

# Generativna umjetna inteligencija.

---

**Miličević, Ana**

**Master's thesis / Diplomski rad**

**2024**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Rijeka, Faculty of Maritime Studies, Rijeka / Sveučilište u Rijeci, Pomorski fakultet**

*Permanent link / Trajna poveznica:* <https://urn.nsk.hr/um:nbn:hr:187:152445>

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

*Download date / Datum preuzimanja:* **2025-03-30**

*Repository / Repozitorij:*



[Repository of the University of Rijeka, Faculty of Maritime Studies - FMSRI Repository](#)



SVEUČILIŠTE U RIJECI  
POMORSKI FAKULTET

ANA MILIČEVIĆ

GENERATIVNA UMJETNA INTELIGENCIJA

DIPLOMSKI RAD

Rijeka, 2024.

**SVEUČILIŠTE U RIJECI  
POMORSKI FAKULTET**

**GENERATIVNA UMJETNA INTELIGENCIJA  
GENERATIVE ARTIFICIAL INTELLIGENCE**

**DIPLOMSKI RAD  
MASTER THESIS**

Kolegij: Umjetna inteligencija

Mentor: doc. dr. sc. Dario Ogrizović

Komentor: David Bačnar, mag. ing. el.

Studentica: Ana Miličević

Studijski smjer: Logistika i menadžment u pomorstvu i prometu

JMBAG: 0112077206

Rijeka, rujan 2024.

Studentica: Ana Miličević

Studijski program: Logistika i menadžment u pomorstvu i prometu

JMBAG: 0112077206

### IZJAVA O SAMOSTALNOJ IZRADI DIPLOMSKOG RADA

Kojom izjavljujem da sam diplomski rad s naslovom  
**GENERATIVNA UMJETNA INTELIGENCIJA**  
(naslov diplomskog rada)

izradila samostalno pod mentorstvom  
**doc. dr. sc. Dario Ogrizović**  
(prof. dr. sc. / izv. prof. dr. sc. / doc dr. sc Ime i Prezime)

te komentorstvom David Bačnar mag. ing. el.

stručnjaka/stručnjakinje iz tvrtke \_\_\_\_\_  
(naziv tvrtke).

U radu sam primijenila metodologiju izrade stručnog/znanstvenog rada i koristila literaturu koja je navedena na kraju diplomskog rada. Tuđe spoznaje, stavove, zaključke, teorije i zakonitosti koje sam izravno ili parafrazirajući navela u diplomskom radu na uobičajen, standardan način citirala sam i povezala s fusnotama i korištenim bibliografskim jedinicama, te nijedan dio rada ne krši bilo čija autorska prava. Rad je pisan u duhu hrvatskoga jezika.

Studentica

(potpis)



Ana Miličević

Studentica: Ana Miličević

Studijski program: Logistika i menadžment u pomorstvu i prometu

JMBAG: 0112077206

**IZJAVA STUDENTA – AUTORA  
O JAVNOJ OBJAVI OBRANJENOG DIPLOMSKOG RADA**

Izjavljujem da kao studentica – autorica diplomskog rada dozvoljavam Pomorskom fakultetu Sveučilišta u Rijeci da ga trajno javno objavi i besplatno učini dostupnim javnosti u cjelovitom tekstu u mrežnom digitalnom repozitoriju Pomorskog fakulteta.

U svrhu podržavanja otvorenog pristupa diplomskim radovima trajno objavljenim u javno dostupnom digitalnom repozitoriju Pomorskog fakulteta, ovom izjavom dajem neisključivo imovinsko pravo iskorištavanja bez sadržajnog, vremenskog i prostornog ograničenja mog diplomskog rada kao autorskog djela pod uvjetima *Creative Commons* licencije CC BY Imenovanje, prema opisu dostupnom na <http://creativecommons.org/licenses/>

Studentica - autor

(potpis)



## **SAŽETAK**

Generativna umjetna inteligencija (GAN) postala je ključni alat u raznim područjima, uključujući logistiku. GAN predstavlja skup algoritama unutar strojnog učenja dizajniranih za generiranje novih podataka sličnih onima korištenim za njihovo treniranje. Njihova sposobnost stvaranja realističnih podataka koji nisu nužno prisutni u skupu podataka za učenje omogućava široku primjenu u logistici. Primjena GAN - a u logistici pruža brojne prednosti. U optimizaciji procesa skladištenja i distribucije, poduzeća mogu efikasnije upravljati skladištima, minimizirati troškove skladištenja i optimizirati raspored robe. Također, GAN se može koristiti za optimizaciju logističkih ruta, što dovodi do smanjenja vremena i troškova transporta. Predviđanje potražnje ključno je za uspješno upravljanje logističkim procesima, GAN omogućuje preciznije predviđanje potražnje na temelju analize trendova i povijesnih podataka. To omogućuje poduzećima prilagodbu strategija proizvodnje i upravljanja zalihamama kako bi se bolje nosili s fluktuacijama potražnje na tržištu. Upravljanje zalihamama je ključni dio logističkih operacija. GAN može poboljšati učinkovitost upravljanja zalihamama identificirajući obrasce u potražnji i omogućujući dinamičko prilagođavanje zaliha. Ovo smanjuje rizik od nedostataka ili viška zaliha, što rezultira smanjenjem troškova i povećanjem učinkovitosti. Generativne umjetne inteligencije također mogu poboljšati komunikaciju i suradnju s dobavljačima. Korištenjem GAN - za predviđanje potražnje i optimizaciju upravljanja zalihamama, poduzeća mogu bolje informirati svoje dobavljače o potrebama tržišta i prilagoditi svoje ponude u skladu s tim. Unatoč izazovima u implementaciji i korištenju GAN, njezin potencijal za transformaciju logističkih operacija čini ih ključnom tehnologijom za budućnost logistike. Sposobnost GAN – a uključuje optimizaciju procesa, poboljšanja predviđanja potražnje, efikasnog upravljanja zalihamama te poboljšanja odnosa s dobavljačima čini ih neizostavnim alatom u modernim logističkim operacijama.

**KLJUČNE RIJEĆI; generativna umjetna inteligencija, diskriminativna umjetna inteligencija, generativne suparničke mreže, generativni modeli, logistika.**

## **SUMMARY**

Generative Artificial Intelligence (GAN) has become a key tool in various fields, including logistics. A GAN is a set of algorithms within machine learning designed to generate new data similar to that used to train it. Their ability to generate realistic data that is not necessarily present in the training dataset allows for wide application in logistics. The application of GAN in logistics provides numerous advantages. By optimizing the storage and distribution process, companies can manage warehouses more efficiently, minimize storage costs and optimize the distribution of goods. Also, GAN can be used to optimize logistics routes, which leads to a reduction in transport time and costs. Demand forecasting is key to successfully managing logistics processes, GAN enables more accurate demand forecasting based on trend analysis and historical data. This allows companies to adjust their production and inventory management strategies to better cope with fluctuations in market demand. Inventory management is a key part of logistics operations. GAN can improve inventory management efficiency by identifying patterns in demand and enabling dynamic inventory adjustments. This reduces the risk of shortages or excess inventory, resulting in lower costs and increased efficiency. Generative AI can also improve communication and collaboration with suppliers. By using GAN - to forecast demand and optimize inventory management, companies can better inform their suppliers about market needs and adjust their offers accordingly. Despite the challenges in implementing and using GAN, its potential to transform logistics operations makes it a key technology for the future of logistics. The ability of GANs to optimize processes, improve demand forecasting, efficiently manage inventory, and improve relationships with suppliers makes them an indispensable tool in modern logistics operations.

**KEYWORDS:** generative artificial intelligence, discriminative artificial intelligence, generative adversarial networks, generative models, logistics.

# SADRŽAJ

SAŽETAK .....	I
SUMMARY .....	II
SADRŽAJ .....	III
1. UVOD .....	1
1.1. Cilj i svrha istraživanja.....	2
1.2. Znanstvena hipoteza.....	2
1.3. Struktura rada.....	3
1.4. Znanstvene metode .....	4
2. ODREDNICE GENERATIVNE UMETNICE INTELIGENCIJE .....	5
2.1. Pojam generativne umjetne inteligencije.....	5
2.2. Razlike između generativne i diskriminativne umjetne inteligencije .....	9
3. ULOGA GENERATIVNIH MODELA U KREIRANJU NOVIH PODATAKA .....	13
3.1. Značaj generativnih modela u predikciji izvornih podataka .....	13
3.2. Vrste generativnih modela.....	14
3.2.1. Generativne suparničke mreže (GAN).....	16
3.2.2. Varijacijski autoenkoderi (VAE) .....	17
3.2.3. Autoregresivni modeli .....	22
3.3. Primjene generativnih modela.....	24
3.4. Pitanja privatnosti i sigurnosti u kontekstu generativne umjetne inteligencije .....	33
3.5. Etički aspekti korištenja generativnih modela za manipulaciju digitalnih sadržaja ..	34
4.1. Generiranje i manipulacija .....	37
4.2. AI za poboljšanje kreativnih procesa .....	40
5. PRIMJENA GENERATIVNE UMETNICE INTELIGENCIJE U POMORSTVU .....	44
5.1. Optimizacija rute plovila .....	44
5.2. Pametno umrežavanje senzora.....	50
5.3. Umjetna inteligencija u robotici .....	50
5.4. Rekonstrukcija oceanskih velikih podataka.....	51
6. PRIMJENA GENERATIVNE UMETNICE INTELIGENCIJE U LOGISTICI.....	53

6.1.	Optimizacija skladišta i distribucije .....	54
6.2.	Poboljšano predviđanje i planiranje potražnje.....	57
6.3.	Optimizacija upravljanja zalihami .....	58
6.4.	Poboljšano upravljanje odnosima s dobavljačima .....	59
6.5.	Prediktivna analitika za predviđanje potražnje .....	60
7.	ZAKLJUČAK .....	63
	POPIS LITERATURE.....	65
	POPIS SLIKA.....	71

## 1. UVOD

Generativne umjetne inteligencije (engl. *Generative artificial intelligence – GAI*) su postale ključni alat u različitim područjima, uključujući logistiku. Ovaj rad analizira ulogu GAI-a u optimizaciji logističkih procesa, poboljšanju predviđanja potražnje, upravljanju zalihami te odnosima s dobavljačima. Generativna umjetna inteligencija predstavlja skup algoritama unutar područja strojnog učenja. Ovi modeli su dizajnirani za generiranje novih podataka koji su slični onima koji su korišteni za njihovo treniranje. Glavna karakteristika GAI je njihova sposobnost stvaranja realističnih podataka koji nisu nužno prisutni u skupu podataka za učenje.

Generativni modeli imaju ključnu ulogu u predviđanju i generiranju novih podataka. Njihova sposobnost generiranja podataka omogućava široku primjenu u raznim industrijama, uključujući logistiku. Primjerice, generativni modeli mogu biti korišteni za predviđanje potražnje proizvoda, optimizaciju logističkih ruta ili čak za stvaranje inovativnih rješenja u procesima skladištenja i distribucije. GAI igra ključnu ulogu u optimizaciji procesa skladištenja i distribucije. Korištenjem GAI-a, poduzeća mogu efikasnije upravljati skladištima, minimizirajući troškove skladištenja i optimizirajući raspored robe [2].

Također, GAI se može koristiti za optimizaciju logističkih ruta, što dovodi do smanjenja vremena i troškova transporta. Predviđanje potražnje ključno je za uspješno upravljanje logističkim procesima. GAI omogućuju preciznije predviđanje potražnje na temelju analize trendova i povijesnih podataka. To omogućuje poduzećima da prilagode svoje strategije proizvodnje i upravljanja zalihami kako bi se bolje nosili s fluktuacijama potražnje na tržištu. Upravljanje zalihami je ključni dio logističkih operacija. GAI može poboljšati učinkovitost upravljanja zalihami identificirajući obrasce u potražnji i omogućujući dinamičko prilagođavanje zaliha [3].

Ovo smanjuje rizik od nedostataka ili viška zaliha, što rezultira smanjenjem troškova i povećanjem učinkovitosti. Generativne umjetne inteligencije mogu poboljšati komunikaciju i suradnju s dobavljačima. Korištenjem GAI za predviđanje potražnje i optimizaciju upravljanja zalihami, poduzeća mogu bolje informirati svoje dobavljače o potrebama tržišta i prilagoditi

svoje ponude u skladu s time. Primjena generativne umjetne inteligencije u logistici pruža brojne prednosti, uključujući optimizaciju procesa skladištenja i distribucije, poboljšano predviđanje potražnje, efikasnije upravljanje zalihami te poboljšanje odnosa s dobavljačima. Unatoč izazovima u implementaciji i korištenju GAI i njihov potencijal za transformaciju logističkih operacija čini ih ključnom tehnologijom za budućnost logistike.

## **1.1. Cilj i svrha istraživanja**

Glavni cilj ovoga rada je opisati i analizirati koncept generativne umjetne inteligencije kako bi čitatelji stekli razumijevanje ove grane umjetne inteligencije (engl. *Artificial intelligence - AI*). Rad istražuje važnost generativnih modela u predikciji izvornih podataka, kao i razlike vrste generativnih modela koje se koriste u tom kontekstu. Također objašnjava etička pitanja i izazove vezane uz korištenje generativnih modela, posebno u kontekstu privatnosti i sigurnosti podataka. Na kraju se istražuje konkretnim primjerima primjenu generativne umjetne inteligencije u pomorstvu kao što su optimizacija rute plovila, predviđanje održavanja plovila i analiza kapaciteta teretnih brodova, te primjenu generativne umjetne inteligencije u logistici, uključujući optimizaciju skladišta i distribucije, predviđanje i planiranje potražnje, upravljanje zalihami i odnosima s dobavljačima te prediktivnu analitiku za predviđanje potražnje. Svrha rada je podići svijest o etičkim pitanjima koja proizlaze iz korištenja generativnih modela, posebno u kontekstu privatnosti, sigurnosti podataka i manipulacije digitalnih sadržaja, te analizirati kako generativna umjetna inteligencija može poboljšati učinkovitost i funkcionalnost procesa u pomorstvu i logistici, pružajući uvide u moguće primjene i koristi za ove industrije.

## **1.2. Znanstvena hipoteza**

U svrhu obrade zadane teme, ovaj rad polazi od sljedećih radnih hipoteza koje će se dokazati ili opovrgnuti:

- Hipoteza 1: Generativni modeli, poput Generativnih Suparničkih Mreža (*Generative Adversarial Networks*) mogu poboljšati predviđanje potražnje u logistici.

*adversarial network - GAN), mogu stvoriti realistične i uvjerljive digitalne sadržaje poput slika, glazbe ili teksta, što potiče kreativnost i inovacije u umjetnosti i dizajnu.*

- Hipoteza 2: Korištenje generativnih modela za optimizaciju ruta plovila, predviđanje potreba za održavanjem plovila i analizu kapaciteta teretnih brodova može rezultirati u smanjenju troškova i povećanju sigurnosti u pomorskoj industriji.
- Hipoteza 3: Primjena generativnih modela u logistici za optimizaciju skladišta i distribucije, predviđanje potražnje i upravljanje zalihamama može povećati učinkovitost i smanjiti operativne troškove u logističkom sektoru.
- Hipoteza 4: Rastuća upotreba generativne umjetne inteligencije za manipulaciju digitalnim sadržajima može izazvati ozbiljne etičke dileme i imati dalekosežne posljedice na privatnost, sigurnost podataka i društvenu dinamiku.

### **1.3. Struktura rada**

U uvodnom poglavlju se uvodi tema istraživanja, postavlja cilj i svrha istraživanja, formulira znanstvena hipoteza te opisuje struktura i metode istraživanja. Drugo poglavlje "Odrednice generativne umjetne inteligencije" definira se pojam generativne umjetne inteligencije i istražuju se razlike između generativnih i diskriminativnih modela. Treće poglavlje "Uloga generativnih modela u kreiranju novih podataka" istražuje značaj generativnih modela u predikciji izvornih podataka, razmatraju se različite vrste generativnih modela te se daju primjeri primjene, uz analizu pitanja privatnosti, sigurnosti i etičkih aspekata. Četvrto poglavlje "Primjene generativne umjetne inteligencije u kreativnim procesima" fokusira se na generiranje i manipulaciju podataka, poboljšanje kreativnih procesa te razvoj virtualne stvarnosti i proširene stvarnosti. Peto poglavlje "Primjena generativne umjetne inteligencije u pomorstvu" razmatra se primjena generativne umjetne inteligencije u pomorskom sektoru, s naglaskom na optimizaciju rute plovila, predviđanje održavanja i analizu kapaciteta teretnih brodova. Šesto "Primjena generativne umjetne inteligencije u logistici" istražuje primjene generativne umjetne inteligencije u logističkim procesima, uključujući optimizaciju skladišta i distribucije, predviđanje potražnje, upravljanje zalihamama i odnosima s dobavljačima. Na kraju je "Zaključak" koji sumira se glavno istraživanje i daju se zaključci.

## **1.4. Znanstvene metode**

Da bi se postigli postavljeni ciljevi i potvridle ili odbacile hipoteze, potrebno je prikupiti odgovarajuće informacije i podatke. Tijekom izrade ovog diplomskog rada koristit će se različite istraživačke metode.

Primarni izvori podataka bit će analizirani diskurzivnom metodom, koja uključuje pregled najvažnijih dostupnih literatura. Sekundarni izvori podataka obuhvatit će širok raspon dostupne domaće i strane literature, znanstvenih i stručnih radova, časopisa, baza podataka te drugih internetskih izvora koji služe kao osnova za razvoj teorijskog okvira. Nadalje, prilikom analize prikupljenih podataka i prezentiranja rezultata istraživanja koristit će se metode analize i sinteze, statističke metode te metoda studije slučaja.

## **2. ODREDNICE GENERATIVNE UMJETNE INTELIGENCIJE**

Generativna umjetna inteligencija predstavlja jedno od najnaprednijih područja unutar šireg polja umjetne inteligencije, s naglaskom na sposobnost strojeva da stvaraju nove, originalne sadržaje koji oponašaju ljudsku kreativnost. Za razliku od tradicionalnih sustava umjetne inteligencije, koji su prvenstveno usmjereni na analizu i prepoznavanje obrazaca u postojećim podacima, generativna AI ima sposobnost stvaranja potpuno novih podataka. Ovi sustavi koriste sofisticirane algoritme, poput dubokih neuronskih mreža i varijacijskih autoenkodera, kako bi generirali tekst, slike, glazbu, pa čak i videozapise.

### **2.1. Pojam generativne umjetne inteligencije**

Generativna umjetna inteligencija predstavlja ključnu granu AI koja je u proteklom desetljeću doživjela izvanredan napredak. Od stvaranja slika, glazbe, teksta pa čak i videa, generativna AI postala je katalizator za stvaranje originalnog sadržaja bez presedana. Ova tehnologija uči iz uzoraka postojećih podataka te ih koristi za generiranje novih rezultata, čime otvara vrata neograničenom spektru mogućnosti. Generativna AI koristi algoritme dubokog učenja i neuronske mreže kako bi naučila obrasce i strukturu svojih ulaznih podataka [4].

Umjesto da se oslanja na unaprijed programirana pravila ili zadane podatke, ovi modeli uče iz iskustva i generiraju autentične rezultate. Ovo oslobađa fleksibilnost algoritama, omogućavajući im da proizvode sadržaj koji može oponašati ljudsku kreativnost na nevjerljiv način. Primjena generativne umjetne inteligencije u industrijama poput igara, zabave i dizajna proizvoda izuzetno je značajna. Ovi alati postaju ključni resursi za stvaranje sadržaja koji privlači korisnike i potrošače. GAN AI, kao jedan od najpoznatijih primjera, sposoban je proizvesti vrlo realističan i složen sadržaj koji se može koristiti u različite svrhe.

Početkom 2020. godine napredak u dubokim neuronskim mrežama zasnovanim na transformatorima donio je revoluciju u generativnu AI. Ovi modeli su poznati po svojoj

sposobnosti prihvaćanja upita prirodnog jezika kao ulaza, što je omogućilo korisnicima da komuniciraju s AI na prirodniji način, čime je olakšana interakcija i stvaranje sadržaja. Unatoč brojnim prednostima, generativna umjetna inteligencija također postavlja pitanja o etici i sigurnosti. [5] Kako AI postaje sposobnija stvarati sve složeniji i autentičniji sadržaj, postavlja se pitanje kako osigurati da se ova tehnologija koristi na odgovoran i siguran način, sprječavajući potencijalne zlouporabe ili manipulacije.

