Industrije 4.0 postavlja temelje za daljnji razvoj generativne umjetne inteligencije, koja će omogućiti još veću automatizaciju i inovaciju

unutar proizvodnih sustava, čime se otvaraju nove mogućnosti za prilagodbu i fleksibilnost proizvodnje na globalnom tržištu.

2. OSNOVE GENERATIVNE UMJETNE INTELIGENCIJE

2.1. Umjetna inteligencija

Kada govorimo o umjetnoj inteligenciji (*eng. Artificial intelligence*), podrazumijevamo sustave koji imaju sposobnost interpretiranja vanjskih podataka s velikom preciznošću, učenja iz tih podataka, i korištenja stečenog znanja za postizanje određenih rezultata i ciljeva [2].

AI sustavi postali su ključni alati u modernom poslovanju i industriji zbog svoje sposobnosti da analiziraju ogromne količine podataka, otkriju uzorke, i donesu predviđanja koja mogu pomoći u optimizaciji procesa i donošenju odluka. Kada govorimo o umjetnoj inteligenciji, važno je razumjeti da ona predstavlja rezultat više od 70 godina kontinuiranog razvoja i niza evoluiranih koncepata, koji je danas čine izuzetno moćnim alatom [5].



Slika 3. Povijesni razvoj umjetne inteligencije [5].

Iz priloženog vidimo da su ključni aspekti u tvorbi generativne umjetne inteligencije [5]:

- Strojno Učenje (*eng. Machine Learning*)
- Duboko Učenje (*eng. Deep Learning*)

2.1.1. Strojno učenje

Strojno učenje je podskup AI-a koji se fokusira na razvoj algoritama koji omogućavaju računalima da uče iz podataka i poboljšavaju se kroz iskustvo bez eksplicitnog programiranja. Ovi algoritmi identificiraju uzorke u podacima i koriste ih za donošenje predviđanja ili odluka. Glavne kategorije strojnog učenja su:

- **Nadzirano učenje (eng. *Supervised Learning*):**
 - Algoritmi uče iz označenih podataka, gdje svaki ulaz odgovara željenom izlazu.
 - Primjeri uključuju klasifikaciju (npr., prepoznavanje slika) i regresiju (npr., predviđanje cijena nekretnina).
- **Nenadzirano učenje (eng. *Unsupervised Learning*):**
 - Algoritmi rade s neoznačenim podacima, pokušavajući pronaći skrivene uzorke ili strukture.
 - Primjeri uključuju grupiranje (clustering) i redukciju dimenzionalnosti.
- **Pojačano učenje (eng. *Reinforcement Learning*):**
 - Algoritmi uče kroz interakciju s okruženjem, primajući nagrade ili kazne na temelju svojih akcija.
 - Koristi se u razvoju autonomnih sustava poput robota ili sustava za trgovanje.

2.1.2. Duboko učenje

Duboko učenje je podskup strojnog učenja koji koristi umjetne neuronske mreže inspirirane ljudskim mozgom za obradu podataka i stvaranje uzoraka za donošenje odluka. Karakterizira ga korištenje višeslojnih mreža (dubokih mreža) koje mogu modelirati složene nelinearne odnose. Duboko učenje predstavlja temeljni sloj svakog AI sustava jer omogućava napredak iz faze strojnog učenja te generira izlazne podatke, koji su konačni cilj svakog sustava [5].

Ključne značajke dubokog učenja su:

- **Višeslojne neuronske mreže:**
 - Sastoje se od ulaznog sloja, nekoliko skrivenih slojeva i izlaznog sloja.
 - Svaki sloj obrađuje podatke i prosljeđuje informacije sljedećem sloju, omogućavajući mreži da uči složene reprezentacije podataka.
- **Automatsko izdvajanje značajki:**

- Za razliku od tradicionalnih metoda koje zahtijevaju ručno inženjerstvo značajki, duboko učenje automatski uči relevantne značajke iz sirovih podataka.

- **Primjena na velike skupove podataka:**

- Duboko učenje posebno je učinkovito kada je dostupno puno podataka, što omogućava modelima da uče detaljne i precizne reprezentacije.

Povezujući rečeno, možemo napraviti usporedbu glavnih značajki i razlika između umjetne inteligencije, dubokog učenja i strojnog učenja kako bismo dobili jednostavniji pregled tih pojmova.

Tablica 1. Usporedba vrsti umjetne inteligencije [5]

	AI	Strojno učenje	Duboko učenje
Optimalni obujam podataka	Varijabilni obujam podataka	Tisuće podatkovnih točaka	Veliki podaci: milijuni podatkovnih točaka
Izlazi	Bilo što od predviđanja do preporuka i donošenja odluka	Numerička vrijednost, poput klasifikacije ili ocjene	Bilo što od numeričkih vrijednosti do slobodnih elemenata, poput slobodnog teksta i zvuka
Kako funkcionira	Strojevi su programirani da oponašaju ljudsku aktivnost s točnošću sličnom ljudskoj	Koristi različite vrste automatiziranih algoritama koji uče modelirati funkcije i predviđati buduće radnje na temelju podataka	Koristi neuronske mreže koje prolaze podatke kroz mnoge slojeve obrade kako bi interpretirale značajke podataka i odnose
Kako se upravlja	Algoritmi zahtijevaju nadzor čovjeka kako bi pravilno funkcionirali	Algoritmi su vođeni analitičarima podataka kako bi ispitali specifične varijable u podatkovnim skupovima	Algoritmi su uglavnom samostalno usmjereni na analizu podataka nakon što se uvedu u proizvodnju

2.2. Generativna umjetna inteligencija

Generativna umjetna inteligencija (GAI) predstavlja specifičnu podvrstu umjetne inteligencije usmjerenu na stvaranje novih podataka, sadržaja ili rješenja koji nisu samo replike postojećih podataka. Dok klasični AI modeli prepoznaju uzorke u postojećim podacima, generativna AI ide korak dalje, stvarajući potpuno nove informacije na temelju naučenih

obrazaca. Ovaj koncept postaje sve značajniji u različitim industrijama, uključujući proizvodnju, gdje generativna AI može značajno unaprijediti procese dizajna, optimizacije i inovacije.

GAI funkcionira na principu učenja iz velikih količina podataka kako bi stvorila nove, originalne uzorke.

Dva najkorištenija modela generativne umjetne inteligencije su:

- Generativne kontradiktorne mreže (eng. *Generative Adversarial Networks*).
- Visoko jezični modeli (eng. *Large Language Models*).

2.2.1. Generativne kontradiktorne mreže (GANs)

Prvi model generativnog AI-a se sastoji od dva modela, generator i diskriminator koji se međusobno nadmeću. Generator pokušava stvoriti vjerodostojne uzorke koji su slični stvarnim podacima, dok diskriminator pokušava prepoznati lažne uzorke među stvarnim podacima. Kroz ovaj proces nadmetanja, generator postaje sve bolji u stvaranju podataka koji mogu zavarati diskriminator, čime se poboljšava kvaliteta generiranih rezultata [6]. Glavna primjena ovih generativnih modela je generiranje slika, generiranje teksta oko slika itd.



Slika 4. GAN model [5].

2.2.2. Veliki jezični modeli (LLMs)

Ovaj model generativne umjetne inteligencije je skup algoritama dizajniranih da razumiju i generiraju ljudski jezik [8]. Ovaj model se trenira na velikim količinama podataka, koristeći kontekstualne veze između riječi ili simbola, omogućavajući mu stvaranje novih sadržaja koji su vrlo slični ljudskom jeziku.

