UTJECAJ UMJETNE INTELIGENCIJE NA KREATIVNU INDUSTRIJU I KREATIVNU EKONOMIJU

Anzulović, Juraj

Master's thesis / Specijalistički diplomski stručni

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Algebra University College / Visoko učilište Algebra**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:225:321005

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

ALGEBRA VISOKO UČILIŠTE

Repository / Repozitorij:

Algebra Univerity College - Repository of Algebra Univerity College

zir.nsk.hr

dabar DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

VISOKO UČILIŠTE ALGEBRA

DIPLOMSKI RAD

Utjecaj umjetne inteligencije na kreativnu industriju i kreativnu ekonomiju

Juraj Anzulović

Zagreb, veljača 2020.

Predgovor

Zahvaljujem se svim koji su me podržali i trpjeli tijekom kreiranja ovog rada.
Posebice bi se zahvalio svom mentoru Siniši Bogdanoviću na strpljenju i pomoći pri realizaciji ovog rada

Prilikom uvezivanja rada, Umjesto ove stranice ne zaboravite umetnuti original potvrde o prihvaćanju teme diplomskog rada kojeg ste preuzeli u studentskoj referadi

Sažetak

Umjetna inteligencija (AI) tema je u gotovo u svih medijima, industrija i mnogim brujanjima gotovo svih profesionalaca nevažno o području ekspertize. Posebno je naglašen u kreativnoj industriji kao svemoći alat koji će kompletno promijeniti paradigmu industrije. Ipak, unatoč tolikoj popularnosti, AI je i dalje nejasan koncept, zbog svoje kompleksnosti i rapidnog razvoja samog polja istraživanja mnoga pitanja su još uvijek nerazjašnjena i zahtijevaju strukturiranje i unificiranje, zato je cilj ovog rada sadržajno razjasniti i pomoću induktivne metode istraživanja prikazati koncept AI-a, te ga odmaknuti od sadašnjeg shvaćanja kao monolitnog pojma, i prikazati sve njegove nijanse i razine, te prikazati njegovu suštinu te sadašnju i buduću primjenu u kreativnoj industriji, i razmotriti posljedice i izazove koje sa sobom nosi.

Ključne riječi: Umjetna inteligencija, Artifficial intelligence, AI, Strojno učenje, Machine learning, ML, Dubinsko učenje, Deep Learning, DL, Kreativna insustrija, Kreativna ekonomija, kreativnost.

Sadržaj

1. Uvod 1
2. Umjetna inteligencija i Big data 2
2.1. Umijetna inteliencija 2
2.2. Big Data 7
2.3. Kreativnost i umjetna inteligencija 11
3. Utjecaj umjetne inteligencije na kreativnu industriju i kreativnu ekonomiju 12
3.1. Pozicioniranje i aplikabilna područja umjetne inteligencije i Big data u kreativnoj industriji 18
3.2. Područja utjecaja 20
3.2.1. Glazba 20
3.2.2. Vizualna umjetnost 25
3.2.3. Content i naracija 32
3.2.4. Content u gaming industriji, filmovima, tehničkim aspektima proizvodnje i dizajnu 37
3.2.5. Informacije i mediji 42
3.2.6. Društvene mreže 43
4. Socioekonomski i tehnološki izazovi 48
4.1. Tehnološki izazovi 48
4.1.1. Data 48
4.1.2. Robusnost i doseg 48
4.1.3. Doseg i limitacije 49
4.1.4. Proaktivna odgovornost (Accountability) 49
4.1.5. Etičnost po dizajnu 49
4.2. Socioekonomski izazovi 50
4.2.1. GDPR 50
4.2.2. Automatizacija 51
4.2.3. Vlasništvo (autorska prava) 51
4.2.4. Pristupačnost (Accessibility) 52
Zaključak 53
Popis kratica 54
Popis slika 55
Popis tablica 57
Literatura 58
Prilog 65

1. Uvod

Umjetna inteligencija (engl. *Artificial intelligence - AI*) i big data su zasigurno najrazvikanije i najrasprostranjenije riječi u područjima znanstvenog istraživanja i u proteklih nekoliko godina te su postali najzanimljivija područja razvoja. Donedavno su ti pojmovi striktno bili vezani uz istraživanja u sferama IT-a, matematike i psihologije te ponekih globalnih kompanija i proizvođača, no njihova primjena je nadišla sfere znanstvenih istraživanja i prešla u domenu masovne primjenjivosti zbog svoje lake konfiguracije, i sve veće dostupnosti velikih količina podataka, što je dovelo do sve veću primjene umjetne inteligencije u sferama fizike, ekonomije, genetike, sociologije i mnogih drugih. Funkcionalnosti umjetne inteligencije inkorporirane su u samu srž mnogih elektroničkih naprava i sustava koje danas koristi većinski udio ovozemaljske populacije što potvrđuje da njihova korisnost već nije striktno limitirana u istraživačkim znanstvenim područjima već je prešla u sfere široke primjenjivosti.

Povećano korištenje umjetne inteligencije je zasigurno bilo najvidljivije u kreativnoj industriji i medijima te se smatraju jednim od ranih usvojitelja umjetne inteligencije kao nove i korisne tehnologije. Kreativna industrija je u konstantnom naporu pronalaženja novih tehnologija i načina za bolje kreiranje te prilagodbe sadržaja upravo zbog paradigme same industrije, a *umjetna inteligencija* zajedno s *big dana-om* pokazala se kao iznimno pogodnim i korisnim alatom, posebice zbog načina razvoja distribucijskih kanala medija, te se smatraju najvećim faktorima utjecaja promjene postojećih paradigmi industrijskih standardi. Cilj ovog rada je napraviti pregled inovacija i njihovih primjena, bilo već implementiranih ili mogućih implementacija, AI-a u kreativnoj industriji i pregleda aplikabilnih područja u segmentima kreativnosti te napraviti pregled dosadašnji i mogućih budući utjecaj na kreativnu industriju i kreativnu ekonomiju.

2. Umjetna inteligencija i Big data

2.1. Umijetna inteliencija

Umjetna inteligencija (eng. *Artificial intelligence* - ***AI***) je jedna od najmlađih grana znanosti i inženjerstva. Naziv i tehničko priznanje kao disciplina znanosti je zadobila poslije Drugog svjetskog rata 1956 godine, a danas je prepoznata kao jedna od najuzbudljivijih disciplina znanosti. AI je generalni termin znanstvene discipline koji obuhvaća raznovrsne potkategorija koje za cilj imaju općenite zadatke poput simuliranja učenja i percepcije do specifičnijih zadataka kao što su igranje šaha, rješenje matematičkih teorema, pisanje poezije, vožnja automobila, otkrivanje bolesti, postavljanja dijagnoza i sličnih. Zbog svog širokog spektar aplikabilnosti danas se sve više koristi za rješavanje specifičnih specijaliziranih zadataka manjih opsega poput audio-vizualnog prepoznavanja, robotske automatizacije ili kreiranja preporuka za gledanje filmova na Netflixu. AI je relevantan u pogledu kreiranja i rješavanja bilo kojih intelektualnih zadataka što ga čini univerzalnom znanstvenom disciplinom. (RUSSELL et al., 2010)

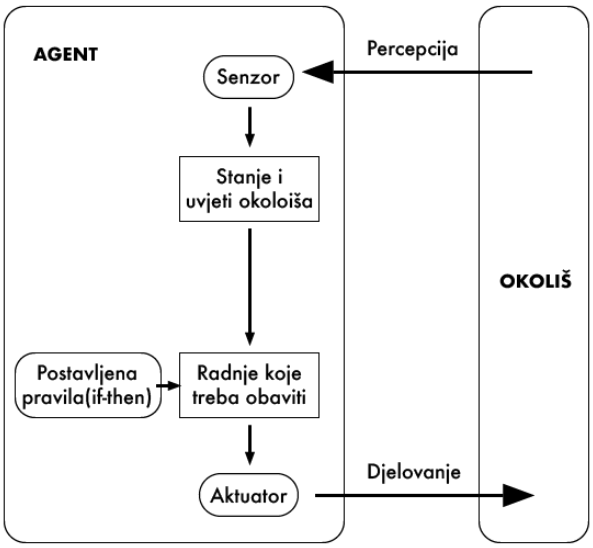
AI je teško konkretno definirati zbog svoje univerzalnosti i raznovrsnosti, no sami cilj AI-a je jasan, a to je da bude pametan i racionalan kao čovjek. Kako bi se što bolje definirala umjetna inteligencija postavljeno je osam definicija podijeljeno u dvije dimenzije ljudskih karakteristika:

Razmišljati ljudski	**Razmišljati racionalno**
"Uzbudljivi novi načini i napori da bi računala razmišljala ... strojevi s umom u punom i doslovnom smislu" (HAUGELAND, 1985) (eng -*"The exciting new effort to make computers think ... machines with minds, in the full and literal sense.*") Automatizacija aktivnosti koje se povezuju uz ljudsko razmišljanje, aktivnosti poput donošenja odluka, rješavanja zadataka, učenje…" (BELLMAN, 1978) (eng -*"The automation of activities that we associate with human thinking, activities such as decision-making, problem solving, learning ..."*)	"Proučavanje mentalnih procesa pomoću računalnih modela ." (CHARNIAK et al, 1985) (eng -*"The study of mental faculties through the use of computational models."*) "Proučavanje računalnih modela koji bi bili u mogućnosti opažati, razumjeti i djelovati ." (WINSTON, 1992) (eng - *"The study of the computations that make it possible to perceive, reason, and act."*)
Ponašati se ljudski	**Ponašati se racionalano**

"Umijeće kreiranja računala koji obavljaju ljudske funkcije koji zahtijevaju intelekt." (KURZWEIL, 1990) (eng- *"The art of creating machines that perform functions that require intelligence when performed by people."*) "Istraživanje načina na koji bi računala obavljali zadatke, u danom trenutku, bolje nego ljudi. " (RICH at al, 1991) (eng - *"The study of how to make computers do things at which, at the moment, people are better."*)	"Računalna inteligencija je grana istraživanja i dizajniranju inteligentnih agenata." (POOLE et al., 1998) (eng - *"Computational Intelligence is the study of the design of intelligent agents."*) "AI . . . se bavi kreiranjem inteligentnog ponašanja u neživim predmetima." (NILSSON, 1998) (eng - *"AI . . . is concerned with intelligent behavior in artifacts."*)

Tablica 2.1. Definicija AI podijeljena u dvije dimenzije ljudskih karakteristika. (KAPLAN at al, 2019)

Specifičnija definicija današnjeg korištenja AI-a bi bila mogućnost sustava da točno interpretira ulazne podatke, uči na temelju tih podataka i koristi te podatke kako bi modelirao i aplicirao te iste s ciljem postizanja konkretnog zadatka. (KAPLAN at al, 2019)



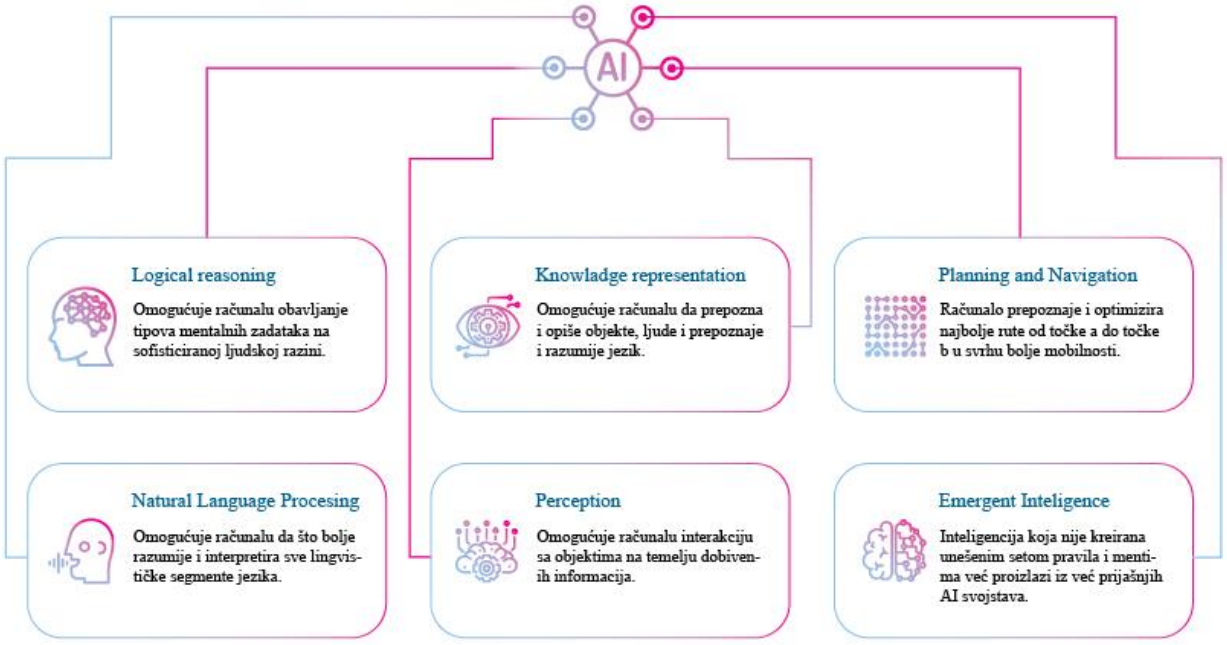
Slika 2.1 Način rada sustava AI-a

Za interpretaciju ulaznih podataka koristi takozvane *inteligentne agente* koji kroz senzore ili druge vrste ulaznih jedinica, procesiraju ulazne podatke iz okoliša te na temelju njih uz postavljena pravila obavljaju zadatak kroz aktuatore.

S ciljem dostignuća funkcionalnosti AI-a jednake razini čovjeka razvile su se mnoge pod grane, tehnike i algoritmi kako bi se što preciznije dostigla te prestigla ljudska razina.

AI posjeduje 6 kategorija svojstava:

- **Logical reasoning** – Omogućuje računalu obavljanje tipova mentalnih zadataka na sofisticiranoj ljudskoj razini .
- **Knowladge representation** – Omogućuje računalu da prepozna i opiše objekte, ljude i prepoznaje i razumije jezik.
- **Planning and Navigation** – Računalo prepoznaje i optimizira najbolje rute od točke a do točke b u svrhu bolje mobilnosti.
- **Natural Language Procesing** – Omogućuje računalu da što bolje razumije i interpretira sve lingvističke segmente jezika.
- **Perception** – Omogućuje računalu interakciju s objektima na temelju dobivenih informacija.
- **Emergent Inteligence** – Inteligencija koja nije unešena setom pravila i programskim elementima već eksplicitno proizlazi iz prijašnje navedenih AI svojstava.



Slika 2.3. kategorija svojstava koje posjeduje AI

Navedena svojstva ne predstavljaju kompletnu strukturu AI-a pošto ne uključuju algoritme tehnike. Iako postoje razni algoritmi i tehnike, šest je najznačajniji i najkorištenijih:

1. **Machine learning –** *(Strojno učenje)* područje AI-a koje koristi algoritam i statističke modele za kreiranje računalnog sustava koje bi obavljao zadatke bez prijašnje programiranih točnih odredbi za rješavanje inicijalno zadanog zadatka.

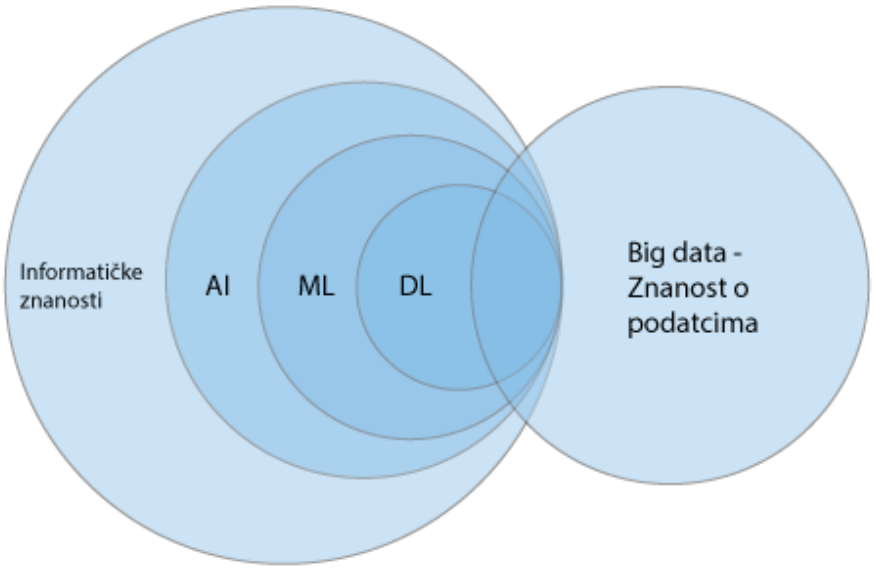
2. **Search and Optimization –** Algoritmi koji analiziraju i iterativno ponavljaju zadatak kako bi usporedili razne solucije i došli do optimalnog rješenja.

3. **Constraint Satisfaction –** proces pronalaženja solucije u sustavu s uvjetovanim restrikcijama koje varijabla mora ispuniti.

4. **Logical Reasoning –** softverski sustav koji stvara zaključke iz dostupnih smislenih podataka koristeći logičke tehnike poput dedukcije i indukcije. Ovakvi sustavi "razmišljanja" igraju važnu ulogu u primjeni AI-a i sustava temeljenih na znanju.

5. **Probabilistic Reasoning –** sustav koji koristi kombinaciju sposobnost teorije vjerojatnosti da se nosi s neizvjesnošću i sposobnost deduktivne logike za iskorištavanje strukture formalne argumentacije. Rezultat je bogatiji i ekspresivniji formalizam sa širokim rasponom mogućih područja primjene.

6. **Control Theory –**Teorija upravljanja u osnovi se primjenjuje na diferencijalne jednadžbe. U teoriji upravljanja se sustavu diferencijalnih jednadžbi, koji opisuje fizički sustav poput robota ili zrakoplova, daje mogućnost dodavanja određenih izraza u diferencijalne jednadžbe koje će promijeniti njihovo ponašanje. U AI sustavima se koristi za postizanje stabilnosti sustava.



Slika 2.3. Taksonomija AI-a i pod grana i dodirne točke sa znanosti o podacima *Big data*

Umjetna inteligencija (eng. *Artificial inteligence* – ***AI***) je krovni skupni naziv grane istraživanja koji spada pod kategorijom informatičke znanosti, dok je **strojno učenje** (eng. *Machine learning* – ***ML***) podvrsta AI-a , a **duboko učenje** (eng. *Deep learning* - ***DL***) podvrsta ML-a, a zajedničke dodirne točke imaju s tehnologijom prikupljanja i klasificiranja velikih količina podataka (eng. ***Big data*** - ***BG***).

- **Strojno učenje** (eng. *Machine learning – ML*)

  grana je umjetne inteligencije koja se bavi oblikovanjem algoritama koji svoju učinkovitost poboljšavaju na temelju empirijskih podataka.

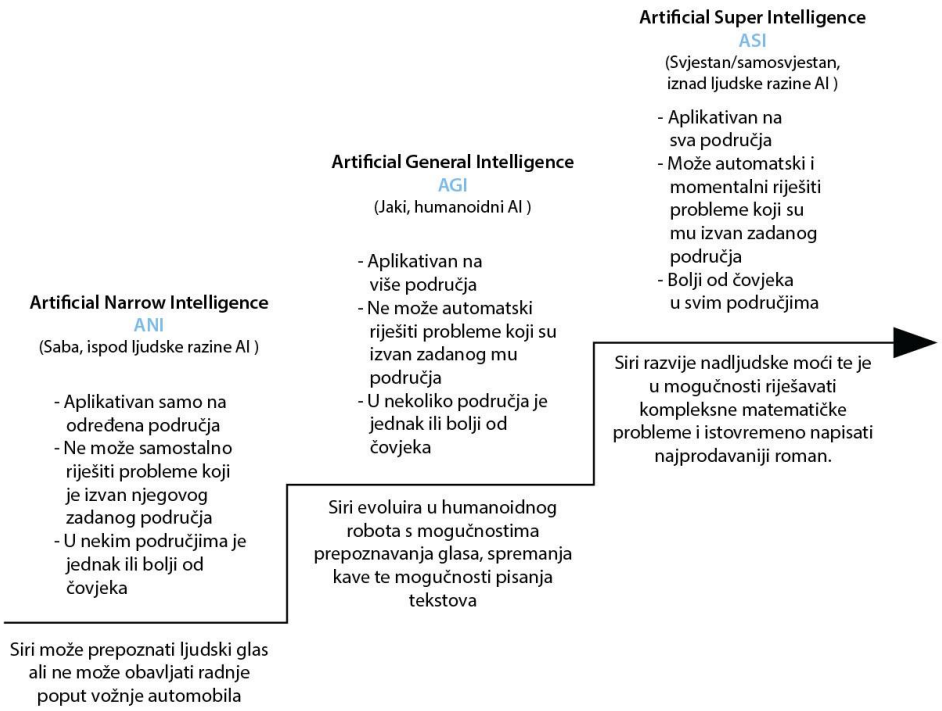
- **Duboko učenje** (eng. *Deep learning - DL*)

  dubinsko učenje je podvrsta strojnog učenja unutar kojeg svaki stroj trenira i uvježbava sam sebe na temelju prijašnjih saznanja i podataka.

AI se razvrstava i diferencira po sposobnostima kognitivne inteligencije, no primijeniti socijalne i emotivne inteligencije na umjetne računalne sustave je teško. Prema vodećim stručnim mišljenjima danas u psihologiji inteligencija se nasljeđuje, a ne stječe i ne može se naučiti. Emocionalna i socijalna inteligencija naspram naslijeđene inteligencije je nešto što pojedinac uči i stječe, a AI ih može oponašati i prepoznavati. Strojevi i umjetna inteligencija nisu u mogućnosti osjetiti emociju, ali posjeduje mogućnost prepoznavanja određenih obrazaca koje pritom prepoznaju kao elemente emocija poput primjera analize mikro-ekspresija lica za uočavanje emocionalnih izraza.

Danas svi više-manje imamo pristup uređajima koji posjeduju ili su predstavljeni da posjeduju neki segment širokog spektra AI-a. Kao što je i navedeno, ideja da računala mogu razmišljati kao ljudi je razmatrana u raznim literaturama više od pola stoljeća, a danas sveprisutna, takoreći prva generacija umjetne inteligencije, je primarno fokusirana na obavljanje specifičnih zadataka.

Iz tog razloga taj se oblik AI-a, koji je fokusiran na obavljanje specifičnog zadatka, referira kao usko usmjerena umjetna inteligencija (eng. *Artificial Narrow Intelligence* – **ANI**) Sustavi *ANI* razine su danas inkorporirani u raznim proizvodima poput Facbooka za prepoznavanje lica na slikama označenih korisnika, kod Appel-ovog Siri za prepoznavanje i razumijevanje jezika i odrađivanje zadataka na temelju navedenih glasovnih uputa, ili kod Teslinim automobilima za omogućavanje razvoj autonomnih sustava vožnje. U budućnosti se očekuje razvoj sekundarne generacije jakog humanoidnog AI-a (eng. *Artificial General Intelligence* – **AGI**) sustava s većom autonomijom i sposobnošću rješavanja problema i zadataka van svog zadanog područja. Krajnja razvojna faza sustava AI- bi bio razvoj treće generacije "super inteligencije", (eng. *Artificial Super Intelligence* – **ASI**) kompletno samosvjesnog sustava umjetne inteligencije koji bi na svojevrstan način ljude učinio suvišnim. Takav bi sustav bio u mogućnosti rješavati znanstvene teoreme, posjedovao bi socijalne vještine i mudrost što bi takav sustav činilo istinskom umjetnom inteligencijom.



Slika 2.4. Prikaz razvoja umjetne inteligencije na primjeru Apple-ovog voice assisten sustava pod nazivom Siri

2.2. Big Data

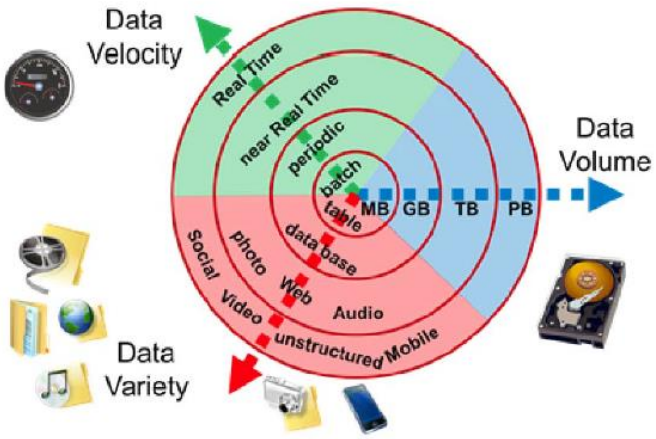
Big data je skupni naziv tehnologije za prikupljanja podataka, a najbolje ga je opisati kao set podataka prikupljen u realnom vremenu koji se sastoji od nestrukturiranih i strukturiranih

podataka. Definicija Big date je postavljena još 2001 od strane Gartnera[1] kao vodeće tvrtke za analizu tržišta, novih tehnologija i savjetovanja :

> *"**Big data** is high-volume, high-velocity and/or high-variety information assets that demand cost-effective, innovative forms of information processing that enable enhanced insight, decision making, and process automation."*

U prijevodu *big data* definiraju tri sastavne komponente "**3V**"

- **Volume** – Volumen, to jest velika količina podataka koja se obrađuje, prikuplja i analizira
- **Velocity** – Brzina kontinuiranog prikupljanja podataka u realnom vremenu
- **Variety** – Raznolikost podataka koji se dobivaju. Odnosi se na segmente strukturiranih i nestrukturiranih podataka



Slika 2.5 Prikaz povećanja big date kroz primarne karakteristike 3V - volume, velocity, variety

Izvor :By Ender005 - Own work, CC BY-SA 4.0, https://commons.wikimedia.org/w/index.php?curid=49888192

Big data čini skupina podataka koja je sačinjena od velikih količina raznovrsnih podataka koji su prikupljeni u realnom vremenu, a iziskuju isplativ način obrade koji bi producirao smislene forme podataka koji bi pomogli u donošenju odluka i/ili kreiranju automatizacije pojedinih procesa.