U posljednjem desetljeću svjedočili smo brzom napretku u području umjetne inteligencije, posebno u domeni generativnih modela poput Generative Pretrained Transformer (GPT) i Midjourney. Ova otkrića donose revoluciju u načinu na koji razmišljamo o AI-u, otvarajući vrata novim mogućnostima i potičući inovacije u raznim područjima. Jedan od najvažnijih aspekata generativne AI jest njezin potencijal za inovacije. Kroz sposobnost stvaranja novih ideja, kreativnih rješenja i originalnih sadržaja, generativna AI potiče razvoj inovacija u područjima poput umjetnosti, znanosti, tehnologije i dizajna. Njena sposobnost generiranja novih perspektiva potiče nas na istraživanje nepoznatih teritorija i otvara nove puteve razmišljanja. Dalje, generativna AI predstavlja značajan napredak u tehnološkom pejzažu. Njena primjena u različitim područjima kao što su strojno učenje, jezično razumijevanje i prepoznavanje slika doprinosi dalnjem razvoju tehnologije.

Na primjer, GPT modeli pokazali su se izuzetno korisnima u poboljšanju jezičnog razumijevanja i stvaranju prirodnijeg interakcije s računalima. Osim toga, generativna AI igra ključnu ulogu u razvoju autonomnih vozila, medicinske dijagnostike i drugih naprednih tehnoloških sustava. No, sva ova obećanja dolaze s odgovornošću prema društvu. Generativna AI ima potencijal značajno utjecati na različita područja društva, uključujući medicinu, umjetnost, poslovanje i obrazovanje. Na primjer, u medicini, AI može pomoći u razvoju novih terapija i liječenju bolesti kroz analizu velikih medicinskih skupova podataka.

Jedno od najistaknutijih područja primjene generativne umjetne inteligencije je u sučeljima prirodnog jezika. Sinteza govora u tekst i obrnuto omogućuje razvoj digitalnih pomoćnika. Ovi sustavi ne samo što omogućuju korisnicima interakciju s uređajima putem glasovnih naredbi, već i pružaju funkcije poput automatskog sažimanja teksta ili generiranja

priopćenja za tisak iz skupa ključnih činjenica. Ova tehnologija postaje neizostavni dio svakodnevnog života, olakšavajući komunikaciju i pristup informacijama [6].

Sinteza slike je još jedno područje gdje GAI ima značajan utjecaj. Generativni modeli sposobni su stvarati vizualne sadržaje na temelju uputa ili konceptualnih ideja. Ova tehnologija nalazi primjenu u dizajnu reklama, modnih kreacija, pa čak i u filmskoj produkciji, gdje može generirati priče ili scene prema zadanim parametrima. Ovo otvara nove mogućnosti u kreativnom procesu, omogućujući umjetnicima i dizajnerima da brzo eksperimentiraju s različitim idejama i konceptima [7].

Prostorna sinteza, koja uključuje stvaranje trodimenzionalnih prostora i objekata, također je područje gdje GAI pokazuje svoj puni potencijal. Alati poput Spacemaker-a omogućuju dizajniranje zgrada, soba, pa čak i kompletnih planova gradova koristeći tehnologiju umjetne inteligencije. Ovo nije samo korisno u arhitekturi i urbanom planiranju, već i u razvoju virtualnih svjetova za igre ili suradnju, gdje se metaverse koncepti mogu ostvariti kroz AI-generirane prostore.

Dizajn proizvoda i sinteza objekata su područja gdje GAI pronalazi primjenu u stvaranju fizičkih objekata poput dijelova strojeva ili kućanskih proizvoda. Korištenjem alata kao što su AutoCAD i SOL75, inženjeri i dizajneri mogu iskoristiti sposobnosti GAI za pomoć u procesu dizajna ili čak za direktnu generaciju novih konceptualnih rješenja [7].

Ova tehnologija, koja se oslanja na algoritme sposobne stvarati nove podatke i sadržaj, postaje sveprisutna i transformira način na koji obavljamo različite aktivnosti. Zdravstvo je jedno od područja koje doživljava dramatičan napredak zahvaljujući generativnoj umjetnoj inteligenciji. Primjena generativnih suparničkih mreža omogućava stvaranje lažnih primjera nedovoljno zastupljenih podataka, što je ključno za obuku i razvoj modela u medicinskim istraživanjima. GAN-ovi također pružaju rješenje za osjetljive probleme privatnosti podataka pacijenata, omogućujući identifikaciju podataka bez ugrožavanja sigurnosti ili privatnosti.

Ova tehnologija olakšava dijagnostiku, personaliziranu terapiju i istraživanje novih tretmana, čime unapređuje kvalitetu zdravstvene skrbi širom svijeta. U glazbenoj industriji, generativna umjetna inteligencija otvara vrata kreativnosti na novim razinama. Putem neuronskih mreža koje imitiraju ljudski mozak, AI može generirati glazbu koja zvuči kao djelo ljudskog skladatelja. Primjena poput Google-ovog softvera Magenta pokazuje kako AI može stvoriti originalne melodije i čak eksperimentirati s novim glazbenim žanrovima [4].

U robotici, generativna umjetna inteligencija pomaže u razvoju naprednih modela strojnog učenja koji su manje pristrani i sposobniji razumjeti apstraktne koncepte. Ova tehnologija omogućuje robotima da uče i prilagođavaju se različitim okruženjima i zadacima, što ih čini fleksibilnijima i korisnijima u stvarnom svijetu. Kroz simulacije i testiranja u stvarnom svijetu, generativna umjetna inteligencija omogućuje razvoj robota koji mogu izvršavati složene zadatke s visokom preciznošću i efikasnošću. Jedan od ključnih izazova s kojima se suočava generativna umjetna inteligencija jest potencijalna zloupotreba od strane loših aktera [9].

Moguće je da se GAI koristi za izvođenje zlonamjernih aktivnosti poput prijevare, stvaranja lažnih vijesti ili čak manipulacije javnim mnijenjem. Ovaj izazov zahtjeva pažljiv nadzor i implementaciju sigurnosnih mehanizama kako bi se spriječila zloupotreba te tehnologije. Drugi značajan izazov leži u potrebi za velikim količinama podataka za obuku generativnih algoritama. Da bi uspješno stvarali novi sadržaj, GAI sustavi trebaju obiman skup podataka koji služi za treniranje modela.

Ovaj zahtjev za ogromnim skupom podataka može predstavljati ograničenje u situacijama gdje takvi podaci nisu lako dostupni ili gdje postoji zabrinutost u vezi s privatnošću i sigurnošću podataka. Također, GAI sustavi nisu imuni na neočekivane rezultate. Primjerice, generativni suparnički mrežni modeli često proizvode nepredvidljive izlaze, a kontroliranje ovih rezultata može biti izazovno.

## 2.2. Razlike između generativne i diskriminativne umjetne inteligencije

Generativni i diskriminativni modeli su dva ključna koncepta u strojnom učenju koji se razlikuju u načinu na koji modeliraju podatke i izvode zaključke. Ovi modeli imaju različite pristupe rješavanju problema učenja iz podataka i imaju svoje specifične prednosti i nedostatke. Generativni modeli pokušavaju modelirati cjelokupnu distribuciju podataka. Ovi modeli su u osnovi zainteresirani za to kako izgleda skup podataka u cjelini.

Primjeri generativnih modela uključuju generativne suparničke mreže, varijacijske autoenkodere (engl. *Variational autoencoder - VAE*) i generativne modele bazirane na Bayesovim mrežama [10].

Prednosti generativnih modela uključuju sposobnost generiranja novih primjera podataka, što ih čini korisnima u situacijama gdje je potrebno sintetizirati podatke. Također, generativni modeli su korisni u situacijama gdje je potrebno modelirati složene distribucije podataka.

Za razliku od generativnih modela, diskriminativni modeli se fokusiraju na modeliranje razlike između različitih klasa ili podskupova podataka. Primjeri diskriminativnih modela uključuju logističku regresiju, neuronske mreže, metoda potpornih vektora (engl. *Support Vector Machine*) i stabla odlučivanja [11].

Prednosti diskriminativnih modela uključuju efikasnost u situacijama gdje je cilj klasifikacija ili regresija, kao i sposobnost rada s velikim skupovima podataka.

Razlike između generativnih i diskriminativnih modela [12]:

- Primjena: Generativni modeli se često koriste za generiranje novih primjera podataka, dok su diskriminativni modeli korisni za klasifikaciju, regresiju ili detekciju.
- Princip modeliranja: Generativni modeli modeliraju cjelokupnu distribuciju podataka, dok diskriminativni modeli modeliraju samo uvjetne distribucije ili granice između klasa.

- Složenost: Generativni modeli su često složeniji jer pokušavaju modelirati cjelokupnu distribuciju podataka, dok diskriminativni modeli mogu biti jednostavniji jer se fokusiraju samo na relevantne značajke za klasifikaciju ili regresiju.

Generativni modeli se koriste kada je potrebno generirati nove primjere podataka ili kada je potrebno modelirati složene distribucije podataka, kao što su slike ili zvukovi. Diskriminativni modeli se koriste kada je glavni cilj klasifikacija ili regresija. U praksi, odabir između generativnih i diskriminativnih modela ovisi o prirodi problema i dostupnim podacima. U nekim situacijama, kombinacija ova dva pristupa može dati najbolje rezultate, koristeći prednosti oba pristupa za rješavanje složenih problema u strojnog učenju.

Generativni modeli predstavljaju ključan pristup u području strojnog učenja, fokusirajući se na modeliranje distribucije klasa unutar skupa podataka. Dok tradicionalni algoritmi strojnog učenja usmjeravaju pažnju na samu distribuciju podataka, generativni modeli dublje zaranjaju u analizu, istražujući zajedničku vjerojatnost različitih varijabli.

Ključna komponenta generativnih modela je pronalaženje zajedničke vjerojatnosti različitih varijabli, što se često postiže korištenjem Bayes-ovog teorema. Generativni modeli imaju širok spektar primjena u području strojnog učenja i umjetne inteligencije. Neki od najčešćih primjera uključuju [13]:

- Generiranje novih podataka: Jedna od ključnih primjena generativnih modela je generiranje novih podataka koji su slični onima koji su korišteni za obuku modela. Ovo se često koristi u područjima poput generativnih suparničkih mreža za generiranje slika, glazbe ili teksta.
- Modeliranje podataka: Modeliranje distribucije podataka omogućava bolje razumijevanje strukture podataka, što može biti korisno za detekciju anomalija ili prepoznavanje obrazaca.
- Procjena vjerojatnosti: Generativni modeli mogu se koristiti za procjenu vjerojatnosti različitih događaja ili pojava. Ovo je korisno u situacijama gdje je potrebno kvantificirati nesigurnost ili rizik.

- Razlikovanje između klasa: Generativni modeli mogu se koristiti za razlikovanje između različitih klasa na temelju vjerojatnosti koje su naučene tijekom treninga. Ovo je ključno u zadacima klasifikacije i segmentacije.

Diskriminativni modeli u strojnom učenju predstavljaju ključan koncept koji se koristi za klasifikaciju i predikciju klase. Suprotno generativnim modelima koji modeliraju distribuciju podataka, diskriminativni modeli se fokusiraju na naučavanje granice između različitih klasa unutar skupa podataka. Njihova osnovna svrha je razgraničiti klase kako bi se primijenile pouzdane oznake klasa na instance podataka. Diskriminativni modeli se razlikuju od generativnih modela po tome što ne pokušavaju modelirati distribuciju podataka direktno, već se fokusiraju na identifikaciju granice odluke između klasa.

Ova granica odluke definira područja u kojima se nalaze instance pripadajuće određenim klasama. Osnovni cilj diskriminativnih modela je naučiti razlikovati između različitih klasa u skupu podataka koristeći uvjetnu vjerojatnost, bez donošenja prepostavki o distribuciji podataka ili pojedinačnim podatkovnim točkama. Jedan od najpopularnijih primjera diskriminativnih modela je metoda potpornih vektora, koji se često koristi za klasifikaciju i regresiju. SVM radi tako što gradi hiper-ravninu ili višedimenzionalnu granicu odluke koja razdvaja različite klase u više dimenzija. Cilj je pronaći hiper-ravninu koja maksimizira razmak između najbližih instanci različitih klasa, što rezultira boljom generalizacijom i robustnošću modela.

Stabla odlučivanja su također diskriminativni modeli koji koriste hijerarhijsku strukturu stabla za razdvajanje instanci podataka na temelju atributa značajki. Svaki čvor stabla predstavlja testiranje određene značajke, dok grane predstavljaju različite mogućnosti atributa.

Slučajne šume su skupovi stabala odlučivanja koji kombiniraju više stabala kako bi se poboljšala stabilnost i generalizacija modela. Svako stablo se konstruira na temelju promatranog skupa podataka, što dovodi do različitih stabala unutar promatranog skupa podataka.

U tu svrhu, diskriminativni modeli, kao što su metoda potpornih vektora (SVM), logistička regresija, stablo odlučivanja i slučajne šume, postaju ključni alati u području strojnog učenja i analize podataka. Metoda potpornih vektora moćan je alat za klasifikaciju i regresiju. Njihova osnovna svrha je pronaći granicu odluke koja najbolje razdvaja različite klase u skupu podataka [8].

Logistička regresija je jednostavan, ali efikasan algoritam za binarnu klasifikaciju. Koristi se funkcija log-odds kako bi se izračunala vjerojatnost pripadnosti jednoj od dvije klase. Sigmoidna funkcija koristi za "zbijanje" te vjerojatnosti na raspon između nula i jedan. Logistička regresija također može biti proširena na višeklasne probleme klasifikacije korištenjem pristupa jedan protiv svih [6].

### **3. ULOGA GENERATIVNIH MODELA U KREIRANJU NOVIH PODATAKA**

Generativni modeli postaju sve važniji alat u modernoj umjetnoj inteligenciji, omogućujući stvaranje potpuno novih podataka temeljenih na učenju iz postojećih informacija. Ovi modeli su dizajnirani tako da ne samo repliciraju ili prepoznaju obrasce iz postojećih podataka, već da ih koriste kao osnovu za generiranje novih, originalnih sadržaja. To ih čini ključnim za primjene u raznim industrijama, od umjetnosti i dizajna do medicine i znanosti o podacima.

#### **3.1. Značaj generativnih modela u predikciji izvornih podataka**

Generativni modeli igraju ključnu ulogu u predviđanju izvornih podataka jer omogućuju razumijevanje i simulaciju složenih distribucija podataka. Njihova važnost ogleda se u nekoliko ključnih aspekata [14]:

- Otkrivanje anomalija: Generativni modeli mogu pomoći u otkrivanju anomalija identificiranjem podataka koji ne odgovaraju naučenoj distribuciji. Ova tehnika je korisna u raznim industrijama, poput financija i zdravstva, gdje je važno brzo i točno otkriti nepravilnosti.
- Poboljšanje robusnosti modela: Generativni modeli mogu se koristiti za generiranje varijacija podataka koje pomažu u obučavanju robusnijih prediktivnih modela. Ovo je posebno važno u područjima gdje se modeli moraju nositi s različitim i neočekivanim situacijama.
- Popunjavanje podataka koji nedostaju: Generativni modeli mogu se koristiti za dopunjavanje vrijednosti koje nedostaju u skupovima podataka. Na primjer, ako neki podaci nedostaju zbog problema s prikupljanjem, generativni modeli mogu predvidjeti i popuniti te nedostajuće vrijednosti na temelju naučene distribucije.

- Prilagodba i personalizacija: Generativni modeli mogu se koristiti za stvaranje personaliziranog sadržaja. Na primjer, u sustavima preporuka, ovi modeli mogu generirati personalizirane preporuke na temelju individualnih preferencija korisnika.
- Primjene u kreativnim industrijama: Generativni modeli važni su u kreativnim industrijama, kao što su glazba, umjetnost i dizajn, gdje mogu generirati nove umjetničke forme i stilove, pružajući alate za inovacije i eksperimentiranje.
- Razumijevanje distribucija podataka: Generativni modeli uče distribucije podataka iz dostupnih uzoraka. To omogućuje modelima generiranje novih podataka koji su slični izvornim uzorcima, pa se na taj način umjetno/virtualno proširuje set podataka.
- Razumijevanje strukture podataka: Kroz procese kao što je redukcija dimenzija, generativni modeli mogu pomoći u razumijevanju složene strukture podataka, otkrivajući latentne čimbenike koji utječu na varijabilnost podataka.
- Sinteza novih podataka: Jedna od najvažnijih primjena generativnih modela je sinteza novih podataka. Na primjer, u domeni slika, generativni modeli kao što su GAN mogu stvoriti slike realističnog izgleda koje se mogu koristiti za obuku drugih modela, čime se povećava raznolikost i veličina skupa za obuku.

### **3.2. Vrste generativnih modela**

Generativne suparničke mreže predstavljaju moćan pristup generiranju realističnih slika. Ovaj model, predložen od strane Ian-a Goodfellow-a i kolega 2014. godine, u kratkom je vremenu postao ključna tehnika u polju generativnog modeliranja [7].

Temeljna ideja GAN-a leži u tome da se istovremeno treniraju dva suparnička modela - generator i diskriminatore - koji se natječu jedan protiv drugoga [2]. Ovaj stalni sukob između generatora i diskriminatora potiče oba modela da poboljšaju svoje performanse sve dok generator ne proizvodi slike koje su toliko realistične da ih diskriminatore više ne može pouzdano razlikovati od stvarnih slika.

Proces treniranja GAN-a započinje s nasumičnim uzorkovanjem iz latentnog prostora i generiranjem slike od strane generatora. Ta generirana slika zatim se šalje na analizu diskriminatoru zajedno s uzorcima stvarnih slika iz skupa za treniranje. Diskriminator zatim procjenjuje vjerojatnost ukoliko je svaka slika stvarna ili generirana. Na temelju ovih procjena, modeli se ažuriraju koristeći tehnike unaprijedne i unazadne propagacije pogreške kako bi se poboljšale performanse oba modela. Jedna od ključnih prednosti GAN-ova leži u njihovoj sposobnosti generiranja visoko detaljnih slika visoke razlučivosti. Ova sposobnost proizlazi iz toga što GAN-ovi uče distribuciju stvarnih podataka, što omogućuje generiranje slika koje su u skladu s prirodnim varijacijama u skupu podataka.

Uz GAN-ove, još dvije važne skupine generativnih modela su difuzijski modeli (engl. *Diffusion models*) i varijacijski autoenkoderi. Difuzijski modeli pristupaju generiranju slika kao procesa difuzije latentnog šuma, gdje se postepeno iz šuma dobiva slika, dok VAE-ovi kombiniraju tehnike autoenkodera s probabilističkim pristupom generiranju slika [4].

VAE je jednostavna, ali moćna arhitektura koja kombinira koncepte autoenkodera s probabilističkim modeliranjem. Autoenkoderi su duboki neuronski modeli koji uče reprezentacije podataka komprimirajući ih u latentni prostor, a zatim ih rekonstruirajući natrag u početni prostor. VAE proširuje ovaj koncept dodavanjem probabilističkog elementa, što omogućuje generiranje novih uzoraka iz naučene distribucije. Primjena VAE-a na stvaranje slika omogućava generiranje novih slika koje su slične onima iz skupa podataka na kojem je model treniran [12].

Jedna od važnih primjena generativnih modela je stvaranje slika s određenim uvjetima, što se postiže uvjetnim varijacijama VAE-a i GAN-a. Ovo otvara mogućnosti za personalizirano generiranje slika prema korisničkim zahtjevima. Na primjer, uvjetni generativni modeli mogu generirati slike lica s određenim svojstvima, poput specifične frizure, izraza lica ili pozadine.

### 3.2.1. Generativne suparničke mreže (GAN)

Generativne suparničke mreže sastoje se od dvije duboke neuronske mreže: generatora i diskriminadora.

Prednosti GAN-a uključuju:

- Generirane slike često su vrlo realistične.
- Mogućnost generiranja visoke razlučivosti slika i videa.
- Fleksibilnost u manipulaciji generiranih sadržaja.

Nedostaci GAN-a uključuju:

- Nestabilnost u treniranju, što zahtijeva pažljivo podešavanje hiper-parametara.
- Nejasnoće u interpretaciji latentnog prostora.
- Primjene GAN-a uključuju generiranje foto-realističnih slika, stvaranje deepfake videozapisa (uvjerljiv krivotvoreni sadržaj; sintetički videozapis) i poboljšanje kvalitete slika.

Generativni modeli u području umjetne inteligencije predstavljaju ključnu paradigmu koja omogućuje stvaranje novih podataka sličnih onima u skupu za učenje. Boltzmann-ov stroj (engl. *Boltzmann machine* - BM) je probabilistički model koji uči distribucije podataka. Njegova arhitektura sastoji se od vidljivih i skrivenih slojeva koji su međusobno povezani te se temelji na konceptima statističke mehanike. Kako bi se prevladali ovi nedostaci, razvijen je restriktirani Boltzmann-ov stroj (engl. *Restricted Boltzmann Machines* - RBM) [15].