LLM-ovi koriste transformersku arhitekturu, što je inovativna struktura neuronske mreže koja omogućava modelima da obrađuju podatke paralelno, umjesto sekvencijalno, što značajno ubrzava obradu. Ova arhitektura koristi mehanizam pažnje (attention mechanism) koji omogućava modelima da se fokusiraju na određene dijelove ulaznog teksta i tako bolje razumiju kontekst i značenje riječi.

Proces treninga LLM-ova možemo podijeliti u tri koraka [9]:

1. Prikupljanje i priprema podataka:

LLM-ovi se treniraju na ogromnim skupovima tekstualnih podataka prikupljenih s interneta, uključujući knjige, članke, web stranice, i druge izvore. Ovi podaci se pripremaju i formatiraju kako bi ih model mogao koristiti za učenje.

2. Učenje obrasca jezika:

Modeli uče identificirati obrasce, sintaksu, i semantiku jezika kroz višestruke slojeve neuronske mreže. Na primjer, model može naučiti da određene riječi često slijede jedna drugu ili da određene fraze imaju specifična značenja.

3. Generacija teksta:

Nakon treninga, modeli su sposobni generirati tekst koji je koherentan i kontekstualno relevantan. Ovisno o ulaznim podacima, modeli mogu pružiti odgovore na pitanja, sažeti tekstove, prevesti jezik, ili čak generirati kreativne sadržaje kao što su priče ili pjesme.

U okviru ovog rada, fokusirat ćemo se na korištenje velikih jezičnih modela, kako bismo istražili njihov utjecaj na modernu proizvodnju. Cilj je analizirati kako ovi modeli mogu povećati produktivnost, efikasnost i unaprijediti druge aspekte proizvodnih procesa

3. PRIMJENA GENERATIVNE UMJETNE INTELIGENCIJE U PROIZVODNJI

Generativna umjetna inteligencija omogućava transformaciju proizvodnih procesa kroz svoju sposobnost da stvara nove podatke, dizajnira proizvode i optimizira različite aspekte proizvodnje. Proizvodnja je široki spektar različitih zadataka gdje su vrijeme i količina grešaka izuzetno važni faktori. Kada bi smanjili te faktore, dolazimo do vrlo učinkovite proizvodnje, što je i krajnji cilj.

Generativna AI može se primjenjivati u različitim fazama proizvodnje, uključujući dizajn proizvoda, optimizaciju proizvodnih linija, kontrolu kvalitete, te prediktivno održavanje opreme. Na primjer, u automobilskoj industriji, General Motors koristi generativnu AI za optimizaciju dizajna automobilskih dijelova. Suradnja s Autodesk-om omogućila je GM-u da redizajnira držač sjedala pomoću generativnog dizajna, što je rezultiralo dijelom koji je 40% lakši i 20% jači od prethodnog dizajna [9]. Ova tehnologija ne samo da poboljšava performanse automobila, već i smanjuje troškove proizvodnje i lanaca opskrbe, što je posebno važno za razvoj električnih vozila. Slično tome, BMW koristi generativnu AI u suradnji s NVIDIA za simulaciju i optimizaciju svojih proizvodnih procesa. Korištenjem NVIDIA Omniverse platforme [10], BMW je razvio "digitalne blizance" svojih tvornica, što im omogućava virtualno testiranje i optimizaciju proizvodnih linija prije implementacije u stvarnom okruženju [10]. Ova tehnologija omogućava brže prilagodbe tvornica novim modelima vozila, povećavajući fleksibilnost i preciznost planiranja za 30% [10]. Ovaj pristup ne samo da poboljšava učinkovitost proizvodnje, već također omogućava BMW-u da odgovori na specifične zahtjeve kupaca kroz personalizaciju proizvoda.

U nastavku ćemo detaljno razmotriti konkretne primjene generativne AI u proizvodnji, uključujući primjere iz različitih industrija. Fokusirat ćemo se na specifične slučajeve upotrebe, kao što su:

- 1. optimizacija dizajna**
- 2. planiranje proizvodnih procesa**
- 3. kontrola kvalitete.**

Kroz detaljniju analizu ovih triju proizvodnih grana, steći ćemo dublje razumijevanje kako generativna AI transformira modernu proizvodnju i omogućava postizanje novih razina učinkovitosti i inovacija.

3.1. Optimizacija dizajna na primjeru automobilske industrije

Optimizacija dizajna je jedan od najvažnijih aspekata proizvodnog procesa gdje generativna umjetna inteligencija (AI) pokazuje svoj puni potencijal. Generativni AI modeli omogućuju inženjerima i dizajnerima da istraže tisuće ili čak milijune dizajnerskih varijacija u vrlo kratkom vremenu, uzimajući u obzir različite parametre kao što su materijali, troškovi, proizvodni procesi, i performanse. Kada govorimo o optimizaciji dizajna primjenom generativnog AI-a tad govorimo o generativnom dizajnu [9]. Generativni dizajn je način na koji istražujemo različita dizajnerska rješenja pomoću oblaka podatak i umjetne inteligencije kombinirajući inženjera i kompjuter [9].



Slika 5. Inženjer pregledava varijacije generativnog dizajna jednog proizvoda [9].

Jedan od najistaknutijih primjera primjene generativne AI u dizajnu dolazi iz automobilske industrije, gdje je General Motors (GM) koristio generativni dizajn za optimizaciju držača sjedala. U suradnji s Autodesk-om, GM je iskoristio generativni dizajn kako bi redizajnirao standardni auto dio, držač sjedala, koji pričvršćuje sigurnosni pojas za sjedalo i sjedalo za pod automobila.

Prije implementacije generativne AI, držač sjedala bio je sastavljen od osam zasebnih dijelova koji su se morali zavarivati zajedno. Korištenjem generativnog dizajna, AI je stvorio preko 150 različitih dizajnerskih opcija, od kojih je GM odabrao onaj koji je 40% lakši i 20%

jači od prethodnog dizajna [9]. Konačni proizvod bio je izrađen od jednog komada, što je značajno smanjilo kompleksnost proizvodnog procesa i troškove proizvodnje.

3.1.1. Hibridni način rada

Jedan od revolucionarnih aspekata generativnog dizajna je hibridni pristup [12], gdje umjetna inteligencija i dizajneri surađuju na stvaranju optimalnih rješenja. U ovom modelu rada, AI sustav predlaže dizajnerske opcije na temelju unesenih podataka i zadanih parametara, ali konačnu odluku i dalje donosi dizajner. Ova suradnja omogućava ljudskim dizajnerima da iskoriste AI-ovu snagu za istraživanje opcija koje možda ne bi sami mogli osmisliti, dok zadržavaju kontrolu nad estetikom i ključnim funkcionalnim karakteristikama.

U hibridnom modelu dizajna, AI analizira različite materijale i predlaže optimalne kombinacije na temelju njihovih svojstava i troškova. Autodesk Dreamcatcher [12], kao ključni primjer ovog pristupa, omogućuje dizajnerima da odaberu među mnogobrojnim varijantama dizajna, dok AI sustav prilagođava prijedloge prema inženjerskim i ekonomskim kriterijima. Ovaj sustav ne samo da ubrzava proces donošenja odluka, već također smanjuje potrebu za fizičkim prototipovima, čime se smanjuju troškovi i vrijeme razvoja.



Slika 6. Koraci hibridnog dizajna.