Jednostavnije postavljeno *big data* su kompleksne i volumenom veće skupine podataka koje se generiraju od određenih medijskih izvora, bilo da se radi o podacima Faceebok posta, Twitter feeda, klikovima na web stranici, mobilnoj aplikaciji ili čak sa senzora za detekciju pokreta. Za neke tvrtke ove količine podataka mogu biti u desecima terabajta, a za poneke i u stotinama petabajta. Ovakve se skupine podataka ne mogu analizirati klasičnim i

1 https://www.gartner.com/en/information-technology/glossary/big-data

tradicionalnim softverima zbog kompleksnosti i nestrukturiranosti podataka. Podaci ne dolaze kao već strukturirani i jednovrsni tipovi podataka nego su raznovrsni i to polustrukturirani i nestrukturirani poput teksta, audio i video formata koji zatim zahtijevaju dodatnu obradu kako bi se ostvarilo smisleno značenje podataka i kreirao *metapodatak* za bazu podataka. *Metapodatak* je tip podatak koji opisuje i označava podatak. U digitalnom smislu to je strukturirani podatak koji opisuje, objašnjava, locira ili na neki drugi način omogućava lakši način upravljanja resursima podataka.

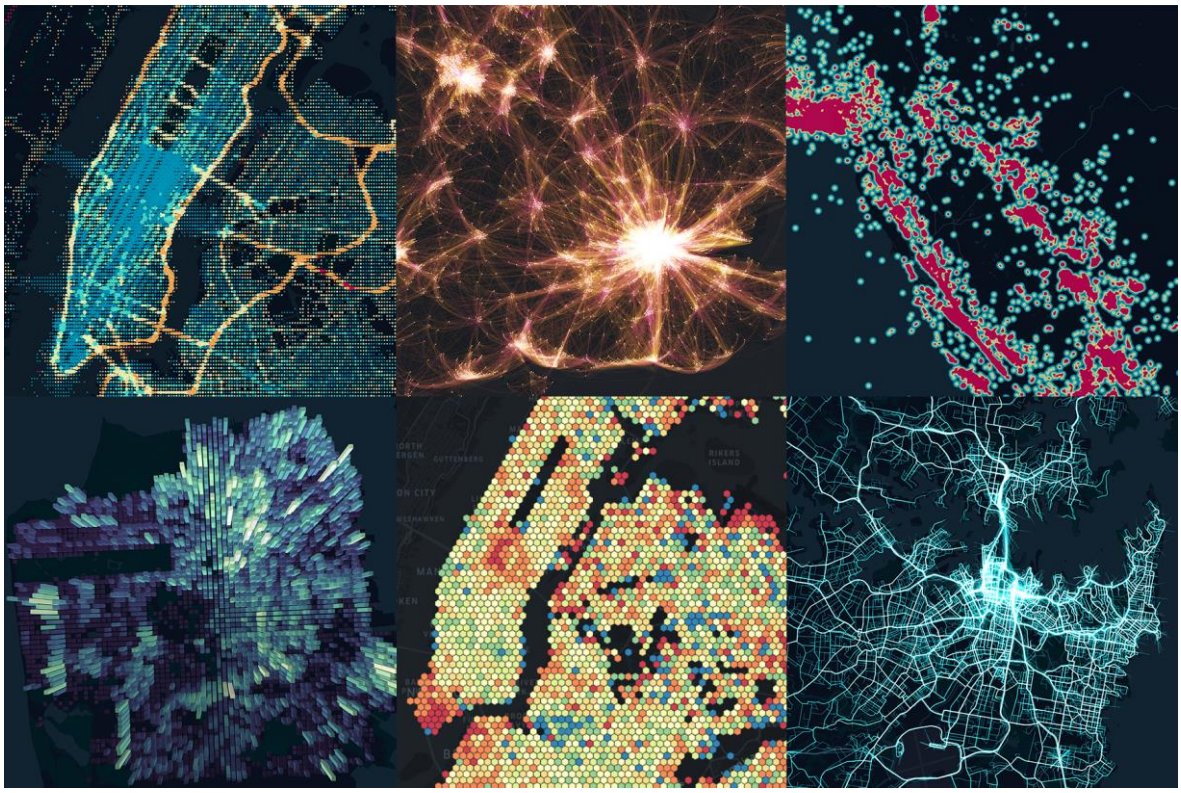
Tehnologija *big date* je iznimno korisna te svoju primjenu ima u raznim granama znanosti, državnim zavodima, zdravstvu, školstvu, osiguranju i raznim drugima, no za potrebe ovog rada fokus će prvenstveno biti na upotrebi u medijima i informacijskom sektoru i primjeni na internetu stvari (eng. *Internet of things* - IoT)

Mediji i industrija oglašavanja danas koriste *big data* sustave kao sredstva bolje prilagodbe mehanizama oglašavanja i kreiranja sadržaja. Postepeno se odmiču od klasičnih pristupa uporabe tradicionalnih medija kako što su print medija ili televizijski emisije već za pristupe što većem broju korisnika koriste big data sustave za prikupljanja podataka (eng. *data mining*) s ciljem što bolje optimizacije i prilagodbe sadržaja prema potrebama i mindsetu potrošača. Krajnji je cilj dostići potpuno prilagođeni sadržaj ili oglas prema potrošačevim željama i potrebama. (*Couldry* et al., 2014) Osim kreiranja prilagođenih sadržaja, *big data* i *IoT* omogućili su preciznije i točnije praćenje podataka što u krajnosti rezultira transparentnim i mjerljivim rezultatima povratka uloženog. (eng. *Return of investment* - ROI)

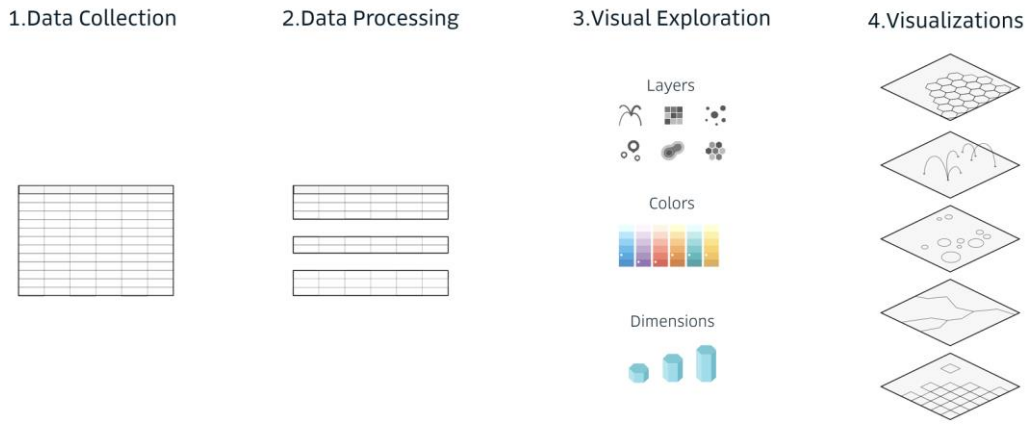
Osim prilagodbe i kreacije sadržaja *big data* je otvorio put potpuno novom stilu novinarstva i grane kreativnosti pod nazivom "*Data journalism and data art*". *Data journalism* se koristi *big data* alatima za usporedbu podataka i kreiranje novih uvida pomoću infografika. Ono pridonosi boljem uvidu u sve većih utjecaj numeričkih podataka korištenih u informatičkoj i informacijskoj eri i preklapa novinarstvo sa znanstvenim poljima dizajna, informatike i statistike. (*Rogers* , 2012)

Osim u novinarstvu istraživački stil vizualizacije *big date* kreirao je novi uvid u analizi podataka kroz infografiku.

Primjer Uberovog tima *" Uber's Visualization group"* koji je kreirao big data open source sustav pod nazivom ***kepler.gl*** kako bi što bolje razumjeli i analizirali podatke o samovozećim automobilima, geoprostornim planovima te poslovnim podacima u kontekstu urbane mobilnosti.



Slika 2.6. Primjeri vizualizacija informacija sustava Kepler.gl
Izvor: https://eng.uber.com/keplergl/



Slika 2.7. Prikaz sustava funkcionalnosti sustava Kepler.gl
Izvor: https://eng.uber.com/keplergl/

Ovakvi sustavi su omogućili bolje uvide u osobne navike korisnika, a time otvorili uvide u bolju optimizaciju platformi i prilagodbe korisničkih sučelja na temelju tih podataka.

2.3. Kreativnost i umjetna inteligencija

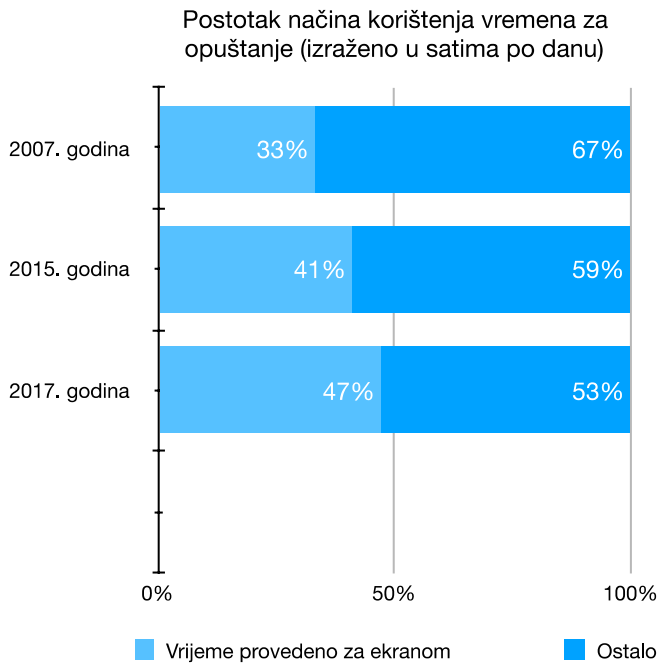
Dok znanstvenici istražuju ljudsku kreativnost od sredine dvadesetog stoljeća, napredci u AI-u i DL-u pokazuje se uzbudljivim, a opet zamagljenim područjem istraživanja i primjene. Zapravo, neki brinu da bi programi ML-a mogli stvoriti kreativnost u doba umjetne inteligencije i tako promijeniti paradigmu različitih profesija koje zahtijevaju visoku razinu ljudskog utjecaja i spoznaje. Ljudska kreativnost ukorijenjena je u nizu socijalnih, emocionalnih i kognitivnih mehanizama: *Afektivno uzbuđenje, preusmjeravanje pozornosti i kognitivna fleksibilnost olakšavaju pronalaženje rješenja, divergentno mišljenje, inkubacija i konvergentni obrasci razmišljanja*. Zauzvrat, kreativnost se može promatrati kao pojedinačni proces ili u širom kontekstu sociokulturoloških sustava. Stoga je sposobnost prilagođavanja novim situacijama kritična i jedinstvena komponenta ljudskog bića koju AI tek mora u potpunosti replicirati. Tehnologije koje su pomogle opstanku čovjeka od poljoprivredne do industrijske revolucije služile su svrsi da život učinimo ugodnijim. Takve su tehnologije kreirane da oslobode ljude od napornih i repetitivnih fizičkih i kognitivnih poslova koji oduzimaju vrijeme. Kad su ljudi naučili iskoristiti prirodne resurse u korist upravljanja usjevima i stokom, prištedena je znatna količina energije. Emocionalna, kognitivna i fizička sredstva mogu se potrošiti na druge vrijedne aktivnosti. Sada, u onome što neki nazivaju četvrtom industrijskom revolucijom, programi ML-a još uvijek služe svojoj namjeri da nam olakšaju život, od algoritama za predviđanje koji mogu učinkovito dijagnosticirati razne bolesti, pa sve do dnevnih zadataka navigacije, preporuke glazbe i provjere pravopisa. AI je dizajniran da smanji naše kognitivno opterećenje donošenjem odluka umjesto nas. Istodobno, naša unutarnja znatiželja za pomicanjem granica umjetnih sposobnosti pruža mogućnost stvaranja programa koji slikaju, komponiraju i reproduciraju. Poznati primjeri "kreativnih"AI-a sustava su: sustav za crtanje pod nazivom AARON[2] kojeg je kreirao profesor Harold Cohen, te Google-ov *Deep Dream* projekt za kojeg poneki smatraju da kreiran nova kreativna djela koji izazivaju emocionalnu reakciju kod gledatelja (više u poglavlju 3.2.2.1.). U doba u kojem roboti uče obavljati, u nekim slučajevima i nadmašiti, određene ljudske zadatke, neki se pitaju mogu li strojevi kreirati nove oblike mišljenja i prepoznati složenije obrasce bolje nego što ljudi mogu. Ipak, nepostojanje sustava emocionalnog uzbuđenja uklanja važnu relacijsku komponentu koja je ljudima potrebna za stvaranje kreativnih i korisnih ideja. Inteligentni algoritam koji, točno percipira, razumije i regulira emocije, nije još u potpunosti razvijen. Ukratko, dok autor *Harari* tvrdi da je "ideja da će ljudi uvijek imati jedinstvenu sposobnost iznad dosega nesvjesnih algoritama samo pitanje vremena" (*Harari, 2016*), sposobnost moralnog i emocionalnog rasuđivanja nadilazi utilitarizam te je nešto što se, bar za sada, ne može ponoviti čak ni složenim algoritmima strojnog učenja. (Lebuda et al., 2019)

2 http://www.aaronshome.com/aaron/index.html

3. Utjecaj umjetne inteligencije na kreativnu industriju i kreativnu ekonomiju

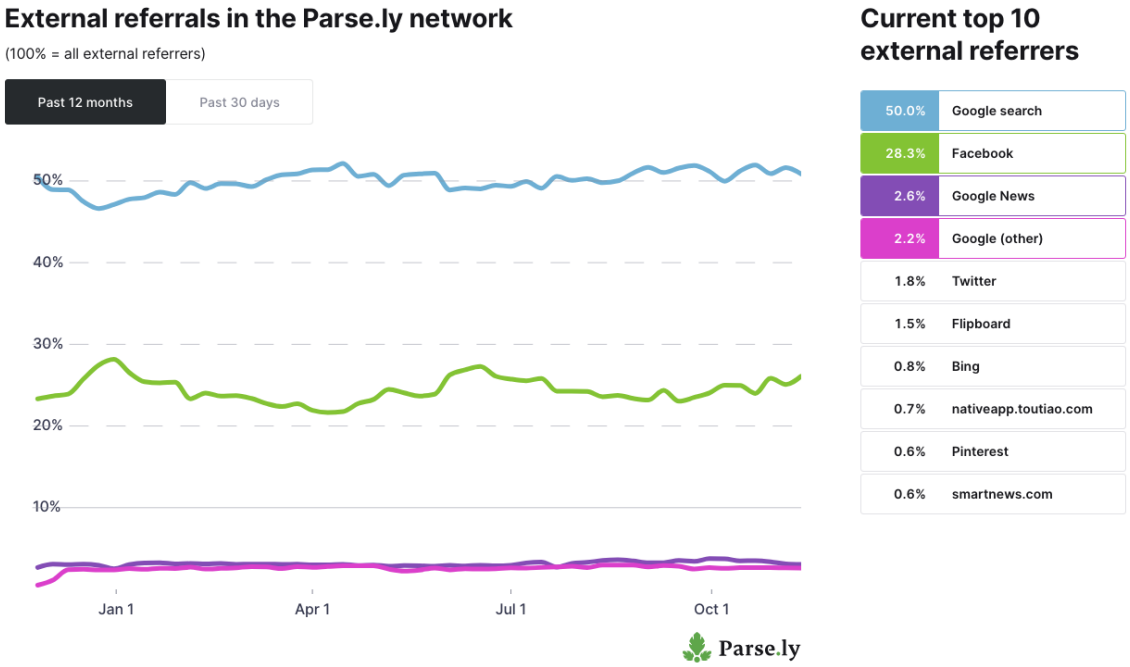
AI sa svojom primjenom mijenja paradigme kreativne industrije, a time i kreativne ekonomije što za sobom povlači pozitivne i negativne utjecaje. Tehnologije AI-a i automatizacije su kreatorima sadržaja pojednostavnili postupak dostavljanja sadržaja ciljanoj publici "naučivši" i klasificirajući preferencije korisnika i time omogućile točnije targetiranje korisnika specifično njima prilagođenom sadržaju. To se postiže s korištenjem ML-a pomoću kojeg se analiziraju veliki setovi podataka kako bi se što bolje proučilo i uvidjelo specifična ponašanja (*poznati primjer je u Google analytics - smart Golas sustav*), a time omogućilo zadanim programima ML-a da bolje prepoznaju specifične obrasce ponašanje i na osnovu njih prilagode djelovanje bez dodatnog redefiniranja programskih pravila. Mogućnosti AI se koriste pri kreiranju sadržaja u svim granama kreativne industrije uključujući glazbu, umjetnost, modu i film. Korisnosti AI su prepoznata i u dijelovima produkcije i kreiranju raznovrsnih sadržaja gdje su zadaci za ljudske standarde preteški ili iziskuju veliki utrošak vremena. No uz pozitivne segmente AI postoje i razni negativni utjecaji koji su nastali iskorištavanjem sustava. Jedan od primjera su kreiranje dezinformacija i širenje netočnih informacija i činjenica putem društvenih medija čije širenje potpomažu algoritmi za dijeljenje viralnog sadržaja. (*World Economic Forum* at al., 2018)

Ako za primjer pogledamo činjenicu da korisnik pametnog telefona koristi uređaj u prosjeku preko 85 puta dnevno (*Perlow* at al., 2012) , a 46% je izjavilo da ne bi mogli živjeti bez uređaja (*Smith* at al., 2015) vidimo da su mobilni uređaji uz ostale digitalne uređaje postali najveći način konzumacije informativnog i ostalog tipa sadržaja.



Slika 2.8. Prikaz načina korištenja vremena za opuštanje
Izvor: World Econimic Forum: dana provided by adam Alter, NYU Stem School of Business 2018

AI zajedno s novim formama online tehnologije mijenja način kreiranje i konzumacije sadržaja i to u dinamičnom okruženju. Kreatori sadržaja koriste dostupne tehnologije za pronalaženje i veće publike no nemaju direktan utjecaj i kontrolu nad načinom na koji korisnici pronalaze i konzumiraju njihov sadržaj. Tehnološke platforme su postale primarni referentni izvori za digitalno izdavaštvo, a ***Parsley.ly*** navodi Facebook i Google kao predvodnike u referentnim platformama za dolaženje do sadržaja.

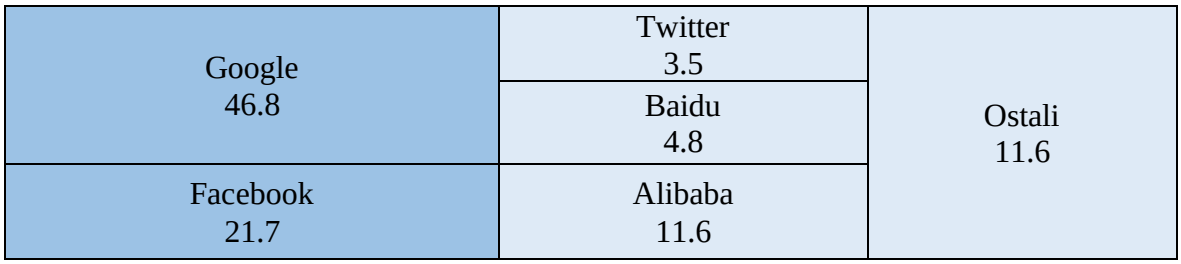


Slika 2.9. Parse.ly izdaje podatke o prometu u stvarnom vremenu o referentnim digitalnim izdavačima. Podaci nisu globalni pošto u ovom primjeru nije uključena Narodna Republika Kina.
Izvor: https://www.parse.ly/resources/data-studies/referrer-dashboard

Novi načini i raspodjela pristupa sadržaja preko tehnoloških platformi je kompletno promijenila sustavne odnose uredništva i monetizacije prihoda izdavaštva. Nove tehnološke platforme, namjerno ili nenamjerno, određuju koja vrsta sadržaja će biti više eksponirana i viđenija. Tvrtke koje u svojem vlasništvu imaju platforme potiču, savjetuju u nekim slučajevima i novčano podupiru izdavače da kreiraju sadržaj prilagođen njihovim platformama. Sam sadržaj ne treba biti od iznimne umjetničke ili društvene vrijednosti, već što bolje prilagođen smjernicama za koje se smatra da će sadržaj učiniti "viralnijim" i djeljivim. Upravo za to koriste *Proprietary AI* algoritme koji osiguravaju da pojedini formati sadržaja budu što pristupačniji i vidljiviji u pretraživanjima korisnika te njihovim feedovima[3]. Google i Facebook koriste tehnologiju AI-a koji smanjuje vrijeme očitavanja sadržaja, ali zahtjeva da taj sadržaj bude prilagođen njihovim standardima. Na taj način platforme djelomično "prisiljavaju" kreatore sadržaja da preoblikuju pristup stvaralaštva i umanje poneke standarde dizajna i struke što je do sada u tradicionalnim medijima bila odlika kreativnosti. (*Bell E.*, et al,. 2017) Ovakvi odnosi gledano iz financijskog aspekta ne

3 (eng. feed – Prednja/prva stranica neke platforme. Primjer "Facebook feed" – prednja stranica Facebook sa objavama.)

idu u korist kreatorima i izdavačima sadržaja, posebice dok pet kompanija zauzima oko 80% globalnog mobilnog oglašavanja, a prema nekim procjenama za oko 90% ukupnog rasta su zaslužne samo Google i Facebook.



Slika 2.10. Udio zarade na mobilnim oglasima izražen u postotcima % na globalnoj razini
Izvor: eMarketer, Thomas Reuters Datastream, Bloomberg, Morgan Stanley

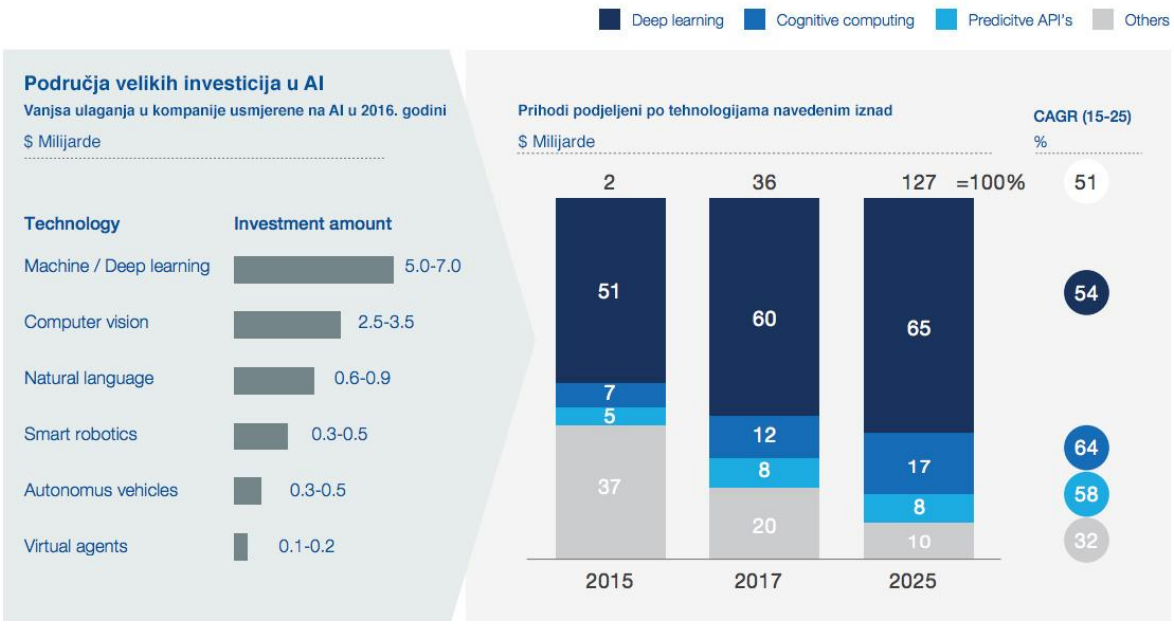
Jedan od problema ovakvog sustava je što u pozadini imamo AI koji nema razvijenu svijest i nije u mogućnosti objasniti razumno njegove *outpute* (izvršenje radnje – u kontekstu pretraživanja bi se radilo o prikazanom sadržaju). Umjesto razuma ono se bazira na podacima i postavkama algoritama. Iako baziranje na podacima i algoritmu ne predstavlja problem pri generiranju glazbe ili slične grane umjetnosti, u slučaju izdavaštva, točnije prikazu sadržaja korisniku, ono postaje kreatorom javnog mijenja i predstavlja mogućnost dezinformiranja i te umanjuje transparentnost informacija.

Poznati slučajevi iskorištavanja ovog sustava danas su poznati po već navedenom slučaju *Cambridge analytice* nazvanog po istoimenoj tvrtki koja je iskoristila sustave oglašavanje kako bi utjecala na razne izbore 2016. – 2017. godine. (*Freedom House*., 2017) (*Cadwalladr C*., 2018) Upravo se zbog takvih slučajeva radi na inicijativama informiranja javnosti o medijskoj pismenosti i sve više se radi na zaštiti i sigurnosti podataka građana(GDPR[4]).