Duboke mreže vjerovanja (engl. *Deep Belief Networks*, DBN) predstavljaju sofisticiranu klasu generativnih modela koja je postala ključna u području dubokog učenja. Njihovu suštinsku arhitekturu čine spojeni Boltzmann-ovi strojevi i restriktivni Boltzmann-ovi strojevi, omogućujući hijerarhijsko učenje i izgradnju složenih reprezentacija podataka [7].

Osnovni Boltzmannov stroj (BM) predstavlja probabilistički model koji se sastoji od vidljivih i skrivenih slojeva čvorova, pri čemu su svi čvorovi međusobno povezani.

Jedna od ključnih tehnika koja je postala neizostavna u tom kontekstu su neuronske mreže s neusmjerenim vezama (engl. *Unrestricted Boltzmann Machines* - UBM) i duboki vjerojatnosni modeli poput dubokih neuronskih mreža (engl. *Deep Belief Networks* - DBN) [11]. Ove tehnike omogućuju slobodan protok informacija kroz višeslojne strukture, što olakšava treniranje i omogućuje otkrivanje složenih, dubokih uzoraka u podacima.

### 3.2.2. Varijacijski autoenkoderi (VAE)

Varijacijski autokoderi su vrsta neuronskih mreža dizajniranih za učenje komprimirane reprezentacije slike ili videa (poznate kao "koder") i naknadno generiranje novih slika ili videa (poznatih kao "dekor"). Glavni cilj VAE-a je naučiti latentni prostor distribucije podataka, omogućavajući generiranje novih uzoraka iz tog prostora. Jedna od ključnih značajki VAE-a je njihova sposobnost generiranja raznolikih uzoraka, jer latentni prostor obično ima kontinuiranu strukturu [14].

Prednosti VAE-a uključuju:

- Mogućnost generiranja raznolikih uzoraka.
- Latentni prostor omogućuje manipulaciju generiranih slika.
- Stohastičnost u procesu generiranja omogućuje veću kreativnost.

Nedostaci VAE-a uključuju:

- Generirane slike često nisu tako realistične kao kod drugih tehnika.
- Problemi s rekonstrukcijom detalja u generiranim slikama.
- Složenost u optimizaciji i treniranju modela.
- Primjene VAE-a uključuju generiranje slika lica, kreiranje umjetničkih djela i interpolacija između različitih slika.

Varijacijski autoenkoder predstavlja posebnu vrstu generativnog modela koji se koristi za generiranje sličnih ili potpuno novih uzoraka na temelju postojećih podataka.

Ova mreža kombinira koncepte autoenkodera s tehnikama modeliranja vjerojatnosti kako bi omogućila stvaranje latentnog prostora koji je kontinuiran i olakšava uzorkovanje i interpolaciju [12].

Varijacijski autoenkoder sastoji se od dvije osnovne komponente: enkodera i dekodera. Enkoder uzima ulazne podatke i pretvara ih u sažetu reprezentaciju koja se naziva latentni prostor. Ovaj proces kompresije podataka omogućuje modelu da izvuče bitne značajke ulaznog skupa podataka. Dekoder koristi reprezentaciju latentnog prostora dobivenu od enkodera kako bi rekonstruirao originalni ulaz. Ovaj proces dekompresije omogućuje modelu da generira nove uzorke koji su slični onima u ulaznom skupu podataka [15].

Jedna od ključnih značajki VAE-a je kontinuiranost latentnog prostora. Ova kontinuiranost omogućuje glatko uzorkovanje i interpolaciju između različitih uzoraka. Za osiguravanje kontinuiranosti latentnog prostora koristi se donja granica vjerojatnosti (engl. *Evidence Lower Bound*, ELBO). ELBO je funkcija gubitka čija se maksimizacija „prisiljava“ latentni prostor da prati normalnu distribuciju. Maksimizacijom ELBO-a, osigurava se stabilan latentni prostor koji omogućuje lako generiranje novih uzoraka [8].

VAE često se primjenjuje za generiranje novih podataka, osobito vizualnih i zvučnih, kada je dostupni skup podataka za treniranje ograničen. Primjeri primjene uključuju generiranje umjetnih slika, poput stvaranja novih uzoraka lica ili kreiranje umjetne glazbe. Osim toga, VAE se može koristiti i za oblikovanje podataka ili kao dio šireg sustava strojnog učenja.

Unatoč mnogim prednostima, varijacijski autoenkoderi imaju nekoliko nedostataka. Jedan od najčešćih je problem s „mutnim“ generiranim slikama. To znači da generirani uzorci mogu biti manje kvalitetni ili manje oštiri od originalnih podataka. Ovaj problem može biti rezultat kompleksnosti modela, veličine latentnog prostora ili nedostataka u arhitekturi mreže.

Dok GAN-ovi pokazuju izvanredne rezultate u mnogim aplikacijama, kao što su generiranje slika za skupove podataka, fotografije ljudskih lica ili fotorealistične slike, oni se suočavaju s problemima poput mode collapse-a, gdje generator proizvodi samo mali podskup stvarnih uzoraka, ili nerealnih artefakata koji se pojavljuju u generiranim slikama. Jedan od načina rješavanja ovih problema jest kroz prilagodbu arhitekture i tehnika treniranja [2].

Primjena tehnika kao što su proširene GAN-ove (StyleGAN), cikličke GAN-ove (CycleGAN) ili upotreba dodatnih uvjetnih informacija može poboljšati stabilnost i kvalitetu generiranih uzoraka [10]. Iako GAN-ovi imaju izvanredan uspjeh u generiranju vizualnog sadržaja, važno je napomenuti i etičke i društvene implikacije njihove upotrebe. Pitanja privatnosti, autentičnosti slika te potencijalna zloupotreba tehnologije za stvaranje lažnih informacija predstavljaju važne izazove koje treba pažljivo razmotriti. GAN-i pokazuju velik potencijal i u drugim sektorima, kao što su medicina, autonomna vožnja, glazba i financije.

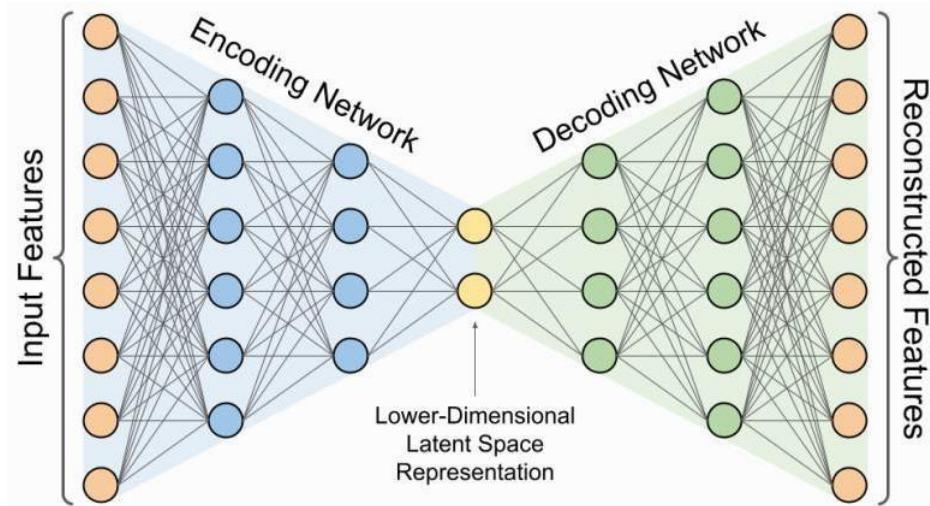
Arhitekture GAN-ova su sljedeće [5]:

- Dvostupanjski GAN (DCGAN): DCGAN je jedna od najranijih i najutjecajnijih arhitektura GAN-a koja koristi konvolucijske slojeve kako bi omogućila stabilno treniranje i generiranje visokokvalitetnih slika.
- Conditional GAN (cGAN): cGAN dopušta kontrolu nad generiranim podacima dodavanjem dodatnih ulaznih podataka koji određuju što će generator generirati.
- Wasserstein GAN (WGAN): WGAN uvodi Wasserstein gubitak koji omogućuje stabilnije treniranje i bolju konvergenciju u usporedbi s tradicionalnim GAN-ovima.
- CycleGAN: CycleGAN je specifičan GAN dizajniran za učenje mapiranja između dva domena bez potrebe za parnim podacima za učenje.
- StyleGAN: StyleGAN je posebno dizajniran za generiranje visokokvalitetnih slika lica, omogućujući kontrolu nad stilskim značajkama generiranih slika.

Primjene GAN-ova [14]:

- Generiranje slika: GAN-ovi su izuzetno korisni za generiranje visokokvalitetnih slika, što se može primijeniti u raznim područjima kao što su dizajn, reklama i računalni vid.
- Obrada prirodnog jezika (engl. *Natural Language Processing - NLP*): GAN-ovi su također korisni za generiranje teksta, poboljšanje prevođenja i stvaranje autentičnih jezičnih uzoraka.
- Medicinska obrada slika: U medicini, GAN-ovi se koriste za generiranje medicinskih slika, poboljšanje dijagnostike i sintezu biomedicinskih podataka.

- Umjetnost i kreativnost: GAN-ovi su postali važan alat za umjetnike i kreativce, omogućujući generiranje novih umjetničkih sadržaja i eksperimentiranje s različitim stilovima.



**Slika 1 Autoenkoder**

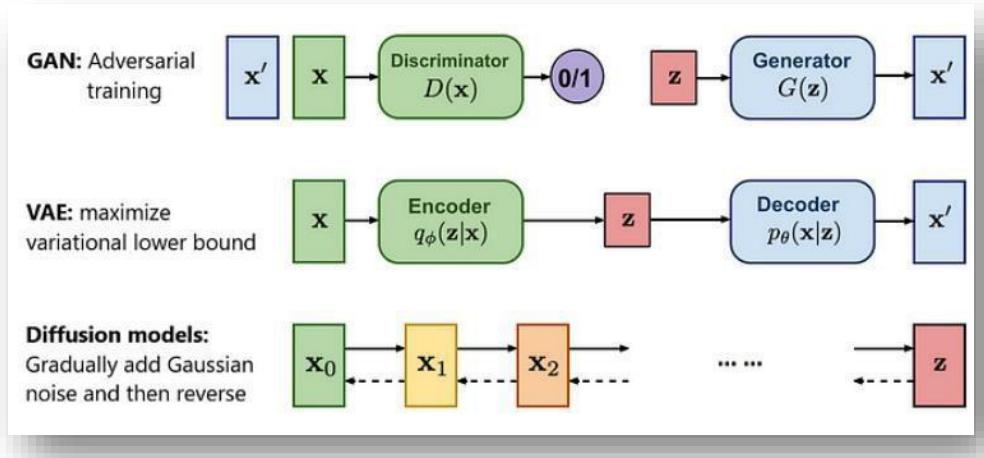
Izvor; Eckerli, F., Osterrieder, J. (2021). Generative Adversarial Networks in finance: an overview.  
<https://doi.org/10.48550/arXiv.2106.06364> ( 20.05.2024.)

Ključna inovacija varijacijskog autoenkodera leži u tome što umjesto jednostavne točke u latentnom prostoru, model uči distribuciju tih točaka. To se postiže prilagođavanjem latentnih prikaza ulaznih podataka prema zadanoj distribuciji. Ovaj pristup omogućuje veću fleksibilnost u generiranju novih primjera, budući da model nije ograničen na samo jednu točku latentnog prostora, već može generirati primjere iz cijele distribucije [12].

Tijekom procesa treniranja, varijacijski autoenkoder nastoji minimizirati dvije ključne funkcije gubitka: rekonstrukcijski gubitak i regulacijski gubitak. Rekonstrukcijski gubitak ocjenjuje koliko učinkovito VAE može obnoviti izvorne podatke koristeći latentne reprezentacije, dok regulacijski gubitak procjenjuje koliko dobro te latentne reprezentacije odgovaraju zadanoj distribuciji.

Nakon što je varijacijski autoenkoder obučen, može se koristiti za stvaranje novih uzoraka podataka. To se postiže uzimanjem uzorka točaka iz definirane distribucije latentnog prostora i njihovim dekodiranjem putem dekodera. Ovaj proces omogućuje generiranje potpuno novih, originalnih primjera koji zadržavaju karakteristike ulaznih podataka, ali su istovremeno jedinstveni. Difuzijski model predstavlja još jedan inovativan pristup generativnim modelima, inspiriran difuzijom u fizici. U fizici, difuzija se odnosi na proces u kojem se tvar pomiciće s područja veće koncentracije prema području niže koncentracije, pri čemu se taj proces zaustavlja kada gradijent koncentracije više ne postoji.

Studije su utvrdile da difuzijski modeli stvaraju slike bolje kvalitete u usporedbi s drugim generativnim modelima. Njihova sposobnost da generiraju visokokvalitetne slike s minimalnim šumom čini ih izuzetno korisnim u mnogim područjima, uključujući računalni vid, medicinsku obradu slika i umjetnu inteligenciju. Sveukupno, varijacijski autoenkoderi i difuzijski modeli predstavljaju moćne alate u generiranju novih podataka i otvaraju vrata za brojne primjene u stvarnom svijetu.



Slika 2 Vizualizacija procesa treniranja generativnih modela

Izvor; Eckerli, F., Osterrieder, J. (2021). Generative Adversarial Networks in finance: an overview. <https://doi.org/10.48550/arXiv.2106.06364> ( 26.05.2024)

### 3.2.3. Autoregresivni modeli

Autoregresivni modeli generiraju nove slike ili videozapise iterativnim predviđanjem vrijednosti svakog piksela na slici ili videu s obzirom na vrijednosti prethodnih piksela. Ovi modeli obično koriste rekurentne neuronske mreže (engl. *Recurrent neural network - RNN*) ili tehnike poput WaveNet-a za generiranje uzoraka.

Prednosti autoregresivnih modela uključuju [14]:

- Mogućnost generiranja visoke razlučivosti slika i videa s finim detaljima.
- Jasna interpretacija procesa generiranja.
- Mogućnost kontrole generiranog sadržaja pomoću početnih ulaza.

Nedostaci autoregresivnih modela uključuju:

- Računalno intenzivne operacije, što može otežati treniranje i korištenje modela.
- Problemi s paralelizacijom, što može ograničiti brzinu generiranja.
- Ograničenja u generiranju raznolikih uzoraka.

Jedna od glavnih prednosti autoregresivnih generativnih modela je njihova sposobnost izračunavanja egzaktne vjerojatnosti. Ova preciznost olakšava robusnu obuku i evaluaciju modela. Za razliku od drugih generativnih modela, poput variacionih autoenkodera, autoregresivni modeli mogu generirati visokokvalitetne uzorke, posebno u domenima kao što su obrada prirodnog jezika i generiranje slika. Ova sposobnost čini ih dragocjenim alatom u situacijama gdje je potrebno generirati realistične podatke.

Proces treniranja GAN-a se odvija putem MIN-MAX igre. Generator nastoji minimizirati funkciju gubitka tako da generira podatke koji su što sličniji stvarnim podacima, dok diskriminator nastoji maksimizirati funkciju gubitka tako da što bolje razlikuje stvarne podatke

od generiranih. Autoregresivni GAN-ovi (engl. *Autoregressive generative adversarial networks – AR-GAN*) imaju široku primjenu u generiranju sekvencijalnih podataka [12].

Primjene AR-GAN-ova [7]:

- Generiranje teksta: AR-GAN-ovi mogu generirati realistične tekstualne sekvence koje zadržavaju gramatičku ispravnost i smisao.
- Generiranje govora: Koristeći autoregresivni pristup, AR-GAN-ovi mogu generirati prirodno zvučne sekvence govora s kontinuiranim tokom.
- Generiranje vremenskih nizova: U područjima poput financija ili meteorologije, AR-GAN-ovi mogu generirati realistične vremenske nizove koji odražavaju temporalne obrazce.

Autoregresivni GAN-ovi izvrsni su u modeliranju uvjetnih vjerojatnosti. Model uči uvjetnu vjerojatnost sljedećeg podatka na temelju sekvence generirane do tog trenutka. Ova sposobnost je ključna za hvatanje ovisnosti i korelacija prisutnih u sekvencijalnim podacima. Na primjer, u generiranju glazbe, vjerojatnost određenog tona ovisi o tonovima koji su prethodno svirani, a model koristi ovu uvjetnost za stvaranje skladnih kompozicija [6].

Integracija autoregresije u GAN-ove uključuje dizajniranje generatora s autoregresivnom strukturom. To se može postići korištenjem različitih arhitektura neuronskih mreža kao što su Rekurentne Neuronske Mreže, Long Short-Term Memory mreže (LSTM-ovi) i Transformeri. Ove arhitekture su inherentno prilagođene za obradu sekvencijalnih podataka, što ih čini idealnim za autoregresivne GAN-ove. RNN-ovi i LSTM-ovi obrađuju sekvence održavajući skrivene stanja koja hvataju informacije iz prethodnih vremenskih koraka, dok Transformeri koriste mehanizme samo-pažnje za dinamičko vaganje važnosti različitih dijelova sekvence.

Jedinstvena svojstva autoregresivnih GAN-ova čine ih posebno moćnima u nekoliko domena [52]:

- U NLP-u, autoregresivni GAN-ovi mogu generirati koherentan i kontekstualno relevantan tekst. Sposobni su proizvoditi rečenice, odlomke ili čak cijele članke koji su gramatički ispravni i kontekstualno prikladni. Primjene uključuju chatbotove i virtualne asistente, kreiranje sadržaja i strojno prevođenje.
- Autoregresivni GAN-ovi mogu skladati glazbu generiranjem sekvenci nota ili akorda koji slijede glazbenu strukturu. Slično tome, u sintezi govora, ovi modeli mogu proizvoditi govor prirodnog zvuka generiranjem sekvenci fonema ili audio uzorka, osiguravajući glatke prijelaze i dosljedan ton.
- Za vremenske nizove podataka, kao što su cijene dionica ili vremenski obrasci, autoregresivni GAN-ovi mogu predvidjeti buduće vrijednosti na temelju prošlih promatranja. Modeliranjem vremenskih ovisnosti, ovi GAN-ovi mogu pružiti točna i pouzdana predviđanja, pomažući donošenju odluka u financijama, meteorologiji i drugim područjima.
- U području generiranja videa, autoregresivni GAN-ovi mogu stvarati realistične video kadrove u sekvenci, održavajući vremensku koherenciju. Ova sposobnost je ključna za primjene u animaciji, sintezi videa i igrama, gdje su konzistentnost i fluidnost generiranih kadrova od najveće važnosti.

### **3.3. Primjene generativnih modela**

Generativna umjetnost vođena umjetnom inteligencijom koristi napredne algoritme za stvaranje jedinstvenih i dinamičnih umjetničkih djela, nudeći nove mogućnosti i izazove za umjetnike i kreatore diljem svijeta. Generativna umjetnost vođena AI-em koristi sofisticirane algoritme za stvaranje umjetnosti koja je neponovljiva i iznimno originalna. Ovi alati mogu generirati širok spektar umjetničkih djela, od apstraktnih dizajna i animacija do složenih ilustracija i realističnih fotografija. Proces kreacije započinje unosom korisničkog unosa - tekstualne naredbe ili opisa - nakon čega algoritam u svega nekoliko sekundi stvara konačno umjetničko djelo [14].

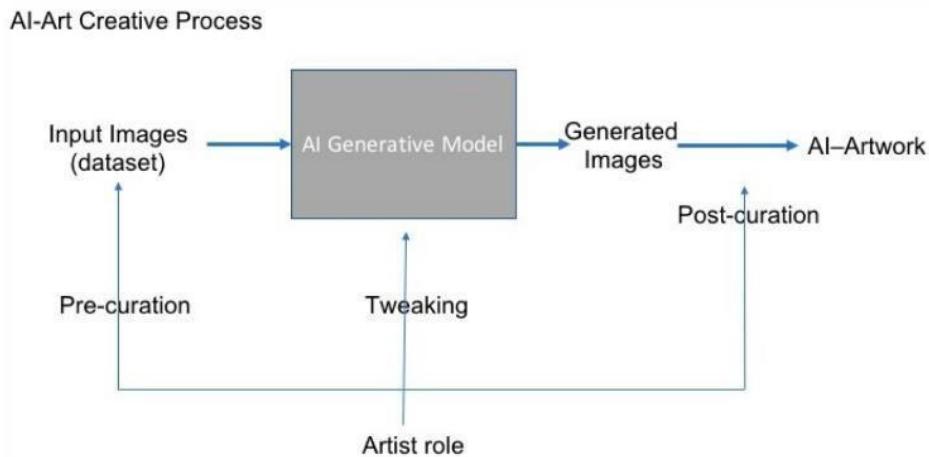
Postoji nekoliko ključnih prednosti korištenja alata generativne umjetnosti vođene AI-em. Svaka kreacija generirana od strane AI-a je neponovljiva, što daje novu dimenziju pojmu originalnosti u umjetnosti. Druga prednost je poboljšana učinkovitost. Proces stvaranja umjetničkih djela pomoću ovih alata je izuzetno brz. Od unosa prompta do konačnog djela, cijeli proces traje manje od jedne minute. To omogućuje umjetnicima i dizajnerima da brzo iteriraju kroz različite ideje i koncepte, čime se znatno ubrzava kreativni proces.