3.2. Planiranje proizvodnih procesa korištenjem generativne umjetne inteligencije

Planiranje proizvodnih procesa jedan je od ključnih izazova za industrije, a generativna umjetna inteligencija (AI) nudi ogromne mogućnosti za optimizaciju tog segmenta. Pomoću generativne AI, kompanije mogu bolje iskoristiti svoje resurse, smanjiti troškove i povećati

učinkovitost proizvodnje. Jedan od najistaknutijih primjera primjene dolazi iz suradnje između BMW-a i NVIDIA-e, gdje se koristi AI platforma za optimizaciju proizvodnih linija.

BMW koristi NVIDIA Omniverse [10] platformu za stvaranje digitalnih kopija svojih proizvodnih pogona, čime se omogućuje virtualno testiranje i optimizacija proizvodnih linija prije nego što se stvarne promjene implementiraju. Ova tehnologija omogućuje BMW-u da u stvarnom vremenu simulira različite proizvodne scenarije, identificira potencijalne uska grla i optimizira tokove materijala. Korištenje generativne AI na ovaj način omogućava kompaniji da brzo prilagodi proizvodne linije novim modelima vozila, smanjujući vrijeme prilagodbe i povećavajući fleksibilnost proizvodnog procesa za 30%[10]. BMW je poznat po svojoj prilagodljivosti u proizvodnji, jer dnevno proizvede desetak automobila s gotovo 40 mogućih modela, koji se mogu prilagoditi na više od 100 različitih načina.



Slika 7. Prikaz digitalnog blizanca tvornice BMW-a. [10].

Primjenom Omniverse platforme, inženjeri mogu upravljati proizvodnim procesima u bilo kojoj tvornici diljem svijeta. Korištenjem softverskih paketa kao što su Revit, Catia, i point cloud [10], BMW-ovi globalni timovi mogu surađivati u stvarnom vremenu, planirati i dizajnirati tvornice u 3D prikazu, gdje su sve promjene odmah vidljive na Omniverse platformi.

Implementacijom ovih tehnologija, posebno velikih jezičnih modela (LLMs), na globalne proizvodne linije, postiže se povezanost svih tvornica, što omogućava brže reagiranje na uočene nepravilnosti i značajno smanjenje vremena i troškova.

3.3. Kontrola kvalitete primjenom generativne umjetne inteligencije

Kontrola kvalitete je proces koji osigurava da proizvodi ili usluge zadovoljavaju unaprijed definirane standarde i specifikacije kako bi se osigurala njihova funkcionalnost, sigurnost i zadovoljenje potreba krajnjih korisnika. Tradicionalno, ovaj se proces oslanjao na ručne inspekcije, uzorkovanje proizvoda i laboratorijske testove kako bi se identificirale nesukladnosti, greške ili manjkavosti u proizvodima. Međutim, s napretkom tehnologije, umjetna inteligencija unosi nove metode i sustave za poboljšanje točnosti, brzine i efikasnosti kontrole kvalitete, revolucionirajući taj sektor.

Tradicionalne metode kontrole kvalitete uključivale su fizičke inspekcije, testiranje proizvoda putem uzorkovanja te upotrebu standardnih postupaka za osiguranje dosljednosti. Na primjer, u proizvodnoj liniji, uzorci proizvoda se nasumično uzimaju i testiraju u laboratorijima radi provjere njihove usklađenosti s tehničkim zahtjevima. Inspektori bi provjeravali vizualne karakteristike poput boje, oblika i teksture te bi vršili testiranja trajnosti i funkcionalnosti. Ova metoda se oslanjala na ljudski faktor, koji je često podložan greškama i varijacijama u procjeni. Ljudska inspekcija, iako važna, može biti spora i neefikasna kada se radi o velikom broju proizvoda na proizvodnoj liniji. Razvoj umjetne inteligencije značajno je unaprijedio kontrolu kvalitete, omogućujući automatizirane, brže i preciznije procese nadzora i evaluacije. Primjena AI-a unosi promjene kroz nekoliko ključnih tehnologija kao što su računalni vid, strojno učenje, te internet stvariv (eng. Internte of Things)[11], čime se kontrola kvalitete podiže na novu razinu.

Jedan od najvećih doprinosa AI-a jest uvođenje računalnog vida (*engl. computer vision*), tehnologije koja omogućava strojevima da prepoznaju i analiziraju vizualne elemente, kao što su boja, oblik, tekstura i veličina proizvoda [11]. Uz pomoć kamera visoke rezolucije i algoritama za analizu slika, sustavi bazirani na računalnom vidu mogu automatski otkriti nedostatke u proizvodima bez potrebe za ljudskom intervencijom. Na primjer, u

prehrambenoj industriji, AI sustavi koriste se za identifikaciju oštećenja ili promjena boje voća i povrća kako bi se uklonili neispravni proizvodi prije nego što dođu do potrošača[11].

Uz računalni vid, strojno učenje omogućava sustavima da uče iz podataka i postupno poboljšavaju svoju preciznost. Algoritmi strojnog učenja mogu prepoznati uzorke na temelju povijesnih podataka te koristiti te uzorke za donošenje odluka u stvarnom vremenu[11]. Na primjer, u industrijama koje se oslanjaju na visoku točnost, kao što je automobilska ili zrakoplovna industrija, AI modeli mogu analizirati milijune podataka prikupljenih tijekom proizvodnje kako bi identificirali anomalije ili potencijalne kvarove prije nego što dođe do kritičnih problema. Internet stvari senzori (IoT senzori) također igraju ključnu ulogu u kontroli kvalitete, posebno kada se integriraju s AI sustavima.

Ti uređaji prikupljaju podatke u stvarnom vremenu, nadzirući parametre poput temperature, vlažnosti i tlaka u proizvodnim procesima. AI analizom tih podataka u stvarnom vremenu mogu se brzo identificirati odstupanja koja bi mogla utjecati na kvalitetu proizvoda te omogućiti pravovremene korektivne mjere. Na primjer, u prehrambenoj industriji, senzori mogu pratiti uvjete skladištenja i transporta [11], a AI algoritmi analizirati podatke kako bi se spriječila kontaminacija hrane ili kvarenje proizvoda.

4. PREDNOSTI GENERATIVNE UMIJETNE INTELIGENCIJE U PROIZVODNJI

Generativna umjetna inteligencija značajno mijenja industrijski sektor, posebice u okviru Industrije 4.0, gdje povezuje digitalizaciju s naprednim proizvodnim procesima. Ova tehnologija donosi nove pristupe dizajnu, optimizaciji i prilagodbi proizvodnih procesa, omogućujući kompanijama da značajno smanje troškove, vrijeme proizvodnje i broj grešaka u proizvodnji, istovremeno povećavajući fleksibilnost i prilagodljivost. Generativna AI koristi algoritme strojnog učenja i dubokog učenja kako bi stvarala nova rješenja, proizvode i metode rada na temelju postojećih podataka, te tako omogućuje tvrtkama da simuliraju i testiraju bezbroj opcija prije nego što odluče o konačnom proizvodnom rješenju.

Jedna od glavnih prednosti GAI u proizvodnji jest njezina sposobnost generiranja inovativnih rješenja u ranim fazama dizajna, što rezultira poboljšanjima u svim fazama proizvodnje. Primjena ove tehnologije u industrijama poput automobilske, zrakoplovne, elektronike i tekstila donosi prednosti kao što su smanjenje vremena potrebnog za dizajn novih proizvoda, optimizacija proizvodnih procesa i poboljšanje kontrole kvalitete. Tvrtke koje implementiraju generativnu AI također mogu unaprijediti prediktivno održavanje svojih strojeva i opreme, smanjujući neplanirane zastoje i povećavajući produktivnost.