Upravo u ovakvim slučajevima se vidi potencijal i snaga koju tehnologija AI-a nosi za sobom, a istraživanja i razvoj AI-a je rapidan. Prema podacima *Bank of America Merrill Lynch*, ukupni generirani prihodi u području AI industrije je u rastu s 5 milijardi dolara u 2015. godini do predviđenih 127 milijardi dolara u 2025. godini što označava rast od 51% prema složenoj godišnjoj stopi rasta (*eng.* ***CARG*** *- Compound annual growth rate*). Najveći rast se vidi u područjima i apliciranju DL-a, *Cognitive computinga* i predviđajući [5]OBJ(eng. *API - application programming interface). (Ma B.,* et al, 2017)

4 Uredba (EU) 2016/679 Europskog parlamenta i Vijeća od 27. travnja 2016. o zaštiti pojedinaca u vezi s obradom osobnih podataka i o slobodnom kretanju takvih podataka te o stavljanju izvan snage Direktive 95/46/EZ (Opća uredba o zaštiti podataka)

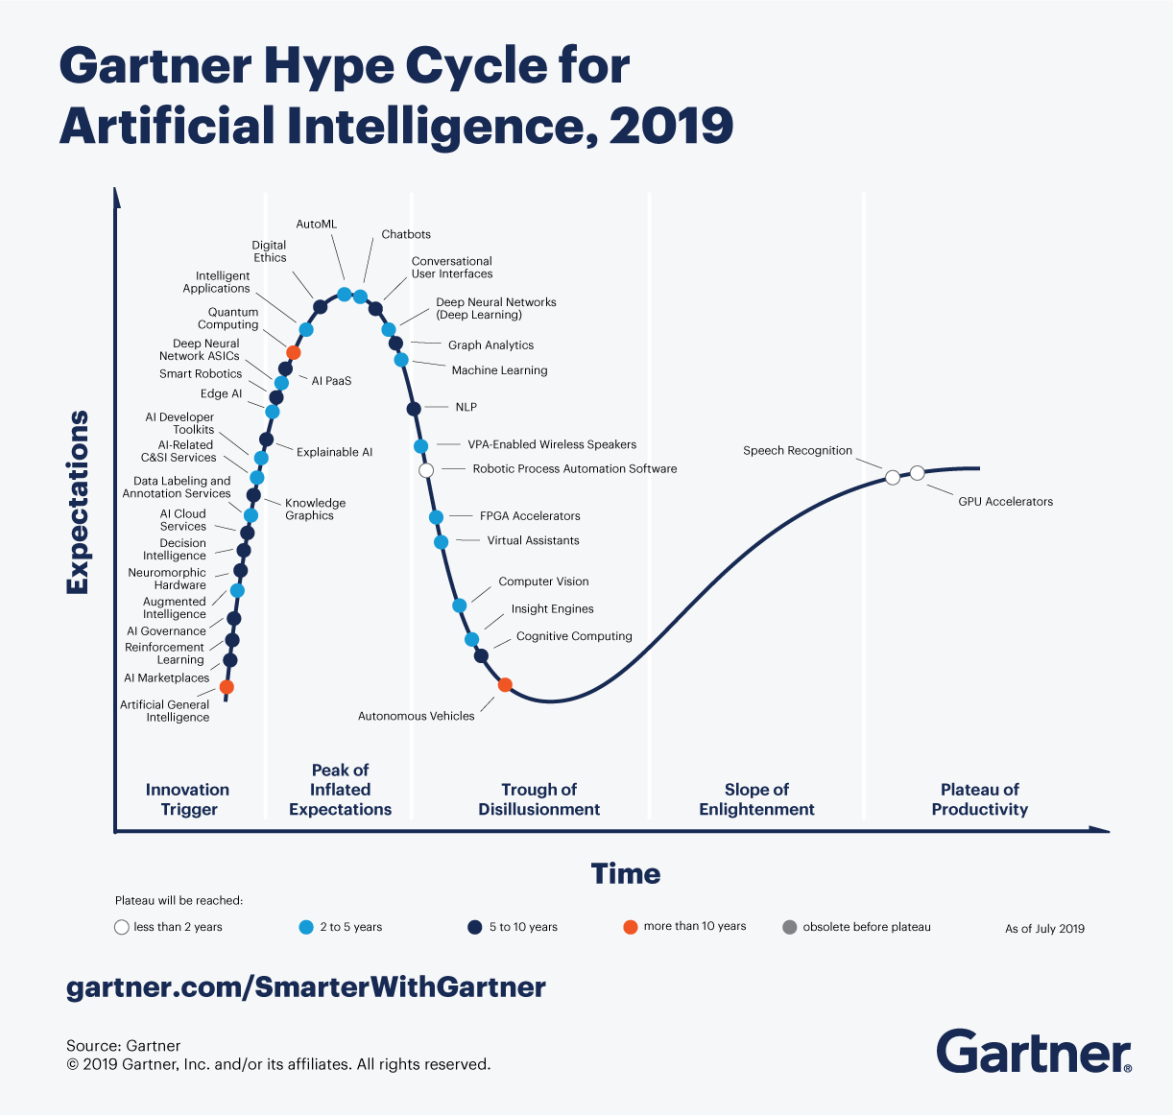
5 API-ji označavaju aplikacijska programska sučelja, oni su softverski blokovi s kojima dvije aplikacije zadobijaju sposobnost međusobnog komuniciranja u stvarnom vremenu.



Slika 2.11. Izvor: World Economic Forum, bazirano na podacima "Capital IQ, Pitch book, Dealogic, McKinsey"

Ukupni postotak kompanija koji je implementirao AI u razdoblju između 2018. i 2020. godine je porastao s 4% na 14% pokazala su istraživanja Gartnera - "*Gartner's 2019 CIO Agenda survey*"[6], a prema Gartnerovom Hype Cycle (Slika 2.9.) predviđanju vidimo stanje pojedinih tehnologija u 5 faza i vremenskom razdoblju dostizanja efektivnosti pojedinih segmenata tih tehnologija.

6 https://www.gartner.com/en/newsroom/press-releases/2018-10-16-gartner-survey-of-more-than-3000-cios-reveals-that-enterprises-are-entering-the-third-era-of-it

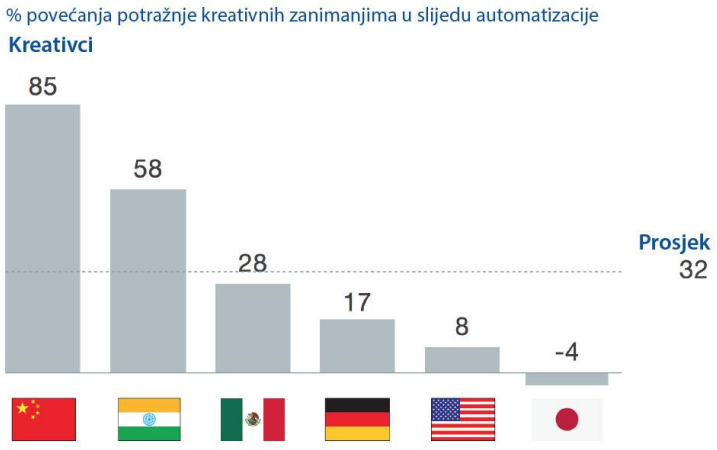


Slika 2.12. Izvor: https://blogs.gartner.com/smarterwithgartner/files/2019/08/CTMKT_736691_Hype_Cycle_for_AI_2019.png

Predvodnici u polju istraživanja i primjene AI tehnologija su takozvani "*FAANGs*" (Facebook, Amazon, Apple, Netflix i Alphabet-Google) i "BAT" (Baidu, Alibaba Tencent). Ove kompanije su najveći ulagači u tehnologiju razvoja AI-a te čije su sposobnosti u prepoznavanju i indeksiranju fotografija (Image recognition)(Novet J., 2015) i prepoznavanju govora već nadišle ili usporedive s ljudskim.

Za ovako rapidan razvoj AI su zaslužna dva ključna elementa. Povećano generiranje i prikupljanje podataka (Big data) i povećanje procesne i računalne moći. Big data je omogućio da AI bude što precizniji i "pametniji" u donošenju odluka posebice u sferama ML-a. (*Ma B.*, et al, 2017) Povećanje procesne i računalne moći omogućilo je AI-u da u što kraćem vremenu analizira i procesuira velike količine podataka. Cijena procesne moći po dolaru se poveća za deset puta svake četiri godine. (*O'Connor G.*, 2014)

No pitanje preostaje, koliki će utjecaj umjetna inteligencija imati na radne odnose u kreativnoj industriji? Koliki pomak je napravljen prema kreiranju autonomnog inteligentnog robota koji će svojim virtualnim mozgom moći parirati ono ljudskom? Prema predviđanjima i podacima stručnjaka s Ai impacts[7] projekta smatra se da bi sustav umjetne inteligencije mogao zamijenit, ili biti jednako kompetentan, kao osoba koja zarađuje 100 dolara po satu (prema sadašnjim standardima plaća) u nadolazećem razdoblju između 2025. i 2050. godine. No to ne znači da će kreativci izgubi posao već upravo suprotno. Promjena je neizbježne ali dolazi u obliku automatizacije i povećanja ljudskog kreativnog procesa. Očekuje se promjena u radnim odnosima i pozicijama. AI sustavi su dosegli mogućnost kreiranja glazbe, montaže videa, kreiranja umjetnosti, čak i kreiranja originalnih igara, no ne posjeduju autonomiju kreativnosti. AI će zamijeniti i olakšati repetitivne i rutinske poslove što u slučaju kreativne industrije znači da ostavlja više vremena i mogućnosti posvetiti se kreativnim procesima te unaprijeđenima. U kontekstu kreativnosti automatizacija i veća posvećenost podacima pomaže kreativcima, ekonomistima i usko povezanim područjima u kreativnoj industriji, da donose odluke na temelju podataka u stvarnom vremenu te da kreativnim postupcima rješavaju probleme. U tom pogledu kreativni segmenti posla se neće više odnositi samo na primjer na dobre kreativne direkciju kampanje ili sam vizualni izgled, već na dobru primjenu podataka inkorporirani kroz cijeli sustav OOH i digitalnih kanala gdje kreativnost služi rješavanju problema bilo ekonomskih ili sličnih kategorija. Za primjer možemo uzeti poslove koji zarađuju na nišnim proizvodima na način da veliki broj jedinstvenih artikala prodaju u relativno malim količinama, uobičajeno kao nadopuna prodaji malobrojnih ali vrlo popularnih artikala u velikim količinama. Primjer jedna takve kompanije je Associated Press koja je povećala svoju listu korisnika s 300 na 4000 tako što je implementirala sustav AI-a za bolje shvaćanje svojih korisnika i bolju adaptaciju sadržaja korisnicima.(*Marcon F.*, 2018) Implementacija AI-a treba težiti simbiozi ljudskog kadra i automatizacije posebice u području analize podataka. AI može brže, bolje i jeftinije u realnom vremenu analizirati i procesuirati podatke i tako otkriti određene dosad ne prepoznate obrasce. Danas se ponajviše u tom kontekstu koristi *Google analytics* ili slični sustavi za bolje praćenje konverzija sa socijalnim medija ili sličnih kako bi što bolje prilagodili svoje kanale i što brže odgovorili na zahtjeve svojih korisnika.



Slika 2.13. Automatizacija će uglavnom imati pozitivan utjecaj i povećati potražnju kreativnih zanimanja - kreativaca (Slikara, umjetnika, dizajnera, snimatelja …)
osim u navedenom slučaju Japana
Izvor: https://www.mckinsey.com/featured-insights/future-of-work/jobs-lost-jobs-gained-what-the-future-of-work-will-mean-for-jobs-skills-and-wages

7 https://aiimpacts.org/ projekt s ciljem poboljšavanja razumijevanja mogućih utjecaja umjetne inteligencije i postupaka dodođenja AI-a do ljudske razine.

3.1. Pozicioniranje i aplikabilna područja umjetne inteligencije i Big data u kreativnoj industriji

Povećano korištenje umjetne inteligencije najvidljivije je zasigurno u kreativnoj industriji i medijima, te se smatraju jednim od ranih usvojitelja umjetne inteligencije kao nove i korisne tehnologije. Kreativna industrija je u konstantnom naporu pronalaženja novih tehnologija i načina za boljim kreiranje te prilagodbi sadržaja. Upravo zbog paradigme kreativne industrije umjetna inteligencija zajedno s big data pokazala se kao iznimno pogodnim i korisnim alatom, posebice zbog načina razvoja distribucijskih kanala medija, te se smatraju najvećim faktorima utjecaja promjene postojećih paradigmi industrijskih standardi. (*Caramiaux* et al., 2019)

Kao što je prije navedeno u radu pod pojmom AI se smatra i spada mnoštvo tehnika obrade i prepoznavanja kompleksnih struktura podataka korištenih za predviđanje, poduzimanje ili transkribiranje radnji. Većinom se radi o sustavima ML-a koji provode statističko učenje (eng. *Logical Reasoning*) gdje sustavi uče strukture iz unesenih velikih količina podataka. Ovakav pristup prvenstveno dominira u kreativnoj industriji zbog sve većeg kreiranja enormnih količina podataka u stvarnom vremenu te dostupnih komputacijski mogućnosti sustava da razumije i analizira te podatke. Ogromna dnevna proizvodnja tekstualnog, slikovnog, video zapisa i audio sadržaja na mrežnim platformama jedan je od ključnih faktora tolike uspješnosti i nužnosti za AI sustavima. Sustavi AI-a su omogućili da se prepoznaju preferencije korisnika te naprave analizu sličnih, na primjer audio sadržaja, i "shvate" obrasce tog korisnika i korisnika sličnih ukusa u žanrovima, izvođačima, stilovima, te na temelju tih podataka postavi pristup predlaganja sličnih sadržaja za koje "smatra" da će se svidjeti korisniku. Taj pristup se pokazao izuzetno uspješnim zahvaljujući dobro razvijenim matematičkim modelima, dostupnosti podataka u stvarnom vremenu te mogućnosti sustava da sve interpretira kao podatke neovisno radilo se o tekstu(porukama, vijestima, knjigama, člancima), slici (lice, objekt, silueta, cesta…), zvuku (glazbi, jeziku…) tekst (prijevod s jednog na drugi jezik) ili čak medijski zapis (audio-vizualni zapis). AI alati također se mogu koristiti za donošenje optimalnih radnji ili odluka, na primjer odabir optimalnog sadržaja ili težine koje će se predložiti u adaptivnoj video igri. Opseg aplikabilnosti AI-a u medijima i kreativnoj industriji sve više raste, a taj rast potiče porast open-source softverskog alata i skupljanje podataka, kao i niskobudžetnih računalnih platformi. Mnoge mlade tvrtke koriste takva tehnološka rješenja da bi što učinkovitije stvorile svoje prve prototipe. Osim mladi tvrtki mnogi stručnjaka sve više razmatraju implementaciju AI u osobne projekte (poput umjetnika, istraživača itd.). (NEM,. 2019)

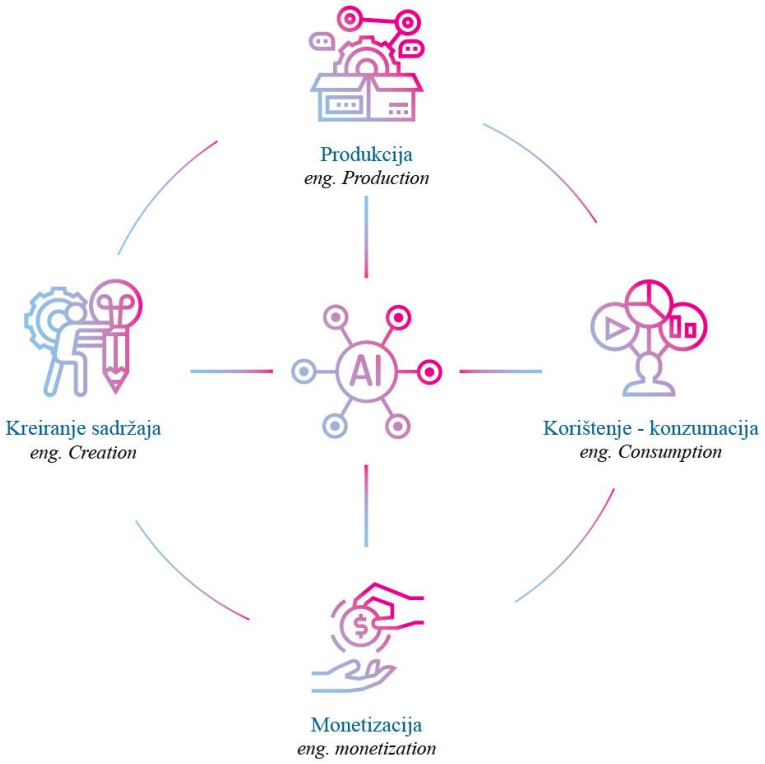
Kako bi se što bolje pokazao opseg i utjecaj AI tehnologija u kreativnoj industriji za potrebe ovog rada navesti ću nekoliko područja utjecaja te načine na koji je AI impliciran (područja u kojima je AI primjenjiv te način na koji potpomaže *kreiranje, produkciju* i *krajnje korištenje proizvoda te njegovu monetizacija*)

- **Kreiranje sadržaja** (eng. ***Creation***)
  Odnosi se na kreiranje novih medijskih sadržaja.

- **Produkcija** (eng. ***Production***)
  Odnosi se na način na koji se medijski sadržaj editira ili ukomponira u finalni proizvod spreman za izpostavu ili korištenje.

- **Korištenje - konzumacija** (eng. ***Consumption***)
  Način na koji finalni proizvod međudjeluje s korisnikom te kako ga koristi krajnji korisnik.

- **Monetizacija**
  Način na koji proizvođač ili korisnik može ostvarivati profit od proizvoda ili usluge.



Slika 2.14. Vizualni prikaz područja primjene AI-a i cikličkog međuodnosa.

3.2. Područja utjecaja

3.2.1. Glazba

Područje glazbe, specifičnije područje zvuka i audio inženjeringa, prolazi kroz velike promjene i uspjehe zahvaljujući AI tehnologiji i primjeni AI-a za obradu sadržaja i podataka. Iako je svoj početke vuče iz analize i primjerne AI-a sustava za obradu i prepoznavanje jezika, sadašnja istraživanja i napredci su više usmjereni u specifična područja zahvaljujući velikim setovima podataka kreiranih od strana produkcijskih studija i kompanija[8], umjetnika koji stvaraju open-source platforme za dijeljenje svojih zvukova i podataka, akademske arhive te mnogim streaming platformama. Upravo zbog svoje široke primjenjivosti AI je danas postao skoro pa neizostavni alat u sferama produkcije, kreacije i konzumacije glazbenog sadržaja.

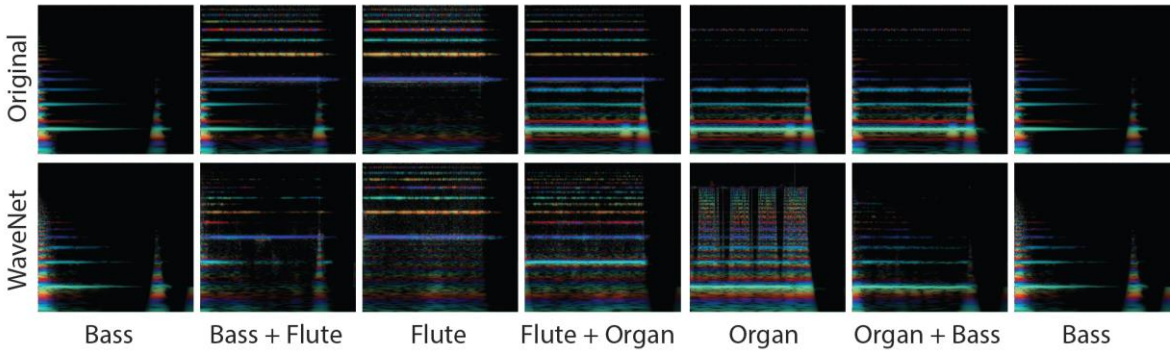
3.2.1.1 Kreiranje sadržaja (Creation)

Klasični pristup komponiranju glazbe pomoću računalnih programa se bazirao na unošenju podataka (eng. *input data*) određenog stila ili kompozitora, koje bi potom program analizirao te izučio određene stilske i kompozicijske paterne. (*Briot at al*, 2017)
Na toj ideji su bazirani većinom svi današnji sustavi AI alata za kreiranje i obradu glazbe. Koriste se metodom učenja dubinske strukture iz niza glazbenih djela i zvukova, koji na osnovu zadanih informacija i parametara dobivenih iz unesenih podataka kreiraju novi sadržaj koji zvuči poput onih uzetih za primjer. Ovakvi alati i metode su postali zanimljivi izvođačima, produkcijskim kućama i slobodnim umjetnicima, te čak amaterima entuzijastima van akademskih zajednica, što je doprinijelo sve kompleksnijem i kreativnijem pristupima obrade zvuka i glazbe[9], posebice u kreiranju loop-ova, semplova i direktne manipulacije zvukova.

Primjer primjene je Googlov AI program *Magenta* te njihov **NSyth** *Neural Audio Synthesis*program koji za razliku od tradicionalnog sintisajzera koji generira zvuk iz ručno dizajniranih komponenti poput oscilatora i zvučnih valova, NSynth koristi duboke neuronske mreže za generiranje zvukova na razini pojedinačnih uzoraka. Učeći izravno iz unesenog podataka, NSynth pruža umjetnicima intuitivnu kontrolu nad bojom i dinamikom zvuka te mogućnost istraživanja novih zvukova koje bi bilo teško ili nemoguće proizvesti ručno podešenim sintesajzerom.

8 https://magenta.tensorflow.org/

9 https://magenta.tensorflow.org/



Slika 3.15. Prikaz NSynth-ovog Rainbowgrama i WaveNet decodera baziranog na neuronskim mrežama.
Izvor: https://magenta.tensorflow.org/nsynth

Iznad se nalaze dva stupca audio isječaka koji odgovaraju dvama redovima *rainbowgrama*. Gornji red *rinbowgrama* prikaz je rezultata ravnomjernog interpoliranja između instrumenata dodavanjem signala. Donji red *rainbowgrama* prikazuje rezultat korištenja NSynth za linearnu interpolaciju preklapanja zvučnih valnih duljina. Proizvod linearnog zbrajanje signala u audio izlaznom prostoru primjerice *drugog reda- prvi stupac, sa slike 3.15,* doslovce će zvučati kao da su istovremeno puštena dva zvuka, u ovom slučaju basa i flaute. Međutim, *prvi stupac drugog reda,* nove note kombiniraju semantičke aspekte dvaju originalnih zvukova kako bi stvorili jedinstveni zvuk koji je i dalje melodičan.

Osim pristupa kreiranja i komponiranja glazbenih sekvenci AI je i doprinio u sferi dekomponiranja glazbenih djela. Specifičnije omogućio je kvalitetno zasebno odvajanje zvučnih elemenata kompozicije (npr. dionica bass gitare, bubnjeva, vokala…). Mnogi glazbenici i kompozitori žele iskoristiti određene elemente pjesme i do sada su većinom ili rekreirali dionice pjesme ili su imali sreće da je svaki instrumenti ili izvor bio sniman u zasebnom zvučnom kanalu te su imali pristup originalnim snimcima. Rijetki su, osim možda studija koji su snimali originalne, imali pristup takvim snimcima te su većinom oslanjali na manualnu dekompoziciju kanala i pokušavali dobiti što čistiji zvučni snimak. Upravo su iz tog razloga uloženi veliki napori u istraživanju načina dekomponiranja glazbenih djela. AI se pokazao kao idealno sredstvo te je ***Deezer.com*** (Kompanija koja se bavi streeamingom glazbe) kreirala algoritam i open source free MIT- licencirani sustav po imenu ***Splitter***[10] koji je pokazao veliki napredak upravo u ovom polju. (*Moussallam M.*, 2019) Iako je Splitter predstavio obećavajući napredak postoje još poneki određeni tehnološki izazovi koje treba nadići. (NEM., 2019)



Slika 3.16. Deezerov prikaz funkcionalnosti Splitter-a
Izvor: https://deezer.io/releasing-spleeter-deezer-r-d-source-separation-engine-2b88985e797e

10 https://deezer.io/releasing-spleeter-deezer-r-d-source-separation-engine-2b88985e797e

Za sada se modeli oslanjaju na produciranje sličnih stilskih glazbenih uzoraka bazirano na unesenim podatkovnim primjerima, dugoročni cilj automatizacije i AI-a je mogućnost kreiranja kompletno novog originalnog djela. Iako za sada postoje napredci u kreiranju vise instrumentalnih strukturiranih glazbenih djela, poput albuma ***Hello world*** francuskog izvođača ***SKYGGE*** koji slovi za prvi album kompletno generiran pomoću AI-a[11], postoje još određeni izazovi koje treba nadići poput boljeg određivanja i prepoznavanja glazbenog segmenta boje zvuka ili shvaćanje jezika, kao u primjeru Sony-jevog AI projekta **Flow Machines[12]** u pjesmi *Daddy's Car*[13], gdje je AI u mogućnosti kreirati pjesmu u stilu The Beatles-a ali s besmislenim tekstom. Svi sustavi koji su do sada prezentirani u domeni glazbe su još uvijek na ANI razini sustava. Krajnji cilj glazbenog generativnog sustava pognojenog AI-om, da bi došao do AGI ili ASI razine, je da bude u mogućnosti u stvarnom vremenu izmjenjivati direktni "sirovi" audio signal. Neki modeli sustava su pokazali da su na dobrom putu postizanju viših razina u obradi "sirovih" direktnih podataka poput sustava *WaveNet*[14], no još uvijek postoje poteškoće u kreiranju smislenog bogatog zvuka koji bi slušatelju zvučao prirodno. (*Van Den Oord et al.*, 2016) Kreiranje glazbe pomoću AI-a je još uvijek u svojim začecima i još postoje mnogi napredci koji se trebaju ostvariti kako bi se dostigla glazbena koherencija i dostigla prava umjetnička razina. Jedan od razloga je inherentna strukturalna kompleksnost komponiranja glazbe, te nemogućnost sakupljanja dovoljno glazbenih setova podataka za razliku od ogromnih količina dostupnih setova fotografija. Jedan od glavnih izazova je sakupljanje simboličkog seta podataka o glazbi što bi uključivalo segmentirane, tj. zasebno odvojene elemente neke kompozicije (npr. dionica bass gitare, bubnjeva, vokala…). Postoje inicijative poput *Lakh*[15] koje su pokrenule kreiranje baza podataka zvukova no limitirani su MIDI formatom koji nema toliku kvalitetu kao ostali napredniji audio formati. Uz *Lakh* postoji i *DSD100 multitrack dataset* no jako je malog volumena.