Treća ključna prednost je inspiracija. Umjetnici često koriste generativne alate kao izvor inspiracije, istražujući nove stilove i tehnike koje možda ne bi otkrili sami. GAN može generirati neočekivane kombinacije boja, oblika i tekstura, otvarajući nove puteve za kreativno izražavanje. Korištenje alata generativne umjetnosti vođene AI-em otvara brojne prilike za umjetnike. Granice tradicionalne umjetnosti se šire, a umjetnici imaju priliku istraživati nove i uzbudljive pristupe stvaranju. Brzina i učinkovitost procesa omogućuju brže prototipiranje i razvoj ideja, dok široka dostupnost ovih alata omogućuje pristup umjetničkom stvaranju širem spektru ljudi, uključujući one bez formalnog umjetničkog obrazovanja [8].

Međutim, korištenje AI-a u umjetnosti također donosi određene izazove. Pitanja autentičnosti i vlasništva nad digitalnim umjetničkim djelima generiranim od strane AI-a postaju sve relevantnija. Također, postoji i rasprava o ulozi ljudske kreativnosti naspram umjetne inteligencije - može li stroj zaista biti kreativan ili je on samo alat u rukama čovjeka? Jedna od najčešće korištenih tehnika u generativnoj umjetnosti vođenoj AI-em je Generativna Suparnička Mreža [14].

Trening proces GAN-ova je iterativan i dinamičan. U početku, generator proizvodi uzorke koji su očito lažni i diskriminatore ih lako prepoznaje. Međutim, kako se trening nastavlja, generator postaje sve bolji u stvaranju uvjerljivijih uzoraka, dok diskriminator postaje sve bolji u njihovom prepoznavanju. Ova suprotstavljena dinamika tjera obje mreže na kontinuirano poboljšanje, sve dok generator ne postigne točku u kojoj su njegovi uzorci toliko realistični da ih diskriminator više ne može razlikovati od stvarnih podataka.

U području sigurnosti, GAN-ovi se koriste za stvaranje lažnih biometrijskih podataka kako bi se testirali i poboljšali sustavi prepoznavanja lica. Unatoč brojnim prednostima, GAN-ovi također postavljaju značajna etička i socijalna pitanja.



**Slika 3 GAN proces umjetne inteligencije**

Izvor: Eckerli, F., Osterrieder, J. (2021). Generative Adversarial Networks in finance: an overview. <https://doi.org/10.48550/arXiv.2106.06364> (04.06.2024.)

Kreativna suparnička mreža (engl. *Creative Adversarial Network* - CAN) predstavlja značajan napredak u području generativnih suparničkih mreža. Dok GAN-ovi omogućuju strojevima da stvaraju slike koje su vrlo slične onima iz originalnih datasetova, CAN-ovi idu korak dalje koristeći „stilsku dvostrislenost“ kako bi postigli originalnost. Generator stvara nove uzorke podataka, dok diskriminator ocjenjuje autentičnost tih uzoraka u usporedbi s pravim podacima [15].

Kreativna suparnička mreža (CAN) temelji se na ovom principu, ali dodaje novu dimenziju u procesu generiranja umjetnosti. Prema [44] CAN se trenira između dvije suprotstavljene mreže, jedne koja potiče stroj da prati estetiku prikazane umjetnosti, minimalizirajući odstupanje, i druge koja kažnjava stroj ako oponaša već uspostavljeni stil, što rezultira

maksimiziranjem stilske dvosmislenosti. Ova inovacija omogućuje CAN-ovima da ne samo repliciraju postojeće stilove, već i kreiraju nove i originalne umjetničke forme. Proces treniranja CAN-a uključuje dvije ključne komponente: generatora i kreativnog diskriminatora. Generator u CAN-u stvara umjetnička djela na temelju naučenih stilova iz treniranog skupa podataka, dok kreativni diskriminator ima dvostruku ulogu. On ne samo da procjenjuje autentičnost generiranih umjetničkih djela, već i ocjenjuje njihovu kreativnost i originalnost.

Kreativni diskriminator koristi dva kriterija za ocjenjivanje [2]:

- estetska vjernost: Ovaj kriterij ocjenjuje koliko generirano umjetničko djelo slijedi stilove i estetske norme treniranog skupa podataka.
- stilska dvosmislenost: Ovaj kriterij ocjenjuje koliko generirano umjetničko djelo odstupa od poznatih stilova i uvodi nove, originalne elemente.

CAN-ovi imaju potencijal da revolucioniraju suvremenu umjetnost na više načina. Prvo, omogućuju stvaranje potpuno novih umjetničkih stilova koji nisu ograničeni ljudskim predznanjem ili predrasudama. Umjetnici i dizajneri mogu koristiti CAN-ove kao alat za eksperimentiranje s novim formama i tehnikama, otkrivajući neistražene kreativne teritorije. Drugo, CAN-ovi omogućuju demokratizaciju umjetničke kreacije. Korištenjem ovih alata, pojedinci bez formalne umjetničke edukacije mogu stvarati visokokvalitetna umjetnička djela, čime se širi pristup umjetnosti i potiče raznolikost u umjetničkoj produkciji.

Jedan od najistaknutijih primjera ovakve primjene AI tehnologije je AICAN (engl. *Artificial Intelligence Creative Adversarial Network*), projekt razvijen u Rutgersovom Art & AI Labu. AICAN demonstrira kako se umjetnici, bilo ljudski bilo umjetni, mogu inspirirati radovima svojih prethodnika te kroz tu inspiraciju stvoriti nešto novo i originalno. AICAN koristi dvije suprotstavljene mreže kako bi generirao originalna umjetnička djela. Prema [43] te dvije mreže omogućuju da generirana umjetnička djela budu originalna, ali da se istovremeno ne odvajaju previše od ustaljenih estetskih normi. Proces stvaranja umjetnosti kroz AICAN

simulira način na koji umjetnici probavljaju djela prethodne umjetnosti, dok u nekom trenutku ne izađu iz ustaljenih stilova i stvore nove. Na ovaj način, AI ne samo da replicira postojeće stilove, već i inovira, kreirajući nove umjetničke izraze. "Image style algorithm" je jedan od takvih algoritama, koji omogućuje spajanje elemenata iz različitih stilova u jedinstvenu kompoziciju [8].

Ovaj algoritam omogućuje umjetniku da koristi baznu sliku i sliku koja služi kao izvor za stil, koje algoritam spoji u konačan proizvod. Ovaj proces spajanja stilova omogućuje umjetnicima da eksperimentiraju i kreiraju kompleksnije i raznovrsnije umjetničke izraze. Jedan od najistaknutijih primjera integracije AI u digitalnu umjetnost je alat Firefly, implementiran u Adobe Photoshop-u. Ovaj alat omogućava korisnicima da proširuju slike dodavanjem pozadina ili različitih objekata koje generira AI, kao i poboljšanje preciznosti uklanjanja objekata sa slike. Do sada je kreirano oko sto milijuna slika korištenjem alata Firefly, što ukazuje na njegovu popularnost i široku primjenu među korisnicima [11].

Firefly predstavlja značajan napredak u digitalnoj umjetnosti jer omogućava umjetnicima da lako eksperimentiraju s novim elementima i brže postignu željene rezultate, čime se smanjuje vrijeme potrebno za tehničke aspekte rada i omogućuje veći fokus na kreativnost. Apple-ov Procreate također koristi AI tehnologiju za poboljšanje korisničkog iskustva. Razni računalno potpomognuti alati za crtanje i bojanje unutar ovog programa omogućavaju umjetnicima da koriste AI za predlaganje boja ili stilova na temelju analize njihovog rada.

Osim alata za crtanje, sustavi klasifikacije slika predstavljaju još jedan važan aspekt primjene AI u umjetnosti. Ovi sustavi koriste ogromne baze podataka za prepoznavanje uzoraka u velikom broju slika, što omogućava umjetnicima da lako pronađu reference, inspiraciju ili da analiziraju vlastiti rad u kontekstu šire umjetničke zajednice. Ovi sustavi također mogu pomoći u automatskom sortiranju, organiziranju i katalogizaciji velikih zbirki umjetničkih djela, čime se umjetnicima štedi vrijeme i omogućuje bolja preglednost i upravljanje njihovim radom.

Dodatno, umjetnički „chatbot-ovi“ predstavljaju inovativan način na koji AI može komunicirati s korisnicima. Ovi chatbot-ovi mogu razgovarati s korisnicima kako bi dobili informacije i upute, te imaju mogućnost procesirati i generirati slike prema zadanim uputama [14]. Takvi

sustavi omogućavaju korisnicima da izraze svoje ideje u prirodnom jeziku, a AI zatim te ideje pretvara u vizualne kreacije. Ovaj pristup ne samo da olakšava proces stvaranja za one koji možda nisu vješti u tehničkim aspektima crtanja, već i otvara vrata novim oblicima interaktivne umjetnosti i suradnje između čovjeka i stroja.

Uz sve navedeno, sistemi preporuke umjetnosti, koji koriste AI za preporuku umjetničkih djela prema osobnim preferencijama i željama korisnika, predstavljaju još jedan koristan alat. Ovi sistemi analiziraju korisnikove preferencije, prethodne izvore i interakcije s umjetničkim djelima kako bi preporučili nove rade koji bi im se mogli svidjeti. Na taj način, AI pomaže korisnicima da otkriju nove umjetnike i djela koja odgovaraju njihovim ukusima, čime se potiče veća povezanost i interakcija s umjetničkom zajednicom. Prvi značajni koraci u spajanju umjetne inteligencije i glazbe sežu u sredinu 20. stoljeća. Leonard Isaacson, zajedno sa svojim timom, stvorio je prvu originalnu skladbu koju je generiralo "superračunalo" još 1956. godine. Skladba nazvana "Illiad Suite" nastala je tako što je računalo generiralo nasumične brojeve koji su odgovarali ritmu, glasnoći i drugim glazbenim parametrima [15].

Umjetna inteligencija je danas toliko napredovala da ima ključnu ulogu u glazbenoj produkciji, obuhvaćajući sve korake od skladanja i aranžiranja do miksanja i masteringa pjesama. Prema [5], AI značajno pojednostavljuje stvaranje profesionalne glazbe putem algoritama obučenih na velikim bazama podataka postojeće glazbe. Ovi algoritmi uče prepoznavati obrasce i strukture različitih glazbenih žanrova i stilova te ih vjerno reproducirati.

Jedna od glavnih prednosti umjetne inteligencije u glazbenoj industriji je njena sposobnost automatizacije složenih procesa koji su inače zahtijevali puno vremena i stručnog znanja. Algoritmi AI-a mogu prilagoditi vokale, kontrolirati razine i tempo instrumenata, ukloniti pozadinske zvukove i neželjene elemente te kreirati nove instrumente i zvučne efekte [10]. Osim toga, umjetna inteligencija može automatizirati zadatke poput komponiranja i analize zvuka, čime se znatno skraćuje vrijeme potrebno za stvaranje glazbe.

Kako se tehnologija razvija, možemo očekivati još sofisticiranije alate koji će dodatno unaprijediti glazbenu produkciju. AI bi mogao postati suradnik glazbenicima, omogućujući im da se usredotoče na kreativne aspekte dok tehnologija preuzima tehničke zadatke.

Goodfellow, Pouget-Abadie i Mirza predviđaju nekoliko ključnih područja u kojima će UI igrati značajnu ulogu u budućnosti glazbene produkcije [7]:

- Miksanje i mastering dodataka i mrežnih usluga: UI može pomoći u automatizaciji tehničkih aspekata glazbene produkcije, čime se štedi vrijeme i omogućava glazbenicima da se više fokusiraju na kreativni proces.
- Demix i remix obrada: Alati potpomognuti UI omogućuju razdvajanje različitih slojeva unutar glazbenih zapisa, što omogućava stvaranje novih remixa i prilagodbi originalnih pjesama.
- Generiranje glazbe i uzoraka sadržaja: UI može generirati nove melodije, ritmove i zvukove, pružajući glazbenicima inspiraciju i nove ideje.
- Generiranje harmonije i melodije: Korištenje algoritama za stvaranje složenih harmonskih struktura i melodijskih linija može poboljšati kreativni proces.
- Postprodukcija: Dodaci za postprodukciju potpomognuti UI mogu automatski prilagoditi zvukovne parametre kako bi se postigao željeni rezultat.
- Glazbena produkcija na temelju jezičnih upita: Razvoj sučelja koje omogućava kreiranje glazbe putem jednostavnih jezičnih upita mogao bi dodatno demokratizirati glazbenu produkciju.
- Generiranje stihova: Alati za generiranje tekstova pjesama mogu pomoći glazbenicima u pisanju stihova koji odgovaraju određenim temama ili stilovima.

Generativni dizajn je pristup dizajniranju koji koristi algoritme za generiranje velikog broja dizajnerskih rješenja temeljenih na zadanim parametrima i ograničenjima. Umjesto tradicionalnog pristupa gdje dizajner kreira jedno rješenje, generativni dizajn omogućuje stvaranje stotina ili čak tisuća varijacija koje se zatim evaluiraju prema zadanim kriterijima kao što su čvrstoća, težina, troškovi i drugo. Ovaj pristup omogućava pronalaženje optimalnih rješenja koja bi inače bila teško zamisliva.

Generativna umjetna inteligencija dodatno unapređuje generativni dizajn korištenjem naprednih algoritama strojnog učenja. AI može analizirati ogromne količine podataka, učiti iz postojećih dizajna i stvarati nova rješenja koja zadovoljavaju specifične potrebe i uvjete. Ova tehnologija omogućava ne samo brže, već i inteligentnije stvaranje dizajna, smanjujući potrebu za ljudskom intervencijom u ranim fazama projektiranja.

Kombinacija generativnog dizajna i AI donosi nove dimenzije u projektiranju i proizvodnji. Dok generativni dizajn omogućava stvaranje širokog spektra rješenja, AI analizira i optimizira ta rješenja, birajući one koji najbolje odgovaraju zadanim skupu kriterija. Ova sinergija rezultira bržim, učinkovitijim i inovativnjim procesom dizajna.

Jedna od ključnih prednosti ove kombinacije je ubrzanje iterativnog procesa dizajna. Tradicionalni procesi često zahtijevaju mnogo vremena za testiranje i evaluaciju različitih rješenja. Generativni dizajn i AI omogućuju brze digitalne iteracije i simulacije, što značajno smanjuje vrijeme od ideje do konačnog proizvoda. Osim toga, poboljšava se i kvaliteta rezultata jer AI može identificirati poteškoće koje bi ljudima mogle promaknuti.

Industrije poput zrakoplovstva, automobilske industrije i arhitekture već koriste ove tehnologije za stvaranje inovativnih rješenja. Na primjer, inženjeri bi mogli koristiti generativni dizajn i AI za optimizaciju struktura zrakoplova, smanjujući težinu i troškove proizvodnje dok istovremeno povećavaju sigurnost i efikasnost. Slično tome, arhitekti mogu koristiti ove alate za stvaranje održivijih i estetski privlačnijih zgrada. S razvojem tehnologije, dizajn je prošao kroz nekoliko značajnih transformacija, od početaka računalno potpomognutog dizajna do suvremenih inovacija poput generativnog dizajna i generativne umjetne inteligencije. Ove napredne tehnologije ne samo da poboljšavaju učinkovitost dizajnerskih procesa, već i potiču ljudsku kreativnost te omogućuju postizanje rezultata koji su prije bili nezamislivi.

Računalno potpomognut dizajn revolucionirao je dizajnerske procese omogućivši preciznije i brže stvaranje nacrta i modela. No, CAD je tek početak evolucije dizajna. Sljedeći korak bio je uvođenje automatiziranih tehnologija, među kojima je generativni dizajn zauzeo posebno mjesto. Generativni dizajn koristi algoritme i računalne resurse kako bi generirao više dizajnerskih rješenja na temelju zadanih parametara i ograničenja. Ova tehnologija omogućava

inženjerima i dizajnerima da istraže širok spektar mogućnosti, često otkrivajući inovativna rješenja koja su ekonomičnija, lakša i jača [8].

U ovom kontekstu, generativni dizajn se koristi za generativno planiranje, posebno u pripremi složenih rasporeda produkcije. Procesi koji su nekada trajali mjesecima sada se mogu optimizirati i ubrzati korištenjem generativnog dizajna. Kada dođe do poremećaja u vremenskom okviru, generativni dizajn može brzo prilagoditi i racionalizirati sve promjene, što ga čini ključnim alatom za učinkovito upravljanje složenim produkcijama. Unatoč svojim prednostima, generativni dizajn ima jedno ograničenje: ne koristi povijesne podatke pri stvaranju novih dizajna.

Ovdje na scenu stupa generativna umjetna inteligencija. Generativna AI kombinira snagu generativnog dizajna s mogućnošću učenja iz ogromnih količina podataka. To znači da može analizirati prethodne dizajne, učiti iz njih i primijeniti ta znanja na nove projekte. Primjena generativne AI omogućava stvaranje još sofisticiranijih i prilagođenijih dizajnerskih rješenja. Korištenje generativnog AI-a je jednostavno: unesite nekoliko osnovnih podataka i višestruki odgovori stići će u roku od nekoliko sekundi.

Jedna od glavnih prepreka u generativnom dizajnu je treniranje neuronske mreže da generira korisne rezultate. Potreban je opsežan i dobro organiziran skup podataka koji može dati željene odgovore na specifična pitanja. Da bi bili nazučinkovitiji, ti podaci moraju biti organizirani, što omogućava lako pretraživanje i pristupanje potrebnim informacijama. ChatGPT je impresivan jer je imao trilijune riječi za obuku na internetu. Za bilo koji AI projekt, 80% početnog rada je samo dobivanje pravih podataka s kojima se nešto može učiniti [5]. Prikupljanje, čišćenje i organizacija podataka ključni su koraci u stvaranju učinkovitog AI sustava. Ali kada su podaci prisutni, potencijal generativnog dizajna je nevjerljiv.

### **3.4. Pitanja privatnosti i sigurnosti u kontekstu generativne umjetne inteligencije**

Generativna umjetna inteligencija donosi revoluciju u načinu na koji vršimo interakciju s tehnologijom, ali nosi i značajne izazove vezane uz sigurnost i privatnost. Iako GAI obećava veliki potencijal, još uvijek je u ranoj fazi razvoja i nije spreman za dostupnu upotrebu. Zabrinutost zbog sigurnosti i privatnosti raste iz više razloga. Jedan od glavnih problema je nedostatak transparentnosti. Tvorci GAI-a često promoviraju otvorene modele, ali ti modeli često nisu dovoljno transparentni. Iako možda omogućuju pristup određenim aspektima modela, poput težina ili dokumentacije, skupovi podataka korišteni za njihovo treniranje ostaju skriveni. Nedostatak transparentnosti znači da korisnici nemaju načina provjere ili potvrde sadržaje ovih modela, uključujući bilo kakve potencijalno protuzakonite ili zlonamjerne podatke koji su mogli biti uneseni tijekom treniranja.

Osim nedostatka transparentnosti, generativni AI modeli predstavljaju značajne sigurnosne rizike. Oni su privlačna meta za kibernetičke prijetnje, budući da svi podaci uneseni u njih čine potencijalno vrlo vrijednu metu. Napadi poput ubrizgavanja uputa, trovanja podataka i ugrađivanja podataka mogu ugroziti integritet ovih modela i omogućiti neovlašteni pristup povjerljivim informacijama. Nekontrolirani unos podataka također otvara vrata kibernetičkim aktivnostima sponzoriranim od strane države, putem trojanskih konja i sličnih taktika.

Dalje, privatnost je još jedna zabrinjavajuća tema u kontekstu GAI. Neprekidno unošenje podataka u ove modele predstavlja rizik za privatnost pojedinaca i društva u cjelini. Dok su propisi koji se fokusiraju na prava podataka važni, oni često nisu dovoljni u rješavanju dinamične prirode GAI modela. Posebno, dinamičke konverzacijeske upute trebaju se smatrati

intelektualnim vlasništvom i zaštititi od korištenja za treniranje modela ili dijeljenja s drugim korisnicima [6].