U prethodnim poglavljima prikazali smo kako generativna umjetna inteligencija mijenja tri područja proizvodnje, a sada ćemo na temelju tih primjera analizirati gdje umjetna inteligencija ima ključnu prednost.

4.1. Prednosti primjene generativne umijetne inteligencije u dizajnu

Tradicionalno, dizajn proizvoda prolazio je kroz nekoliko iteracija, često zahtijevajući brojne prototipe i ispitivanja kako bi se postigla optimalna izvedba. Ovaj proces bio je dugotrajan i skup, što je usporavalo cijeli razvojni ciklus. Međutim, s uvođenjem generativne AI, inženjeri sada imaju alat koji omogućuje automatsku generaciju više dizajnerskih rješenja temeljenih na unaprijed definiranim parametrima, kao što su troškovi, materijali, mehaničke karakteristike i ekološka održivost.

Na primjer, generativna AI koristi algoritme za stvaranje tisuća različitih varijanti dizajna te za procjenu svakog od njih u pogledu performansi i resursne učinkovitosti.

Jedan od najistaknutijih primjera primjene generativne AI u dizajnu dolazi iz automobilske industrije koju smo već spomenuli u poglavlju 3.1.

General Motors je u suradnji s Autodesk-om koristio generativni dizajn kako bi optimizirao dizajn držača sjedala. Stari drzac je bio kockastog oblika nacinjen od ukupno 8 manjih dijelova. U ovoj aplikaciji, AI je generirao više od 150 različitih verzija ovog dijela, uzimajući u obzir faktore poput čvrstoće, težine i troškova proizvodnje. Konačni dizajn rezultirao je jednim novim dijelom koji je bio 40% lakši i 20% jači od prethodnog, smanjujući time troškove materijala i poboljšavajući performanse proizvoda [9].



Slika 8. Stari dio kućišta sačinjen od osam manjih dijelova (lijevo) i novi jedinstveni komad dobiven generativnim dizajnom (desno).

Još jedan od najistaknutijih primjera primjene generativnog dizajna je Autodeskov program Dreamcatcher, koji omogućuje inženjerima i dizajnerima da istraže mnoštvo različitih rješenja dizajna na temelju unosa osnovnih parametara. U programu Dreamcatcher [12], konstruktor unosi početne uvjete, kao što su dimenzije, opterećenje i materijali, nakon čega AI generira niz mogućih konstrukcijskih opcija.

Jedna od ključnih prednosti Dreamcatchera je sposobnost generiranja oblika i struktura koje su teško ostvarive tradicionalnim dizajnerskim metodama [12]. Korištenjem naprednih algoritama, Dreamcatcher može stvoriti složene oblike koji su prilagođeni specifičnim funkcionalnim zahtjevima, smanjujući količinu potrebnog materijala i povećavajući trajnost

proizvoda. Primjerice, u automobilskoj industriji, optimizirani dijelovi izrađeni ovim pristupom mogu smanjiti težinu vozila, čime se poboljšava energetska učinkovitost bez narušavanja sigurnosnih standarda.

4.1.1. Smanjenje troškova i resursna efikasnost

Najveća prednost generativnog dizajna je smanjenje troškova proizvodnje kroz optimizaciju korištenja materijala. Umjetna inteligencija analizira razne materijale i nudi rješenja koja omogućuju minimalno korištenje resursa bez kompromitiranja kvalitete i čvrstoće proizvoda. U nekim industrijama, poput zrakoplovstva, smanjenje težine dijelova proizvoda može značajno smanjiti potrošnju energije ili goriva, što rezultira dugoročnim uštedama i poboljšanim ekološkim učincima.

Uz to, AI sustavi smanjuju potrebu za višestrukim iteracijama dizajna, što tradicionalno povećava troškove razvoja. Generativni dizajn omogućuje simulaciju različitih scenarija i brzu identifikaciju optimalnih rješenja, smanjujući potrebu za fizičkim prototipovima i skraćujući vrijeme razvoja novih proizvoda. Prilagodljivost je još jedna važna karakteristika generativnog dizajna. Sustavi mogu brzo prilagoditi dizajn novim zahtjevima tržišta ili promjenama u materijalima. Korištenjem podataka iz stvarnog svijeta i učenja kroz AI sustave, generativni dizajn može neprekidno poboljšavati proizvode te omogućiti bržu reakciju na promjene u potražnji ili tehnološkom napretku.

Na temelju recenog, prednosti generativne umjetne inteligencije mozemo sazeti u sljedeća područja:

- **Generiranje višestrukih dizajnerskih opcija.**
- **Optimizacija materijala i troškova .**
- **Smanjenje vremena razvoja .**
- **Smanjenje fizičkih prototipova .**
- **Hybridni način rada .**
- **Prilagodljivost i fleksibilnost .**

4.2. Prednosti primjene generativne umjetne inteligencije u planiranju proizvodnih procesa

Generativna umjetna inteligencija ne donosi revoluciju samo u dizajnu proizvoda, već i u planiranju proizvodnih procesa, koji je ključni element svakog proizvodnog sustava. Tradicionalno, planiranje proizvodnih procesa uključivalo je složene korake organizacije i koordinacije različitih faza proizvodnje, često vođene ljudskom ekspertizom i dugotrajnim analizama [13]. No, uvođenje generativne UI donosi brojne prednosti u smislu optimizacije vremena, resursa i smanjenja troškova, čineći proizvodne procese učinkovitijima i prilagodljivijima.

Generativna AI omogućava detaljnu analizu i simulaciju cijelog proizvodnog procesa, čime se omogućava optimizacija tokova materijala, resursa i radne snage. Tradicionalno, proizvodne linije se projektiraju na temelju iskustava i predviđanja, što može dovesti do stvaranja "uskih grla" ili neiskorištenih kapaciteta. AI sustavi analiziraju tokove rada, identificiraju potencijalne probleme u opskrbnim linijama te nude alternativna rješenja kako bi se optimizirala učinkovitost. Primjena umjetne inteligencije (AI) u proizvodnim procesima donosi brojne prednosti, posebno kroz upotrebu digitalnih blizanaca i konvolucijskih neuronskih mreža (eng. convolutional neural networks CNN) [13].

4.2.1. Digitalni blizanci i konvolucijske neuronske mreže

Digitalni blizanac je virtualna replika stvarnog proizvodnog sustava, uključujući sve fizičke karakteristike, procese i resurse tvornice. Korištenje digitalnih blizanaca omogućuje tvornicama da prikupljaju podatke u stvarnom vremenu i simuliraju proizvodne procese u virtualnom okruženju. Ovo pomaže u optimizaciji operacija, održavanju i planiranju, bez potrebe za fizičkim intervencijama.