Kao što je navedeno, mogućnosti AI-a u kreiranju glazbe je potaknulo i mnoge entuzijaste i ostale van akademskih zajednica da se počnu baviti i istraživati mogućnosti. Jedan od najboljih primjera je već navedeni albuma ***Hello world*** francuskog izvođača ***SKYGGE*** koji se smatra prvim albumom gdje je sustav AI-a potpomogao kreatoru da kreira nove zvukove koje bi potom ukomponirao u glazbene cjeline. Na većoj instanci nailazimo na projekt Jukedeck[16] koji korisnicima nudi set alata da kreiraju personalizirani soundtreck. Cilj je ponuditi i kreirati nove kreativne alate dostupne glazbenicima, producentima i široj javnosti te ubrzati proces kreiranja glazbe, a pritom olakšati kreativni proces, i to kroz lako i jednostavno user friendly sučelje. Tim bi se dosada kompleksna forma kreiranja glazbe dovela u sferu šire javnosti a time i otvorio put široj konzumaciji. Jedan od takvih primjera je startup iz Londona *Mogees*[17] koji je kreirao hardwear-softwear sustav koji omogućava glazbenicima da bilo koji predmet pretvore u glazbeni instrument tako što na predmet pričvrste senzor koji preko sustava kreira određeni zvuk temeljen na vibracijama tog predmeta.

11 https://www.helloworldalbum.net/about-hello-world/

12 http://www.flow-machines.com/

13 https://www.youtube.com/watch?v=LSHZ_b05W7o

14 https://arxiv.org/abs/1609.03499

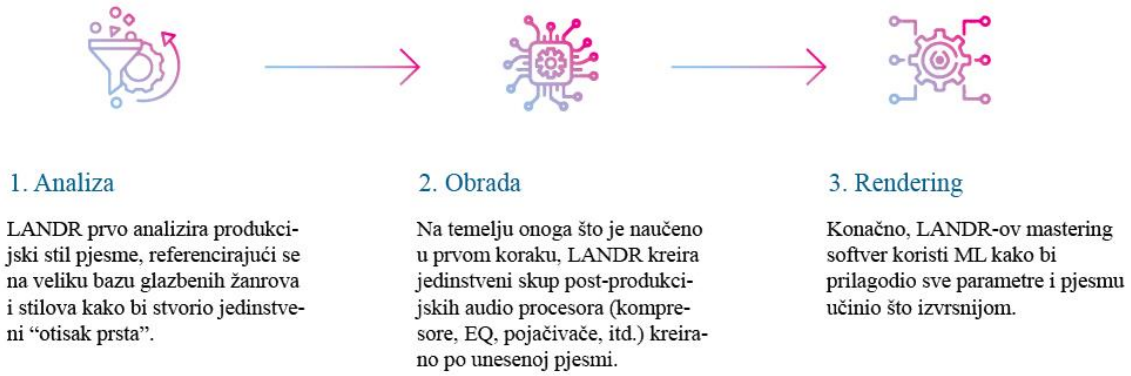
15 https://colinraffel.com/projects/lmd/

16 https://www.youtube.com/watch?v=adn8KEV7Ing

17 https://www.mogees.co.uk/

3.2.1.2 Produkcija (Production)

Glazbena produkcija je u procesu velikih transformacije u zbog korisnosti AI sustava. Danas se sve više glazbenika okreće samostalnom i neovisnom radu i izdavaštvu bez produkcijskih kuća i studija zbog sve dostupnije i jeftinije kvalitetne tehnologije za obradu zvuka. Kanadska start-up tvrtka *Landr*[18] je primjer koja je razvila kvalitetni sustav za masteriranje, produkciju i dijeljenje glazbenog sadržaja.



Slika 3.17. Prikaz funkcionalnosti i procesa LANDR sustava

Glazbena industrija je uvijek u potrazi za novim alatima i poboljšanju sadašnjih standardi posebice u pogledu kvalitete. Današnje streaming platforme i novi sustavi reprodukcije glazbe nude mnogo bolje standarde u pogledu kvalitete zvuka za razliku od standarda od prije 20 godina i više. Što u retrospekciji znači da su mnoga djela od kulturne važnosti snimana u lošim kvalitetama s puno šuma te su dostupni samo u mono reprodukciji. (*NEM., 2019*) Iz tih razloga novi sustavi s AI-om su se pokazali kao iznimno kvalitetni i obećavajući alati za prepravak starih glazbenih snimaka i prilagodbi za nove standarde reprodukcije. Jedna od vodećih nedavnih tehnologija u tom segmentu je već spomenuta tehnika dekomponiranja segmenata zvuka koja je omogućila audio inženjerima dosada nemoguću slobodu u uređivanju zvuka.

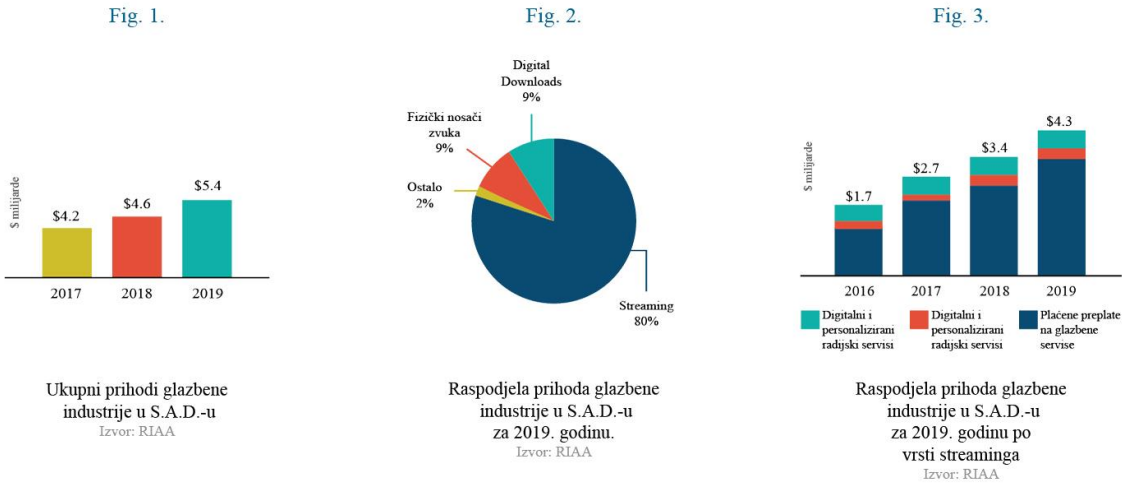
Osim ponovnog iskorištavanja zvukova i stvaranje zvučnih repozitorija glazbena industrija može imati velike koristi od AI-a u pogledu studijskog ili uživo snimanja. Veliki aspekt kreativnosti i dinamike se gubi prilikom odvojenog studijsko snimanja gdje glazbenici trebaju zasebno snimati svoje glazbene dionice kako bi se izbjeglo i reducirao odbijanje zvuka i jeke na snimci. Usklađeno studijsko snimanje, iako smanjuje problem nastanka jeke i interferencije zvukova, zahtjeva mnogo vremena i novaca. Kranji željeni cilj bi u ovom slučaju bio dovesti sustav da simultano prepoznaje i klasificira izvore zvukove od svih izvora, a pri tome da zadrži kvalitetu zvuka. Takva bi se sustav mogao primijeniti i na rekonstruiranju koncerta uzevši sve snimke s manje kvalitetnim senzorima zvuka, primjerice mikrofonima na mobilnim uređajima, kako bi se zadobila visokokvalitetna snimka koncerta.

18 https://www.landr.com/en/

Temeljna inovacija i istraživački izazov u kontekstu audio inženjeringa je spajanje AI i obrade signala. Dok se obrada signala uglavnom bavi manipulacijom audio uzorcima kako bi se iz njih izdvojio željeni signal, AI tehnologija sada omogućuje uzimanje signala jednostavno kao ulazne informacije koji pomoću već izučenih glazbenih i zvukovnih strukturalnih podataka mogu nadomjestiti izgubljene zvukovne segmente i ukloniti smetnje nastale snimanje. Ovakvi sustavi su tek začecima za razliku od sličnih sustava obrade fotografija[19].

3.2.1.3 Korištenje konzumacija (Consumption) i monetizacija

Digitalizacija i IoT su doveli mnoge promjene u načinu konzumaciji glazbe omogućivši korisniku pristup doslovce skoro svim glazbenih kompozicijama i sadržajima u samo nekoliko klikova. Na taj način se dodana vrijednost promocije i prodaje glazbenih zapisa preselila iz specijaliziranih glazbenih trgovina u sfere online sustava za preporuku glazbenih sadržaja. Iz tog razloga sustavi preporuka su postali osnovna djelatnost tvrtki koji imaju streaming platforme za audio sadržaja poput Spotify, Deezer, Apple, Amazon, i ostalih. Tehnički pristup shvaćanja i kreiranje glazbenih preporuka pomoću AI tehnologija proizašao je iz dokumentiranja i analiziranja velikih količina podataka o korisničkim navikama i njegovim sesijama tijekom korištenja aplikacije. Sustavi preporuka glazbe su područje velikih ulaganja i istraživanja posebice jer se radi o segmentu glazbene industrije čiji je udio u 2018. godini iznosio 75% (3.4 milijarde američkih dollara) ukupnog prihoda s više od 229 milijuna pretplatnika, (*Hernandez P.*, 2018)(*Washenko A.*, 2018) a 2019. godine trend se nastavio i brojke su se udvostručile. Ukupni prihodi porasli su za 18% na 5,4 milijarde dolara u maloprodaji u prvoj polovici 2019. Streaming glazbe čini 80% prihoda industrije. Na veleprodajnoj vrijednosti prihodi su porasli 16% na 3,5 milijardi USD[20]. Postoje još izazovi u usavršavanju ovakvih sustava. Osim tehničkih aspekata usavršavanja algoritama postoji problem usvajanja i otkivanja točnih personaliziranih korisničkih preferencija, pošto sam sustav nije dovoljno sofisticiran da bez involviranja korisnika odredi točne preferencije.



Slika 3.18. Ukupni prihodi i raspodjela izvora prihoda glazbene industrije u S.A.D-u prema podacima - *The Recording Industry Association of America*® (RIAA)
Izvor: http://www.riaa.com/wp-content/uploads/2019/09/Mid-Year-2019-RIAA-Music-Revenues-Report.pdf

19 https://dmitryulyanov.github.io/deep_image_prior

20 https://www.riaa.com/reports/2019-mid-year-music-industry-revenue-report-riaa/

Drugi važni aspekti glazbene industrije se odnose i na tehnologiju reproduciranja glazbe. Tradicionalni stereo sustavi su danas sveprisutni no vidimo sve veći broj pametnih sustava zvučnika i slušalica pogonjeni AI tehnologijom koji aktivno i pasivno uklanjaju šumove i određene zvukove, (*NEM.*, 2019) a s napretkom u tehnologiji dekomponiranja glazbe mogući su veliki napredci u polju segmentiranja zvukova gdje primjerice utišamo vokala za kreiranje instant karaoka ili izdvojimo određene zvukove za instant remiksiranje i kreiranje novih kompozicija.

Vidimo da postoji mnogi načini razvoja konzumiranja glazbenih sadržaja, a iz perspektive ASI-a mogli bi očekivati da se glazba producira specifično, u stvarnom vremenu, prilagođena korisnikovim preferencijama, emocijama i trenutnom psihofizičkom stanju kombinirajući setove glazbenih segmenata raznovrsnih djela ukomponirana u novo originalno autorsko djelo.

Može se očekivati pomak u segmentu glazbenog stvaralaštva gdje će se glazbena produkcija proširiti na kreiranje ne samo gotovih autorskih djela (pjesama, zvukova, segmenata) već i kreiranje specifičnih segmenata podataka kao dodatak za streaming platforme s uputama o glazbenim preferencijama. Tako bi jedan umjetnik nove generacije kreirao profil glazbenih preferencija i pravila za sustav preporuka glazbenih sadržaja koji bi korisnik mogao dodati svom profilu i setu preferencija.

3.2.2. Vizualna umjetnost

3.2.2.1 Kreiranje sadržaja (Creation)

AI sustav za kreiranje umjetnosti i foto realističnih fotografija je danas često tema prisutna u medijima prvenstveno zbog uspjeha sustava s DL metodama u produciranju i apliciranju raznih filtera i uspješnosti u kopiranju stilova i stilskih obilježja.

Prekretnica u istraživanjima AI za kreiranja umjetnosti je DeepDream[21] sustav (eng. *Computer vision program*) program računalnog vida kojeg je kreirao Google. (*Mordvintsev 2015*) DeepDream koristi Convolutional Neural Network[22] (CNN) za pronalaženje i pojačavanje uzoraka u slici pomoću *algoritma pareidolia*[23]. (*Algoritam nazvan prema psihološkom fenomenu kada ljudi različitim neživim predmetima na osnovu nasumičnih linija prepisuju ljudske karakteristike.*) Za ulaznu informaciju uzima fotografiju, koji potom modificira i što više izmjenjuje, kako bi aktivirao željene elemente neuronske mreže i producirao gotovo nestvarni halucinogen efekt u namjeri da kreira što "izobličenu" fotografiju. Iako Deep Dream zahtjeva sliku kao ulaznu informaciju i polazišnu točku, krajnji rezultat je toliko različit od originala da izaziva emocionalnu reakciju u gledatelju pa se čak može smatrati umjetničkom slikom.

21 https://deepdreamgenerator.com/

22 U dubokom učenju, konvolucionarna neuronska mreža (CNN ili ConvNet) je klasa dubokih neuronskih mreža, koja se najčešće primjenjuju u analizi vizualnih slika.

23 https://doorofperception.com/2015/10/google-deep-dream-inceptionism/



Slika 3.19. Proces Deep Dream na fotografiju
izvor: https://deepdreamgenerator.com/

DeepDream je originalno kreiran kao alat koji bi pomogao da se shvati kako neuronske mreže funkcioniraju i kako pojedini segmenti neuronskih mreža uče i donose zaključke, te kako rade klasifikaciju elemenata koje "percipiraju". To znači da umjesto određivanja i davanja uputa koje slojeve da program izmjeni i amplifira, dopustili su programu da sam odabire. U primjeru gdje je ulazna informacija fotografija, neuronska mreža detektira i odabire željeni sloj i segment fotografije koji će pritom apstrahirati. Svaki pojedinačni segment neuronske mreže "percipira" i obrađuje unose različito, zato ovisno o odabranom sloju i segmentu fotografije zadobijemo različite rezultate obrade. Obrađena fotografija prikazuje elemente koje na izvornoj fotografiji nisu do sada bili prisutni, ali ih je neuronska mreža percipirala te ih na tom segmentu implementirala i apstrahirala. (*Vidimo na slici 3.13. kako je neuronska mreža u pozadini fotografije prepoznala određene promjene u slojevima bojama te ih apstrahirala u oblike.*) Rezultati DeepDream-a su uvjetovani iskustvom neuronske mreže, što znači da rezultati ovise o prijašnjim unesenim informacijama, te će krajnji rezultat iste fotografije biti drugačiji prilikom različitih faza treniranja neuronske mreže.

Nakon objave rada "*Image Style Transfer Using Convolutional Neural Networks*"[24] 2016. godine na ECCV-u, pojavio se sve veći interes za istraživanjem apliciranja AI-a umjetničkim slikama. U radu je predložena metoda prijenosa stilskih obilježja sa jedne na drugu fotografiju, što je dovelo do velikog interesa u daljem istraživanju tog polja. Popularnost metode je najbolje vidljivo u aplikacijama poput *Prisme*[25], *Artisto*[26] i *Algorithmia*[27].

Gotovo svi postojeći generativni modeli bazirani su na "*Generative Adversarial Networks* (**GANs**)" modelu. (*Goodfellow et al, 2014*) Model se sastoji od generatora koji *generira* uzorke koristeći uniformnu distribuciju i *diskriminatora* koji razlikuje fotografije prema tome jesu li prave ili umjetno generirane. Originalno je model zamišljen da kreira slike specifičnih stvari, poput određenog broja, osobe ili predmeta, bazirano na fotografijama na kojima je sustav treniran. No **GAN** model danas je primijenjen i u mnogim drugim područjima primjene. Jedan od takvih područja i generiranje pastiša, tj. umjetničkih slika

24 https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/Gatys_Image_Style_Transfer_CVPR_2016_paper.pdf

25 https://prisma-ai.com/

26 https://artisto.my.com/

27 https://algorithmia.com/

koje imitiraju i posuđuju elemente drugih stilova. Prema autorima "*CAN: Creative Adversarial Networks Generating "Art" by Learning About Styles and Deviating from Style Norms"* bazirajući se na GAN model, autori su kreirali mrežni sustav "**deep-Net**" koji je uspješno naučio i klasificirao razne umjetničke stilove i stilske segmente mnogih umjetnika te je na osnovu kombinacija tih raznovrsnih stilova kreirao novo umjetničko djelo. (*Elgammal et al*., 2017)

Jedan od novih uzbudljivih područja istraživanja fokusiran je generiranja fotografija iz tekstualnih opisa prema istraživačkom radu "*Generating Images from Captions with Attention*" (Mansimov et al., 2016). Cilj ovakvih modela je kreiranju foto realističnih fotografija te umjetničkih slika. No generiranje visoko kvalitetnih foto realističnih fotografija je izuzetno teško jer iziskuje mnoštvo detalja. Zato je lako prepoznati umjetno generirane fotografije od pravih fotografija, no nedavna istraživanja provedena u nVidia (Slika 3.14.) tvrtki pokazala su značajni napredak u području kariranja foto realističnih fotografija visoke rezolucije. (*Karras at al*., 2018)



Slika 3.20. Prikaz generiranih foto realističnih fotografija ljudskih lica pomoću GAN modela neuronske mreže.
Izvor: https://futurism.com/incredibly-realistic-faces-generated-neural-network

Drugi pristup imaju autori rada "*Towards the Automatic Anime Characters Creation with Generative Adversarial Networks*" (*Jin et al*., 2017) koji žele pomoću sličnog modela bazirano na *DRAGAN SRResNet sustavu sličnom* GAN modelu automatizirati kreiranje anime likova kako bi reducirali utrošak vrijeme i novac za crtanje i animiranje.

3.2.2.2 Produkcija (Production)

U području vizualne umjetnosti produkcija se može razmatrati kroz razne instance. Možemo razmatrati produkciju u kontekstu fotografske montaže, gdje se manipuliranje elemenata postojećih fotografija i korištenjem filtera kreira nova fotografija, ili korištenju već postojećih fotografija u video montaži za kreiranje novih originalnih video zapisa. Vidimo da AI ima raznovrsnu primjenu u ovom polju te je uspješno apliciran u mnogim segmentima obrada fotografija i video zapisa. Primjerice rad "*Deep Bilateral Learning for Real-Time Image Enhancement*" (*Gharbi et al*., 2017) prikazuje pristup obrade koloriranja fotografija u stvarnom vremenu prema primjerima obrada iz baze podataka gdje je sustav treniran na mnoštvu primjera obrada od strane profesionalaca. Ovakav pristup, potpomognut

algoritmima baziranim na ML-u, omogućava korisnicima da štede vrijeme izbjegavajući iscrpan proces retuširanja i obrade fotografija koji osim vremena zahtjeva i napredno poznavanje alata za obradu. Ono što u navedenim pristupima nije uzeto u obzir je kontekst fotografije. No pristup prikazan u radu "*Automatic Photo Adjustment Using Deep Neural Networks"* koristi *DL* i posebno kreirane značajke koje uzimaju u obzir i kontekst fotografije pri kreiranju filtera za obradu fotografije. "(*Yan et al*., 2014)

Razvijene su i tehnike za primjenu DL-a za prilagodbu različitih umjetničkih stilova i stilskih figura na odabranu fotografiju, a da pritom ne izmjene kompletnu strukturu fotografije već očuvaju prepoznatljivost sadržaja izvorne fotografije. Na primjer, moguće je modificirati fotografiju da izgleda poput djelo umjetnika Miroa ili Muncha. (Slika 3.15) (*Gatys et al*., 2017)



Slika 3.21. Sustav algoritma - Neuronskog Stilskog Prijenosa (eng. *Neural Style Transfer*) , baziranog na sustavu DL i metode transfernog učenja koji je omogućava stilsku prilagodbu bilo koje fotografije s rezultatom visoke kvalitete i očuvanja izvorne strukture.
Izvor: http://bethgelab.org/research/machine_learning/style_transfer

Osim za kreiranje novih slika i fotografija, mogućnosti AI-a su iskorištene i za rekonstrukcija izgubljenih ili oštećenih dijelova slika i fotografija. Takav pristup je postavljen u djelu "*Semantic Image Inpainting with Deep Generative Models*" gdje su autori predstavili model koji je u mogućnosti prepoznati kontekst fotografije i njen sadržaj te pronaći i automatski zamijeniti oštećene ili nedostajuće dijelove. Primjerice ako na fotografiji nedostaje oko subjekta, neuronska mreža je u stanju prepoznati nedostatak i automatski generirati novo i postaviti ga na točno mjesto. (*Yeh et al.,* 2016)

Slični modeli AI-a korišteni su za povećanje rezolucija fotografija. U ovakvim modelima iskorištena je sposobnost neuronskih mreža da shvate kontekst i semantičke informacije fotografije, te je upotrijebljeno kako bi se povećalo rezoluciju nisko rezolucijske fotografije s očuvanjem kvalitete. (*Ledig et al*., 2016)

Kao što je već navedeno, za stvaranje novih sadržaja često je potrebna upotreba postojećih slika. Na primjer, slike se često koriste u reportažama, tijekom produkcije vijesti i slično, te u tim slučajevima, osim alata za uređivanje slika, potrebni su i alati za prepoznavanje i dohvaćanje slika relevantnih za potrebe proizvođača iz mogućih vrlo vjerojatno velikih baza. Dohvaćanje slike može se provoditi pomoću slika kao *upita* (eng. *query*) ili korištenjem tekstualnih upita koji opisuju željeni sadržaj slike. U prvom slučaju, koji se obično naziva

Sadržajno Pretraživanje Slika (eng. *Content-Based Image Retrieval* CBIR), potreban nam je način da usporedimo sliku upita sa slikama u bazi podataka i da odlučimo koje su najrelevantnije. U drugom slučaju, ili moramo slike povezati s tekstualnim opisima ili stvoriti vizualne značajke koje će se koristiti za usporedbu slika izravno iz tekstualnih upita.

Već nekoliko godina CBIR se obavljao oslanjajući se na ručno unesene karakteristike, dizajnirane prema ljudskim generiranim matematičkim opisima slikovnih sadržaja koji uspoređuju prema sličnostima da bi se zadobio relevantan rezultata slika u odnosnu na upitnu sliku. Nedavno je postignut značajan iskorak uvježbavanjem dubokih neuronskih mreža za kreiranje *vizualnih deskriptora* iz slike (nazvano *Deep Features*) koji pritom dodaju semantičke informacije u kod slike. U slučaju velikih jednakost deskriptora i slaganja semantičkih informacija povećava mogućnost željenog rezultatu. Vizualni deskriptori mogu se izdvojiti pomoću "*Deep Convolutional Neural Networks*", osposobljenim za izvođenje zadataka za prepoznavanju i aktivaciju neurona u unutarnjem sloju mreže kao deskriptora. To je, na primjer, predloženi pristup u djelu"*CNN Features off-the-shelf: an Astounding Baseline for Recognition*" gdje autori pokazuju da je izvedba superiorna drugim najmodernijim sustavima uz upotrebu Deep featurs (*Razavian et al,*. 2014)

Za dohvaćanje slika pomoću tekstualnih upita, potrebno je pridružiti tekstualne opise slike ili koristiti tehnike koje mogu generirati vizualne značajke iz tekstualnih upita. U oba slučaja, AI nudi značajna rješenja za ove probleme. AI se može koristiti za automatsku analizu sadržaja slika radi generiranja anotacija (*Amato et al*., 2017), dodjele naslova (*Mao et al.,* 2014), identificiranju objekta (*Redmon et al*., 2016), prepoznavanje lica (*Cao et al*., 2017), prepoznavanju odnosa objekata (*Santoro et al*., 2017). Podatak jednom generiran i izvučen može se povezati sa slikama i koristiti kao segment za pretraživanje .

S druge strane, unakrsne tehnike pretraživanja (eng. *Cross-media search*) mogu prevesti upite izražene u jednom mediju na upite za drugi medij oslanjajući se na tehnike AI-a. Na primjer, moguće je koristiti tekst za pretraživanje slika i obrnuto. U ovom slučaju, prednost je u tome što baza podataka slika koja je indeksirana na bazi vizualnih značajki, pomoću dubokih konvolucijskim neuronski mreža (eng. *Deep Convolutional Neural Networks* DCNN), se može tehnikom unakrsnih medija povezati s pojmovi i izrazi mogu prevedenim u vizualna obilježja, a pritom ne zahtijevajući ponovo reindeksiranje kompletne baza podataka. Samo treba zamijeniti alate za obradu upita. Ovaj smjer je prikazan u "*Generating High Level Visual Representations From Textual Descriptions"*, gdje je neuronska mreža obučena da generira vizualnog značajke u Deep Feturse značajkama izvađene iz fc6 i fc7 unutarnjih slojeva ImageNet-a, počevši od teksta upit. (*Carrara et al*., 2016)



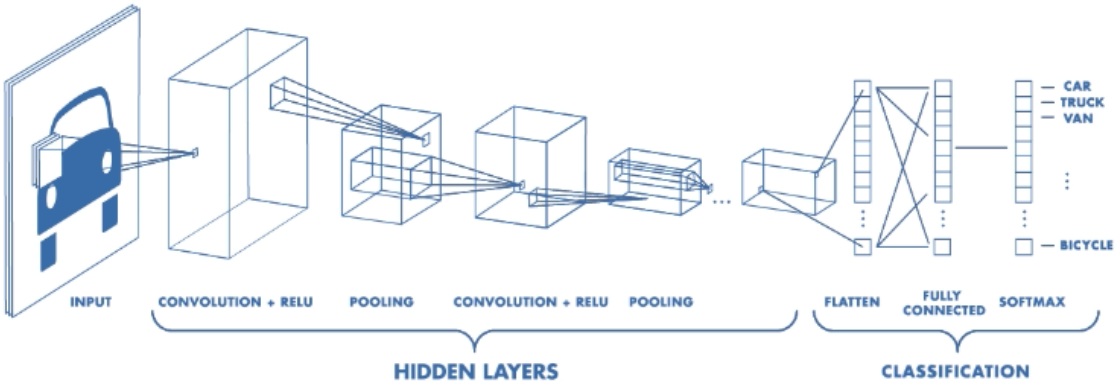
Slika 3.22. Primjeri rezultata pretraživanja triju metoda iz rada *Generating High Level Visual Representations From Textual Descriptions*
Izvor: https://arxiv.org/pdf/1606.07287.pdf

3.2.2.3 Korištenje konzumacija (Consumption) i monetizacija

Jedan od glavnih karakteristika za efektivno korištenje izvora digitalnih fotografija je mogućnost lakog pretraživanja i dohvaćanja željenih i relativnih sadržaja. Problem nastaje što većina baza fotografija nije dobro indeksirana, označena i opisana što čini pretraživanje i dohvaćanje željenih sadržaja iznimno teškim i mukotrpnim. To stvara veliki problem posebice profesionalcima u kreativnoj industriji u pronalaženju dobrih i specifičnih sadržaja, primjerice fotografije osobe koja drži određeni predmet u određenoj ruci na određeni način. Problem je u oslanjanju na sustav koji koristi metadata za opise digitalnog sadržaja koji ne garantira opisnu točnost.