Kako bismo riješili ove izazove, potrebno je poduzeti niz koraka. Prvo, potrebno je poboljšati transparentnost u vezi s GAI modelima, osiguravajući da korisnici imaju jasan uvid u podatke korištene za njihovo treniranje. Drugo, nužno je razviti napredne sigurnosne mehanizme koji će zaštititi ove modele od različitih vrsta kibernetičkih prijetnji. I konačno, potrebno je ažurirati propise o privatnosti kako bi se bolje nosili s dinamičnom prirodom GAI modela, posebno kad je riječ o zaštiti intelektualnog vlasništva konverzacijskih uputi [7].

Generiranje izmišljenih ili netočnih informacija je još jedan problem koji se može pojaviti s korištenjem generativne umjetne inteligencije. Alati poput ChatGPT-ja mogu stvarati sadržaj koji može biti netočan ili zavaravajući, što može dovesti do širenja dezinformacija. Važno je educirati korisnike o mogućnosti netočnih informacija i poticati ih da uvijek provjeravaju izvore informacija. Napokon, generativna umjetna inteligencija može biti izložena kibernetičkim napadima.

### **3.5. Etički aspekti korištenja generativnih modela za manipulaciju digitalnih sadržaja**

Generativna umjetna inteligencija donosi sa sobom revolucionarne mogućnosti, ali istovremeno postavlja važna etička pitanja koja zahtijevaju pažljivo promišljanje i regulativne mјere kako bi se osigurala odgovorna upotreba. Generativna AI omogućuje stvaranje autentičnih sadržaja poput slika, videozapisa i tekstova koji mogu biti iznimno uvjerljivi i teško razlikovati od stvarnih. To otvara vrata za različite primjene, poput poboljšanja umjetničkih procesa, razvoja novih proizvoda i usluga te unaprjeđenja korisničkog iskustva [4].

Osim toga, generativna AI može predstavljati prijetnju privatnosti pojedinaca. Korištenjem dostupnih podataka na internetu, AI sustavi mogu generirati detaljne profile pojedinaca ili čak simulirati njihove identitete. To otvara mogućnost za špijuniranje, krađu identiteta i druge oblike zloupotrebe osobnih podataka. Kako bi se suočili s tim izazovima, potrebno je razviti jasne smjernice i regulative koje će regulirati upotrebu generativne AI. To uključuje definiranje standarda za autentičnost i transparentnost generiranih sadržaja, kao i zaštita privatnosti podataka.

Također je važno educirati javnost o potencijalnim opasnostima generativne AI te poticati razvoj tehnologija za detekciju i sprječavanje zloupotrebe. Europska komisija je formirala stručnu skupinu koja je razvila etičke smjernice za korištenje ove tehnologije. Ove smjernice sadrže niz prava i načela etičnosti koja trebaju biti temelj svih aktivnosti vezanih uz AI. Prvo i osnovno načelo je poštovanje dostojanstva ljudi. To znači da se svaka osoba treba tretirati s jednakim poštovanjem i da ni tehnologije poput AI-a ne bi smjele dovesti u pitanje tu vrijednost.

Ovo načelo je esencijalno jer osigurava da se ne diskriminiraju ljudi na temelju njihove upotrebe ili neupotrebe AI-a. Primjerice, u kontekstu vizualne umjetnosti, ovo načelo implicira da umjetničko djelo ne bi trebalo vrednovati više ili manje samo zato što je stvoreno uz pomoć AI-a, već bi se trebalo vrednovati na temelju kvalitete i originalnosti. Drugo načelo, sloboda, naglašava važnost pružanja svim pojedincima slobode da donose vlastite odluke. To uključuje pristup tehnologijama AI-a te osiguranje jednakih prilika za sve [7].

Ovo načelo podrazumijeva da bi razvoj i korištenje AI-a trebali doprinijeti širenju mogućnosti i poticanju raznolikosti, a ne stvaranju novih oblika ograničenja ili privilegija. Treće načelo, poštovanje pravde, prava i demokracije, naglašava da AI sustavi moraju djelovati u skladu s pravnim okvirom i demokratskim procesima. To znači da se AI ne smije koristiti na načine koji bi mogli ugroziti demokratske procese ili prava pojedinaca. Na primjer, AI sustavi ne bi smjeli biti korišteni za manipuliranje političkim procesima ili ograničavanje slobode izražavanja.

Na kraju, ravnopravnost, solidarnost i prava građana naglašavaju važnost osiguravanja jednakih prava i prilika za sve članove društva. To uključuje borbu protiv diskriminacije, promicanje socijalne solidarnosti te zaštitu prava građana u digitalnom okruženju. Primjena ovog načela zahtijeva kontinuiranu reviziju politika i praksi kako bi se osiguralo da AI doprinosi izgradnji pravednijeg i inkluzivnijeg društva. Generiranje vizualne umjetnosti pomoći AI alata postalo je sve popularnije, ali s tim dolaze i razni pravni izazovi i pitanja autorskih prava.

Jedan od glavnih izazova je pitanje autorskih prava i priznavanja autorstva. Budući da AI može generirati umjetnička djela na temelju velike količine podataka koje obrađuje, često je teško utvrditi tko je pravi vlasnik autorskog djela. AI može koristiti obrasce i stilove koji su slični postojećim umjetničkim radovima, što može dovesti do situacija u kojima je teško razlikovati izvorni rad od generiranog rada [11]. To može rezultirati sporovima oko autorskih prava, jer su većina autorskih djela zaštićena zakonom. Osim toga, nedostatak jasne identifikacije autora može dovesti do nedostatka priznavanja zasluga i kompenzacije za njihov rad.

Drugi važan aspekt je korištenje podataka. AI alati često zahtijevaju velike količine podataka kako bi generirali umjetnička djela. Međutim, korištenje tih podataka može biti problematično ako nije u skladu s pravilima o zaštiti privatnosti ili ako se koristi u komercijalne svrhe bez odgovarajućeg dopuštenja. Nepoštivanje uvjeta korištenja podataka može dovesti do pravnih problema, uključujući tužbe za kršenje privatnosti ili intelektualnog vlasništva.

Nadalje, tehnološka rješenja poput digitalnih potpisa ili blockchain tehnologije mogu pružiti mehanizme za verifikaciju autentičnosti i autorskog prava umjetničkih djela generiranih pomoći AI-a. Implementacija ovih tehnoloških rješenja može pomoći u osiguranju prava umjetnika i olakšavanju praćenja i priznavanja autorstva. Uz to, važno je promicati dijalog između pravnih stručnjaka, tehnoloških stručnjaka, umjetnika i regulatornih tijela kako bi se razumjeli izazovi i pronašla rješenja koja će omogućiti napredak umjetničke prakse uz poštovanje prava svih sudionika. Kroz suradnju i inovaciju, možemo stvoriti okruženje u kojem AI može biti kreativni alat bez ugrožavanja autorskih prava i prava na privatnost.

## **4. PRIMJENE GENERATIVNE UMJETNE INTELIGENCIJE**

Generativna umjetna inteligencija brzo je postala jedna od najdinamičnijih i najinovativnijih tehnologija današnjice, s primjenama koje obuhvaćaju širok spektar industrija. Njena sposobnost da stvara nove i originalne podatke, slike, tekstove, glazbu i druge oblike sadržaja, revolucionira način na koji pristupamo kreativnosti, analizi podataka, te čak i svakodnevnim poslovnim procesima. U ovom poglavlju istražit ćemo različite primjene generativne AI, od kreativnih industrija i zabave, do znanosti, medicine i poslovanja.

### **4.1. Generiranje i manipulacija**

Tehnološki napredak je doveo do nevjerljivih inovacija u načinu na koji stvaramo i obrađujemo vizualne sadržaje. Prvo, treba istaknuti ulogu umjetne inteligencije u generiranju slika. Tehnologije poput DALL-E i Stable Diffusion, razvijene od strane organizacija kao što su OpenAI, koriste duboke neuronske mreže za generiranje novih slika na temelju tekstualnih opisa [11]. Ove tehnologije omogućuju stvaranje visokokvalitetnih, originalnih vizuala koji se mogu koristiti u raznim kontekstima, od umjetnosti do oglašavanja. Primjerice, DALL-E može generirati sliku "plavog slona koji svira violinu u svemiru" na temelju jednostavnog tekstualnog opisa, pružajući kreativcima nevjerojatne mogućnosti za vizualnu eksperimentaciju.

Dalje, ove AI tehnologije koriste složene algoritme za analizu i sintezu vizualnih podataka. Stable Diffusion, na primjer, koristi tehnike difuzije za stvaranje i poboljšanje slika, omogućujući preciznu kontrolu nad stilom i sadržajem generiranih vizuala. Korištenje dubokog učenja u generiranju slika predstavlja značajan korak naprijed u kreativnim industrijama, omogućujući umjetnicima i dizajnerima da brže i učinkovitije realiziraju svoje vizije. Drugi ključni aspekt tehnološkog napretka u vizuelnoj obradi je 3D modeliranje [2].

Napredak u ovom području omogućuje detaljnije, realističnije i interaktivnije vizualne sadržaje. Kroz softvere za 3D modeliranje, umjetnici mogu stvarati trodimenzionalne objekte, scenarije

i karaktere s izuzetnom preciznošću. Ovo nije samo korisno u filmskoj industriji za stvaranje specijalnih efekata, već i u arhitekturi, videoograma, medicini i mnogim drugim područjima. 3D modeliranje omogućuje kreiranje virtualnih svjetova koji su gotovo neodvojivi od stvarnog svijeta, pružajući korisnicima iskustva koja su prije bila nezamisliva.

Osim toga, softveri za uređivanje i filtri omogućuju korisnicima da manipuliraju i poboljšavaju postojeće slike na brz i jednostavan način. Ovi alati pružaju širok spektar mogućnosti, od osnovnih korekcija boja do naprednih manipulacija, poput uklanjanja objekata ili stvaranja fotorealističnih efekata. Takvi alati postaju sve pristupačniji i intuitivniji, omogućujući korisnicima svih razina vještina da postignu profesionalne rezultate. Uz sve navedeno, važno je istaknuti da tehnološki napredak u vizualnoj obradi otvara nova pitanja i izazove, poput etičkih i pravnih dilema vezanih za manipulaciju slika i autorska prava. Ipak, ako se pravilno koristi, ova tehnologija ima potencijal da unaprijedi naše sposobnosti za stvaranje i izražavanje, te da inspirira nove oblike umjetničkog izraza. U današnjem digitalnom dobu, 3D modeliranje i renderiranje igraju ključnu ulogu u raznim industrijskim granama, od filmske produkcije do arhitekture, igara i marketinških kampanja. Takvi alati postali su nezamjenjivi resursi za stvaranje virtualnih svjetova s nevjerljivom preciznošću i detaljima [44]. Paralelno s razvojem 3D modeliranja, softveri za uređivanje slika poput Adobe Photoshop-a i GIMP-a omogućuju korisnicima da transformiraju sirove slike u vizualna remek-djela. Ovi alati pružaju širok spektar alata za retuširanje, izmjenu boja, dodavanje efekata i druge obrade slika. Photoshop, kao industrijski standard, nudi profesionalnim dizajnerima i fotografima sve što im je potrebno za kreativnu manipulaciju slika. S druge strane, GIMP, kao open-source alternativa, pruža slične funkcionalnosti bez troškova licence, što ga čini pristupačnijim široj publici [4].

Krenimo s vizualnom stranom. Aplikacije poput Instagram-a i Snapchat-a pružaju korisnicima širok spektar preddefiniranih filtera i efekata koji omogućuju poboljšanje u realnom vremenu i personalizaciju fotografija i videozapisa. Ovi alati, koji su postali neizostavan dio društvenih medija, omogućuju svakome, bez obzira na tehničko znanje, da transformira svoje medijske sadržaje. Retro filteri, efekti proširene stvarnosti i razne druge opcije otvaraju prostor za izražavanje individualnosti i kreativnosti korisnika, istovremeno olakšavajući brendovima i marketinškim stručnjacima da dosegnu svoju publiku kroz vizualno atraktivne kampanje [8].

Manipulacija zvukova putem digitalnih audio radnih stanica (engl. *Digital audio workstation - DAW*) također predstavlja ključni aspekt suvremene audio produkcije. Ovi sofisticirani softveri omogućuju umjetnicima i inženjerima zvuka da snimaju, uređuju, miješaju i aranžiraju zvučne elemente na mikroskopskoj razini, rezultirajući finalnim glazbenim produkcijama visoke kvalitete. Procesori zvuka, kao što su reverb, delay i equalizer, su esencijalni alati u glazbenoj produkciji i post-produkciji zvuka [6].

Generativni modeli teksta, poput GPT-4 i BERT (engl. *Bidirectional Encoder Representations from Transformers – BERT*), predstavljaju revolucionarne algoritme dubokog učenja koji su u mogućnosti generirati tekstove na temelju zadanih unosa. Ovi modeli koriste složene neuronske mreže trenirane na ogromnim korpusima tekstualnih podataka kako bi naučili jezikovne obrasce i kontekst. Njihova sposobnost generiranja koherentnih tekstova koji imaju smisla omogućuje njihovu upotrebu u raznim aplikacijama poput "chatbot-ova", stvaranja sadržaja i automatiziranog pisanja.

Automatizirani alati za pisanje, poput Article Forge-a i Jarvis-a, pružaju korisnicima mogućnost generiranja pisanih sadržaja s minimalnim ljudskim nadzorom. Ovi alati koriste tehnologiju generativnih modela teksta ili druge napredne tehnike kako bi stvorili sadržaj koji je relevantan i privlačan ciljanoj publici, što ubrzava proces kreiranja i objavljivanja sadržaja na webu. Uređivači teksta, kao što su Microsoft Word i Google Docs, omogućuju korisnicima pisanje, uređivanje i formatiranje tekstualnih dokumenata na intuitivan način [7]. Ovi alati nude različite funkcije poput provjere pravopisa i gramatike, mogućnost dodavanja slika i tablica te suradnju u stvarnom vremenu, olakšavajući proces stvaranja i dijeljenja sadržaja.

Alati za analizu teksta, poput Grammarly-ija i Hemingway App-a, pomažu korisnicima u provjeri gramatičkih grešaka, stila i jasnoće njihovih pisanih tekstova. Koristeći napredne algoritme jezične analize, ovi alati identificiraju i sugeriraju poboljšanja u tekstu, pomažući korisnicima u stvaranju kvalitetnijih i profesionalnijih sadržaja. U svijetu videa, alati poput animacije, računarski stvorene slike (engl. *Computer Generated Imagery - CGI*), AI generiranja videa i manipulacije videozapisa pružaju neizostavne mogućnosti za stvaranje sadržaja.

Animacija i 3D računalna grafika CGI su postali neizostavni elementi u filmskoj industriji, televiziji, video igrami i marketinškim kampanjama. Ovaj brzorastući sektor oblikuje način na koji percipiramo svijet oko sebe i pruža nevjerojatne mogućnosti za kreativno izražavanje i pričanje priča [2]. Prva perspektiva koju valja razmotriti je razvoj softvera kao što su Adobe After Effects i Autodesk Maya, koji su postali kamen temeljac u industriji animacije i vizualnih efekata. Adobe After Effects nudi moćne alate za kombiniranje različitih medijskih formata, omogućujući korisnicima da stvore dinamične animirane sekvene. S druge strane, Autodesk Maya pruža napredne mogućnosti za modeliranje, animaciju i renderiranje 3D objekata, često se koristeći u filmskoj industriji za stvaranje realističnih CGI likova i svjetova. Ova softverska rješenja omogućuju umjetnicima i animatorima da svoje vizije pretvore u stvarnost s visokom razinom detalja i realizma.

## **4.2. AI za poboljšanje kreativnih procesa**

Alati poput Adobe Photoshop-a i Procreate-a postali su neizostavni saveznici mnogim umjetnicima, omogućujući im da stvore remek-djela na digitalnom platnu. Dok je Photoshop dominirao scenom od ranih 90-ih godina, Procreate je relativno novi igrač koji je brzo stekao popularnost od svog lansiranja 2014. godine [14].

Jedna od ključnih prednosti Procreatea leži u njegovoj raznolikosti kistova. S impresivnih 130 ugrađenih kistova, umjetnici imaju bogatstvo mogućnosti za eksperimentiranje s različitim stilovima i tehnikama crtanja. Mogu prilagoditi postojeće četkice ili stvoriti potpuno nove prema svojim specifičnim potrebama. Nadalje, verzija 5.0 Procreatea omogućuje uvoz kistova iz Photoshopa, pružajući korisnicima dodatnu fleksibilnost i mogućnost stvaranja umjetnosti s omiljenim kistovima.

Osim bogatstva kistova, Procreate se ističe i svojim jednostavnim i korisnički prijateljskim sučeljem. Za početnike, ovo sučelje pruža intuitivno iskustvo, olakšavajući navigaciju kroz izbornike, filtre i postavke aplikacije. Uz malo istraživanja, korisnici brzo shvaćaju ugrađene značajke i prečace, čime se smanjuje vrijeme provedeno u učenju i povećava produktivnost. Široka paleta boja još je jedan atribut koji čini Procreate privlačnim umjetnicima. Mogu stvoriti

i spremiti prilagođene palete boja, omogućujući im da brzo pristupe omiljenim nijansama i tonovima [8]. Fleksibilnost u mijenjanju boja dodirivanjem zaslona olakšava proces eksperimentiranja s različitim bojama i stvaranja željenog vizualnog učinka.

Iako Procreate nudi impresivne značajke, važno je napomenuti da Adobe Photoshop ostaje ključni igrac u svijetu digitalne umjetnosti. S dugogodišnjom prisutnošću na tržištu i širokim rasponom profesionalnih usluga, Photoshop je neizostavan alat za mnoge umjetnike i dizajnere. Adobe Photoshop se ističe kao nezamjenjiv alat u arsenalu kreativaca i profesionalnih dizajnera diljem svijeta. Njegove posebne značajke, funkcionalnosti i fleksibilnost čine ga prvim izborom za obradu slika, ilustracija, dizajn web stranica, retuširanje fotografija i još mnogo toga.

Jedna od ključnih karakteristika koja izdvaja Photoshop od drugih alata je njegova sposobnost rada s više slojeva. Dok su drugi programi, poput Procreate, ograničeni na manji broj slojeva, Photoshop omogućuje stvaranje stotina slojeva, što je od vitalnog značaja za složene projekte s više detalja. Ova funkcionalnost omogućuje korisnicima da uređuju svaki sloj zasebno, olakšavajući prilagodbu i eksperimentiranje bez potrebe za spajanjem slojeva.

Jedan od manje poznatih, ali izuzetno moćnih alata u Photoshopu je alat za prilagođene oblike. Ovaj vektorski alat omogućuje korisnicima stvaranje kompleksnih oblika i uzoraka s lakoćom, čime se otvara vrata za kreativne eksperimente i inovativne dizajne. Ovaj alat nema izravnog analoga ni u jednoj drugoj popularnoj aplikaciji za slikanje, što dodatno potvrđuje jedinstvenost i moć Photoshopa kao dizajnerskog alata. Adobe Photoshop također nudi širok spektar alata za fotografije, uključujući uređivanje fotografija, retuširanje, filtre i podršku za RAW format fotografije. Ova sveobuhvatna funkcionalnost čini Photoshop idealnim alatom ne samo za dizajnere, već i za fotografе i umjetnike koji žele postići vrhunske rezultate u obradi slika [15].

Nadalje, Adobe Photoshop pruža slobodu izbora gadgeta, što znači da se može koristiti na laptopima, računalima i tabletima, prilagođavajući se potrebama i preferencijama korisnika. Ova fleksibilnost omogućuje kreativcima da rade na svojim projektima bilo gdje i bilo kada, bez obzira na to koji uređaj imaju pri ruci. Računalno potpomognuti dizajn predstavlja ključnu tehnologiju koja je duboko utkana u širok spektar industrija, od inženjeringu do dizajna automobila, arhitekture, medicinske tehnologije i mnogih drugih. Njegova sveprisutnost ne

samo da je transformirala način na koji se dizajnira i razvija proizvode, već je i donijela značajne promjene u načinu poslovanja i komunikacije unutar organizacija.