Konvolucijske neuronske mreže (CNN) su posebna vrsta umjetnih neuronskih mreža dizajnirana za obradu i analizu slika. CNN koriste slojeve za ekstrakciju značajki iz vizualnih podataka, što ih čini vrlo korisnima u proizvodnji za prepoznavanje objekata, praćenje stanja

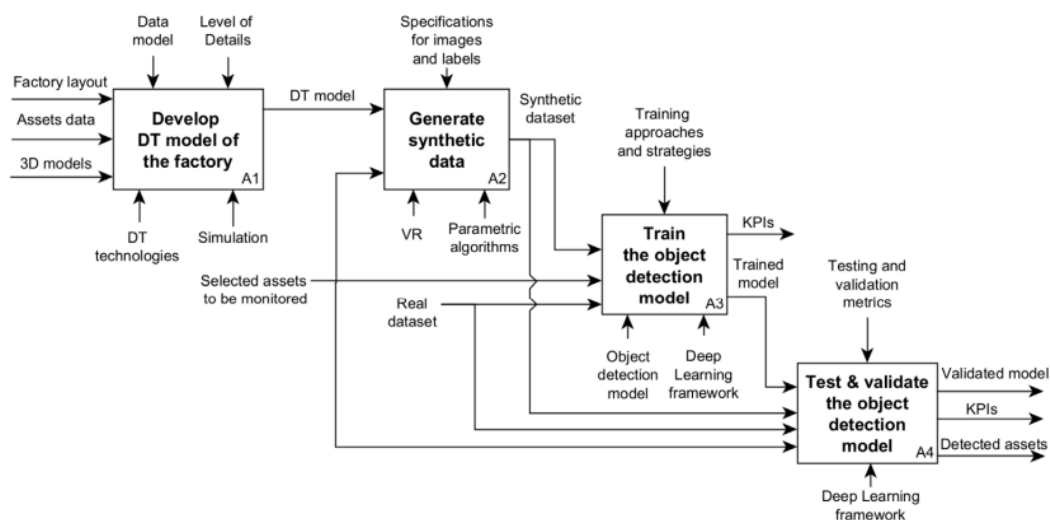
dijelova i vizualnu inspekciju. Oni mogu identificirati i locirati objekte poput dijelova i alata u složenim proizvodnim okruženjima, čime se poboljšava nadzor i kvaliteta procesa.

CNN modeli trenirani na stvarnim i sintetičkim podacima prepoznaju dijelove, prate njihovu poziciju u stvarnom vremenu i otkrivaju moguće kvarove.

Primjena sintetičkih podataka generiranih pomoću digitalnih blizanaca omogućuje treniranje CNN modela čak i kada stvarni sustav nije dostupan. Ovaj pristup ubrzava uvođenje novih sustava bez potrebe za dugotrajnim prikupljanjem podataka iz stvarnih postrojenja.

U nastavku ćemo prikazati dijagram (Slika 7.) koji prikazuje korake korištenja digitalnog blizanca (Digital Twin) u razvoju AI modela za nadzor proizvodnje.

CIRP Journal of Manufacturing Science and Technology 50 (2024) 249–268



Slika 9. Tijek nadzornih proizvodnih procesa u digitalnim blizancima [13].

Proces započinje izradom modela tvornice, generiranjem sintetičkih podataka za treniranje, zatim treniranjem modela detekcije objekata putem CNN-a, a završava testiranjem i validacijom modela u stvarnim uvjetima. Model se evaluira na osnovu ključnih pokazatelja uspješnosti (KPI), što omogućava optimizaciju proizvodnih procesa i detekciju grešaka u realnom vremenu.

Na temelju recenog, prednosti generativne umijetne inteligencije prilikom nadziranja proizvodnih procesa možemo sažeti u sljedeća područja:

- **Optimizacija proizvodnih linija:** AI analizira tokove rada i predlaže prilagodbe za maksimalnu učinkovitost.
- **Prediktivno održavanje:** Korištenjem senzora i podataka u stvarnom vremenu, AI predviđa kvarove prije nego što se dogode.
- **Praćenje resursa:** CNN modeli omogućuju praćenje dijelova i komponenti u stvarnom vremenu.
- **Smanjenje troškova:** AI smanjuje potrebu za fizičkim intervencijama i optimizira korištenje materijala.
- **Digitalni blizanci:** Omogućuju simulaciju stvarnih sustava za optimizaciju i testiranje bez prekida rada.

4.3. Prednost primjene generativne umjetne inteligencije u kontroli kvalitete

Umjetna inteligencija značajno transformira kontrolu kvalitete u proizvodnim procesima, pružajući brzu detekciju grešaka, povećanu točnost i smanjenje ljudskih pogrešaka kao što smo opisali u poglavlju 3.3. Primjena naprednih AI tehnologija poput računalnog vida, strojnog učenja i IoT (eng. Internet of Things) senzora omogućava sustavima da automatski prepoznaju defekte u proizvodima u stvarnom vremenu, uz minimalnu ljudsku intervenciju.

Na primjer, konvolucijske neuronske mreže (CNN) koriste se za vizualne inspekcije proizvoda, što omogućuje prepoznavanje teksture, boje i oblika te otkrivanje anomalija s visokom preciznošću. Računalni vid omogućava automatsko prepoznavanje vizualnih nedostataka, poput promjene boje, teksture ili dimenzija, što znatno ubrzava proces inspekcije u usporedbi s tradicionalnim metodama koje su često sporije i podložne ljudskim pogreškama.

Korištenje AI u kontrolama kvalitete smanjuje mogućnost ljudskih pogrešaka, koje su česte u tradicionalnim metodama inspekcije. Ljudski faktor može dovesti do previdljivosti ili neusklađenosti u procjeni kvalitete, dok AI sustavi osiguravaju konzistentnost i objektivnost u procjeni svakog proizvoda. Osim toga, IoT senzori igraju ključnu ulogu u prikupljanju podataka o radu strojeva i okolišnim uvjetima u proizvodnji. Slika u nastavku prikazuje visokorezolucijske kamere koje prikupljaju podatke koji se kasnije obrađuju za daljnju kontrolu kvalitete, dakle prvi parametar u vizualnoj analizi.



Slika 10. Visokorezolucijske kamere koje prikupljaju vizualne podatke za obradu u kontroli kvalitete [14].

Ti prikupljeni vizualni podaci se analiziraju pomoću AI sustava koji mogu predvidjeti moguće kvarove, omogućujući prediktivno održavanje i smanjujući neplanirane zastoje koji mogu negativno utjecati na proizvodnju.

Tvrtka 3B-Fiberglass, koja se bavi proizvodnjom staklenih vlakana, implementirala je umjetnu inteligenciju kako bi poboljšala kontrolu kvalitete u svom proizvodnom procesu [14]. Korištenjem AI sustava temeljenih na računalnom vidu, tvrtka je uspjela predvidjeti pucanje staklenih vlakana 75 sekundi prije nego što bi se dogodilo. To je omogućilo pravovremeno poduzimanje korektivnih radnji, smanjujući gubitke i povećavajući učinkovitost proizvodnje.

Ova implementacija rezultirala je značajnim poboljšanjima u kvaliteti proizvoda i optimizaciji procesa, čime su smanjeni troškovi proizvodnje.

Dakle, prednosti koje implementacija generativnih modela umjetne inteligencije u kontroli kvalitete donose možemo sažeti u sljedeće točke

- **Brža identifikacija problema** putem računalnog vida i dubokog učenja.
- **Analiza temeljnih uzroka** i sprečavanje budućih grešaka.
- **Optimizacija proizvodnje** smanjuje otpad i troškove.
- **Lako skalabilno rješenje** za primjenu u različitim tvornicama.