Iz tih se razloga profesionalci iz kreativnih industrija oslanjaju na iskusne arhiviste koji poznaju materijale ili su prisiljeni uložiti velike napore u pretraživanjima i naknadnim obradama materijala. No zbog silne brzine i volumena kreiranja novih fotografija i medijskih sadržaja postaje skoro pa nemoguće dugoročno, efektivno i sistemsko klasificiranje svih podataka. Uzmimo za primjer novinsku produkciju. Svakodnevno primaju gomilu fotografija iz cijelog svijeta koje potom šalju agencijama u nadanju da će se iskoristi njihovi materijali za prikaz povezanih događanja. Vjerojatnost je da će se mali postotak tih audiovizualnih materijal biti iskorišteno te će ostati zakopani u arhivama neiskorišteni i postati gotovo nevidljiv zbog lošeg indeksiranja.

U tom pogledu AI nudi efektivna rješenja. AI sustavi - *Sadržajno Pretraživanje Slika* (eng. *Content-Based Image Retrieval* CBIR), kontekstualnog pretraživanje slika, pretraživanja semantičkih informacija, prepoznavanja lica i unakrsne tehnike pretraživanja su danas dostupne i omogućavaju laku i efektivnu pretragu. Tehnike DL-a bazirane na CNN-u pomoću računalnog vida (eng. *Computer vision*) danas nude najnaprednije načine rješavanja problema klasifikacije, (*Krizhevsky et al*., 2012) pronalaženje i prepoznavanje objekata. (*Donahue et al*., 2013) Konvolucionarne neuronske mreže (CNN) iskorištavaju računalnu snagu GPU-a za treniranje i učenje iz ogromnih skupova podataka.



Slika 3.23. Arhitektura CNN-a
Izvor: https://www.mathworks.com/videos/
introduction-to-deep-learning-what-are-convolutional-neural-networks--1489512765771.html

CNN sustav prikazan na slici iznad (slika 3.23) za razliku od običnih neuralni mreža objekte klasificira kroz tri dimenzije prostora (širina, visina, dubina) te je finalni rezultat komputacije CNN-a sveden na singularni vektor mogućeg rješenja. CNN se sadrži od dvije komponente: ***Skrivenih slojeva*** (eng. *Hidden layers*) i **Klasifikacijskog dijela** (eng. *Classification*).

- **Skriveni sloj**

  U ovom dijelu mreža izvršava niz preokreta (eng. *convolution + relu*) i operacija objedinjavanja (*pooling*) tijekom kojih se otkrivaju značajke unosa. Ako je unos slika zebre, ovo je dio na kojem bi mreža prepoznala njegove pruge, dva uha i četiri noge.

- **Klasifikacija**

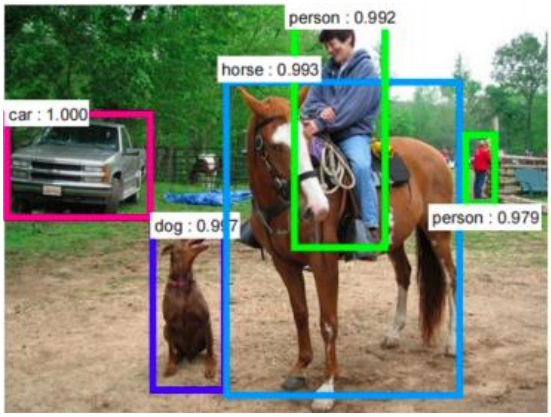
  Ovdje će potpuno povezani slojevi (eng. *fully connected*) služiti kao klasifikator na vrhu ovih izvučenih značajki. Oni će dodijeliti vjerojatnost da će objekt na slici biti ono što algoritam predviđa da jest.

Nedostatci ovakvog pristupa su to što većina velikih setova za treniranje ovakvog pristupa izgrađena za akademske svrhe (primjerice ImageNet baza podataka) i nije moguće efektivno je iskoristiti u ostalim okruženjima.

Algoritmi za prepoznavanje lica su također imali koristi od uvođenja pristupa dubokog učenja. Među njima je DeepFace (*Taigman et al.*, 2014), duboki CNN osposobljen za klasifikaciju lica pomoću skupa podataka od 4 milijuna slika lica koje pripadaju više od 4000 jedinstvenih identiteta. Nedavno je objavljen skup podataka VGGFace 2 (*Cao et al.*,2017) koji sadrži 2,31 milijuna slika 9131 subjekta. Na ovom skupu podataka obučena je ResNet-50 konvolucionarna neuronska mreža koja također može odrediti pozu i starost osoba.

Iako nove tehnike prikazuju obećavajuće rezultate postoje određene poteškoće prije nego što te metode uđu u domenu široke primjene. Primjerice generiranje fotografija na temelju opisa je još uvijek izazovno i teško iako su se pokazali značajni napredci. Ujedno, sustavi za kreiranje umjetnosti su još uvijek u začecima, a najveći napredak je zapravo u prijenosu stilskih segmenata na fotografije koji su se pokazali iznimno uspješnim te se očekuju mali napredci u segmentu stilskog prijenosa.

Veliki napredak je postignut u pogledu AI za prepoznavanja objekata, radnji, događanja i sl. na fotografijama ali cjelovito shvaćanje sadržaja fotografije je još uvijek ostaje kompleksan zadatak za AI.



Slika 3.24. Prepoznavanje sadržaja i objekata fotografije pomoću AI sustava pogonjeno CNN-om
Izvor: https://arxiv.org/pdf/1506.01497v3.pdf

Unakrsne metode pretraživanja (eng. *Cross-media search*) za pronalaženje fotografija sadržajno jednakim unesenom tekstualnom upitu (eng. *queries*), su pokazale iznimne napretke no vrlo je mala vjerojatnost široke primjene zbog tehničke strukture posebice u pogledu skalabilnosti sustava i semantičke ekspresivnosti.

Metode rekonstrukcije oštećenih ili izbrisanih dijelova fotografija su izvrsne u pogledu rekonstrukcije jednostavnih struktura poput lica, dok su rezultati za kompleksnije strukture poput pejzaža još uvijek nezadovoljavajuće i loše.

3.2.3. Content i naracija

Kreativna industrija se oslanja dobro kreirane narative i dobro skrojene priče posebice u područjima poput filmova, televizije, igrica, umjetnosti, medija i vijesti. Dobra priča jedan je od glavnih segmenata kreiranja iskustva, zato su nam potrebni dobro kreirani narativi pomoću kojih bi opisali i interpretirali svijet kojim smo okruženi. No sve više vidimo kako tradicionalni sveobuhvatni kanali gube na važnosti i svjedočimo rapidnom razvoju kompleksnih struktura kanala informacija, što dosadašnju strukturu linearne i statične naracije čini zastarjelom i neefektivnom u dohvaćanju suvremene publike. (*Nem* ,2019)

Digitalni narativi putem digitalnih kanala (eng. *Digital storytelling*) su postali glavni mediji kreativne industrije zbog mogućnosti kreiranja nelinearnih narativa na raznovrsnim

platformama. Cilj je kreirat imerzivne i interaktivne narative edukativnog, zabavnog ili samo oglasnog sadržaja za razne platforme i aplikacije. Interakcijom i imerzivnošću korisnika pomoću senzornih unosa (primjerice kontroliranjem segmenata oglasa, interaktivnim video sadržajima, heatmapa...) kreiraju se podaci koji se pritom analiziraju u svrhu generiranja što boljeg iskustva i poboljšanja korisničkog iskustva (UX) kako bi se unaprijedili sadržaji i postigle više razine afilijacije korisnika prema sadržaju.

Digital storytelling nije ograničen na jednu jedinstvenu pripovijest kao u tradicionalnoj strukturi priča, već nudi okvir za podršku razvoju niza glavnih i sporednih likova i detalja o njima u zasebnom kontekstu. Kreiraju se višestruke naracije, svaka zasebno kreirana za svoju platformu ili kanal strukturalno prilagođena toj određenoj publici, no sve nose zajedničku premisu i uklapaju se u jednu zajedničku smislenu veću priču.

U *digital storytelling-u* AI je već pronašao primjenu i sve više ide u smjeru da postane jedan od osnovnih alata. Primjer je suradnja Intela i Međunarodnog olimpijskog odbora gdje se tehnologija na bazi AI-a koristi za kreiranje interaktivnog iskustva sportskih igara tako što kombinira fotografije iz više perspektiva i izvora.[28] Kreiranje *digital storytellinga* na bazi informacija i podataka o korisnicima predstavlja područje u kojem AI i ML tehnologije nude raznovrsne mogućnosti, te poneka već sada gotova rješenja[29].

3.2.3.1 Kreiranje sadržaja (Creation)

Narativ za *digital storytelling* kao stvaralački proces započinje kao ideja koja da bi bila upotrebljiva, se mora moći transkribirati u oblik koji se na kraju može pretvoriti u digital format. Ovaj postupak zahtijeva trans disciplinarni skup vještina i alata. Kreiranje i produkcijski proces može zahtijevati uporabu raznovrsnih pristupa te čak uporabu elektronike, senzora, pokretača i alata u obliku hardvera i softvera. Da bi se finalni proizvod dostavio potrošačima, potrebno je ovisno o vrsti poslovanja, segmenta unutar kreativne industrije i formata u kojem će biti pušten, prvenstveno pozabaviti pitanjima poput finalne vizualizacije i korisničkih sučelja.

A uz sve veći porast i konstantni napredak dostupnog hardvera ukazuje na mnoge mogućnosti kreiranja novih načina interakcije s korisnikom. Sve veći porast popularnosti i dostupnosti pametnih mobilnih uređaja i VR tehnologija pokrenuo je trend kreiranja što boljeg interaktivnog sadržaja. No VR primjerice nije nova tehnologije. Neki segmenti VR kakvog danas poznajemo postoje još od prije 50 godina, kao primjerice VR kojeg je 1962. godine kreirao *Morton Heilig* pod imenom *The Sensorama* ili *Experience Theatre*[30]. Druge slične inicijative su skoro sve bazirane na dugo poznatom principu transmedijalnog narativnog prepričavanja (eng. transmedia storytelling). (*Jenkins,* 2006) AI tehnlogija, posebice ML, u linearnom storytellingu se već koristi za optimiziranje i efektivno korištenje podataka, na primjer za pretraživanje velikih arhiva ili poboljšanje postojećih narativa novim sadržajem na temelju *feedbacka*. Primjer korištenja je u nedavnom radu Američke svemirske agencije NASA i redatelja *Todd Douglas Millera* gdje su za potrebe snimanja dokumentarca *Apollo 11* [31] iskoristili privatne arhive 16,25,60 i 70 milimetarskih filmova i audio traka kako bi rekreirali slijetanje na mjesec za proslavu 50. godišnjice slijetanja.

28 https://www.olympic.org/sponsors/intel

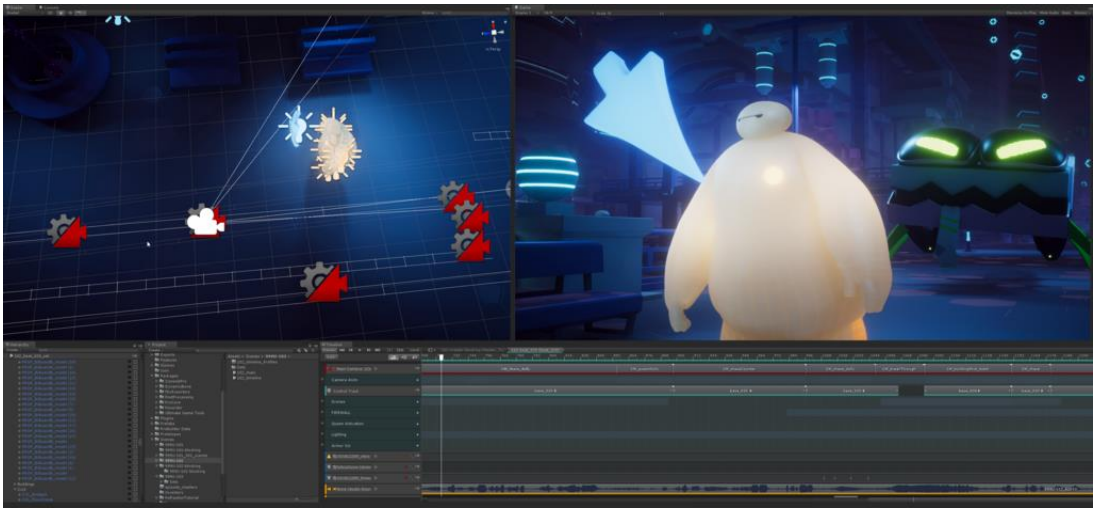
29 https://narrativescience.com/Products/Quill/

30 https://patents.google.com/patent/US3050870

31 https://www.rollingstone.com/movies/movie-features/making-the-mind-blowing-apollo-11-doc-802297/

Kod *digital storytellinga* koji koristi senzore za interakciju omogućava korisnicima interakciju sa sadržajem i pruža iskustvo vlastitog kreiranja puta kroz priču i narative. Takav pristup je poznat kao nelinearni *storytelling*. Pošto je cilj digital storytelling da što više uvuče korisnika u narative i kreira iskustveni doživljaj, korisno je imate tehnologiju baziranu na senzorima kako bi se korisnika što više uvuklo u srž narativ i aktiviralo što više osjetila, i time pružilo osjećaj kompletne uronjenosti u narativ i sadržaj.

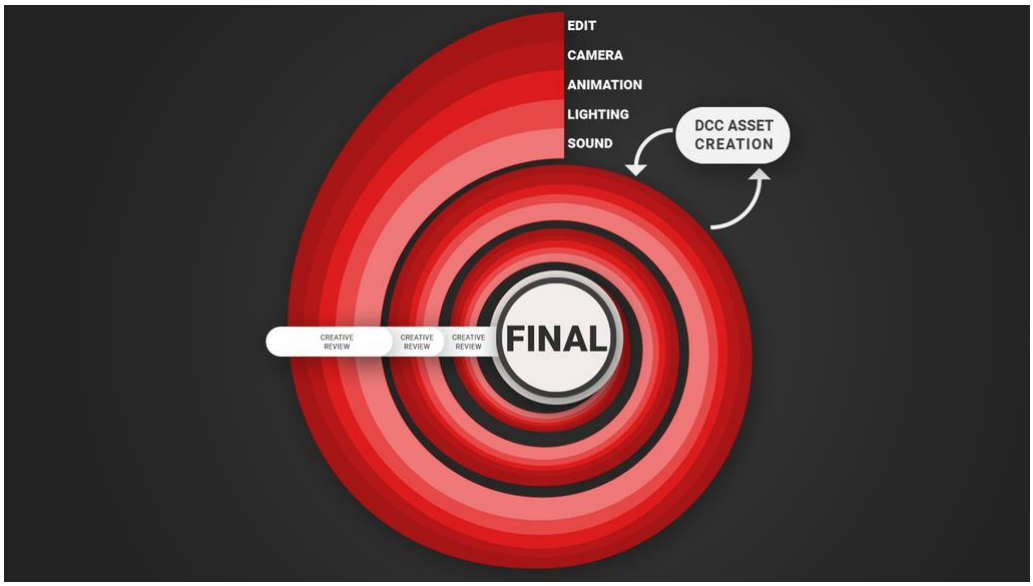
Nelinearni *storytelling* sam po svojoj definiciji služi za kreiranje opsežnijih narativa koji imaju mogućnost potpune personalizacije. No potpuno personalizirani pristup zahtjeva zasebno autorstvo za koje za sada ne postoje deducirani alati za generiranje zasebnih dijelova priče i narativa. Upravo zbog nedostatka dealata nelinearnog *storytellinga* radi se kompromis korisničkog iskustva i doživljaja, naspram uloženog vremena i radne snage potrebne za kreiranje "personalizacija" narativa. Dodavanjem senzora za kreiranje kompleksnosti *digital storytelling*, bez uspješnog kreiranja skalabilnih deduciranih alata za autorstvo, teško će doživjeti komercijalnu upotrebu. Upravo je AI u tom području pokazao iznimne mogućnosti i napredak pri kreiranju alata za ostvarivanje što boljeg interaktivnog i ekspresivnog storytellinga. (*Riedl et al., 2013*) Primjer primjene takvog alata je *Cinemachine* kreiran od strane *Unity* tvrtke zajedno sa *Cinecast* tvrtkom. *Cinemachine* i *cinecast* [32] je dinamički alat kamera za kreiranje i editiranje kinematografskih sekvenca iz različitih *gameplaya* igara u stvarnom vremenu.



Slika 3.25. Prikaz sučelja *Cinemachine* i korištennja postavka kamera unutar 3D animiranog prostora za kreiranje Disney-jevog Big Hero 6 nastavka.
Izvor: https://unity.com/madewith/baymax-dreams

Ovakvi alati su iznimno korisni posebice u *eSportu* gdje se koristi i do 5000 različitih kamera za kreiranje narativa *storytellinga*. Sustav AI-a editira unose gameplaya prema preferencijama i postavkama igrača te kreira narativ za gledatelje. Takav alat AI-a ima moguću primjenu i u kinematografiji, gdje se sadržaj kreiran u datom trenutku automatski preveden u simbolički vizualni podatak i obrađen. Takav alat bi spojio inače razdvojene procese produkcije i postprodukcije te bi proces kreiranja krajnjeg audiovizualnog djela pretvorio u iterativni singularni kružni proces za razliku od sadašnjeg sekvencijalnog ili eng. *waterfall* načina.

32 https://create.unity3d.com/cinecast



Slika 3.26. Procesa kreiranja audiovizualnog djela pomoću Cinemachine postaje iterativnim singularnim kružnim procesom za razliku od klasičnog sekvencijalnog procesa.
Izvor: https://unity.com/madewith/baymax-dreams

Takav alat bi svakako pronašao različite primjene kod stručnjaka i amatera. Stručnjaci bi iskoristi pojedine segmente i htjeli sami kreirati i specificirati određene elemente procesa i izgleda finalnog produkta, dok bi za većinu amaterskih produkcija zadovoljila opcija već postavljenih točnih specifikacija deducirana kreiranju određenih vrsta finalnih proizvoda prilagođena sadržaju. Što dovodi do zaključka da će teško biti kreirati jedan deducirani alat. Različiti korisnici će zahtijevati različite pristupe i različite zadane postavke, zato je jedan od sadašnjih izazova kreirati alat za nestručne korisnike za stvaranje interaktivnih narativa. (*Riedl et al.*, 2013)

Multimedijalni narativi su danas postali stalna praksa gdje vidimo odvojene i zaseban elemente priča iz zajedničkog narativa rasprostranjene po različitim platformama prilagođenih pristupa određenim publikama. Ovakva praksa je zaživjela zbog sve većeg razvoja i popularnosti distribucijskih platformi i kanala. Multimedijalni narativi su složene forme narativa koji zahtijevaju kompleksne procese distribucije i prilagodbe zbog sve većih kanala distribucije koji uključuju razne formate od zabavnih aplikacija, oglašavanja, marketinga i društvenih mreža. Teško je jednostavno odrediti i definirati koncept multimedijalnog *storytellinga* zato ga je potrebno razmatrati kroz njegove osnovne komponente produkcije, stvaralaštva i korištenja. Svaka komponenta nosi svoje određene vrijednosne aspekte međusobno isprepletene sa ostalim komponentama te ovisno o finalnom konceptu zahtijevaju različite pristupe radilo se o kreiranju narativa, interaktivnih igara, interaktivnih medijskih sadržaja i sl.

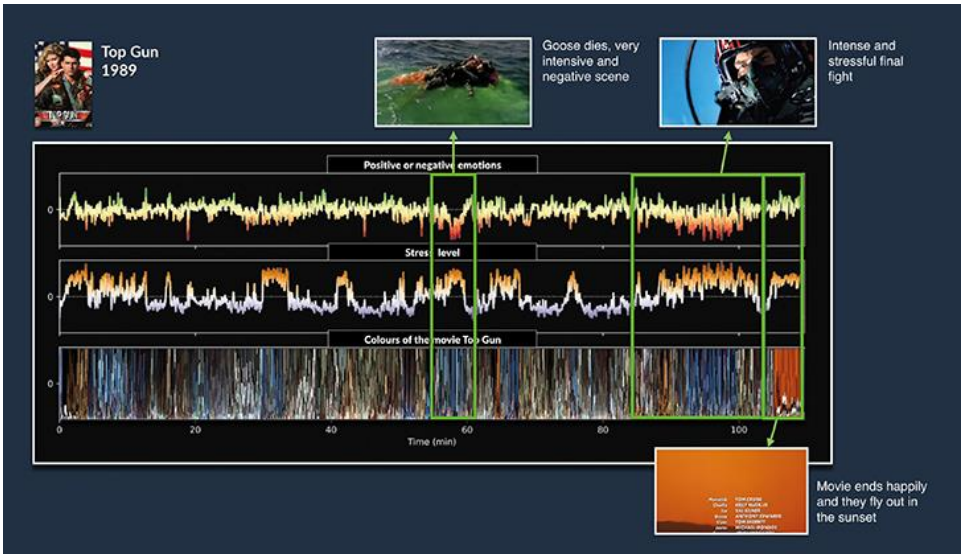
AI igra veliku ulogu u kreiranju i praćenju funkcionalnosti multimedijalnog *storytellinga,* posebice u spremanju i klasificiranju sadržaja i podataka kroz različite platforme. *Cincast* i *Cinemamachine* je primjer jednog takvog sustava.

3.2.3.2 Produkcija (Production)

Uporaba AI-a za kreiranje narativa i *storytellinga* će postati sve nužnija posebice u kreiranju multimodalnih interaktivnih i virtualnih iskustava. (*Cavazza et al,*. 2017) Za primjer, *Guerinni* u svom djelu "*Interactive film recombination"* predlaže interaktivnu filmsku dekonstrukciju koja koristi AI za planiranje i kreiranje raznovrsnih alternativa, baziranih na korisničkim unosima, kombinirajući video segmente prema semantičkim deskripcijama. (*Guerrini et al.,* 2017) U tom kontekstu tehnologija AI bi omogućila kreiranje "pametnih" zapleta i akcijskih segmenata kreiranih prema stablu strukturnih odluka kreiranih za narativ filma. Takva primjena bi otvorila razna područja primjerice u kreiranju likova i kreiranju njihovih karakteristika i osobina, oblikovanja ugođaja narativa na bazi audio vizualnog interpretacija.

3.2.3.3 Korištenje konzumacija (Consumption) i monetizacija

Kao primjer korištenja AI-a za kreiranje interaktivnog narativa možemo uzeti nedavno korištenje takvog sustava za kreiranje interaktivnog filma i interaktivnog oglašavanja. Naime, *Netflix* je kreirao film koji na bazi korisničkog unosa određuje daljnji tijek razvoja narativa filma prema već predodređenoj strukturalnoj formi.[33] Osim toga surađuje s tvrtkom Vionlabs[34] koja je izgradila AI sustav koji interpretira sadržaj i ugođaj filma na osnovu teorije boja, audio vizualnih segmenata i ljudskih senzornih informacija (emocionalne i biometričke informacije), za razliku od sadašnjih sustava baziranim na *metapodacima*, te generira set podataka za što bolju optimizaciju filmskih preporuka. Osim toga iskoristili su generirane podatke da zadaju AI sustavu zadatak kreiranja najave za filmove prema određenim setovima podataka. Rezultati su i više nego zadovoljavajući te su uspjeli istrenirati AI da prema glazbi određuje ugođaj najave. [35]



Slika 3.27. Prikaz *Vionlab-ovog* sustava ocjenjivanja sadržaj na temelju emocionalnog utjecaja na gledatelje za kreiranje boljeg sustava preporuka.
Izvor: https://feedmagazine.tv/future-shock/if-you-liked-that-youll-love-this/

33 https://variety.com/2018/digital/news/netflix-black-mirror-bandersnatch-interactive-1203096171/

34 https://vionlabs.com/

35 https://www.youtube.com/watch?v=3BssoseVLHw

Osim tog razmatra se i o korištenju AI tehnologija za automatsko implementiranje proizvoda u serijama (eng. product placemant)[36], automatizaciju generiranje reklamnih spotova[37] kompletno sa scenarijom i videom kao finalnim proizvodom. Posebnu primjenu vidimo i danas u dinamičkom optimiziranju oglasa koje pružaju platforme poput Google[38] i Facebooka[39]. Izvrstan primjer multimedijalne narativne strategije je kampanja Američkog lanca brze prehrane *Wendy's* koja je iskoristila popularnost igre *Fortnite* za kreiranje interaktivnog narativa.[40] Kampanja se pokazala iznimno uspješnom i smatra se izvrsnim primjerom korištenja *digital sotrytellinga* i kreiranja multimedijalnog narativa.

U ovom pogledu bi *AI ASI* dosega mogao bi kreirati istovremeno narative za sve razine uzimajući u obzir sve elemente platforme i pritom inkorporirati podatke o korisniku te na temelju njih graditi strukture odluka. Primjer bi bio kreiranje kompletne personifikacije brenda prisutnog na svim medijskim platformama kompletno personaliziranog pristupa pojedincima u realnom vremenu.