Primjene CAD Tehnologije u Industriji [7]:

- Inženjering: CAD tehnologija transformira procese projektiranja i testiranja, omogućujući inženjerima da preciznije analiziraju i optimiziraju svoje dizajne prije proizvodnje.
- Automobilska industrija: U automobilskoj industriji, CAD tehnologija koristi se za dizajniranje i testiranje svih aspekata vozila, uključujući motor, karoseriju, unutrašnjost i sigurnosne sustave.
- Arhitektura: Arhitekti koriste CAD softver za stvaranje detaljnih digitalnih modela zgrada i prostora, olakšavajući proces planiranja i vizualizacije projekata.
- Medicinska tehnologija: U medicinskoj industriji, CAD tehnologija koristi se za dizajniranje medicinskih uređaja, proteza i implantata, pružajući preciznost i prilagodljivost potrebnu za individualizirane rješenja. S druge strane, stomatološke poliklinike koriste CAD/CAM tehnologiju kako bi poboljšale kvalitetu stomatoloških usluga. Od izrade krunica do proteza, CAD/CAM tehnologija omogućuje brže, preciznije i učinkovitije izvođenje složenih stomatoloških restauracija. Povećana točnost i učinkovitost CAD/CAM tehnologije rezultira smanjenjem ukupnih troškova za pacijente i ordinacije, dok vizualizacija krajnjeg izgleda zuba osigurava predvidljivije rezultate i smanjuje broj posjeta. Time se poboljšava i udobnost pacijenata, čineći stomatološke zahvate manje invazivnima i stresnijima.
- U proizvodnji, CAD tehnologija revolucionizira način na koji se dizajniraju i proizvode prototipovi i komponente. Omogućuje proizvođačima da koordiniraju proizvodnju, procijene vremenske okvire, nadgledaju tijek rada te dijele važne informacije s dionicima i dobavljačima. Time se osigurava učinkovitost i održivost proizvodnog procesa, što rezultira povećanjem profitne marže i poboljšanjem kvalitete proizvoda.
- U arhitekturi, CAD tehnologija olakšava stvaranje detaljnih nacrta, analizu dizajna te organizaciju građevinske dokumentacije. Digitalne slike nacrta omogućuju arhitektima

brže i preciznije izmjene, što rezultira kraćim vremenom izrade nacrtu, preciznim procjenama i ispunjenjem projektih rokova.

- U grafičkom dizajnu, CAD tehnologija pruža grafičkim dizajnerima alate za razvoj detaljnijih modela, jedinstvenih oblika te dodavanje različitih vizualnih efekata. Osim toga, omogućuje učinkovitu komunikaciju među timovima i brže primjene izmjena na rad, što rezultira smanjenjem vremena obrade, otklanjanjem grešaka i isporukom proizvoda više kvalitete.
- U industriji videoigara, CAD tehnologija igra ključnu ulogu u dizajnu i razvoju videoigara, omogućujući tvrtkama da stvore kvalitetniji sadržaj koji zadovoljava visoke standarde modernih potrošača. Igrača industrija je jedno od područja gdje CAD tehnologija igra ključnu ulogu. Alati za slikanje i uređivači materijala omogućuju dizajnerima da prilagode sjenčanje i teksturu, stvarajući detaljne svjetove koji zadovoljavaju očekivanja i ukuse obožavatelja. Ali to nije sve što CAD omogućuje. Korištenjem CAD softvera, dizajneri mogu provesti bolje sesije snimanja pokreta, osigurati siguran prijenos podataka te izraditi visokodetaljne 3D modele komponenti poput likova i objekata. Osim toga, CAD tehnologija omogućuje razvoj jedinstvenog osvjetljenja igre i animacija likova, što rezultira impresivnim vizualnim iskustvom za igrače. Ukratko, korištenje CAD tehnologije u igračoj industriji ne samo da olakšava proces dizajna, već i rezultira kvalitetnijim proizvodima koji zadovoljavaju zahtjeve suvremenih igrača.

Definicije temeljene na modelu također imaju važnu ulogu u olakšavanju procesa dizajna i proizvodnje. Eliminirajući potrebu za tradicionalnim crtežima na papiru i 2D prikazima, CAD omogućuje brži protok informacija i smanjuje mogućnost grešaka, što rezultira uštedom vremena i smanjenjem otpada. Uz to, sve veća upotreba softvera za 3D printanje dodatno transformira način na koji se proizvode dijelovi i prototipovi. Ova tehnologija omogućuje bržu izradu prototipa i komponenti sa složenim dizajnom, pružajući dizajnerima i inženjerima mogućnost da eksperimentiraju s različitim idejama i iteriraju dizajn prije nego što krenu u punu proizvodnju.

## **5. PRIMJENA GENERATIVNE UMJETNE INTELIGENCIJE U POMORSTVU**

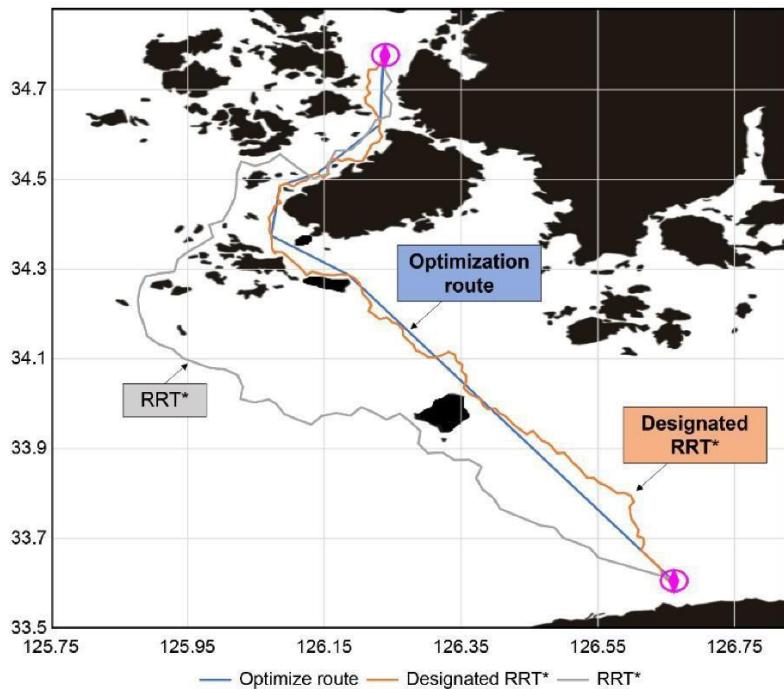
Generativna umjetna inteligencija počinje igrati sve značajniju ulogu u pomorstvu, gdje se njene inovativne mogućnosti koriste za poboljšanje operativne učinkovitosti, sigurnosti i održivosti. Pomorska industrija, koja obuhvaća širok spektar aktivnosti poput brodogradnje, navigacije, logistike i upravljanja flotom, suočava se s mnogim izazovima, uključujući optimizaciju rute, smanjenje emisija i povećanje sigurnosti na moru. Jedna od ključnih primjena generativne AI u pomorstvu je optimizacija navigacijskih ruta. Generativni modeli mogu analizirati velike količine podataka, uključujući vremenske uvjete, morsku struju, podatke o prometu i povijesne rute, kako bi generirali optimalne rute za plovila. Time se ne samo smanjuje vrijeme putovanja i potrošnja goriva, već se također povećava sigurnost plovidbe, izbjegavanjem područja s nepovoljnim uvjetima. Takva optimizacija može rezultirati značajnim smanjenjem troškova operacija te smanjenjem emisija stakleničkih plinova, što je ključno za ekološki prihvatljivo pomorstvo.

Generativna AI također se koristi za prediktivno održavanje pomorskih plovila i opreme. Modeli trenirani na podacima o kvarovima, performansama strojeva i uvjetima rada mogu generirati upozorenja i preporuke za održavanje prije nego što dođe do kritičnih kvarova. Ovo proaktivno održavanje smanjuje vrijeme neaktivnosti, produljuje vijek trajanja opreme i povećava sigurnost na moru. Također, generativni modeli mogu simulirati različite scenarije i moguće incidente, pomažući posadama da se bolje pripreme za hitne situacije.

### **5.1. Optimizacija rute plovila**

Više od 80% svjetske robne trgovine odvija se morem, a pomorstvo igra vitalnu ulogu u otpremi robe u svijetu. Morska plovidba priznata je kao kamen temeljac lanca opskrbe proizvodnje i međunarodne trgovine. Ekonomski struktura jedne nacije također uvelike ovisi o sektoru pomorskog prometa, koji uvozi i izvozi resurse i stvara radna mjesta. Glavna čvorišta u mreži

pomorskog prometa su morske luke. Usporedno, luke u modernoj koncepciji globalnog opskrbnog lanca razvile su se od tradicionalnih čvorista za utovar, istovar i skladištenje robe do značajnih čvorova koji koordiniraju cijeli opskrbni lanac. Kao što je pokazano pojavom kontejnerske plovidbe, koja je ujedinila međunarodnu trgovinu i potaknula veze između različitih načina prijevoza, ovo širenje dramatično je povećalo potražnju za lukama u posljednjih nekoliko desetljeća [23].



**Slika 4 Primjer - optimizacija rute plovila**

Izvor: Karras, T., Laine, S., Aila, T. (2019). A Style-Based Generator Architecture for GAN. CVPR konferencija. <https://doi.org/10.48550/arXiv.1812.04948> (20.06.2024)

Osim toga, većina velikih luka diljem svijeta fizički je ograničena gradovima koji ih okružuju. Luke stoga moraju povećati svoju unutarnju i vanjsku učinkovitost kako bi smanjile ukupne logističke troškove. Pomorska i logistička industrija ključne su za funkcioniranje globalnog gospodarstva budući da služe kao temelj međunarodne trgovine. Te industrije obuhvaćaju različite aktivnosti povezane s prijevozom robe, sirovina i putnika preko oceana, mora i kopna. Pomorski sektor, koji se često naziva pomorska industrija, obuhvaća sve aspekte pomorskog

prometa, uključujući pomorstvo, brodogradnju, lučke operacije i pomorske usluge. Pomorstvo je posebno bitna komponenta ovog posla budući da uključuje kretanje robe i proizvoda korištenjem plovila kao što su brodovi i čamci. Pojam obuhvaća različita plovila, u rasponu od kontejnerskih brodova i brodova za prijevoz rasutog tereta do tankera i specijaliziranih brodova kao što su trajekti i brodovi za krstarenje, među ostalim plovilima. Pomorsku industriju podupire mreža tvrtki koje zajedno rade kako bi osigurale učinkovito kretanje robe kroz globalne opskrbne mreže. To uključuje brodarske tvrtke, brodograditelje, lučke uprave i pružatelje pomorskih usluga [23].

Logistički proces uključuje nekoliko komponenti: transport, skladištenje, upravljanje zalihami i optimizaciju distribucijskog lanca. Logističke tvrtke postižu učinkovito kretanje robe duž opskrbnog lanca korištenjem širokog raspona načina prijevoza, kao što su brodovi, kamioni, vlakovi i zrakoplovi. Kao rezultat širenja e-trgovine i globalizacije, došlo je do porasta potrebe za sofisticiranim logističkim rješenjima, što je dovelo do povećanja razine inovacija i tehničkog napretka u industriji. U modernom upravljanju opskrbnim lancem, jedna od najkritičnijih komponenti je integracija operacija koje uključuju pomorski i logistički sektor. Luke su ključni čvorovi u globalnoj logističkoj mreži, služeći kao čvorišta koja olakšavaju kretanje robe između različitih načina prijevoza, uključujući brodove, kamione i vlakove, između ostalog. Učinkovito lučko poslovanje ključno je za smanjenje vremena potrebnog za putovanje robe, uštedu novca i povećanje ukupne učinkovitosti aktivnosti opskrbnog lanca.

Kako bi se dodatno naglasila potreba za bespjekornom koordinacijom među pomorskim prijevoznicima, pružateljima logističkih usluga i drugim dionicima, ključno je optimizirati rute otpreme i riješiti sve potencijalne logističke izazove. Posljednjih su godina pomorska i logistička industrija naglasile potrebu za mjerama održivosti. Drugi čimbenici potaknuli su igrače u sektoru da usvoje održivije prakse, uključujući zabrinutost za okoliš, zakonske zahtjeve i mijenjanje preferencija kupaca. Promjene u poslovnim praksama i promicanje inovacija u ekološki odgovornim transportnim sustavima nastaju zbog nastojanja da se smanje emisije ugljika, promišlujući rješenja za čistu energiju i smanji utjecaj na okoliš. Pomorski i logistički sektor aktivno istražuju strategije za smanjenje utjecaja na okoliš i doprinos održivoj budućnosti. Ti naporci uključuju izgradnju ekološki prihvatljivih brodova kao i provedbu ekoloških logističkih

inicijativa. Pomorski i logistički sektor igraju ključnu ulogu u olakšavanju globalne trgovine, povezivanju gospodarstava i promicanju gospodarskog rasta. Te su industrije u dobroj poziciji da se uhvate u koštač s problemima i prilikama svijeta koji postaje sve više međusobno povezan zbog svojih širokih komunikacijskih mreža, vrhunske tehnologije i predanosti očuvanju okoliša. Kroz razumijevanje složenosti i dinamike pomorskih i logističkih operacija, svi sudionici angažirani u istima se mogu uspješno snalaziti u krajoliku međunarodne trgovine koji se stalno razvija i dati značajan doprinos razvoju globalnog ekosustava opskrbnog lanca koji je učinkovitiji, otporniji i održiviji. Održivost u pomorskom prijevozu igra ključnu ulogu u utjecaju na okoliš, gospodarstvo i društvo u velikim razmjerima. Pomorski transport vitalna je komponenta globalnog transporta, koja je ključna u omogućavanju međunarodne trgovine [24].

Ipak, utjecaj pomorskih operacija na okoliš, kao što su emisije stakleničkih plinova, izljevanja nafte i onečišćenje mora, predstavljaju značajne prepreke održivosti. Jedan od glavnih pokretača za fokusiranje na održivost u pomorskom prijevozu su posljedice brodskih aktivnosti na okoliš. Pomorska plovila igraju značajnu ulogu u onečišćenju zraka i vode ispuštanjem štetnih zagadživača poput sumpornih oksida ( $\text{SO}_x$ ), dušikovih oksida ( $\text{NO}_x$ ) i čestica (PM) [25]. Čestice su mikroskopske čestice koje mogu biti krute ili tekuće, a ispuštaju se u atmosferu kao rezultat različitih procesa, uključujući izgaranje goriva u motorima pomorskih plovila. PM uključuje fine čestice poput PM<sub>10</sub> (čestice promjera manjeg od 10  $\mu\text{m}$ ) i PM<sub>2.5</sub> (čestice promjera manjeg od 2,5  $\mu\text{m}$ ) [25], koje su posebno opasne za zdravlje jer mogu prodrijeti duboko u pluća i krvotok, uzrokujući respiratorne i kardiovaskularne probleme.

Prihvaćanje održivih praksi u pomorskom prijevozu može pomoći u smanjenju ovih troškova i poboljšati dugoročnu održivost pomorskog sektora. Uz ekološka i ekonomska razmatranja, održivost u pomorskom prometu nosi i društvene implikacije. Obalne zajednice i ranjivo stanovništvo snose najveći teret štetnih učinaka onečišćenja mora i degradacije staništa. Nadalje, korištenje fosilnih goriva za pomorski pogon dovodi do energetske nesigurnosti i geopolitičkih napetosti. Pomorska industrija može unaprijediti društvenu jednakost, potaknuti javno zdravlje i ojačati globalnu energetsku sigurnost usvajanjem čišćih i održivijih goriva i tehnologija [24].

Optimizacija rute plovila je ključan korak u omogućavanju razvoja i implementacije autonomnih sustava, omogućujući brodovima da rade uz minimalnu ljudsku interakciju uz održavanje sigurnosti, učinkovitosti i usklađenosti s pomorskim pravilima. Algoritmi pomažu autonomnim brodovima da ispravno vide i razumiju svoje okruženje.

Ova svijest o situaciji u stvarnom vremenu omogućuje donošenje inteligentnih procjena o navigaciji, izbjegavanju sudara i planiranju rute, smanjujući vjerovatnost nesreća i povećavajući ukupnu pomorsku sigurnost. Nadalje, prediktivna analitika temeljena na strojnem učenju poboljšava autonomne navigacijske sposobnosti brodova predviđanjem varijabli okoline, stanja mora i ponašanja plovila. Autonomni ratni brodovi mogu predvidjeti promjene u vremenskim obrascima, prevladavajućim morskim strujama i obrascima prometa koristeći povijesne podatke i algoritme strojnog učenja, omogućujući proaktivne izmjene navigacijskih ruta i profila brzine kako bi se poboljšala učinkovitost goriva i performanse putovanja [24].

Generativna umjetna inteligencija u brodarstvu i navigaciji nadilazi područje vizije u stvarnom vremenu i donošenja odluka kako bi se obuhvatilo širok raspon bitnih zadataka i sposobnosti. Prilikom dizajniranja boljih sustava upravljanja koji plovilima omogućuju precizno i učinkovito pregovaranje u izazovnim pomorskim scenarijima, generativna umjetna inteligencija je područje u kojem se ističe. Moguće je optimizirati pristupe upravljanju za autonomne brodove upotrebom algoritama strojnog učenja koji uzimaju u obzir dinamiku plovila, čimbenike okoliša i operativna ograničenja [24].

Generativna inteligencija značajno pridonosi otpornosti i robusnosti autonomnih navigacijskih sustava. To doprinosi kreiranju napredovalog učenja i adaptivne kontrole, koji predstavljaju dva pristupa koje autonomni brodovi mogu primijeniti kako bi učili iz svojih iskustava i dinamički prilagodili svoje navigacijske strategije kao odgovor na neočekivane događaje kao što su neispravna oprema, nepovoljni vremenski uvjeti ili sudari s drugim plovilima. Korištenje tehnika strojnog učenja pridonosi optimizaciji strategija izbjegavanja sudara za autonomne zrakoplove. Algoritmi strojnog učenja mogu analizirati podatke o putanjama zrakoplova, prometnim obrascima i varijablama rizika od sudara, kako bi predvidjeli potencijalne situacije

sudara. Navedeni algoritmi mogu propisati taktiku izbjegavanja kako bi se izbjegle nesreće i osigurao siguran prolaz. Ova proaktivna tehnika izbjegavanja sudara povećava sigurnost i pouzdanost autonomnih pomorskih operacija, smanjujući rizik od pomorskih nesreća i smanjujući potencijalne negativne učinke na okoliš i gospodarstvo. Širok raspon sposobnosti, kao što su percepcija, donošenje odluka, kontrola i izbjegavanje sudara, stječu se strojnim učenjem u kontekstu autonomnog brodarstva i navigacije. Korištenjem snage strojnog učenja za analizu podataka, stjecanje znanja iz iskustva i prilagođavanje promjenjivim okolnostima, autonomni brodovi imaju potencijal revolucionirati pomorsku industriju. To bi otvorilo novu eru pomorskih operacija koje su sigurnije, učinkovitije i ekološki prihvatljivije [24].

Prediktivno održavanje i praćenje stanja, koji koriste strojno učenje, smatraju se revolucionarnima u pomorskoj industriji. Očekuje se da će ove metode značajno poboljšati pouzdanost plovila, operativnu učinkovitost i ekonomičnost. Strojno učenje omogućuje brodskim operaterima da proaktivno otkriju i isprave potencijalne kvarove opreme. Navedeno smanjuje vrijeme zastoja plovila, smanjuje troškove održavanja i poboljšava performanse plovila.

Proaktivno planiranje operacija održavanja, učinkovito upravljanje zaliham rezervnih dijelova i raspodjela resursa omogućavaju operaterima brodova koji mogu predvidjeti vjerojatnost kvara opreme da procijene preostali vijek trajanja opreme. To im omogućuje da optimiziraju iskorištenje imovine dok minimaliziraju nepredviđena razdoblja neaktivnosti. Nadalje, metodologije strojnog učenja omogućuju sustavima za praćenje stanja da identificiraju i steknu znanje iz tokova podataka u stvarnom vremenu, čime se olakšava kontinuirano poboljšanje i poboljšanje modela predviđanja. Algoritmi strojnog učenja mogu poboljšati preciznost i pouzdanost predviđanja održavanja integracijom povratnih petlji i dodatnih izvora podataka, uključujući povratne informacije osoblja, uvjete okoline i operativne parametre. Takvi ishodi mogu rezultirati poboljšanim strategijama za smanjenje rizika i poboljšanim donošenjem odluka. Prediktivno održavanje potaknuto strojnim učenjem povećava pouzdanost opreme i operativnu učinkovitost te ima značajne ekološke prednosti za pomorski sektor, osiguravajući njegovu kontinuiranu održivost. Smanjivanjem rizika od kvarova opreme, operateri plovila mogu smanjiti vjerojatnost ekoloških problema, nesreća i zagađenja [24].

## **5.2. Pametno umrežavanje senzora**

Takozvani oceanski inteligentni senzori također primjenjuju generativnu umjetnu inteligenciju kod tehnologije na senzore. Ovi senzori također igraju ogromnu pomoćnu ulogu u promatranju oceana. S mnogim prednostima, poput male veličine, lakog umrežavanja i otpornosti na elektromagnetske smetnje, također se očekuje da postanu pomoćni alat za mjerjenje u promatranju oceana. Inteligentna senzorska mreža kombinira mnoge temeljne elemente sustava za promatranje oceana, ugrađuje okvir za asimilaciju podataka i olakšava prilagodljivo uzorkovanje i kalibraciju. Senzori se prvenstveno postavljaju u mreže u oceanu kako bi se olakšalo promatranje oceana. Senzorska mreža je podvodna bežična mreža senzora koja se obično sastoji od niza oceanskih senzora, autonomnih podvodnih vozila, površinskih istraživačkih plovila, a u nekim slučajevima, od obalnih radara i velikih jedrilica. Mreže morskih senzora imaju širok raspon primjena i veliki potencijal za promatranje i predviđanje oceana [24].