5. IZAZOVI I OGRANIČENJA GENERATIVNE UMJETNE INTELIGENCIJE

Generativna umjetna inteligencija (AI) već je dokazala svoj potencijal u revoluciji proizvodnje, unoseći inovacije u gotovo sve aspekte proizvodnih procesa. Od dizajna proizvoda, preko optimizacije proizvodnih linija, pa sve do kontrole kvalitete, AI omogućava poboljšanje učinkovitosti, smanjenje troškova i bržu prilagodbu tržišnim zahtjevima. Iako donosi brojne prednosti, generativna AI je još uvijek relativno novo područje i suočava se s nizom izazova koji zahtijevaju temeljitu analizu i daljnji razvoj.

Zbog svoje složenosti i potencijala za transformaciju industrije, AI otvara mnoga tehnička, etička i ekonomska pitanja. Neka od njih uključuju kako osigurati kvalitetu podataka na kojima se AI sustavi treniraju, kako spriječiti pojavu pristranosti u algoritmima, kao i kakav utjecaj široka implementacija AI-a može imati na radnu snagu. Također, potrebno je razviti odgovarajuće regulatorne okvire kako bi se osiguralo da AI tehnologije budu sigurno i etički korištene u industriji. Iako su prednosti jasno vidljive, ova pitanja moraju biti riješena kako bi se AI u potpunosti implementirala bez ikakvih briga i s maksimalnim učinkom.

5.1. Tehnički izazovi

Jedan od glavnih tehničkih izazova u primjeni AI-a je kompleksnost sustava. AI tehnologije, osobito one koje uključuju strojno učenje i duboko učenje, zahtijevaju velike količine podataka za treniranje modela. Kvaliteta i dostupnost tih podataka često je ograničena, a nepravilni podaci mogu dovesti do nekonzistentnih i nepouzdanih rezultata.

Problem postaje još složeniji kada se radi o aplikacijama poput generativne umjetne inteligencije (GAN modeli), koji stvaraju nove sadržaje ili simuliraju proizvodne procese. U takvim slučajevima, tehnički izazovi vezani uz točnost i interpretabilnost modela postaju ključni, jer pogreške u interpretaciji podataka mogu rezultirati financijskim gubicima i nepredviđenim problemima u proizvodnji.

Također, skalabilnost AI sustava predstavlja tehnički izazov. Iako se AI može uspješno implementirati u manjim segmentima proizvodnje, povećanje njegove primjene na veće pogone zahtijeva prilagodbu infrastrukture, što uključuje optimizaciju mreža, senzora i obrade podataka, stvaranje posebnih softvera i dodatnu edukaciju radnika. Svi ti faktori dodato

povećavaju rizik i same troškove implementacije i zato se korju detaljno analizirati i pomno odabrati.

5.2. Etički izazovi

Uz tehničke izazove, etički izazovi u primjeni AI-a su sveprisutan problem, osobito u kontekstu prikupljanja podataka i njihovog korištenja. AI sustavi često ovise o velikim količinama osobnih ili osjetljivih podataka, što otvara pitanja privatnosti i zaštite podataka [15]. Na primjer, kada AI prikuplja podatke o radnicima ili korisnicima u industrijskom kontekstu, postavlja se pitanje transparentnosti u vezi s time kako se ti podaci prikupljaju, tko im pristupa i kako će biti korišteni.

Daljnji etički izazovi uključuju pristranost u AI modelima. Budući da se AI sustavi treniraju na povijesnim podacima, postoji rizik da se postojeće pristranosti u tim podacima prenesu u buduće odluke. To je osobito važno u industrijama gdje su potrebne nepristrane odluke, poput zapošljavanja ili evaluacije učinka. Eticke izazove generativne umjetne inteligencije možemo svrstati u određene kategorije [15]:

- **Privatnost, povjerenje i pristranost.**
- **Autorska prava i akademski integritet.**
- **Dezinformacije i lažnjaci (eng. Deepfakes)**
- **Transparentnost i odgovornost.**

5.2.1. Privatnost, povjerenje i pristranost.

Privatnost je jedan od ključnih izazova u primjeni generativne umjetne inteligencije jer ti sustavi prikupljaju i obrađuju ogromne količine osobnih i osjetljivih podataka. Kada ti podaci nisu adekvatno zaštićeni, može doći do kršenja privatnosti korisnika [15]. Osim toga, povjerenje u AI sustave narušeno je kada se prepozna pristranost u algoritmima, osobito ako se temelje na neodgovarajućim ili jednostranim podacima.

Na primjer, sustavi za prepoznavanje lica mogu pokazivati značajnu pristranost prema određenim rasnim ili spolnim skupinama, što može dovesti do diskriminacije. Kako bi se to izbjeglo, pri implementaciji AI sustava potrebno je pažljivo dizajnirati algoritme i modele kako bi se uklonile potencijalne pristranosti. To znači da sustavi moraju biti trenirani na raznolikim

i reprezentativnim podacima, a proces donošenja odluka mora biti transparentan, kako bi se spriječile odluke koje bi mogle dovesti do diskriminacije.

5.2.2. Autorska prava i akademski integritet.

Generativna AI donosi brojne izazove vezane uz autorska prava jer je vlasništvo nad generiranim sadržajem često nejasno. AI može kreirati tekstove, slike ili glazbu koji su izuzetno slični postojećim autorskim djelima, što dovodi do pitanja kršenja autorskih prava.

U obrazovanju i znanstvenom istraživanju, postoji problem akademske integriteta kada studenti koriste AI kako bi generirali tekstove ili druge oblike rada, bez odgovarajuće atribucije ili intelektualnog truda [15]. Takvi slučajevi postavljaju pravne i etičke izazove, pa je važno razviti sustave koji poštuju pravila autorskog prava i etičke standarde u akademskim kontekstima.

5.2.3. Dezinformacije i lažnjaci (eng. Deepfakes).

Jedan od najopasnijih aspekata generativne AI jest njena sposobnost stvaranja deepfakeova i drugih oblika dezinformacija. Deepfakes su visoko realistični, ali lažni videozapisi i slike koji mogu obmanjivati javnost i narušiti povjerenje u medije i institucije.

Primjerice, korištenje deepfake tehnologije u političkim kampanjama može ozbiljno utjecati na percepciju birača, potičući širenje lažnih informacija. Ovi etički izazovi dodatno se kompliciraju zbog teškoće u razlikovanju stvarnih od lažnih sadržaja, što zahtijeva razvoj tehnologija za detekciju i regulaciju deepfakeova.

5.2.4. Transparentnost i odgovornost.

Transparentnost u donošenju odluka ključan je izazov za umjetnu inteligenciju. Mnogi AI sustavi, osobito oni koji koriste duboko učenje, funkcioniraju kao "crne kutije", što znači da se odluke donose na temelju složenih algoritama koje je teško objasniti ljudima. Nedostatak transparentnosti može rezultirati nedostatkom povjerenja u AI sustave i otežati njihovu odgovornost.

Na primjer, u medicinskom kontekstu, ako AI model predloži određeni tretman, a liječnik ne može razumjeti kako je došlo do te preporuke, teško je prihvatiti takvu odluku bez sumnje.

Stoga je ključno razviti objašnjivu umijetnu inteligenciju (explainable AI) kako bi se osigurala odgovornost i povjerenje korisnika.

5.3. Ekonomski izazovi.

S ekonomskog stajališta, visoki troškovi implementacije AI tehnologija predstavljaju značajan izazov za mnoga poduzeća, osobito mala i srednja poduzeća koja možda nemaju resurse potrebne za uvođenje ovakvih naprednih tehnologija. Implementacija AI sustava često zahtijeva znatna ulaganja u infrastrukturu, uključujući senzore, podatkovne centre i napredne računalne sustave, što može biti prevelik financijski teret za mnoga poduzeća.