3.2.4. Content u gaming industriji, filmovima, tehničkim aspektima proizvodnje i dizajnu

3.2.4.1 Kreiranje sadržaja (Creation) i produkcija (Production)

Nekoliko industrija se bori s izazovima kreiranja velikih detaljnih modela prostora i oblika. Takvi modeli zahtijevaju iznimnu posvećenost kreiranju što geometrijski i izgledom točnijih objekta, a pritom pazeći da vizualni elementi poput oštrine, boje, teksture… budu što realističniji. Primjerice u industriji video igara pri kreiranju krajolika kojim se korisnik može slobodno kretati i istraživati, a da ujedno bude interaktivan i responzivan. Filmska industrija je suočena sa sličnim izazovima pri kreiranju virtualnih setova kako za animirane tako i za regularne filmove i serije. Pri kreiranju virtualnih okruženja potrebno je točno zadovoljiti određene kriterije u smislu estetike, pokretnosti i realnosti izgleda. U dizajnu i inženjerstvu, prilikom procesa osmišljavanja i modeliranja dijelova razmatraju se segmenti strukturalnih zahtjeva, funkcionalnosti i učinkovitošću, ograničenja izrade i estetika. A pomoću današnjih tehnologija trodimenzionalnog ispisa (eng. *additive manufacturing*) omogućavaju proizvodnju predmeta s detaljima veličine od desetine mikrona do pola metra.

Danas su zadaci kreiranja takvih sadržaja postali ekstremno zahtjevni za kreiranje pomoću standardnih alata za modeliranje (CAD/CAM softveri) čak i za najiskusnije profesionalce, prvenstveno zbog same veličine i detaljnosti zahtjeva za današnje potrebe. Potrebe kreiranja virtualni ambijenti u video igricama i filmovima se kreću od produciranja zgrada do kompletnih planeta. U inženjeringu, pronalaženje prave ravnoteže između oprečnih ciljeva često zahtijeva zamoran proces pokušaja i pogrešaka pri istraživanje mogućih dizajna. Pri pronalaženju rješenja postoje razna ograničenja koja treba razmotriti (pomicanje, strukturna vjerodostojnost, mehanički i strukturalni pomaci itd.) Ti postupci čine standardno modeliranje izuzetno teškim što dovodi da dizajner često mora prvo zamisliti kakvo može biti konačno rješenje, isprobati njegove nacrte i raditi iteracije i dorade i to pomoću skupih i vremenski zahtjevnih simulacija i kreiranja prototipa.

36 https://www.adweek.com/tv-video/is-virtual-product-placement-tvs-latest-disruptor/

37 https://adage.com/creativity/work/burger-king-ai-ad-whopper/950441

38 https://support.google.com/google-ads/answer/9023565?hl

39 https://www.facebook.com/business/ads/dynamic-ads

40 http://www.netimperative.com/2019/06/cannes-lions-winner-wendys-wins-social-top-prize-for-keeping-fortnite-fresh-campaign/

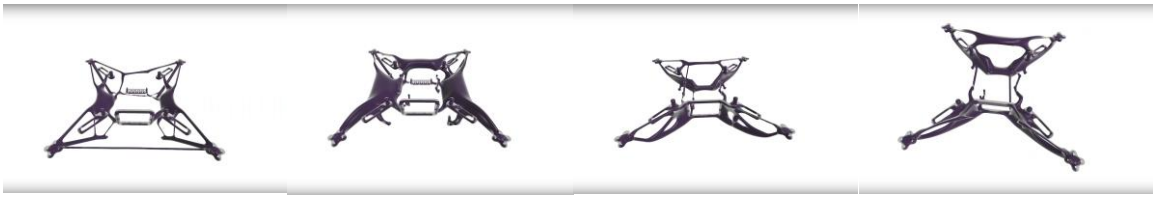
Kako bi riješili te probleme, polje istraživanja računalne grafike je razvilo mnoge solucije i koncepte za kreiranje sinteze sadržaja i tekstura (eng. *content and texture synthesis*). Tim metodama se pokušava automatizirati kreiranje sadržaja primjerice automatsko ispunjenjem dijelova (*Wei et al,.* 2009) ili objekata (*Majerowicz et al.,* 2013) s teksturama, automatsko generiranje detalja pejzaža (*Zhou et al.,* 2007)(*Cordonnier et al.,* 2017), automatsko generiranje vegetacija i gradova (*Prusinkiewicz et al.,* 1996)(*Parish et al.,* 2001)(*Vanegas et al.,* 2012), te generiranje planova zgrada i prostornih planova.(*Merrell,* 2007)(*Merrell et al.,* 2010)(*Ma et al.,*2014)

Primjena AI metoda u ovom kontekstu predstavlja značajnu napredak u simplificiranju procesa kreiranja sadržaja. *Content synthesis* metoda često rezultira neefektivnim rješenjima ili kreira kompleksan rezultat što nije rješenje kompleksnog zadatka generiranja sadržaja. Cilj je proizvesti raznolika rješenja iz kojih korisnik može odabrati (*Sims.,* 1991)(*Matusik et al.,* 2005)(*Talton et al.,* 2009)(*Lasram et al.,* 2012)(*Shugrina et al.,* 2015) Takvo rješenje je izuzetno važno za polja inženjeringa i dizajniranja gdje je generativni dizajn sve popularniji. Algoritam, u suradnji s unesenim preferencijama i modifikacijama korisnika, proizvede nekoliko tehnički validnih solucija dok korisnik odabire i sugerira estetske komponente. U industriji video igara takvi se algoritmi koriste za generira razina (eng. *levels*) igre na zahtjev i tako povećava šansu ponovnog igranja i ne repetitivnosti, smanjuje troškove u pogledu smanjenja utroška vremena i kreiranja sadržaja te smanjenja ukupne veličine podataka (Razina u ponekim igrama može zauzimati i do nekoliko gigabajta podataka).

Pri kreiranju primjerice video igre, mnogi elementi poput povezivanja s mrežom strukturalnih i geometrijskih zahtjeva mogu se formulirati objektivnim funkcijama, dok su estetski segmenti podložni subjektivnom i kulturalnom utjecaju. Upravo su u tim poljima subjektivnih preferencija AI modeli ML-a pogodni za razvoj automatizacije. Posebice metode *sinteze sadržaja po primjeru.* (*Wei,* 2009) Takve metode rezultiraju generiranjem estetski sličnog sadržaja prema zadanom primjeru imitirajući segmente boje, veličine, oblika, i ostalih geometrijskih osobina. U ovom području se ekstenzivno radi na učinkovitom iskorištavanju AI-a te istraživanjima i poboljšanju modela *GANs-a,*(*Gatsy et al.,* 2015) i postepeno se širi na sva područja sinteze sadržaja.(*Mitra et al.,* 2018)

U *additive manufacturingu* metoda sinteze sadržaja je značajno pridonijela u pogledu dizajna i strojarstva. (*Attene et al.,* 2018) Jedna od obećavajućih metoda redukcije težine je kreiranje detaljnih struktura unutar samog objekta što rezultira promjenom svojstva materijala. Tim su tehnikama kreirani digitalni materijali (eng. *metamaterials*), hibridni materijali (eng. *architectured materials*), a moguće je i kreiranjem metodom 4D tiskanja, a svoju primjenu su pronašli u zrakoplovnoj industriji, medicini (prostetika) i automobilskoj industriji. S obzirom na dosadašnje uspjehe vjerojatnost je da će u buduće inženjeri sve više koristiti ovakve tehnike za izradu visokokvalitetni dijelova. No još uvijek postoje prepreke u modeliranju ovakvih struktura i dijelova zbog kompleksnosti, detalja i razmjera veličina. Zato metode sinteze sadržaja bazirane na AI-u mogu pomoći u kreiranju ovakvih struktura. (*Primjer slike 3.17.)* S obzirom na to da takve strukture trebaju biti optimizirane prema određenim kompleksnim matematičkim zakonitostima (strukturalna čvrstoća, dinamika fluida, aerodinamika, apsorpcija vibracija), pri kreiranju su potrebne ekstenzivne i skupe simulacije koje su se do sada provodile tako da se testira jedan objekt koristeći računalne

clustere[41]. Ključ je iskoristiti potencijal AI-a i ML-a za fokusiranje računalne komputacije na samo određena potrebna područja.



Slika 3.28. AI sustav koji na temelju zadanih preferencija istražuje i modelira prijedloge šasije za dron.
https://www.ted.com/talks/maurice_conti_the_incredible_inventions_of_intuitive_ai

3.2.4.2 Korištenje konzumacija (Consumption) i monetizacija

Video igre su postale jedan od glavnih formi zabave i sve više dobivaju na snazi u kreativnoj industriji. Sada na tržištu, industrija video igara ima najveći udio zarade u sferi zabave prešavši filmsku i glazbenu industriju.[42] Sektor video igara koristi AI alate već desetljećima posebice za kreiranje likova ili protivnika. No nedavni uspjesi u sferama ML-a i velika dostupnost podataka otvorila je vrata kreiranju sve veće personalizacije iskustva igranja. Video igre prvenstveno imaju za cilj pružiti užitak, zadovoljstvo i sveukupno pozitivno korisničko iskustvo svojim igračima (što također može pridonijeti većoj prodaji i / ili većim pretplatama na igru).

Ključni element za zadovoljenjem igračeve potrebe za zabavom i dobrih iskustvom tijekom igranja je u održavanju stanja zanosa (eng. *Flow*). (*Chen,* 2007) *Flow* je psihološko stanje intenzivnog fokusa i uronjenosti u zadatak, tijekom kojeg osoba izgubi osjećaj za vrijeme, te odrađuju zadatak s kompletnim kapacitetom i predanošću, a pritom uživaju u izvršenju zadatka. Stanje *flowa* se ponajviše događa kada je osobi predstavljen izazov u razini njegovog znanja i vještina, tako čineći igru dovoljno izazovnom da nije prelagana i dosadna, niti preteška što bi igrača dovelo do stanja frustracije. No svaki igrač ima raznovrsne vještine i zahtijeva različiti sadržaj i različitu težinu igranja da bi potpuno uživao u igri. Da bi se ostvario maksimalan broj zadovoljnih igrača potrebno je kreirati personalizirane igrice čiji bi se sadržaj i težina automatski i dinamički adaptirao igračevim sposobnostima.

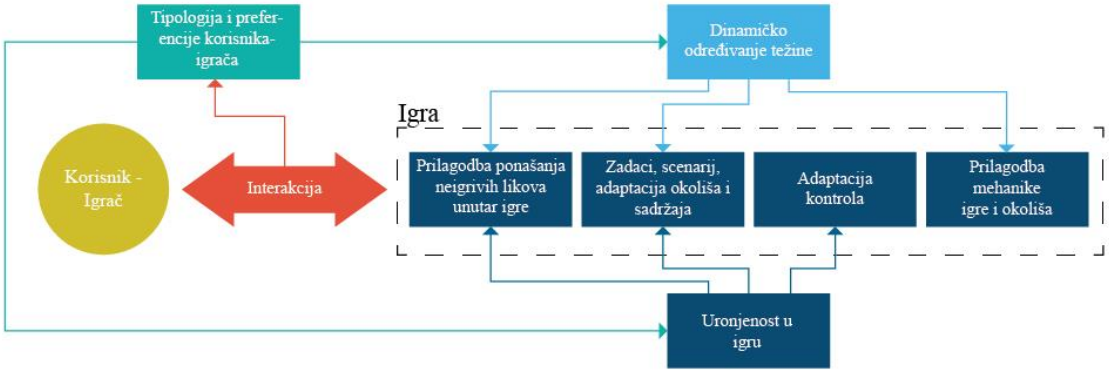
AI metode se mogu iskoristi za kreiranje takvih personaliziranih igara tako što bi kreirali tipološki *model* korisnika, dinamički adaptirali sadržaj baziran na *modelu* korisnika, (*Cowley 2016*) i pritom generirali neprekinuto stanje *flowa* i uživanja u igri.

Kako bi se igra prilagođavala igraču potrebno je da prepoznaje preferencije korisnika, a to bi se postiglo tako da se kreira *model* korisnika na osnovu dostupnih podataka. Korisne informacije za kreiranje takvog modela bi se sastojale od *korisničkih vještina*, *kognitivnog stanja* (koliko je sposoban držati koncentraciju), *konativnog stanja* (koliko je motiviran) i afektivnog stanju (koliko je frustriran ili sretan), te ponekim karakternim osobinama. Takvi podaci se mogli zadobiti ML-om (specifičnije *classification algorithmima*) analizirajući

41 Računalni cluster je skup usko povezanih računala koja rade zajedno tako da se mogu gledati kao jedno računalo.

42 https://fortunly.com/blog/video-game-industry-revenue/

podatke dostupne iz raznih sesija igranja. Prema ponašanju igrača tijekom igre mogu se zaključiti sposobnosti i vještine, te odrediti kognitivno stanje, a jednako tako mogu se zaključiti i po postignutim rezultatima korisnika u igri (*Herbrich et al., 2007*) (*Bishop, 2013*) prema jednostavno sustavu procjene baziranom na ML-u koristeći podatke s *Xbox live-a* ili sličnog sustava.[43] Razni podaci o kognitivnom i konativno stanju igrača se mogu procijeniti putem dobivenih fizioloških signala iz senzora ugrađenim u kontrolerima, igraćim uređajima, ili pametnih uređaja (pametnih satova ili slično). Na primjer, postoje prvi laboratorijski rezultati koji sugeriraju da bi se neka kognitivna stanja, kao što su opterećenje radom, ili neka afektivna stanja (npr. pozitivne ili negativne emocije), mogla prepoznati do nekih razina točnosti iz prilično uobičajenih fizioloških signala, primjerice iz snimke govora, praćenje pokreta očiju, izraza lica (iz fotografija ili videozapisa) (*Nacke et al.,* 2008) ili iz kompleksnijih kao što su mišićna aktivnost (elektromiografija - EMG), otkucaji srca, galvanski odgovor kože (GSR) (Cowley *et al.,* 2016) (*Drachen et al.,* 2010) (*Nacke,* 2013) ili čak iz moždanih signali poput elektroencefalografije (EEG) (*Frey et al.,* 2014)(*Frey et al.,* 2016)(*Mühl et al.,* 2014). Za sada se samo neka od tih stanja mogu procijeniti i to prilično nepouzdano i nespecifično. Suvremeni AI / ML sustavi obećavaju mogućnost očitavanja većeg raspon stanja (uključujući, na primjer, stanje *flowa*) i to na robustan način, kako bi se dobili bogati i pouzdani modeli igrača.



Slika 3.29. Shematski prikaz generičke strukture optimizacije flowa pomoću AI-a.
Izvor: https://doi.org/10.1016/j.entcom.2017.02.003

Nakon što se identificiraju i procijene različita stanja, vještine i osobine, AI se može upotrijebiti za modeliranje i procjenu utjecaja događaja u igrama, mehanike i / ili razine poteškoće za održavanja igračeva uživanja (što se odražava na procjenjivanje igračevi "afektivnih stanja). Takav sveobuhvatni model bi mogao predvidjeti kako će se igrač ponašati i percipirati igru ovisno o igračevom stanju i vještinama te o kontekstu igre. Jednom kada se dobije ovako robustan model igrača, različiti AI alati mogli bi se koristiti za dinamično prilagođavanje igre. Takvi AI alati bi mogli, na primjer, prilagoditi poteškoću igre, promijeniti ili izmijeniti priču ili scenarij igre, kreirati razne događaje da potaknu različite emocije ili pružiti novo iskustvo igračima. Na primjer, gore definirani modeli igrača mogu se upotrijebiti za predviđanje mogućih utjecaja različitih odabranih akcija i prilagoditi igru prikladnim akcijama za maksimiziranje *flowa* i uživanja u igri. Neki su autori nedavno predložili da se alati za strojno učenje poput sustava preporuka mogu koristiti za odabir

43 Xbox Live je online multiplayer gamin i medijska platforma u vlasništvu kompanije Microsoft.

akcija koje imaju pozitivan utjecaj na igračko iskustvo, temeljeno na akcijama koje je korisnik birao u prošlosti. (Tondelloet al., 2017)

Ovakvi sustavi imaju i široku primjenu u kreiranju "ozbiljnih" igara, to jest igara edukacijskog sadržaja. Području istraživanja Inteligentnih sustava učenja (eng. *Intelligent Tutoring Systems*), koristi slične sustave modeliranja i adaptivnih AI alata za kreiranje personaliziranih sustava učenja. No ovakvi modeli dovode u pitanje ključne etičke i moralne dileme. Modeli koji za cilj imaju održavati korisnika u konstantnom stanju *flowa* i uživanja u igri mogu dovesti do stanja ovisnosti korisnika. *World Health Organization* je odnedavno klasificirao ovisnost o igrama kao bolest[44], smatra se da je potrebno u AI alate implementirati sustave i algoritme koji za cilj imaju održavanje moralnih aspekata sustava (eng. *ethics by design*). (*Dignum et al.,* 2018)

3.2.4.2.1 Analiza primjenjivosti i tehnički izazovi

- Sintetizacija velikih okoliša ostaje izazov, unatoč značajnom napretku u specifičnim domenama. Konkretno, velika okruženja su heterogena i zahtijevaju različite vrste sadržaj - zgrade, teksture, elemente prirode - koji grupirani trebaju izgledati što prirodnije i realnije te imati organizacijsku strukturu. Trenutno nam nedostaje algoritmi i metodologije koje bi omogućile međusobnu interakciju različitih modela.

- AI pristupi često zahtijevaju velike skupove ulaznih podataka kako bi se postavilo sučelje algoritam strojnog učenja. Međutim, također bi trebalo razviti metode koje mogu djelovati iz manjih unosa koji je kreirao dizajner ili inženjer sa specifičnim naumom onog što želi postići algoritmom.

- Dostupni formalizmi često rezultiraju stohastičkim procesima uzimanja nasumičnih primjera iz modela baziranog na sadržaju. Ovakvim modelima se ne može lako integrirati ograničenja, kao što su mogućnosti proizvodnje, povezivanje, kompatibilnost i strukturni zahtjevi. Trenutno još uvijek je potrebno izvršavanje manualnog odbacivanja (Shugrina et al., 2015) ili progresivno usavršavanje tijekom istraživanja predvođeno korisnikom (Umetani et al., 2015). Iako opisane metode kreiraju učinkovita rješenja, zahtijevaju vremena i ljudske inpute, te izazov ostaje definirati metodologije koje mogu same implementirati instance i automatski proizvesti gotove i optimizirane solucije.

- Metode sinteze sadržaja često se smatraju čisto automatskim, stohastičkim procesima, iako većina aplikacija zahtijeva oblik suradnje s dizajnerom. To obično zahtijeva metode koje mogu komunicirati s korisnikom, uz brzi vremenski odziv, isključujući korištenje skupih simulacija u petlji. Slično tome, potrebne su nam metode koje korisnicima mogu pomoći u odabiru i navigaciji raznih mogućnosti, od kojih svaka nudi različite kompromise uz provođenje određenih ograničenja.

- Potrebno je razviti nove metodologije za analizu rezultata sinteze sadržaja, posebno u pogledu izračuna prosjek i odstupanje u određenih svojstava. Točnost je presudna

[44] https://www.who.int/features/qa/gaming-disorder/en/

u pogledu proizvodnji sitnih funkcionalnih dijelova u strojarstvu.

- Kreiranje robusnog alata ML-a za procjenu stanja korisnika (kognitivni, konativni i afektivna stanja) pouzdano, iz njihovog ponašanja i fizioloških signala, koji djeluje u stvarnom vremenu dok korisnik igra, gledanja film ili koristi obrazovni softver.

- Sustav AI-a koji prepoznajte što se može prilagoditi u igrama i filmovima i kako, te predložite sljedeće radnje u cilju povećanja *flowa* i drugih željenih mentalnih stanja tijekom igre.

- Proširiti i prilagoditi AI alate koji se koriste da za kreiranje pozitivnog korisničko iskustvo u igri na obrazovni sektora, kako bi se favoriziralo učinkovito učenje, npr. na ozbiljne igre ili drugo softver za digitalno učenje.

- Formirati i razvijati " *ethics by design*" u AI alatima za generiranje boljeg *flowa* i ostalih pozitivni elemenata korisničkog iskustva, kako bi se spriječila ovisnost.

3.2.5. Informacije i mediji

3.2.5.1 Produkcija (Production), korištenje / konzumacija (Consumption) i monetizacija

Sektor izdavalaštva se s velikim interesom uključilo u razvoju sustava AI-a koji koriste ML baziran na učenje s postavljenim pravilima, te istraživanja potencijalnih aplikabilnosti, poput korištenja *logical reasoninga* za shvaćanja sadržaja web stranica. Dva moguća područja uporabe AI u izdavalaštva, prvenstveno izdavalaštvu knjiga, je korištenje AI-a za poboljšanje učinkovitosti procesa izadavalštva (uključujući razvoj proizvoda usmjereno prema kreiranju sadržajno boljeg proizvoda bolje prilagođenog targetiranoj publici), ili za kreiranje dostupnijih formata i olakšanju pristupa izdanom sadržaju.

Kreiranje dostupnih formata i olakšanje pristupa se ne odnosi samo na generiranje virtualnih asistenata za čitanje za pomoć osobama s vidnim poteškoćama, već i automatizaciju procesa kreiranja raznih formata publikacije. Time bi se omogućila ravnopravnost dostupnosti kvalitete sadržaja za sve korisnike. Kako bi se omogućilo potpuno ravnopravno iskustvo potrebno je omogućiti i interpretaciju fotografija i slika unutar sadržaja. AI ima značajnu moguću primjenu, a nedavno ostvareni napredci u pogledu smislene interpretacije sadržaja konteksta i sadržaja fotografije (vidjeti poglavlje 3.2.2.2. *Deep fetures*) omogućavaju da se ostvari potpuno iskustvo interpretacije fotografije, a pritom ne oslanjajući se na šture i kratke opise fotografija i slika. Osim u adaptiranju novih publikacija ML ima i primjenu u translatiranju već postojećih djela u dostupnije formate.

Navedeni pristupi prepoznavanja sadržaja mogu pomoći i u segmentu upravljanja i zaštiti autorskih prava. AI tehnologije za prepoznavanja tekstualnog i vizualnog sadržaja bi mogla pomoći u pronalaženju o nedopuštenog korištenja zaštićenih autorskih sadržaja i spriječiti daljnje korištenje ili obavijestiti autore o zloporabi njihovog vlasništva na. Kombiniranjem

AI sustava i *Blockchain*[45] tehnologije omogućilo bi kreiranje inteligentnih *agenata* koji bi pretraživali sadržaj web-a i pri pronalasku nelicenciranog zaštićenog autorskog djela blokirali prikaz sadržaja i zatražili mikro transakciju. Tim bi se putem zaštitila autorska djela, onemogućilo ilegalno kopiranje sadržaja i povećala vjerodostojnost izvora informacija.

Osim u području izdavalaštva i autorstva AI ima primjenu i poboljšanje korisničkog iskustva, posebice u pogledu poboljšanja pronalaženja i kreiranja preporuka knjiga. Cilj takvih sustava je kreiranje boljeg shvaćanje sadržaja i formiranje boljeg sustava preporuka naslova korisniku, na temelju njegovih preferencija. Koncepti se mogu bazirati na sličnim sustavima preporuka poput sustava preporuka glazbe (poglavlje 3.2.1.3.), ili sustava preporuka medijskih sadržaja (poglavlje 3.2.3.3.). Dosadašnji pristupi se baziraju na modelu generiranja velikih količina podataka o prodaji i popularnosti nekih djela, ali takvi modeli su se pokazali neefikasnim i nedovoljno dobrima upravo zbog ne shvaćanja radnji i konteksta knjiga i ne uzimajući u obzir ljudski faktor preferencija. Novi pristupi se više fokusiraju na shvaćanju sadržaja i aspekti poput žarna, likova, napetosti radnje i ostalih, te na temelju tih segmenata kreiraju preporuke. Takvi sustavi preporuka će zasigurno igrati veliku ulogu u budućem razvoju *e-prodaje* književnih djela, posebice ako se uzme u obzir da su društvene mreže postali jedni od najvećih platformi za izmjenu i preporuke književnih djela, time postajući digitalni ekvivalent marketinga usmene predaje.

3.2.5.1.1 Analiza primjenjivosti i tehnički izazovi :

- Procijeniti koji su sustavi aplikativni i koji će poslovanje učiniti učinkovitijim i / ili pomoći u razvoju boljeg proizvoda – te razmotriti ekonomsku mogućnost implementiranja takvog sustava.

- Uvidjeti kolika je stvarna mogućnost apliciranja AI sustava prije ulaganja u kreiranja odjela razvoja AI-a ili preuzimanja gotovih besplatnih rješenja (API-a) i izgradnja sustava bazirano na njima.

- Definiranje prava intelektualnog vlasništva odnosno na ulazne i izlaz podatke za treniranja AI sustava.

- Općenito gledano, tekstovi i podaci "gorivo" su svake AI aplikacije. Što se AI-a tiče ono se smatra obećavajućim područje za razvoj budućeg poslovanje i društvenog napretka, što kontrolu "goriva" robota čini važnom političkom materijom hoće li se stvoriti potreba za standardizacijom jezika robotskog kodiranja i čitanja, kako bi se izbjeglo namjerno patentiranje i onemogućavanje metoda kodiranja i kreiranja sustav?

3.2.6. Društvene mreže

Društvene mreže, kojima uglavnom dominiraju velike tvrtke iz SAD-a, poput *Googlea, Twittera, Instagrama* ili *Facebooka*, postali su važan kanal za informacije i zabavu,

45 https://blockgeeks.com/guides/what-is-blockchain-technology/

prenoseći ogromne količine osobnih podataka koje se mogu koristiti kao *proxy*[46] za proučavanje i nadzor ljudi i njihovih mišljenja o određenoj temi ili proizvodu. AI tehnologija je već izmijenila način indeksiranja, pretraživanja i korištenja sadržaja na društvenim mrežama, s ključnom tehnologijom poput prepoznavanja predmeta, lica ili radnje u slikama i videozapisima, otkrivanja entiteta u tekstovima ili izrade mišljenja i karakterizacije (navedeno u prijašnjim poglavljima). Visoko raspodijeljeni sustavi preporuka koji koriste profiliranje korisnika danas su od presudne važnosti za društvene mreže, uključujući i za postavljanje oglasa. Osim analize sadržaja generiranog od strane korisnika za svrhu indeksiranja i pretraživanja, nadgledanjem sadržaja i korisnika na društvenim mrežama mogu se zadobiti vrijedne informacije i znanja o određenim zajednicama, njihovom ponašanju i mišljenju, društvenim trendovi i slično.