## **5.3. Umjetna inteligencija u robotici**

Kombinacija tradicionalnih robota s umjetnom inteligencijom i njihovo korištenje za promatranje oceana također je iznjedrila mnoge suvremene tehnološke inovacije temeljene na robotici za promatranje oceana, kao što su podvodni roboti, roboti za bušenje nafte i dr. Tradicionalni roboti mogu se nazvati programabilnim strojevima i izvršavaju niz operacija i uputa automatski ili poluautomatski. Uz dodatak generativne umjetne inteligencije, roboti se mogu automatizirati i učiti neovisno. Dizajnirali su klizne robote s višestruko povezanim elementima u načinu rada za iskorištavanje morskih resursa i nadzor naftnih platformi. Robot

može plivati fleksibilno, učinkovito kliziti u tri dimenzije i analizirati pokrete pri klizanju i plivanju [24].



**Slika 5 Intelligentni roboti**

Izvor: Izagirre, U.; Andonegui, I.; Landa-Torres, I.; Zurutuza, U. A practical and synchronized data acquisition network architecturefor industrial robot predictive maintenance in manufacturing assembly lines. Robot. Comput. Integr. Manuf. 2022 (20.06.2024.)

Umjetna inteligencija u robotici značajno mijenja način na koji promatramo oceane, omogućujući preciznija i učinkovitija istraživanja morskih ekosustava. Primjenom AI-a, robotske platforme mogu autonomno prikupljati i analizirati ogromne količine podataka, što doprinosi boljem razumijevanju i zaštiti morskog okoliša. Ovaj tehnološki napredak ne samo da ubrzava otkrića u oceanografiji, već također pruža nove alate za očuvanje oceana i suočavanje s izazovima poput klimatskih promjena i gubitka bioraznolikosti.

#### **5.4. Rekonstrukcija oceanskih velikih podataka**

Za znanstvena istraživanja oceana, ključne su dvije karakteristike oceanskih velikih podataka: točnost i prostorno-vremenski kontinuitet. Stvarni proces generiranja podataka o oceanu iz promatranja oceana dovodi do podataka koji nedostaju ili su nedostupni zbog pogrešaka u opremi za promatranje, satelitima, vremenu i drugim čimbenicima, što onda uključuje problem rekonstrukcije podataka. Interpolacijski algoritmi obično se koriste za postizanje rekonstrukcije oceanskih podataka. Proces interpolacije dovodi do gubitka važnih informacija, što rezultira velikim pogreškama rekonstrukcije podataka i predstavlja veliki izazov

za tradicionalne metode rekonstrukcije podataka. Pojava umjetne inteligencije također vrlo dobro ublažava ovaj problem. Među metodama umjetne inteligencije, duboko učenje može naučiti složene modelle iz velike količine uzoraka podataka i može kontrolirati učinkovitost modela. Na primjer, Ducournau i Fablet [26] upotrijebili su konvulcijsku neuronsku mrežu super-razlučivosti (engl. *Image Super-Resolution Using Deep Convolutional Neural Networks - SRCNN*) kako bi riješili problem smanjivanja satelitski generirani podaci o temperaturi površine mora (engl. *Sea Surface Temperature - SST*).

## 6. PRIMJENA GENERATIVNE UMJETNE INTELIGENCIJE U LOGISTICI

Primjena umjetne inteligencije u skladištima postaje imperativ za tvrtke koje teže efikasnosti i konkurentnosti. Prvo i najvažnije, primjena AI u skladištima omogućuje automatizaciju mnogih procesa koji su ranije zahtjevali ljudsku intervenciju. Sustavi pametnih strojeva i algoritama mogu samostalno upravljati inventarom, optimizirati raspored skladišnih prostora, te čak predviđati potražnju i potrebe za opskrbom. Time se ne samo smanjuje ljudski faktor u procesu, nego se i ubrzava reakcija na promjene u tržištu, minimizirajući rizik od nedostatka ili viška zaliha [27].

Drugo, AI omogućuje analizu ogromnih količina podataka u stvarnom vremenu. Kombinirajući podatke o prodaji, sezonskim trendovima, vremenskim uvjetima, i mnogim drugim varijablama, algoritmi mogu generirati precizne prognoze i preporuke za upravljanje zalihamama. To omogućuje tvrtkama da optimiziraju svoje inventarne razine, smanje troškove pohrane i transporta, te istovremeno osiguraju dostupnost proizvoda kada je to potrebno [28].



**Slika 6 Generativna umjetna inteligencija u logistici**

Izvor: Kose, U., Prasath, V. B., Mondal, M., sur. (2023). "Artificial Intelligence And Smart Agriculture Applications." CRC Press (23.06.2024)

Primjena generativne umjetne inteligencije u logistici predstavlja značajan iskorak u optimizaciji i transformaciji ovog sektora. Generativni modeli omogućuju stvaranje naprednih rješenja za kompleksne logističke izazove, poput optimizacije ruta, predviđanja potražnje, te upravljanja skladišnim operacijama. Korištenjem generativne AI, tvrtke mogu simulirati različite scenarije, prilagoditi se dinamičnim uvjetima tržišta i poboljšati učinkovitost svojih operacija. Osim što omogućuje poboljšanje operativne učinkovitosti, generativna AI također potiče inovacije unutar logističkog sektora. Njena primjena omogućuje razvoj novih modela poslovanja i usluga, koji su usmjereni na smanjenje troškova, brže isporuke i poboljšanje korisničkog iskustva. Uz to, AI pomaže u donošenju informiranih odluka temeljenih na analizi velikih količina podataka, čime se smanjuju rizici i povećava preciznost operacija.

Kao rezultat, generativna umjetna inteligencija ne samo da unaprjeđuje postojeće logističke procese, već i otvara vrata prema potpuno novim mogućnostima u ovom sektorу. S dalnjim razvojem i implementacijom ovih tehnologija, očekuje se da će logistika postati još fleksibilnija, održivija i prilagođenija potrebama modernog tržišta. Generativna AI će nastaviti igrati ključnu ulogu u oblikovanju budućnosti logistike, donoseći nove standarde učinkovitosti i inovacije.

## 6.1. Optimizacija skladišta i distribucije

Jedan od najvažnijih aspekata primjene AI u logistici je automatizacija rutinskih poslova u skladištima. Umjesto da se radnici zaokupljaju repetitivnim zadacima poput praćenja zaliha ili planiranja isporuka, AI može preuzeti te zadatke i obavljati ih brže i preciznije. To ne samo da oslobađa ljudske resurse za važnije zadatke, već i smanjuje mogućnost ljudske pogreške, čime se povećava kvaliteta procesa.

Optimizacija rasporeda radnika u skladištu također je važan aspekt primjene AI. AI može analizirati podatke o radničkim performansama, rasporedu poslova i promjenama u potražnji kako bi predložio najučinkovitije rasporede radnika. To ne samo da povećava produktivnost skladišta, već i smanjuje troškove radne snage. Optimizacija ruta distribucije je još jedan ključni segment poboljšanja logističkih procesa uz pomoć AI. Koristeći podatke o lokacijama skladišta, dostupnim transportnim sredstvima i prometnim uvjetima, AI može odrediti najoptimalnije rute

za distribuciju proizvoda. Navedeno smanjuje troškove prijevoza, već i skraćuje vrijeme potrebno za isporuku, što dodatno poboljšava iskustvo kupaca.

Korištenje AI za automatizaciju rutinskih poslova i optimizaciju logističkih procesa ima širok spektar prednosti. Povećava efikasnost i točnost, smanjuje troškove rada i distribucije, poboljšava iskustvo kupaca i omogućuje tvrtkama da ostanu konkurentne u dinamičnom tržišnom okruženju. WMS (eng. Warehouse Management System), kao temeljni element digitalne transformacije skladišta, omogućuje automatizaciju i optimizaciju različitih poslovnih procesa. Integracija WMS sustava prilagođava se specifičnim potrebama i zahtjevima pojedinog skladišta, što rezultira povećanom učinkovitošću i smanjenjem operativnih troškova. Skladišta opremljena WMS sustavom imaju značajno veću produktivnost, točnost rada i brži protok robe, čime se osigurava konkurentna prednost na tržištu [29].

Uz WMS, AMR (eng. Autonomous Mobile Robot) roboti postaju sve prisutniji u skladišnim operacijama. Njihova sposobnost brzog i preciznog prijenosa robe ne samo da smanjuje vrijeme potrebno za obavljanje poslova, već i smanjuje rizik od ozljeda radnika. AMR roboti donose fleksibilnost u operacije skladišta, zamjenjujući do tri radnika i smanjujući troškove radne snage. Ova tehnologija donosi revolucionarne promjene u tradicionalne modele skladišnog poslovanja, omogućujući bržu i efikasniju distribuciju robe. Glasovna tehnologija, kao integrirani dio WMS sustava, predstavlja novi korak prema digitalizaciji skladišta. Korištenjem VoiceXtreme (VoX) aplikacije, radnici mogu koristiti glas umjesto računalnih ekrana ili drugih uređaja za obavljanje poslova u skladištu [1].

Glasovno upravljanje u skladištima donosi brojne prednosti: pojednostavljuje rad zaposlenicima, skraćuje vrijeme potrebno za izvršenje zadataka, smanjuje mogućnost ozljeda i povećava preciznost u obavljanju poslova. Primjerice, radnik može glasovnom naredbom uputiti robota da premjesti određeni artikl na željeno mjesto u skladištu, što ubrzava radne procese i smanjuje rizik od ozljeda.

Bitno je istaknuti da glasovna tehnologija nije rezervirana samo za velika skladišta, već je prilagođena i srednjim i malim poduzećima. Podržavajući 35 jezika, ova tehnologija pruža

sigurno rješenje za poboljšanje i optimizaciju poslovnih procesa, s povratom investicije već u prvih 9-18 mjeseci. Time se otvara prostor za široku implementaciju ove tehnologije na globalnoj razini. Automatizacija skladišnih operacija i primjena korisničkog sučelja u logistici donose niz ključnih prednosti koje optimiziraju procese i poboljšavaju učinkovitost u opskrbnom lancu. Integracija automatizacije skladišta s softverom za upravljanje skladištem stvara integrirani sustav koji omogućuje bolje kretanje transporta i skladištenja te operativno upravljanje. Kroz kontinuiranu analizu podataka, korisničko sučelje pomaže optimizirati resurse i prilagođavati se promjenama u tokovima.

Jedna od ključnih uloga AI je revolucionizacija izbora transportnih ruta i optimizacija kretanja robe. Kroz sustave poput upravljanja skladištem i upravljanja flotama za prijevoz robe, AI omogućuje precizniju koordinaciju logističkog transporta. Primjena samovozećih vozila koja se prilagođavaju okolini i dinamički mijenjaju rutu predstavlja samo jedan primjer kako AI optimizira kretanje robe i povećava učinkovitost [27].

Nadalje, pojava autonomnih vozila i dronova redefinira logistički krajolik, a AI je ključni faktor u ovoj revoluciji. Autonomni agenti mogu upravljati složenim okruženjima, od užurbanih gradskih ulica do udaljenih ruralnih područja, dostavljajući pakete bez ljudske intervencije [3].

Pokretana umjetnom inteligencijom, ova vozila mogu se prilagoditi neočekivanim preprekama, osiguravajući da se isporuke obavljaju s izvanrednom učinkovitošću i preciznošću. Vizija dronova koji ispuštaju pakete na vašem pragu ili autonomnih kamiona koji voze autocestama brzo postaje stvarnost, zahvaljujući umjetnoj inteligenciji.

Osim optimizacije rute i upravljanja autonomnim vozilima, AI također ima široku primjenu u upravljanju zalihami, predviđanju potreba, identificiranju potencijalnih problema i optimizaciji procesa u cijelom opskrbnom lancu. Kroz analizu velikih količina podataka, AI može identificirati obrasce i trendove koji bi inače bili neuhvatljivi ljudskom oku, omogućujući tvrtkama da donose informirane odluke i optimiziraju svoje operacije. Međutim, iako AI donosi mnoge prednosti, postavlja i izazove.

Na primjer, pitanja privatnosti podataka, sigurnosti sustava i etičke implikacije autonomnih vozila zahtijevaju pažljivo razmatranje i regulaciju. Jedan od najznačajnijih doprinosova AI-u u

upravljanju skladištem je automatizacija procesa. Tradicionalno, procesi komisioniranja i pakiranja bili su radno intenzivni i skloni ljudskim pogreškama. Međutim, s razvojem AI-a, sustavi za komisioniranje postaju sve više automatizirani, koristeći tehnike strojnog učenja i dubokog učenja kako bi prepoznali obrasce u narudžbama i optimizirali putanje za prikupljanje proizvoda [30].

Jedan od ključnih izazova u upravljanju skladištem je osigurati da su proizvodi uvijek dostupni i spremni za isporuku. AI revolucionira ovaj aspekt poslovanja pružajući prediktivnu analitiku koja pomaže u procjeni potreba za zalihami i predviđanju potražnje. Kombinirajući podatke o prodaji, sezonske trendove, meteorološke uvjete i druge relevantne faktore, AI može stvoriti precizne modele predviđanja koji pomažu u optimalnom upravljanju inventarom. Time se smanjuje rizik od prekomjernog zaliha ili nestašice proizvoda, što rezultira uštedama u troškovima i poboljšanoj usluzi za kupce. Treba napomenuti da je skladište budućnosti postalo mjesto reda i učinkovitosti zahvaljujući AI-u. Umjesto kaosa i nereda koji su nekada bili povezani s tradicionalnim skladištima, danas svjedočimo transformaciji u kojoj su procesi strogo organizirani, optimizirani i vođeni preciznim algoritmima. Ovo nije samo tehnološka revolucija, već i kulturna promjena koja potiče organizacije da prihvate digitalnu transformaciju i usvoje nove tehnologije radi poboljšanja svoje konkurentske pozicije [29].

## 6.2. Poboljšano predviđanje i planiranje potražnje

Upravljanje opskrbnim lancem predstavlja ključni element uspjeha u suvremenom poslovanju, a točno predviđanje potražnje igra ključnu ulogu u osiguravanju efikasnog i konkurentnog lanca opskrbe. Uz napredak umjetne inteligencije, ova disciplina doživljava revolucionarne promjene, postavljajući novi standard u preciznosti, dinamičnosti i suradnji. Jedno od najmoćnijih oružja AI u predviđanju potražnje leži u sposobnosti strojnog učenja. Umjesto oslanjanja na tradicionalne metode, koje su često oskudne u preciznosti, AI analizira obilje povijesnih podataka, uključujući faktore poput ekonomskih pokazatelja, tržišnih trendova i društvenih mreža.

Ovaj sveobuhvatni pristup omogućuje AI-u da identificira suptilne obrasce i trendove koji bi inače mogli ostati nezamijećeni, čime se postiže neusporediva točnost u predviđanju potražnje. No, AI nije samo o brojevima, već razumije priču koju pričaju podaci. Analizirajući društvene mreže, internetske recenzije i trendove vijesti, AI dobiva dublji uvid u promjene u potražnji potrošača, omogućujući tvrtkama da predvide tržišne trendove i prilagode svoje strategije u realnom vremenu. Ova sposobnost brze prilagodbe ključna je u današnjem dinamičnom poslovnom okruženju, gdje se neočekivane promjene mogu dogoditi brzo i neočekivano.

Dalje, AI potiče suradnju između dionika u lancu opskrbe, integrirajući podatke iz različitih izvora kako bi pružio sveobuhvatan pogled na potražnju. Ovo suradničko predviđanje osigurava da sve strane rade s istim informacijama, smanjujući rizik od neusklađenosti i poboljšavajući cjelokupnu učinkovitost lanca opskrbe. AI donosi dinamično predviđanje u stvarnom vremenu, omogućujući upraviteljima opskrbnog lanca brzu reakciju na promjene. Ovo nije samo o reagiranju na prošle događaje; AI omogućuje predviđanje puta pred nama, omogućujući tvrtkama da budu korak ispred konkurencije.

### **6.3. Optimizacija upravljanja zalihamu**

Jedna od ključnih prednosti AI u upravljanju zalihamu leži u njegovoj sposobnosti precizne analize podataka. Umjetna inteligencija može analizirati velike količine podataka o prodaji, performansama dobavljača i tržišnim trendovima, koristeći napredne algoritme kako bi predvidjela zahtjeve zaliha s iznenadjujućom preciznošću. Ovo predviđanje omogućuje tvrtkama da održe optimalne razine zaliha, minimizirajući gubitke i smanjujući troškove skladištenja. Dalje, AI uvodi koncept dinamičkog nadopunjavanja, gdje se narudžbe automatski prilagođavaju u stvarnom vremenu na temelju promjena u potražnji i vanjskih čimbenika poput sezonskih trendova ili promotivnih aktivnosti.

Ovo osigurava da su razine zaliha uvijek usklađene s potražnjom, minimizirajući rizik od prekomjernih zaliha ili nestašice. Pored toga, AI ne samo da predviđa potražnju, već i ocjenjuje učinak dobavljača, nadzire vrijeme isporuke, kvalitetu i pouzdanost. Na temelju analize povijesnih podataka i trenutnih trendova, AI može predvidjeti moguće rizike i omogućiti tvrtkama da proaktivno prilagode svoje strategije zaliha, minimizirajući negativne učinke kašnjenja ili smetnji dobavljača [28].

Nadalje, AI potiče integraciju planiranja kroz cijeli opskrbni lanac, razbijajući silose između različitih odjela i omogućujući dijeljenje podataka i uvida. Ovaj holistički pristup osigurava usklađenost strategija zaliha s rasporedima proizvodnje, marketinškim kampanjama i finansijskim ciljevima, što doprinosi boljoj učinkovitosti i konkurentnosti tvrtke. AI redefinira krajolik upravljanja zalihami, omogućujući tvrtkama da postignu razine učinkovitosti i preciznosti koje su prije bile nezamislive [28].

#### **6.4. Poboljšano upravljanje odnosima s dobavljačima**

Jedna od ključnih uloga AI u upravljanju odnosima s dobavljačima je kao "graditelj mostova". Kroz analizu velikih količina podataka, AI omogućava tvrtkama dublje razumijevanje performansi dobavljača, identificirajući njihove snage i slabosti. Prediktivna analitika AI-a omogućuje tvrtkama da predvide potencijalne probleme prije nego što se pojave, što rezultira pravovremenim intervencijama i stalnim poboljšanjima. Ova vrsta uvida omogućuje tvrtkama da učinkovitije surađuju sa svojim dobavljačima, optimizirajući njihove operacije i smanjujući rizike. Ublažavanje rizika je još jedna ključna prednost AI-a u upravljanju odnosima s dobavljačima. U današnjem nepredvidivom poslovnom okruženju, opskrbni lanci su izloženi rizicima, od geopolitičkih sukoba do prirodnih katastrofa. AI može proaktivno identificirati potencijalne prijetnje kontinuitetu opskrbe analizirajući globalne vijesti,

medije i druge izvore podataka. Ovo omogućuje tvrtkama da brzo reagiraju na promjenjive okolnosti, osiguravajući alternativne izvore ili prilagođavajući razine zaliha kako bi se izbjegli prekidi u opskrbnom lancu.

Dinamička procjena performansi je još jedan ključni aspekt AI-a u upravljanju odnosima s dobavljačima. Tradicionalni pristupi procjeni dobavljača često su ograničeni na periodične preglede, što može rezultirati propuštanjem važnih informacija. Kroz kontinuirani nadzor, AI omogućuje tvrtkama da prate performanse dobavljača u stvarnom vremenu i brzo reagiraju na bilo kakve nedostatke ili probleme. Ovo ne samo da osigurava kvalitetniju suradnju s dobavljačima, već i potiče transparentnost i odgovornost u cijelom opskrbnom lancu.

Na kraju, AI olakšava optimizaciju suradnje između tvrtki i njihovih dobavljača kroz dijeljenje uvida i predviđanja. Kroz bolje usklađivanje strategija i operacija, tvrtke mogu maksimizirati učinkovitost i prilagodljivost svog opskrbnog lanca. AI ne samo da optimizira postojeće procese, već i otvara vrata za nove prilike i inovacije u upravljanju opskrbnim lancem.