Osim toga, postoji izazov u nedostatku stručnosti. Razvoj, implementacija i održavanje AI sustava zahtijevaju visoko kvalificirane stručnjake, a manjak talentiranih inženjera i znanstvenika u području AI-a može usporiti procese implementacije i povećati troškove rada. Također, kako se AI tehnologija brzo razvija, postoji potreba za kontinuiranom obukom postojećih zaposlenika, što donosi dodatne troškove.

Još jedan važan ekonomski izazov odnosi se na automatizaciju i zamjenu radne snage. Iako AI sustavi mogu poboljšati učinkovitost i smanjiti operativne troškove, postoji zabrinutost da će šira primjena AI-a dovesti do zamjene ljudske radne snage, osobito u industrijama gdje su radna mjesta visoko automatizirana što u jednu ruku predstavlja imlementaciju generativne umijetne inteligencije kao "dvosjekli mac" [15]. Ova zamjena može dovesti do gubitka radnih mjesta i povećanja ekonomske nejednakosti.

6. PRIMJENA GENERATIVNE UMIJETNE INTELIGENCIJE U TVORNICI ZA UČENJE

6.1. Tvornice za učenje.

U ovom poglavlju istražiti ćemo primjenu generativne umjetne inteligencije (AI) unutar koncepta tvornice za učenje (engl. *Learning Factory*). Tvornica za učenje je koncept razvijen kako bi se unaprijedilo učenje i razvoj u industrijskom sektoru kroz integraciju naprednih tehnologija, simulacija i stvarnih proizvodnih procesa [16]. Tvornice za učenje služe kao eksperimentalne platforme za inovacije gdje industrije mogu testirati nove tehnologije u kontroliranim uvjetima, simulirajući stvarne industrijske okoline. Ovaj koncept pruža sigurno okruženje za ispitivanje novih tehnoloških rješenja, kao što su umjetna inteligencija (AI), generativna AI, Internet stvari (eng. Internet of Things) i digitalni blizanci, prije njihove implementacije u stvarne proizvodne pogone.

Glavna prednost tvornice za učenje je mogućnost brze prilagodbe novim tehnologijama i procesima, uz minimalne troškove i smanjenje rizika. Umjesto implementacije novih tehnologija u stvarnim postrojenjima, što može izazvati skupe zastoje i pogreške, tvornice za učenje omogućuju simulaciju i analizu različitih scenarija. Ove tvornice koriste podatke iz stvarnih proizvodnih linija i kombiniraju ih s naprednim algoritmima kako bi pružile točne rezultate i preporuke za poboljšanje.



Slika 11. Karakteristike i zadaci tvornice za učenje.

Jedan od ključnih ciljeva tvornica za učenje je kontinuirano unapređenje proizvodnih procesa kroz prikupljanje i analizu podataka. Tvornica za učenje postaje središte u kojem se inovacije ne samo testiraju, već i stalno poboljšavaju kroz povratne informacije iz stvarnog okruženja. To omogućuje tvrtkama da optimiziraju procese poput razvoja prototipova, kontrole kvalitete i održavanja opreme.

U narednom dijelu rada, obradit ćemo konkretan primjer primjene generativne AI unutar tvornice za učenje u željezničkoj industriji, gdje je generativna AI omogućila optimizaciju održavanja, smanjenje operativnih troškova i poboljšanje sigurnosti prilikom proizvodnje ležajeva za željeznička vozila.

6.2. Primjer primjene generativne umjetne inteligencije u željezničkoj industriji.

Na primjeru istraživanja o živornom vijeku ležajeva vagona u tvornici za učenje pokazati ćemo kako primjenom umjetne inteligencije možemo smanjiti rizik i povećati efikasnost upotrebom prediktivnog održavanja. Prediktivno održavanje ležajeva u željezničkoj industriji koristi generativnu AI tehnologiju kako bi optimizirala proces održavanja, smanjila neplanirane kvarove i zastoje, te osigurala sigurnost i pouzdanost operacija.

Glavni cilj ovog sustava bio je predvidjeti kvarove na ležajevima kotača vlakova prije nego što bi došlo do ozbiljnih oštećenja ili nesreća. Za postizanje toga korišteni su IoT senzori, koje smo spomenuli u poglavlju 4.3., za prikupljanje podataka o temperaturama ležajeva tijekom vožnje vlakova. Ovi senzori prikupljaju podatke u stvarnom vremenu, a ti podaci se koriste za treniranje generativnih AI modela koji mogu predvidjeti kvarove na temelju povijesnih podataka.


6.2.1. Prikupljanje i analiza podataka.

U procesu primjene generativne AI u tvornici za učenje, prikupljanje podataka s ležajeva točkova vlakova ključno je za omogućavanje točnih predikcija o stanju strojeva i mogućim kvarovima. Ovaj proces počinje instalacijom IoT senzora na ključnim mjestima, kao što su ležajevi na osovinama vlakova, koji kontinuirano prate različite parametre u stvarnom vremenu. Jedan od najvažnijih parametara koji se prati je temperatura ležajeva. Povišena temperatura ležaja može ukazivati na probleme s trenjem, nedostatak podmazivanja ili opterećenje izvan predviđenih granica. Senzori prikupljaju podatke o temperaturi u realnom vremenu, a bilo kakvo povećanje temperature koje premašuje standardne vrijednosti odmah se bilježi i

analizira. Također se prate promjene temperature kroz vrijeme kako bi se utvrdili trendovi zagrijavanja.

Na primjer, nagli porast temperature tijekom rada može signalizirati kvar koji zahtijeva hitno održavanje. Stabilnost temperature ključna je za održavanje ležajeva, jer nagle promjene mogu ukazivati na mehaničke probleme ili pogreške u opterećenju. U slučaju željezničke industrije, optimalna radna temperatura ležajeva može varirati, ali svako kontinuirano povećanje temperature iznad 100°C može ukazivati na neispravnost. Uz temperaturu, prate se i vibracije ležajeva. Nagla povećanja vibracija također mogu ukazivati na probleme s trenjem ili oštećenje ležajeva. Prikupljeni podaci o vibracijama, u kombinaciji s temperaturnim podacima, omogućuju generativnoj AI da stvori prediktivne modele koji točno predviđaju kvarove i preporučuju održavanje prije nego što dođe do većih problema. Slika u nastavku nam pokazuje proces predviđanja

Prikupljeni podaci se zatim šalju generativnim AI sustavima, koji koriste algoritme kao što je Levenberg-Marquardt algoritam [17] za optimizaciju predviđanja i određivanje preostalog vijeka trajanja (eng. Remaining Useful Life) ležajeva. Na temelju prikupljenih podataka, AI model predviđa kada će ležaj vjerojatno zakazati i automatski generira preporuku za održavanje. Taj proces predviđanja nam je jasno prikazan u sljedećim dijagramom.



Slika 12. Proces predviđanja korištenjem Gen AI-a [18].

6.2.2. Rezultati primjene

U analizi rezultata prediktivnog modela za ležajeve točkova vlakova, ključni parametri koji su pratili i predviđjeli kvarove bili su temperature ležajeva, koje su igrale odlučujuću ulogu u procjeni preostalog vijeka trajanja (RUL) ležajeva. Prikupljali su se podaci s četiri kuglična ležaja, s ciljem praćenja njihovog ponašanja tijekom neprestanog rada. Ležajevi su imali granicu sigurnog rada na temperaturi od 120°C, iznad koje se smatralo da ležaj ulazi u opasnu zonu, što može signalizirati kvar ili nadolazeći problem.