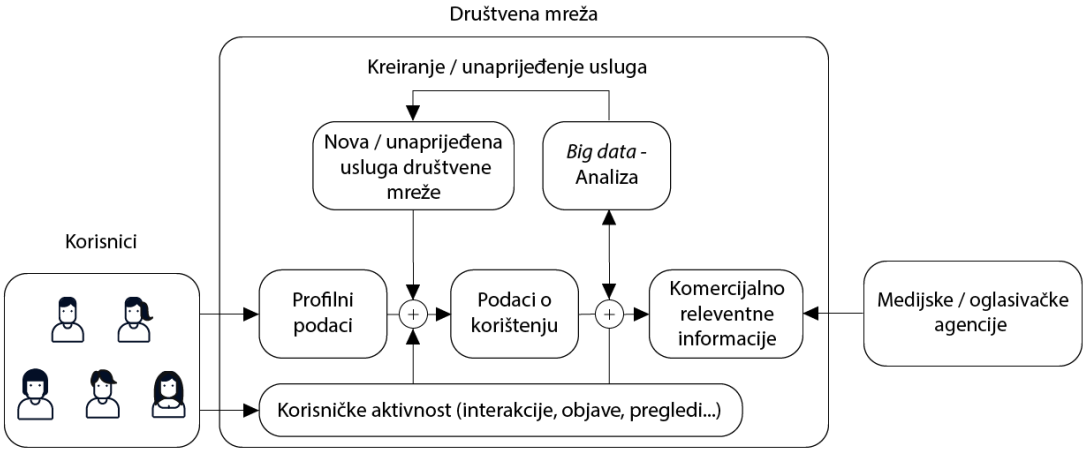
3.2.6.1 Produkcija (Production), korištenje / konzumacija (Consumption) i monetizacija

Big data- prikupljanje podataka i analiza platformi društvenih mreža imaju direktna utjecaj na moderno društvo i sve više mijenjaju način života i interakciju ljudi s ostatkom svijeta. Društvene mreže su uspjele privući sve veći broj korisnika pružanjem usluga i mogućnosti na bazi poslovnog modela koji se od strane korisnika doživljava kao "besplatan". Pridruživanjem na društvenu mrežu korisnici zadobivaju pristup zajednici koja dijeli informacije, sadržaj i emocije te priliku da uvijek budu povezani s osobnim kontaktima, bez obzira na fizičku udaljenost. Ali zauzvrat, od korisnika se traži da pruže sljedeće stvari:

- Osobne podatke (Ime i prezime, dob, mjesto rođenja, mjesto prebivanja…)
- Korisnika se navodi na interakciju sa sadržajem (objavom fotografija, označavanjem drugih korisnika, dijeljenje sadržaja sa zajednicom, komentiranje…)
- Pravo na prikupljanje, pohranu i obradu svih korisničkih podataka u različite svrhe.

Platforme društvenih mreža, putem prikupljanja i analize velikih podataka, mogu izvući preferencije i ponašanje svojih korisnika i pritom te podatke koristiti za generiranje zarade prodajući podataka trećim strankama (eng. *Third party*), poput reklamnih agencija koje na temelju tih podataka učinkovito kreiraju ciljane marketinške kampanje. Osim prodaje, korisničke podatke koriste i za ažuriranje i optimizaciju postojećih usluga i kreiranje novih.

46 Posrednički poslužitelji, najčešće se koriste za posluživanje web stranica, tj. uporabu Interneta. U ovom je slučaju iskorišten kao termin za sredstvo posredovanja poslužitelja podataka.



Slika 3.30. Poslovni model društvenih mreža utemeljen na prikupljanju i analiziranju velikih podataka.

Takav se model pokazao izuzetno uspješnim i korisnim svima uključenim u "lancu". Rast broja korisnika i stupnja angažiranosti na društvenim platformama naglo raste u posljednjim godinama, dovodeći do prosječne dnevne uporabe društvenih medija oko 135 minuta.[47] Očekuje se da će taj broj još više rasti zbog sve većeg broj korisnika koji se pridružuju zajednicama. Osim broja korisnika na pojedinačnim platformama raste i broj platformi zahvaljujući sve ekonomično pristupačnijim pametnim telefonima i širokopojasnoj mreži.

Kako bi se maksimizirao angažman korisnika društvene mreže kontinuirano poboljšavaju svoje platforme i šire svoje usluge, a na taj način povećavaju kanale zarade i povećavaju interes oglašivačkih agencija. S ciljem pokrivanja što više aspekata životnog stila korisnika i stvaranja usluga koje pružaju ne samo komunikacijske, informacijske i zabavne kanale, nude i rješenja potreba korisnika, poput kupovine dobara i usluga, te izvršavanja financijskih transakcija.

Platforme društvenih mreža također (bilo zbog internih razloga poboljšanja usluga ili zbog zahtjeva i pritiska izvana[48]) istražuju načine da postanu pouzdani subjekti za pristupa vijestima i informacijama. Facebook je, primjerice, proveo inicijative za označavanje potencijalnog lažnih vijesti (eng. *Fake new*s).[49]

Društvene mreže su odigrale i veliku ulogu u promjeni paradigme izdavalaštva i digitalizacije medija. Digitalizacija je značajno transformirala lanac izdavačke vrijednosti, uvodeći znatne mogućnosti disintermedijacije i uklonivši aspekte reintegracije, jer digitalne tehnologije uklanjaju određena ograničenja fizičkog svijeta, a novi igrači preuzimaju neke od novih funkcija. Iako je potencijal transformacije očit, digitalni prijelaz ne eliminira ili čak u potpunosti ne subverzira bitne uloge vrijednosnog lanca: npr. pisanje i objavljivanje knjiga kao jedan od istaknutih primjera. Za izdavače novi proizvodni procesi podrazumijevaju mnoštvo zadataka, posebice povezanih s proizvodnjom e-knjiga i upravljanjem metapodacima, kao i širokim rasponom inovacija proizvoda (uglavnom usmjerenih na digitalno unapređenje objašnjeno u poglavlju 3.2.5.1.), usluga i poslovnih modela.

47 https://ourworldindata.org/grapher/daily-hours-spent-with-digital-media-per-adult-user

48 https://www.theguardian.com/world/2019/oct/29/europe-accuses-facebook-of-being-slow-to-remove-fake-accounts

49 https://about.fb.com/news/2016/12/news-feed-fyi-addressing-hoaxes-and-fake-news/

Društvene mreže važan su element evoluirajućeg okvira alternativnih kanala izdavačkog marketinga i prodaje, omogućavaju uspostavljanje izravne veze s čitateljima, uspostavljanje dijaloga te naglašavanje i podizanje ugleda izdavačke kuće među kupcima. Društvene mreže također mogu postati alat za inovaciju u proizvodnji knjiga, jer mogu biti sredstvo za uključivanje čitatelja u kreativni proces (Primjer korištenja AI za ove procese je naveden u poglavlju 3.2.5.1.). Pojavilo se i nekoliko društvenih platformi posvećenim knjigama, pričama i čitanju, poput Medium[50] i Flipboard[51], koji razvijaju zajednice s zajedničkim interesima i postepeno postaju instrumenti za kreiranje knjiga i autora.

Fenomen društvenih mreža rezultat je evolucije mega trendovskog sadržaja kojeg je stvorio korisnik i time pokrenuo revoluciju u kreativnoj industriji. Danas u isto vrijeme korisnici postaju akteri i medijatori interaktivnog zajedničkog scenarija putem digitalnih platformi. Danas je ta realnost sve veće vidljiva posebice na Facebooku, Instagramu, pa čak i platformi za upoznavanje poput Tinder-a. Uglavnom digitalni urođenici (eng. *Digital natives*), ali sve više i digitalni pridošlice (eng. *Digital imigrants*) takve medije koriste alternativno i kumulativno s postojećim medijima, ali njihov se fokus značajno pomaknuo: *Pojedinačno ljudsko postojanje stapa se na neviđen način s medijaliziranim svijetom*. Stvarnost je medijalizirana, mediji su postali stvarnost, a sredstvo medija porukom. U estetskom kapitalizmu simbolički atributi postaju od ekonomske vrijednosti, a potraga za slavom u virtualnoj zajednici postaje sve važnija. U ovom okruženju kreativna ekonomija sve više postaje značajan element dodatne vrijednosti. (*Adzic et al*., 2017) Možemo prepoznati dva mega trenda:

• S jedne strane, jasno vidimo sve veću želju za autentičnošću i "stvarnosti" (stvarnosti u kontekstu kreiranje što realističnijih iskustava). Postoji mogućnost da nakon mobilnog kao najmlađeg sektor kreativne ekonomije, sektor 3D ispisa postane novi snažni sektor kreativne ekonomije. Također, tehnologije poput AR i VR - obično precijenjene u prošlosti - mogle bi igrati skromnu ulogu. Spoj stvarnog života i doprinos pojedinca zajedničkom "teatru", kao što je to već danas moguće u Minecraftu (gdje pojedinac kreira strukture i scenarije dostupne sudjelovanju i ostalim igračima), sve će više određivati kreiranje javnogmišljenja i ponašanja. Takva komunikacija i intermedijalnost upogonjena AI tehnologijom (kao što je navedeno u poglavlju 3.2.3.). Utjecaj društvenih mreža na ljudsko ponašanje puno je dublje i značajnije od bilo koje druge medijske revolucije do sada. Korisnik prelazi iz pasivne potrošnje u interaktivnu ulogu. Razvijanje zajednica grupiranih oko zajedničkih mišljenja i interesa te skulpturiranje njihovog mnijenja samo po sebi je moderirano i teško, ali je pojačano kroz vrlo personalizirano oglašavanje i marketing utjecaja (eng. *influencer marketing)*. Sve veće prilagođavanje i personaliziranje oglašavanja, i veći napredak tehnologija AI-a, omogućava razvoj poslovnih modela koji potiču kreiranje društvenih mreža kako bi pokrili sve aspekte ljudskih života i generirali što bolje i točnije preglede korisničkih navika.

• S druge strane možemo prepoznati sve veći porast suprotnog trenda : Korisnici sve više čeznu za dubljim i značajnijim narativima. Taj trend je sve više vidljiv po sadržaju *streaming* platformi (Netflix, Amazon Prime itd.), a djelomično i na sadržajima televizijskih postaja (kao što je navedeno u poglavlju 3.2.3.). Ta čežnja za dubljim značenjem u pričama je prirodna i implicitna reakcija na mrežni pristup generirana između stvarnosti i medijalne stvarnosti, (*Adzic et al*., 2017) te stvara sve veći stupanj opuštenosti i sigurnosti u okruženju

50 https://medium.com/

51 https://flipboard.com/

neizvjesnosti. Stoga bi bilo pogrešno gledati korisničku stvarnost na društvenim medijima kao jedini mega trend; istodobno, postoji i novi oblik pripovijedanja (eng. Storytelling), koji tek počinje i koji se neće svesti samo na televizijske serije. Narativni dizajn dobiva sve više na značaju i to kroz sve segmente kreativnih medija.

4. Socioekonomski i tehnološki izazovi

U prethodnom je poglavlju postavljen pregled mogućih primjena i aplikativnih područja AI i *big data* tehnologija u medijima i kreativnoj industriji. Za svako polje primjene identificiran je niz specifičnih tehnološko / znanstvenih izazova za pojedinačno područje primjene. Na temelju priloženih možemo identificirati da postoje određeni generički, neovisne o području apliciranja, tehnološki izazovi. No osim tehnoloških izazova, postoje i moralno etički izazovi, posebice ako govorimo u primjeni u kreativna industrija gdje se proizvode kreiraju za širu javnost. Iz toga razloga potrebno je sagledati moguće implikacije AI tehnologija u pogledu socioekonomskim i tehnološkim polemika.

4.1. Tehnološki izazovi

4.1.1. Data

Mnoge suvremene AI tehnike, a posebno *Deep Learning*, da bi se kalibrirali zahtijevaju ogromnu količinu podataka za treniranje kako bi se mogli prepoznati obrasci unutar podataka na temelju kojih bi se donijele odluke i predviđanja. Opći je izazov pribaviti i izgraditi velike baze podataka relevantnih podacima i unosima za svako područje primjene. Štoviše, takvi podaci moraju biti točno označeni i čitljivi pošto mnoge najnovije metode AI-a zahtijevaju nadzor i kalibraciju. To predstavlja poseban izazov za kreativnu industriju pošto obrasci koje treba detektirati i analizirati su preferencije korisnika s raznih aplikacija i platformi (kakav sadržaj glazbe ili videa preferiraju, filmove koje gledaju u kinu, kakve vijesti ili sadržaje video igara vole, postavke formata prikaza itd.). Takve postavke korisnici rijetko izričito pružaju, niti ih se tako lako može generirati na jednom sučelju. Generički izazov je zadobiti takve preferencije iz ponašanja korisnika (povijest izbora, vrijeme konzumiranja itd.) ili raznih drugih neizravnih mjera korisnika, poput različitih fizioloških signala. Konačno, pribavljanje i klasificiranje velikih količina podataka iz raznih medijskih izvora izazov je samo po sebi. Iako su neke tehnike AI koji nisu nadzirane i regulirane ili su slabo regulirane počele raditi na malim količinama podataka te postepeno ih strukturalno nadograđivati, još uvijek je izazov dizajnirati AI alate koji mogu raditi na primjerice 20 opisanih ili neopisanih podataka.

4.1.2. Robusnost i doseg

U medijima i kreativnoj industriji većinsko korištenje AI alati je za prepoznavanje uzoraka, na primjer za prepoznavanje govora, slika, zvukova, stilova ili mentalnih stanja korisnika. Iako su nedavni alati za DL uvelike poboljšali točnost prepoznavanja pojedinih medijskih zapisa, posebno slika, video zapisa ili govora, trenutačna točnost izvedbe tih alata nije zadovoljavajuća za navedene formate, te još uvijek zahtijevaju znatna poboljšanja za ostale formate. Stoga je potrebno osmisliti AI alate koji mogu snažnije i pouzdanije prepoznati uzorke u podacima, čak i kada su ti podaci sa smetnjama ili nisu jasno čitljiva, što je slučaj s mnogim podacima u sektoru kreativne industrije. Takvi alati bi trebali također biti stabilni i generirati rezultate čak i uz nedostatne podatke.

4.1.3. Doseg i limitacije

Moderni AI alati pokazali su se posebno učinkovitima u mnogim domenama za analizu različitih podataka i medija. Međutim, većina njih radi vrlo dobro samo za vrlo specifičnu domenu, samo s vrlo specifičnom vrstom podataka. Stoga postoji potreba za razvijanje metoda koje bi omogućuju da se AI alati razvijeni za određene domene povežu. Takvi AI alati bi bili u mogućnosti istovremeno indeksirati i shvatiti podatke iz više izvora (eng. *cross-modality*) , na primjer, teksta, slika ili govora. To se posebno može pokazati korisnom za analizu ili sintetizaciju vijesti - čiji se sadržaj može predstaviti u različitim modalitetima, ili za omogućavanje pristupačnosti sadržaja, na primjer, prevođenjem ili preoblikovanjem u govoru, tekstu ili znakovni jezik. Slično tome, *cross-modality* bi mogao omogućiti obavljanje pretraživanja medija i sadržaja iz različitih izvora, npr., pretraživanje slika iz opisa teksta ili govora. Metode s više domena mogu se koristiti i za provođenje analize s više razina, npr. radom na više vremenskih skala za analizu glazbenog stila ili radom na više prostornih razmjera za analizu ili sintetizaciju velikih stvarnih ili virtualnih okruženja. Konačno, metode s više domena mogu omogućiti učinkovitiji prijenos stila (npr. prijenos glazbenog stila ili prijenos stila slike), čak i s nerealnim sadržajem, npr., ne-fotorealističkim slikama ili bojom tona.

4.1.4. Proaktivna odgovornost (Accountability)

Nedavne metode DL u postigle su različite uspjehe u zadacima kao što su prepoznavanje govora, slika, pjesama itd. No, također se zna da su takve metode prilično nejasne u pogledu kriterija koji se koriste za predviđanje i donošenje odluka. Točnost izvedbe je jedino realno mjerilo uspjeha ovih metoda, ali u posljednje vrijeme dobar dio istraživanja počeo je raditi i na njihovoj proaktivnoj odgovornosti što bi trebao biti iznimno važan faktor u medijima i kreativnoj industriji. U ovom kontekstu se ne govori u preuzimanju odgovornosti zbog neke negativne posljedice već o odgovornosti koja je nenametnuta i koja je poduzeta svjesno i odgovorno te proaktivno u pogledu donošenja moralne odluke i držanja do vrijednosti i standardi.

4.1.5. Etičnost po dizajnu

AI alati mogu generirati i izučiti mnoge informacije o ponašanju, sklonostima i potrebama korisnika. Jednako tako mogu i utjecati na ponašanje korisnika. Stoga postoji hitna potreba da se razmotre etičke dileme takvih sustava i postave jasne smjernice etičkog dizajna. S tehnološkog / znanstvenog stajališta, to znači da je se javlja težak izazov stvaranje algoritama i alata za etično oblikovanje, koji bi osigurali poštivanje etički načela. To znači da namjena alata i algoritama treba transparentno i odgovorno označiti kako bi se spriječila zloporaba.

4.2. Socioekonomski izazovi

Nove disruptivne tehnologije doista stvaraju nove etičke i regulatorne izazove. Ovi su aspekti dobro razmotreni u nekoliko dokumenata, poput izvještaja Villani i drugih "*AI za čovječanstvo*"[52]. Slično tome, Opća uredba o zaštiti podataka (*GDPR*) prvenstveno ima za cilj pružanje kontrole građanima i stanovnicima nad njihovim osobnim podacima i pojednostavljenje propisa. Potrebno je uvidjeti važnost i utjecaj AI na socioekonomske aspekte i odrediti jasne smjernice i postaviti regulacije.

4.2.1. GDPR

Opća uredba o zaštiti podataka (*GDPR*) (EU) 2016/679 uredba je Europske unije kojom se regulira zaštita podataka i privatnost osoba unutar Europske unije, a donosi i propise vezane za iznošenje podataka u treće zemlje. Glavni su ciljevi GDPR-a vratiti građanima nadzor nad njihovim osobnim podacima i pojednostaviti regulatorno okruženje za međunarodne korporacije ujednačavanjem propisa u cijeloj Uniji.[53]

Kada se govori o pravilima umjetne inteligencije (AI), teško je istovremeno ne govoriti o GDPR-u. To je zato što je GDPR imao najviše utjecaja od bilo kojeg zakona na globalnoj razini u smislu stvaranja regulacije tržišta podataka - dok su podaci ključni sastojak sustava AI-a. Svakako, GDPR-a u pogledu korištenja AI-a pokreće intrigantna pitanja vezana uz političke dileme. U kreiranju politika EU-a, AI i strojno učenje postavljeni su kao direktni ciljevi gdje Europa želi biti vodeća sila u usvajanju AI-ja. No srž rasprave o AI-u i potencijalni novi propisi spadaju pod područjem GDPR-a.[54]

AI djeluje analizirajući velike skupove prethodno označenih podataka i donoseći informirane odluke iz tih podataka. Stoga, kako bi organizacije mogle iskoristiti potencijal AI-a , one moraju osigurati da tehnologija AI ili softver koji koriste imaju pristup što većem broju čistih podataka. Uvođenje GDPR-a znači da sada postoje ograničenja u korištenju informacija od strane korporacija za treniranje i razvoj svojih sustava. Uvođenjem takve regulative u slučajima AI-a dovelo je do poteškoća i zastoja u implementaciji i daljnjem razvoju. Na primjer, bilo je slučajeva da su organizacije morale izbrisati ogromne baze podataka o kontaktima iz CRM sustava zbog toga što nisu prikupile suglasnost ili dokaze o prethodnoj aktivnosti i legitimnom interesu da bi zadovoljile članak 6. GDPR-a, ograničavajući njihovu sposobnost primjene AI tehnologije na njihovi podacima u CRM-u. U tom pogledu, ne pati samo industrija AI-a, već i pojedine organizacije jer to znači da ne uspijevaju ne samo realizirati korist od AI-a, već i ne uspijevaju iskoristiti istinski potencijal za ostvarivanje prihoda od svojih CRM sustava.

Iako se čini kao problem, gledajući dugoročno GDPR može zapravo poslužiti u korist AI-a i tehnološke industrije. GDPR i ostali propisi o privatnosti koji au na snazi širom svijeta pružaju okvir za način na koji tvrtke trebaju postupati s osobnim podacima i štititi privatnost korisnika. Takve regulative potiču programere da stave privatnost na prvo mjesto i ugrade standarde privatnosti u svoje proizvode od samog početka. GDPR također pruža model izvršenja za organizacije koje u prvi plan stavljaju privatnost, u koju se AI može uspješno

52 https://www.aiforhumanity.fr/pdfs/9782111457089_Rapport_Villani_accessible.pdf

53 https://hr.wikipedia.org/wiki/Op%C4%87a_uredba_o_za%C5%A1titi_podataka

54 https://www.sas.com/en_us/insights/articles/data-management/gdpr-and-ai--friends--foes-or-something-in-between-.html#/

integrirati. Osim kreiranje većih standarda sigurnosti GDPR odredba će pomoći i u strukturiranju boljih i jasnijih podataka. (Rogynskyy, 2019)

4.2.2. Automatizacija

AI se često vidi kao učinkovit način za "automatizaciju" sve složenijih zadataka. Međutim, ako se AI sagleda kao netransparentni autonomni sustav onda uviđamo da to dovodi do ogromne pristranosti. Prvo, prekriva se tko donosi odluke i kreira oslobađanje od proaktivne odgovornosti. Ako AI dizajnira nečije *feedove* vijesti, kreira preporuke pjesama prema preferencijama korisnika, tada tvrtka ili grupa ljudi, kreira netransparentno profit. To daleko nadilazi oglašavanje i nužnost transparentnog i etičnost oglašavanja. Drugo, neki aspekti moći imaju tendenciju da budu zadani onima koji imaju moć nad podacima i algoritmima, npr. u obrazovanju, gdje tvrtke koje grade obrazovne digitalne resurse odlučuju na mnogo dublji način o knjigama te osmišljavanju nastavnog plana i programa. Što se tiče medija, to može imati dramatični utjecaj u pogledu slobode izražavanja. Netransparentni autonomni sustavi otežavaju razumijevanje njegova rada ljudima, a razumijevanje funkcionalnosti tih sustava omogućava nam da shvatimo da to nije neka vrsta "magije" te da nema vlastitu volju, te da konstruiramo prikaz onoga što se s tim može učiniti ili ne može. Što se tiče pogleda informatike i razumijevanja informatičkih sustava, potrebno je sad sve više kloniti se pogrešne ideje da ne trebamo razumjeti kako stvari funkcioniraju, nego ga jednostavno poslušno koristiti. To se također odnosi na AI i glavni je cilj popularizacije znanosti je obrazovati i proizvoditi resurse o tim temama da bi se, osim razvoja informatičkog razmišljanja (uključujući i razvijanje kreativnosti, a ne samo korištenja alata kao što je to do sada bio slučaj) razvije i kritičkog mišljenja. (*Adzic et al*., 2017) Ne smijemo biti ni tehnofob ni tehnofili, već tehnokritičari.

4.2.3. Vlasništvo (autorska prava)

Kako se tehnologija razvija i mijenja mnoga područja svakodnevnog života, ona također dovodi do novih rasprava među pravnim stručnjacima o potrebi promjene postojećeg zakonodavstva. AI stvara i omogućava niz situacija koje zahtijevaju preispitivanje prethodnih propisa poput onih o intelektualno vlasništvo posebice zbog složenosti i inovativne prirode i višestrukih funkcija. Brojni zakoni zahtijevaju da fizička osoba bude navedena kao autor izuma, dok tvrtka može podnijeti prijavu patenta predočivši licencu ili ugovor o ustupanju potpisan s izumiteljem, neživi subjekt ne može biti prepoznat kao tvorac izuma.

Pitanje autorskih prava AI-a zadobila je sve veću javnu popularnost nakon što su dva profesora sa Sveučilišta u *Surreyu* u Velikoj Britaniji pokušavali imenovati AI sustav izumiteljem u dvije prijave patenta.[55] Sustav nazvan *Dabus* razvio je ideje kroz ML i izumio je dva potencijalna nova patenta. *Dabus* se razlikuje od uobičajenih AI sustava po tome što ne pomaže ljudima u njihovim aktivnostima, već obavlja intelektualnu aktivnost kreiranja inovacija i izuma. Pokušaj profesora važan je s obzirom na trenutni tehnološki scenarij. Međutim, slučaj još nije dobilo odobrenje pošto vlasti smatraju da je tehnologija alat koji ljudi koriste u kreativnim procesima. Još uvijek se smatra da je potreban doprinos čovjeka u

55 https://futurism.com/scientists-ai-inventor-patent

procesu razvoja izuma da bi se opravdao naziv izumitelj. AI je već postigao točku u kojoj ima dovoljno autonomije za stvaranje pjesama, slika i knjiga bez dodatnog doprinosa svojih programera, što je potaknulo raspravu na polju autorskih prava u vezi s autorskim pitanjima. Što se tiče izuma koji podliježu patentnoj zaštiti, vjerojatno je da će se to suočiti s istom neizvjesnošću, jer AI sustavi razvijaju nove izume za patentiranje bez ikakvog doprinosa svojih tvorca. Neki znanstvenici tvrde da je uključivanje izumitelja AI-a u prijavu patenta pokušalo riješiti situaciju i omogućiti zaštitu i koristi dobivene od izuma stvorenog ovom tehnologijom. Međutim, čini se da to nije adekvatno rješenje za ovo pitanje u pogledu određenih zakonodavstava. Zbog visoke razine autonomije AI sustava, dodavanje stvaratelja u postupak patenta kao jednog od izumitelja ne bi bilo točno jer oni možda nisu pridonijeli stvarnom izumu. Ova strategija izbjegavanja javnih domena izuma AI prihvaća pretjerano široko razumijevanje onoga što karakterizira izumitelja i ne može se opravdati trenutnim zakonom o intelektualnim pravima. Rasprava o autorstvu AI stvara dodatne, složene i neizbježne rasprave i kršenja u daljnjim pravnim poljima. (*Caneiro et al.*, 2019) Zakonodavstvo još uvijek ima polemike oko kreiranje zakona i formiranja pravnih okvira u pogledu autorstva i AI-a, a evidentno je da je nužno potrebna legislativa vezano za izume kreirane AI-em i autorskim pravima sustava AI-a.