## **6.5. Prediktivna analitika za predviđanje potražnje**

Uloga umjetne inteligencije u upravljanju opskrbnim lancem sve više dobiva na važnosti, pokrećući transformaciju industrije kroz tehnološki napredak, pristup obilju podataka i rastuću potrebu za održivošću i otpornošću. Ključni trendovi i razvoji oblikujući budućnost umjetne inteligencije u upravljanje lancem opskrbe (eng. Supply Chain Management - SCM) naglašavaju njezinu ulogu u prediktivnoj i preskriptivnoj analitici, logistici te autonomnim operacijama opskrbnog lanca [30].

Prvo, umjetna inteligencija će nastaviti unapređivati prediktivnu analitiku u SCM-u. Kroz dublje uvide u potražnju, optimizaciju zaliha i upravljanje rizikom, AI će omogućiti tvrtkama da predviđaju buduće potrebe i prilagode svoje strategije.

Osim predviđanja, AI će pružati i sugestivne uvide, sugerirajući konkretne radnje za optimizaciju performansi opskrbnog lanca. Ovo će omogućiti brže i proaktivnije procese donošenja odluka, unapređujući ukupnu operativnu efikasnost. Drugo, uloga umjetne inteligencije u logistici će se proširiti dalje od fizičkog kretanja robe. AI će biti ključan u predviđanju fluktuacija u potražnji, omogućavajući prilagodbe logističkih strategija kako bi se osiguralo kontinuirano zadovoljstvo kupaca. Bolje upravljanje zalihamama, smanjeni troškovi skladištenja i poboljšano zadovoljstvo kupaca bit će rezultati ovog prediktivnog pristupa.

Treće, umjetna inteligencija će biti ključna u racionalizaciji logistike i distribucije. Kroz upotrebu AI-a, tvrtke će moći prevladati tradicionalne izazove, optimizirati rute, koristiti autonomna dostavna vozila te upravljati skladištima s neviđenom učinkovitošću. Ovaj napredak obećava ne samo učinkovitije, već i održivije i otpornije opskrbne lance. Koncept autonomnih operacija opskrbnog lanca postaje sve realniji. AI, uz pomoć robotike, Interneta stvari (engl. *Internet of Things - IoT*) i drugih tehnologija, omogućit će opskrbnim lancima da automatski upravljaju rutinskim operacijama, kao i složenim procesima donošenja odluka [1].

Ova automatizacija će omogućiti opskrbnim lancima da se dinamički prilagođavaju promjenama u okolini bez potrebe za ljudskom intervencijom. Upravljanje opskrbnim lancima je ključni element uspješnog poslovanja u današnjem globaliziranom svijetu. Međutim, kako se svijet sve više kreće prema digitalizaciji i tehnološkim inovacijama, umjetna inteligencija postaje centralni faktor u oblikovanju budućnosti SCM-a. Jedan od ključnih potencijala koje AI donosi u SCM je poboljšana suradnja i integracija unutar ekosustava opskrbnih lanaca. AI omogućuje tvrtkama da razbiju silose između dobavljača, proizvođača, distributera i trgovaca kroz platforme koje omogućuju dijeljenje podataka i uvida u stvarnom vremenu. Ovo koordinirano upravljanje omogućuje efikasniji i odzivniji pristup, poboljšavajući učinkovitost SCM-a.

Održivost je također ključna tema u suvremenom poslovanju, a AI igra važnu ulogu u poticanju prijelaza na kružne lance opskrbe. Napredna analitika i strojno učenje omogućuju tvrtkama optimizaciju korištenja resursa, smanjenje otpada i implementaciju održivih praksi poput prediktivnog održavanja, optimiziranog rutiranja i recikliranja materijala [29]. Međutim, s potencijalnim koristima dolaze i izazovi i odgovornosti. Etička uporaba AI-a postaje sve važnija, posebno u kontekstu upravljanja opskrbnim lancima. Kompanije moraju osigurati transparentnost, poštenje i odgovornost u korištenju AI-a, posebno kada odluke mogu imati utjecaj na radnike, zajednice i okoliš. Razvoj standarda i okvira za etičku uporabu AI-a postaje imperativ.

Također, razvoj vještina postaje ključan izazov u kontekstu sve veće integracije AI-a u SCM - u. Potrebno je uložiti napore u usavršavanje i prekvalificiranje radnika kako bi se nosili s promjenama koje donosi tehnologija. Osim toga, pitanja privatnosti podataka i sigurnosti postaju sve izraženija, zahtijevajući usklađene napore poduzeća, vlada i obrazovnih institucija.

## 7. ZAKLJUČAK

Logistika je vitalni dio suvremenog poslovanja, igrajući ključnu ulogu u učinkovitosti lanaca opskrbe, skladištenju i distribuciji proizvoda. U posljednjih nekoliko godina, sve veći fokus stavljen je na primjenu umjetne inteligencije kako bi se optimizirali procesi logistike. Među mnogim tehnikama i algoritmima AI-a, generativna umjetna inteligencija (engl. *Generative artificial intelligence – GAI*) se izdvojila kao posebno moćan alat, pružajući inovativne načine za rješavanje složenih logističkih problema. Generativna umjetna inteligencija su vrsta neuronskih mreža koje imaju zadatak generiranja novih podataka koji su slični onima u skupu podataka na kojem su trenirani.

Generativne suparničke mreže (engl. *Generative adversarial network – GAN*) se sastoje od dva glavna dijela: generatora, koji stvara nove primjere, i diskriminadora, koji ocjenjuje autentičnost tih primjera. Ovaj sukobni proces treniranja omogućava GAN-ovima da postižu visoku razinu realističnosti u generiranju podataka. Jedna od glavnih primjena GAN u logistici je optimizacija rasporeda i ruta. Korištenjem GAN-ova, moguće je generirati optimalne rute za distribuciju robe temeljene na složenim varijablama poput vremena putovanja, troškova goriva i prometnih uvjeta. GAN mogu biti korisni alati za predviđanje potražnje, što je ključno za efikasno upravljanje zalihami i planiranje proizvodnje.

Generiranje realističnih projekcija potražnje omogućuje poduzećima da pravovremeno prilagode svoje procese kako bi zadovoljili potrebe tržišta. GAN-ovi također mogu biti korisni u razvoju inovativnih dizajna proizvoda ili ambalaže, što može poboljšati učinkovitost logističkih procesa poput skladištenja, transporta i manipulacije. Primjena GAN-a u logistici može rezultirati značajnim poboljšanjima u učinkovitosti procesa, smanjenjem troškova i optimizacijom resursa. Generativni modeli omogućuju preciznije prognoze potražnje, smanjujući rizik od prekomjernih zaliha ili nedostataka proizvoda. Korištenje GAN-a može potaknuti inovacije u logističkim procesima, otvarajući put prema novim pristupima i rješenjima.

Izazovi GAN-ova u logistici su kvaliteta podataka ključna je za uspješno funkcioniranje GAN-

a, stoga nedostatak kvalitetnih podataka može ograničiti njihovu učinkovitost, te interpretacija rezultata generativnih modela može biti izazovna, posebno kada se koriste u složenim logističkim sustavima gdje je potrebno razumijevanje konteksta. Budućnost primjene GAN u logistici izgleda obećavajuće. Očekuje se daljnji napredak u razvoju algoritama i tehnika koji će omogućiti još veću preciznost i efikasnost u rješavanju logističkih problema. Integracija GAN s drugim tehnologijama kao što su IoT i blockchain također bi mogla proširiti njihove mogućnosti i primjene. Generativna umjetna inteligencija predstavlja moćan alat koji transformira način na koji se logistika obavlja. Kroz optimizaciju procesa, predviđanje potražnje i poticanje inovacija, GAN-ovi pružaju nevjerovatne mogućnosti za poboljšanje učinkovitosti i konkurentnosti logističkih lanaca. Iako postoje izazovi koje treba riješiti, potencijalna korist koju GAN-ovi donose u logistici čini ih ključnom tehnologijom za budućnost ovog sektora.

## **POPIS LITERATURE**

1. Afrić, W. (2010). Temeljna načela izgradnje virtualne realnosti u RPG sustavima [Doktorska disertacija]. Zagreb: W. Afrić.
2. Afrić, W. (2013). Smisao (RPG) sustava igranja virtualnih uloga: sveučilišni udžbenik. Koprivnica: Medijsko sveučilište.
3. Ahmetović, M. (2022). Autonomni brodovi bez posade (Završni rad) Rijeka: Sveučilište u Rijeci, Pomorski fakultet. Preuzeto s <https://urn.nsk.hr/urn:nbn:hr:187:662420> (20.7.2023.)
4. Baladauf, M.; Mehdi, R.A.; Fonseca T.; Kitada, M. (2018). Conventional Vessels and Marine Autonomous Surface Ships – A Love Marriage?. World Maritime University, Geneva, Switzerland.
5. Barthelsson, P.; Sagefjord, J. (2017). Autonomous ships and the operator's role in a Shore Control Centre. CTH, Göteborg, Sweden.
6. Breslauer, N., Horvat, D. M., & Jovanocska, D. (2019). Prijedlozi implementacije elemenata proširene stvarnosti s ciljem proširenja turističke ponude grada Čakovca. Zbornik radova Međimurskog veleučilišta u Čakovcu, (15-19).
7. Brown, D. (2019). "Artificial Intelligence; 3 Books in 1: Machine Learning for Beginners, Artificial Intelligence for Business and Computer Networking for Beginners: A Complete AI and Deep Learning Guide."
8. Brownlee, J. (2023). How to Implement GAN Hacks in Keras to Train Stable Models. Machine Learning Mastery. Retrieved November 14, 2023, from <https://machinelearningmastery.com/how-to-code-generativeadversarial-network-hacks/>
9. Castells, M. (2000). Informacijsko doba: ekonomija, društvo, kultura. Zagreb: Golden marketing.
10. Choi, S. K., Fraser, S. (2023). "AI as other: An art-as-research approach to generative AI art practice." Retrieved from [https://computationalcreativity.net/iccc23/papers/ICCC-2023\\_paper\\_109.pdf](https://computationalcreativity.net/iccc23/papers/ICCC-2023_paper_109.pdf)

11. Čulo, K., & Skenderović, V. (2009). Pradigms of virtual teams on the communication process. *Informatologija*, 42(3), 197-204.
12. Ćorić, D.; Pajković, M. (2018). Autonomni brod – nova vrsta broda u pomorskom zakonodavstvu. *Zbornik radova 2. Međunarodne znanstvene konferencije iz pomorskog prava – Suvremeni izazovi pomorske plovidbe (ISCML)*, Pravni fakultet Sveučilišta u Splitu, Split.
13. Divya, D.; Marath, B.; Santosh Kumar, M. Review of fault detection techniques for predictive maintenance. *J. Qual. Maint. Eng.* 2023, Vol. 29
14. Ducournau, A., Fablet, R., Deep learning for ocean remote sensing: Anapplication of convolutional neural networks for super-resolution on satellite-derivedsst data,, 9th IAPR Workshopon Pattern Recogniton in Remote Sensing (PRRS)(IEEE), 2016
15. Eckerli, F., Osterrieder, J. (2021). Generative Adversarial Networks in finance: an overview. <https://doi.org/10.48550/arXiv.2106.06364>
16. Egon, K., Potter, K., Lord, M. L. (2020). AI in Art and Creativity: Exploring the Boundaries of Human-Machine Collaboration. Retrieved from [https://www.researchgate.net/publication/374945291\\_AI\\_in\\_Art\\_and\\_Creativity\\_Exploring\\_the\\_Boundaries\\_of\\_Human-Machine\\_Collaboration](https://www.researchgate.net/publication/374945291_AI_in_Art_and_Creativity_Exploring_the_Boundaries_of_Human-Machine_Collaboration)
17. Fuchs, P., Moreau, G., & Guittot, P. (Ur.). (2011). Virtual reality: concepts and technologies. Boca Raton: CRC Press.
18. Galanter, P. (2021). Artificial Intelligence and Problems in Generative Art Theory. Retrieved from [https://www.researchgate.net/publication/334643022\\_Artificial\\_Intelligence\\_and\\_Problems\\_in\\_Generative\\_Art\\_Theory](https://www.researchgate.net/publication/334643022_Artificial_Intelligence_and_Problems_in_Generative_Art_Theory)
19. Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., sur. (2014). Generative Adversarial Nets. Département d'informatique et de recherche opérationnelle, Université de Montréal, Montréal.
20. Granot, A. (2016). Autonomous Cargo Vessels: Analysis for a Future Operations Model. Erasmus University Rotterdam.
21. Guan, S., Loew, M. (2019). Evaluation of Generative Adversarial Network Performance Based on Direct Analysis of Generated Images. *IEEE Applied Imagery Pattern*

Recognition Workshop (AIPR), Washington.

<https://doi.org/10.1109/AIPR47015.2019.9174595>

22. Harris, A.; Yellen, M. Decision-Making with Machine Prediction: Evidence from Predictive Maintenance in Trucking. 2024
23. Huertas, A., & Gonzalo, J. (2020). The role of augmented reality in destination branding. *Tourism and Hospitality Management*.
24. Izagirre, U.; Andonegui, I.; Landa-Torres, I.; Zurutuza, U. A practical and synchronized data acquisition network architecture for industrial robot predictive maintenance in manufacturing assembly lines. *Robot. Comput. Integr. Manuf.* 2022
25. Karras, T., Laine, S., Aila, T. (2019). A Style-Based Generator Architecture for Generative Adversarial Networks. *CVPR konferencija*.  
<https://doi.org/10.48550/arXiv.1812.04948>
26. Kečkeš, L. A., & Tomičić, I. (2017). Augmented Reality in Tourism - Research and Applications Overview. *Interdisciplinary Description of Complex Systems*.
27. Kipper, G. (2013). Augmented reality: An emerging technologies guide to AR. Waltham: Syngress.
28. Kose, U., Prasath, V. B., Mondal, M., sur. (2023). "Artificial Intelligence And Smart Agriculture Applications." CRC Press.
29. Kurajić, E. (2019). Autonomni brodovi (Završni rad) Rijeka: Sveučilište u Rijeci, Pomorski fakultet. Preuzeto s <https://urn.nsk.hr/urn:nbn:hr:187:459862> (20.7.2023.)
30. Lanier, J. (2017). Svitanje novog svega: susret sa stvarnošću i virtualnom stvarnošću. New York: Henry Holt and Co.
31. LaValle, M. S. (2016). Virtual reality. University of Illinois.
32. Lavorgna, A.; Acciaro, M.; Bozzo, R.; Musso, E. (2018). Analysis of the Technological, Regulatory and Economic Framework for Autonomous Ships. *Sustainability*, 10(7), 2354.
33. Lee, Tuan Khee. (2016). Liability of Autonomous Ship: The Scandinavian perspective. How the liability regimes shall be regulated in the Scandinavian region?. University of Oslo, Norway.

34. Luo, H., Wang, X., Xu, Z., Liu, C., and Pan, J.-S. (2022). A software-defined multi-modal wireless sensor network for ocean monitoring. *Int. J. Distributed Sens. Netw.* Vol. 18
35. Merkert, R., & Hoberg, K. (2023). "Global Logistics and Supply Chain Strategies for the 2020s: Vital Skills for the Next Generation." Springer.
36. Michalec, R. (2018). Autonomous Ships: Maritime Transport without Crews?. SGH Warsaw School of Economics, Warsaw.
37. Miščević, M.; Ćorak, M.; Petrović, S. (2019). Legal and practical challenges of the introduction of autonomous ships into the existing legal framework. *Journal of Maritime Law & Commerce*, 50(4), 443-463.
38. Mitchell, M. (2019). "Artificial Intelligence: A Guide for Thinking Humans." Pelican.
39. Murray, M. D. (2023). "GENERATIVE AI ART: COPYRIGHT INFRINGEMENT AND FAIR USE." Retrieved from <https://scholar.smu.edu/cgi/viewcontent.cgi?article=1360&context=scitech>
40. Neil, C. (2020). "Artificial Intelligence For Business: How Artificial Intelligence Can Be Applied In Your Company, In Marketing And Find Out How AI Is Revolutionizing Our Life In Healthcare And Medicine."
41. Pajković, M. (2017). Da li brod dron ulazi u pojam broda prema hrvatskom pomorskom pravu? Diplomski rad, Pravni fakultet Sveučilišta u Rijeci, Rijeka.
42. Panayides, M. P., & Song, D. W. (2015). "Maritime Logistics: A guide to contemporary shipping and port management." Kogan Page Limited.
43. Radford, A., Metz, L., Chintala, S. (2016). Unsupervised Representation Learning with Deep Convolutional Generational Adversarial Networks. ICLR konferencija. <https://doi.org/10.48550/arXiv.1511.0643>
44. Rocca, J. (2019). Understanding Generative Adversarial Networks (GANs). Retrieved from <https://towardsdatascience.com/understanding-generative-adversarialnetworksgans-cd6e4651a29>
45. Rončević, A., Gregorić, M., & Horvat, D. M. (2019). Primjena virtualne i proširene stvarnosti u promociji turističkih destinacija sjeverozapadne Hrvatske = The use of

- virtual and augmented reality in the promotion of tourist destinations in Northwestern Croatia. *Podravina*, 18(36), 146-157.
46. Russel, S., & Norvig, P. (2020). "Artificial Intelligence: A Modern Approach", Fourth Edition.
47. Sančanin, B., Penjišević, A. (2022). "Use of artificial intelligence for the generation of media content." *Social Informatics Journal*, 1(1), 1-7.
48. Sjafrie, H. (2019). "Introduction To Self-Driving Vehicle Technology." CRC Press.
49. Smierzchalski, R. (2005). Intelligent Marine Control Systems, Enhanced Methods in Computer Security, Biometric and Artificial Intelligence Systems. Springer US.
50. Šugar, D.; Pajković, M. (2019). Autonomous ships – liability for damage. Proceedings of the 25th Biennial International Conference on the Law of the Sea, University of Athens, Athens.
51. Tomas, V.; Šegulja, I.; Vlačić, M. (2010). Osnove automatizacije, Pomorski fakultet u Rijeci, Sveučilište u Rijeci, Rijeka.
52. Tripathi, S., et al. (2022). Recent advances and application of generative adversarial networks in drug discovery, development, and targeting. *Artificial Intelligence in the Life Sciences*, 2. <https://doi.org/10.1016/j.ailsci.2022.100045>
53. Vojković, G.; Milenković, M. (2018). Novi pravni okvir i klasifikacija autonomnih, daljinski upravljanih i srodnih brodova, *Zbornik radova 2. Međunarodne znanstvene konferencije iz pomorskog prava – Suvremeni izazovi pomorske plovidbe (ISCML)*, Pravni fakultet Sveučilišta u Splitu, Split.
54. Vojković, G.; Milenković, M. (2019). Autonomous ships and legal authorities of the ship master. *Case Studies on Transport Policy*. <https://doi.org/10.1016/j.cstp.2019.12.001>. (20.7.2023.)
55. Wang, C., Lu, J., Ding, X., Jiang, C., Yang, J., and Shen, J. (2021). Design, modeling, control, and experiments for a fish-robot-based iot platform to enable smart ocean. *IEEE Internet Things*, Vol. 8
56. Wilkins, N. (2019). "Artificial Intelligence: What You Need To Know About Machine Learning, Robotics, Deep Learning, Recommender Systems, Internet of Things, Neural Networks, Reinforcement Learning, And Our Future."

57. Williams, D. (2017). Autonomous ships: A regulatory perspective. *Marine Policy*, 85, 73-79.
58. Xiang, Z. (2022). "Impact of Artificial Intelligence on the Development of Art Projects: Opportunities and Limitations." Retrieved from [http://paper.ijcsns.org/07\\_book/202209/20220945.pdf](http://paper.ijcsns.org/07_book/202209/20220945.pdf)
59. You, A., Kim, J. K., Ryu, I. H., Yoo, T. K. (2022). Application of generative adversarial networks (GAN) for ophthalmology image domains: a survey. *Eye and Vision*. <https://doi.org/10.1186/s40662-022-00277-3>
60. Zhang, L.; Chen, S.; Xu, H. (2019). Autonomous Navigation and Control of Ships. *IEEE Transactions on Control Systems Technology*, 27(5), 2122-2132
61. Zonta, T.; Da Costa, C.A.; da Rosa Righi, R.; de Lima, M.J.; da Trindade, E.S.; Li, G.P. Predictive maintenance in the Industry 4.0:A systematic literature review. *Comput. Ind. Eng.* 2020., Vol. 15

## **POPIS SLIKA**

### **SLIKE**

<b>Slika 1 Autoenkoder .....</b>	<b>20</b>
<b>Slika 2 Vizualizacija procesa treniranja generativnih modela .....</b>	<b>21</b>
<b>Slika 3 GAN proces umjetne inteligencije.....</b>	<b>26</b>
<b>Slika 4 Upotreba SeaAware sustava.....</b>	<b>51</b>
<b>Slika 5 Prikaz Zaslona K-Load sustava .....</b>	<b>53</b>