Ovi podaci su prikupljeni putem IoT senzora, koji su kontinuirano mjerili i bilježili temperaturu ležajeva, omogućujući precizno praćenje njihovog stanja tijekom vremena.



Slika 13. Graf temperatura kugličnih ležaja s obzirom na broj dana u pogonu.

Na grafovima su korištene različite boje kako bi se prikazala područja rada ležajeva.

- Zelena boja označava zdravo stanje ležaja, u kojem se temperatura nalazi unutar sigurnih granica od 50°C-120°C
- Žuta boja označava opasnu zonu, kada temperatura pada ispod 0°C ili prelazi 120°C i ide do 140°C tada postoji opasnost za smanjenje vijeka trajanja lezaja i maziva pa ova zona oznacava opasnost.
- Crvena boja označava kvar ili stanje blizu kvara, kada temperatura uvelike prelazi 120°C u rangu od 140°C do 250°C, što zahtijeva hitnu intervenciju ili zamjenu ležaja kako bi se izbjeglo oštećenje sustava.

Na temelju ovih podataka, generativna AI analizirala je trendove u porastu temperature i predviđala kada će ležaj prijeći iz zdravog stanja u opasnu zonu, omogućujući preventivno održavanje prije nego što se dogodi kvar. AI sustavi su omogućili pravovremenu reakciju na

potencijalne kvarove, čime su smanjeni neplanirani zastoji i produljen vijek trajanja ležajeva.

Sada na temelju ovog primjera, a i ostalih primjera primjene generativne umjetne inteligencije u proizvodnji možemo izvesti glavne prednosti primjene kroz usporedbu tradicionalnog pristupa i implementacije generativne umjetne inteligencije:

Tablica 2. Analiza klasičnog održavanja i prediktivnog održavanja implementacijom generativne umjetne inteligencije [18].

Kriterij	Bez AI (Klasično održavanje)	S AI (Prediktivno održavanje)
Točnost dijagnoze kvarova	Niska	Visoka (R = 0.83)
Preventivno održavanje	Ograničeno	Omogućeno
Trošak održavanja	Veći zbog reaktivnog pristupa	Manji zbog prediktivnog pristupa
Preostali životni vijek komponenti	Nepredviđen	Točno procijenjen
Sigurnost sustava	Viši rizik od kvara	Niži rizik zbog ranog otkrivanja
Ekološka učinkovitost	Niska zbog čestih popravaka	Viša zbog optimiziranog održavanja

7. ZAKLJUČAK

Generativna AI, kao specifična grana umjetne inteligencije, pokazuje velik potencijal u optimizaciji proizvodnih procesa, smanjenju troškova, poboljšanju dizajna i povećanju učinkovitosti rada. Ova tehnologija omogućava stvaranje novih rješenja na temelju postojećih podataka i pruža značajne prednosti u dizajnu proizvoda, planiranju proizvodnih procesa, kontroli kvalitete, te prediktivnom održavanju. Prilikom analizi željezničke industrije, gdje je AI sustav korišten za prediktivno održavanje ležajeva, jasno se pokazalo da primjena generativnih modela može značajno poboljšati operativnu učinkovitost, smanjiti troškove održavanja i produljiti vijek trajanja opreme. Kroz prikupljanje podataka o temperaturama i vibracijama ležajeva putem IoT senzora, AI modeli su uspješno predviđali kvarove i omogućili pravovremeno održavanje, čime su smanjeni neplanirani zastoji i produžen životni vijek sustava. Ovaj primjer nam je pokazao koliko je bitno imati precizne podatke i odgovarajuće algoritme kako bi se osigurale predikcije koje omogućuju preventivne mjere. Te zaključke možemo primijeniti na širu industriju i zaključiti da implementacija umjetne inteligencije u industrijske procese otvara put bržim, učinkovitijim i ekonomski isplativijim operacijama, čime se kao krajnji rezultat povećava profitabilnost. Međutim, ovakve prednosti donose i neizbježna pitanja, uključujući tehnološke, etičke i ekonomske izazove. Kako bi se AI uspješnije primjenjivao u nadolazećoj budućnosti industrije, nužno je jasno definirati granice njegove primjene, osiguravajući time zaštitu i proizvođača i korisnika.

LITERATURA

- [1] Geissbauer, R., et al. (2016). Industry 4.0: The Future of Productivity and Growth in Manufacturing Industries. 1.9.2024.
- [2] Pervaiz Akhtar, Arsalan Mujahid Ghouri, Aniq Ashraf : Smart product platforming powered by AI and generative AI: Personalization for the circular economy. 2.9.2024.
- [3] Farhan Alenizi , Shirin Abbasi , Adil Hussein Mohammed.: The artificial intelligence technologies in Industry 4.0: A taxonomy, approaches, and future directions.
- [4] Što je AI?: <https://www.techtarget.com/searchenterpriseai/definition/AI-Artificial-Intelligence>. 2.9.2024.
- [5] Povijesni razvoj umjetne inteligencije: <https://www.ibm.com/topics/artificial-intelligence>. 2.9.2024.
- [6] Usporedba:<https://www.techtarget.com/searchenterpriseai/definition/AI-Artificial-Intelligence>. 2.9.2024.
- [7] GAN: <https://www.unite.ai/hr/what-is-a-generative-adversarial-network-gan/>
- [8] Kadhim Hayawi, Sakib Shahriar, Mohamed Adel Serhani: [Generative AI and large language models: A new frontier in reverse vaccinology](#). 3.9.2024.
- [9] GM i implementacija AI u dizajn: <https://www.autodesk.com/customer-stories/general-motors-generative-design>. 3.9.2024.
- [10] NVIDIA, BMW Blend Reality, Virtual Worlds to Demonstrate Factory of the Future: <https://blogs.nvidia.com/blog/nvidia-bmw-factory-future/>
- [11] Naga Ramesh Palakurti: AI Applications in Food Safety and Quality Control. 4.9.2024.
- [12] Chun Hyunjin: A Study on Application of Generative Design System in Manufacturing Process. 4.9.2024.
- [13] Marcello Urgo, Walter Terkaj, Gabriele Simonetti: Monitoring manufacturing systems using AI: A method based on a digital factory twin to train CNNs on synthetic data
- [14] Primjena AI-a u kontroli kvalitete: <https://postindustria.com/how-ai-for-quality-control-enhances-yield-in-ml-manufacturing/>. 5.9.2024.
- [15] Mousa Al-kfairy, Dheya Mustafa, Nir Kshetri, Mazen Insiew and Omar Alfandi: Ethical Challenges and Solutions of Generative AI: An Interdisciplinary Perspective. 5.9.2024.
- [16] Eberhard Abele, George Chryssolouris, Wilfried Sihn, Joachim Metternich: Learning factories for future oriented research and education in manufacturing. 6.9.2024.

-
- [17] Ilesanmi Daniyana, Khumbulani Mpofoa, Moses Oyesolaa, Boitumelo Ramatsetsea, Adefemi Adeodu: Artificial intelligence for predictive maintenance in the railcar learning factories. 8.9.2024.
- [18] Smanjenje neplaniranih zastoja : <https://www.bcg.com/publications/2023/predictive-maintenance-in-manufacturing>. 9.9.2024.
- [19] Poboljšanje produktivnosti: <https://www.pecan.ai/blog/improving-predictive-maintenance-generative-ai/>. 10.9.2024.