4.2.4. Pristupačnost (Accessibility)

Kao što je opisano u poglavlju 3.2.5.1 AI alati bi se mogli pokazati vrlo učinkovitim u omogućavanju pristupa mediju svima, na primjer, automatskim generiranjem prijevoda teksta ili govora ili automatskim generiranjem podnaslovom ili znakovnog jezika. To pokazuje potrebu za stalnim naglaskom na dostupnosti medijskih sadržaja te naglaskom na obrazovanju. Standardizacija i zakonodavstvo utemeljeno na zdravim akademskim i industrijskim istraživanjima i uključivanjem svih članova u lanca vrijednosti, ne isključujući korisnike. Drugi izazov pristupačnosti gdje AI može imati važan utjecaj je u pogledu migracija i migranata. Migracije bi trebale biti gledano kroz perspektivu promicanje višestrukog znanja (o onima koji se usele i o njihovim znanjima), o kulturološkim razlikama i ekonomskim stranama. Mnoge migranti koji dolaze u strane zemlje mogu postati pokretačima gospodarski rast. AI alati mogu podržati, na primjer, prevoditeljske alate u stvarnom vremenu s ciljem osnaživanja ljudskog kontakta. Migranti moraju biti povezani s jezikom zemlje, ali i s njihovim jezikom. Osim gore navedenih prevodilačkih alata, mediji (posebno javni servisi) mogu poslužiti kao platforma za širenje obrazovanja i znanja za sve uključujući migrante i lokalno stanovništvo. Kreatori sadržaja, kreativci i pripovjedače mogli bi se "ohrabriti" da stvaraju sadržaj povezan s imigrantima izvan dosadašnjih vijesti i izvještaja koja se temelje na hitnim ili nesretnim slučajevima.

Zaključak

Kreativna industrija i mediji su medijatori ljudskog mijenja i mišljenja kroz procese prikupljanja podataka te adaptiranja sadržaja prikladno preferencijama korisnika s ciljem monetizacije i kreiranja profita. Upravo zbog takve paradigme industrije pažnja, uronjenost u sadržaj i angažman (eng. engagement) korisnika postaju nova valuta kreativne ekonomije. Kako bi se profitiralo i monetiziralo takve podatke potrebni su alati koji su u mogućnosti u realnom vremenu obrađivati raznovrsne skupine podatke i kreirati jasne i čitljive rezultate. U tom pogledu se AI tehnologija zajedno s Big data sustavima pokazala kao prikladnim alatima s obećavajućim rezultatima. Iako je AI kao znanost relativno mlada grana svoje primjene je danas pronašla u mnogim sferama, posebice zbog sve većeg napredak IT industrije i globalne povezanosti što omogućava brz i efikasan prijenos podataka u realnom vremenu, u Kreativnoj industriji je postala svojevrsni *buzzword* te je često krivo predstavljena kao svemoćni alat koji će kompletno promijeniti paradigmu industrije.
Ipak, unatoč tolikoj popularnosti, AI je i dalje mnogim nejasan gotovo futuristički koncept zbog svoje kompleksnosti i rapidnog razvoja polja istraživanja. Iako često predstavljen kao monolitni pojma AI je zapravo krovni naziv za kompleksnu sferu znanosti koja posjeduje mnoge podznanosti, a spada pod kategoriju informatičke znanosti te je krovni naziv za strojno učenje i podvrstu dubokog učenja koji zajedno s tehnologijom prikupljanja i klasificiranja velikih količina podataka su omogućili kreiranje korisnih i funkcionalnih alata. Zato je cilj rada jasno predstaviti i pojasniti AI i njegove strukture i na primjerima prikazati njegove dosege i limitacije, a time ga odmaknuti od sadašnjeg shvaćanja kao monolitnog *buzzword* pojma. Svi dosadašnji oblici alata Ai-a su kreirani da obavljaju specifičan zadatak. Takva forma AI također se naziva usmjerena umjetna inteligencija (eng. Artificial Narrow Intelligence) jer posjeduju limitacije u pogledu obavljanja kompleksnih zadataka van svojih zadanih sfera. Usprkos tome u određenim zadacima spomenuti AI alati nadišli su ljudske sposobnosti te ih obavljaju s lakoćom u kratkom vremenu što ih čini pogodnim alatima za obavljanje repetitivnih i zahtjevnih radnji. Osim toga zbog svoje jedinstvenosti omogućuju uvid u podatke iz različitih kutova promatranja što je otvorilo put razvoju novih sfera istraživanja podataka i njihovog značenja.
Time su se pokazali kao iznimno relevantnim i korisnim alatima za širok raspon medija i kreativnih zadataka za potrebe kreiranja, produkcije, konzumacije i monetizacije sadržaja u sferama glazbe, vizualne umjetnosti, kreiranje sadržaja (eng. content) i naracije, optimizacije i prilagodbe medija te su doprinijeli evoluciji i revoluciji društvenih mreža.
Iz tih razloga tvrtke ulažu velike napore i sume novaca kako bi što bolje i brže prilagodili i primijenili takve alate, a time smanjili troškove i povećali profit.
Evidentno je da AI alati predstavljaju budućnosti te će uistinu izmijeniti paradigmu kreativne industrije. Iako za sada po svi istraživanjima i predviđanjima AI se nalazi u početnoj fazi razvoja i primjene u kojoj profitabilnost još nije jasno vidljiva, jasno je da će utrku budućnosti pobijediti rani usvojitelji koji već sad kreiraju put optimizaciji i primjeni takvih alata. No na putu optimizacije i težnji za primjenom AI alata potrebno je ne zanemariti ljudski faktor, odnosno pripremiti ljude na promjenu i prilagoditi infrastrukturu AI-a ljudima jer umjetna inteligencija nije i ne smije biti kreirana kao zamjena za ljude i ljudsku kreativnost već alat za pomoć i napredak ljudskog roda.

Popis kratica

AI	*Artificial inteligence*	umjetna inteligencija
ML	*Machine learning*	strojno učenje
DL	*Deep learning*	duboko učenje
BG	*Big data*	znanost velikih podataka
ANI	*Artificial Narrow Intelligence*	usko usmjerena umjetna inteligencija
AGI	*Artificial General Intelligence*	jaki humanoidni AI
ASI	*Artificial Super Intelligence*	super inteligencija
3V	*Volume, Velocity, Variety*	volumen, brzina prikupljanja i raznolikost podataka
IoT	*Internet of Things*	internet
ROI	*Returne of investment*	povrat uloženog novca
CARG	*Compound annual growth rate*	složena stopa godišnjeg rasta
CNN	*Convolutional Neural Network*	vrsta neuronske mreže
GANs	*Generative Adversarial Networks*	vrsta generativnog modela neuronske mreže
DCNN	*Deep Convolutional Neural Networks*	duboke konvolucijse neuronske mreže
CBIR	*Content-Based Image Retrieval*	kontekstualnog pretraživanje slika
UX	*User experiance*	korisničko iskustvo
VR	*Virtual reality*	virtualna stvarnost
AR	*Argumented reality*	proširena stvarnost

Napomena: na naslov **Popis kratica** primijenite stil Heading 1, a zatim ručno maknite brojčanu oznaku (to je važno kako bi i skraćenice ušle u sadržaj na početku rada, prije uvoda). Pri kreiranju popisa skraćenica koristite stil nabrajanje.

Popis slika

Slika 2.1 Način rada sustava AI-a 3
Slika 2.3. kategorija svojstava koje posjeduje AI 4
Slika 2.3. Taksonomija AI-a i pod grana i dodirne točke sa znanosti o podacima *Big data* . 6
Slika 2.4. Prikaz razvoja umjetne inteligencije na primjeru Apple-ovog voice assisten sustava pod nazivom Siri 7
Slika 2.5 Prikaz povečanja big date kroz primarne karakteristike 3V - volume, velocity, variety 8
Slika 2.6. Primjeri vizualizacija informacija sustava Kepler.gl Izvor: https://eng.uber.com/keplergl/ 10
Slika 2.7. Prikaz sustava funkcionalnosti sustava Kepler.gl Izvor: https://eng.uber.com/keplergl/ 10
Slika 2.8. Prikaz načina korištenja vremena za opuštanje Izvor: World Econimic Forum: dana provided by adam Alter, NYU Stem School of Business 2018 12
Slika 2.9. Parse.ly izdaje podatke o prometu u stvarnom vremenu o referentnim digitalnim izdavačima. Podaci nisu globalni pošto u ovom primjeru nije uključena Kina. Izvor: https://www.parse.ly/resources/data-studies/referrer-dashboard 13
Slika 2.10. Udio zarade na mobilnim oglasima izražen u postotcima % na globalnoj razini Izvor: eMarketer, Thomas Reuters Datastream, Bloomberg, Morgan Stanley 14
Slika 2.11. Izvor: World Economic Forum, bazirano na podacima "Capital IQ, Pitch book, Dealogic, McKinsey" 15
Slika 2.12. Izvor: https://blogs.gartner.com/smarterwithgartner/files/ 2019/08/CTMKT_736691_Hype_Cycle_for_AI_2019.png 16
Slika 2.13. Automatizacija će uglavnom imati pozitivan utjecaj i povećati potražnju kreativnih zanimanja - kreativaca (Slikara, umjetnika, dizajnera, snimatelja …) Izvor: https://www.mckinsey.com/featured-insights/future-of-work/jobs-lost-jobs-gained-what-the-future-of-work-will-mean-for-jobs-skills-and-wages 17
Slika 2.14. Vizualni prikaz područja primjene AI-a I cikličkog međuodnosa. 19
Slika 3.15. Prikaz NSynth-ovog Rainbowgrama i WaveNet decodera baziranog na neuronskim mrežama. Izvor: https://magenta.tensorflow.org/nsynth 21
Slika 3.16. Deezerov prikaz funkcionalnosti Splitter-a Izvor: https://deezer.io/releasing-spleeter-deezer-r-d-source-separation-engine-2b88985e797e 21
Slika 3.17. Prikaz funkcionalnosti i procesa LANDR sustava 23
Slika 3.18. Ukupni prihodi i raspodjela izvora prihoda glazbene industrije u S.A.D-u prema podacima - *The Recording Industry Association of America*® (RIAA) Izvor: http://www.riaa.com/wp-content/uploads/2019/09/Mid-Year-2019-RIAA-Music-Revenues-Report.pdf 24
Slika 3.19. Proces Deep Dream na fotografiju izvor: https://deepdreamgenerator.com/ 26
Slika 3.20. Prikaz generiranih foto realističnih fotografija ljudskih lica pomoću GAN modela neuronske mreže. Izvor: https://futurism.com/incredibly-realistic-faces-generated-neural-network 27
Slika 3.21. Sustav algoritma - Neuronskog Stilskog Prijenosa (eng. *Neural Style Transfer*) , baziranog na sustavu DL i metode transfernog učenja koji je omogućava stilsku prilagodbu bilo koje fotografije s rezultatom visoke kvalitete i očuvanja izvorne strukture. Izvor: http://bethgelab.org/research/machine_learning/style_transfer 28
Slika 3.22. Primjeri rezultata pretraživanja triju metoda iz rada *Generating High Level Visual Representations From Textual Descriptions* Izvor: https://arxiv.org/pdf/1606.07287.pdf 30

Slika 3.23. Arhitektura CNN-a Izvor: https://www.mathworks.com/videos/ introduction-to-deep-learning-what-are-convolutional-neural-networks--1489512765771.html 31
Slika 3.24. Prepoznavanje sadržaja i objekata fotografije pomoću AI sustava pogonjeno CNN-om Izvor: https://arxiv.org/pdf/1506.01497v3.pdf 32
Slika 3.25. Prikaz sučelja *Cinemachine* i korištennja postavka kamera unutar 3D animiranog prostora za kreiranje Disney-jevog Big Hero 6 nastavka. Izvor: https://unity.com/madewith/baymax-dreams 34
Slika 3.26. Procesa kreiranja audiovizualnog djela pomoću Cinemachine postaje iterativnim singularnim kružnim procesom za razliku od klasičnog sekvencijalnog procesa. Izvor: https://unity.com/madewith/baymax-dreams 35
Slika 3.27. Prikaz *Vionlab-ovog* sustava ocjenjivanja sadržaj na temelju emocionalnog utjecaja na gledatelje za kreiranje boljeg sustava preporuka. Izvor: https://feedmagazine.tv/future-shock/if-you-liked-that-youll-love-this/ 36
Slika 3.28. AI sustav koji na temelju zadanih preferencija istražuje i modelira prijedloge šasije za dron. https://www.ted.com/talks/maurice_conti_the_incredible_inventions_of_intuitive_ai 39
Slika 3.29. Shematski prikaz generičke strukture optimizacije flowa pomoću AI-a. Izvor: https://doi.org/10.1016/j.entcom.2017.02.003 40
Slika 3.30. Poslovni model društvenih mreža utemeljen na prikupljanju i analiziranju velikih podataka. 45

Popis tablica

Tablica 2.1. Definicija AI podijeljena u dvije dimenzije ljudskih karakteristika. 3

Literatura

[1] CARAMIAUX, B., LOTTE, F., GEURTS, J. *NEM preposition paper "Artificial Intelligence in the Media and Creative Industries"* 2019. https://nem-initiative.org/wp-content/uploads/2019/04/nem-white-paper-ai-in-the-creative-industry-april-2019-final.pdf

[2] COULDRY, N., TUROW, J., *Advertising, big data and the clearance of the public realm: marketers' new approaches to the content subsidy. International Journal of Communication*. 2014.

[3] ROGERS, SIMON., *"Data journalism at the Guardian: what is it and how do we do it?", The Guardian* 2012. https://www.theguardian.com/news/datablog/2011/jul/28/data-journalism

[4] RUSSELL, S.J., NORVIG, P., *Artificial Intelligence: A Modern Approach, Third Edition*, 2010.

[5] HAUGELAND, J., *Artificial Intelligence:The Very Idea. MIT Press.* 1985.

[6] BELLMAN, R. E., *An Introduction to Artificial Intelligence: Can Computers Think?*, 1978.

[7] CHARNIAK, E., MCDERMOTT, D. *Introduction to Artificial Intelligence. Addison-Wesley*, 1985.

[8] WINSTON, P. H., *Artificial Intelligence (Third edition). Addison-Wesley* ,1992.

[9] KURZWEIL, R., *The Singularity is Near*, 2005.

[10] RICH, E., KNIGHT, K., *Artificial Intelligence (second edition)*, 1991.

[11] POOLE, D., MACKWORTH, A. K., GOEBEL, R., *Computational intelligence: A logical approach*, 1998.

[12] NILSSON, N. J., *Artificial Intelligence: A New Synthesis. Morgan Kaufmann*, 1998

[13] KAPLAN, A., HAENLEIN, M., *"Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence". Business Horizons*, 2019.

[14] PERLOW, L.A., *Sleeping with Your Smartphone: How to Break the 24/7 Habit and Change the Way You Work*, 2012.

[15] SMITH, A., *U.S. Smartphone Use in 2015, Pew Research Center*, 2015.

[16] WORLD ECONOMIC FORUM®,. *Creative Disruption: The impact of emerging technologies on the creative economy*, 2018.

[17] BELL E., OWEN T., BROWN P., HAUKA C., RASHIDAN N., *The Platform Press: How Silicon Valley Reengineered Journalism*, Tow Center for Digital Journalism, Columbia University, 2017.

[18] FREEDOM HOUSE ., *https://freedomhouse.org/article/new-report-freedom-net-2017-manipulating-social-media-undermine-democracy* , 2017

[19] CADWALLADR C,. *The Cambridge Analytica Files - 'I made Steve Bannon's psychological warfare tool': meet the data war whistleblower* – The Guarrdian ,. 2018.

[20] MA B., NAHAL S., TRAN F., *Data Capital – Global Big Data and AI Primer*, Bank of America Merrill Lynch, 2017.

[21] NOVET J., *Microsoft Researchers Say Their Newest Deep Learning System Beats Humans – and Google,* 2015. https:// venturebeat.com/2015/02/09/microsoft-researchers-say-their-newestdeep-learning-system-beats-humans-and-google.

[22] O'CONNOR G., *"Moore's Law Gives Way to Bezos's Law",* 2014. https://gigaom.com/2014/04/19/moores-law-gives-way-tobezoss-law.

[23] MARCON F., *Expert interview with Francesco Marconi, the Associated Press*., 2018.

[24] NEM,. *Artificial intelligence in the media and creative industries – Position paper,.version 1.* 2019.

[25] BRIOT JEAN-PIERRE, PACHET F., *Music Generation by Deep Learning - Challenges and Directions*., 2017.

[26] MOUSSALLAM M ., *Audio Signal Processing and Machine learning for Music., https://deezer.io/releasing-spleeter-deezer-r-d-source-separation-engine-2b88985e797e ,.* 2019.

[27] VAN DEN OORD A., DIELEMAN S., ZEN H., SIMONYAN K., VINYALS O., GRAVES A., KALCHBRENNER N., SENIOR A., KAVUKCUOGLU K., *WaveNet: A Generative Model for Raw Audio.* 2016.

[28] HERNANDEZ P., *Streaming now accounts for 75 percent of music industry revenue. Retrieved from https://www.theverge.com/2018/9/20/17883584/streaming-record-sales-music- industry-revenue* , 2018.

[29] WASHENKO A., *Global music subscriber base continues to grow, led by Spotify. Retrieved from https://rainnews.com/global-music-subscriber-base-continues-to-grow-led-by-spotify/* ., 2018.

[30] MORDVINTSEV A., Christopher O., Mike T., *Inceptionism: Going deeper into neural networks. Google Research Blog* ., 2015.

[31] GOODFELLOW J., POUGET-ABADIE J., MIRZA M., XU B., WARDE-FARLEY D., OZAIR S., COURVILLE A., BENGIO Y., *Generative adversarial nets. In Proceedings of the 27th International Conference on Neural Information Processing Systems - Volume 2 (NIPS'14)., 2014.*

[32] ELGAMMAL A., LIU B., ELHOSEINY M., MAZZONE M., *CAN: Creative Adversarial Networks Generating "Art" by Learning About Styles and Deviating from Style Norms.*, 2017.

[33] MANSIMOV E., PARISOTTO E., LEI BA J., SALAKHUTDINOV R., *Generating Images from Captions with Attention.*, 2016.

[34] KARRAS T., AILA T., LAINE S., LEHTINEN J., *Progressive Growing of GANs for Improved Quality, Stability, and Variation.* 2018

[35] GHARBI M,. CHEN J,. T. BARRON J,. W. HASINOFF S,. Durand F., *Deep Bilateral Learning for Real-Time Image Enhancement,* 2017.

[36] YAN Z., ZHANG H., WANG B., PARIS S, YU Y., *Automatic Photo Adjustment Using Deep Neural Networks,* 2014

[37] GATYS L. A., ECKER A. S., BETHGE M., *A Neural Algorithm of Artistic Style*. 2015.

[38] YEH R. A., CHEN C, LIM T. Y., SCHWING A. G., HASEGAWA-JOHNSON M, DO M. N., *Semantic Image Inpainting with Deep Generative Models*, 2016

[39] LEDIG C., THEIS L., HUSZAR F., CABALLERO J., CUNNINGHAM A, ACOSTA A., AITKEN A., TEJANI A., TOTZ J., WANG Z., SHI W., *Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network*, 2016.

[40] RAZAVIAN A. S., AZIZPOUR H., SULLIVAN J., CARLSSON S, *CNN Features off-the-shelf: an Astounding Baseline for Recognition*, 2014.

[41] AMATO G., FALCHI F., GENNARO C, RABITTI F., *Searching and annotating 100M Images with YFCC100M-HNfc6 and MI-File. In Proceedings of the 15th International Workshop on Content-Based Multimedia Indexing*, 2017. https://doi.org/10.1145/3095713.3095740

[42] MAO J., XU W., YANG Y., WANG J., HUANG Z., YUILLE A., *Deep Captioning with Multimodal Recurrent Neural Networks*, 2014.

[43] REDMON J., FARHADI F., *YOLO9000: Better, Faster, Stronger*, 2016.

[44] Cao Q, Shen L., Xie W., Parkhi O. M., Zisserman A., *VGGFace2: A dataset for recognising faces across pose and age*, 2017

[45] Santoro A., Raposo D, Barrett D. G.T., Malinowski M., Pascanu R., Battaglia P, Lillicrap T, *A simple neural network module for relational reasoning*, 2017.

[46] Carrara F., Esuli A., Fagni T, Falchi F, Fernández A. M., *Picture It In Your Mind: Generating High Level Visual Representations From Textual Descriptions*, 2016 arXiv:1606.07287

[47] KRIZHEVSKY A., SUTSKEVER I., HINTON G. E.,. *ImageNet classification with deep convolutional neural networks. In Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1 (NIPS'12), F. Pereira, C. J. C. Burges, L. Bottou, and K. Q. Weinberger (Eds.), Vol. 1. Curran Associates Inc.*, 2012.

[48] DONAHUE J., JIA Y., VINYALS O., HOFFMAN J., ZHANG N., TZENG E., DARRELL T., *DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition*, 2013 arXiv:1310.1531

[49] TAIGMAN Y., YANG M, RANZATO M., WOLF L., *DeepFace: Closing the Gap to Human-Level Performance in Face Verification. In Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR '14). IEEE Computer Society*, 2014
https://doi.org/10.1109/CVPR.2014.220

[50] JENKINS H., *Convergence Culture: Where Old and New Media Collide. New York: New York University Press*, 2006.

[51] Riedl M. O., Bulitko V., *Interactive narrative: An intelligent systems approach. Ai Magazine, 34(1), 67-67.* 2013.

[52] CAVAZZA M., YOUNG R. M., *Introduction to interactive storytelling. Handbook of Digital Games and Entertainment Technologies*, 2017.

[53] GUERRINI F., ADAMI N., BENINI S., PIACENZA A., PORTEOUS J., CAVAZZA M., LEONARDI R., *Interactive film recombination. ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 2017.

[54] WEI L-Y., LEFEBVRE S., KWATRA V., TURK G., *State of the art in example-based texture synthesis. Eurographics,* 2009.

[55] MAJEROWICZ L., SHAMIR A., SHEFFER A., HOOS H. H., *Filling Your Shelves: Synthesizing Diverse Style-Preserving Artifact Arrangements, IEEE TVCG*, 2013.

[56] ZHOU H., SUN J., TURK G., REHG J. M.. *Terrain synthesis from digital elevation models. IEEE Transactions on Visualization and Computer Graphics*, 2017.

[57] CORDONNIER G., GALIN E., GAIN J., BENES B., GUÉRIN E., PEYTAVIE A., CANI M.-P., *Authoring landscapes by combining ecosystem and terrain erosion simulation. ACM Transactions on Graphics,* 2017.

[58] PRUSINKIEWICZ P., LINDENMAYER A., *The Algorithmic Beauty of Plants. Springer-Verlag*, 1996.

[59] PARISH Y. I. H., MÜLLER P., *Procedural modeling of cities. In Proceedings of SIGGRAPH*, 2001.

[60] VANEGAS C.A., GARCIA-DORADO I., ALIAGA I.D., BENES B., WADDELL P., *Inverse Design of Urban Procedural Models - ACM Transactions on Graphics,* 2012.

[61] MERRELL P., *Example-based model synthesis. In Proceedings of I3D, stranice 105–112*, 2007.

[62] MERRELL P., SCHKUFZA ER., KOLTUN V., *Computer-generated residential building layouts. ACM Transactions on Graphics,* 2010.

[63] MA C., VINING N., LEFEBVRE S., SHEFFER A., *Game level layout from design specification. Computer Graphics Forum, 33(2):95–104*, 2014.

[64] SIMS K., *Artificial evolution for computer graphics. Proceedings of ACM SIGGRAPH,* 1991.

[65] MATUSIK W., ZWICKER M., DURAND F., *Texture design using a simplicial complex of morphable textures. ACM Transactions on Graphics,* 2005.

[66] TALTON J., GIBSON D., YANG L., HANRAHAN P., KOLTUN V., *Exploratory modeling with collaborative design spaces. ACM Transactions on Graphics*, 2009.

[67] LASRAM A., LEFEBVRE S., DAMEZ C., *Procedural texture preview. Computer Graphics Forum,* 2012.

[68] SHUGRINA M., SHAMIR A., MATUSIK W., *ACM Transactions on Graphics, Fab Forms: Customizable Objects for Fabrication with Validity and Geometry Caching,* 2015.

[69] GATYS L., ECKER A., BETHGE M., *Texture Synthesis Using Convolutional Neural Networks. Advances in Neural Information Processing Systems,* 2015

[70] MITRA N. J., KOKKINOS I., GUERRERO P., THUEREY N., RITSCHE T., *Creative AI: Deep Learning for Computer Graphics, Course at SIGGRAPH Asia,* 2018

[71] Attene M., Livesu M., Lefebvre S., Funkhouser T., Rusinkiewicz S., Ellero S., Martínez J., Bermano A.H., Design, *Representations, and Processing for Additive Manufacturing, Morgan & Claypool Publishers - Synthesis Lectures on Visual Computing*, 2018

[72] CHEN J., *Flow in games (and everything else). Communications of the ACM*, 50(4), 31-34. 2007

[73] (a) COWLEY B. U., CHARLES D., *Adaptive Artificial Intelligence in Games: Issues, Requirements, and a Solution through Behavlets-based General Player Modelling. arXiv preprint arXiv:1607.05028 ,* 2016

[74] HERBRICH R., MINKA T., GRAEPEL T., *TrueSkill™: a Bayesian skill rating system. In Advances in neural information processing systems,* 2007

[75] BISHOP C. M., *Model-based machine learning. Phil. Trans. R. Soc. A,* 2013

[76] NACKE L., LINDLEY C. A., *Flow and immersion in first-person shooters: measuring the player's gameplay experience. In Proceedings of the 2008 Conference on Future Play: Research, Play, Share, ACM, 2008*

[77] (B) COWLEY B., FILETTI M., LUKANDER K., TORNIAINEN J., HENELIUS A., AHONEN L., RAVAJA N., *The psychophysiology primer: a guide to methods and a broad review with a focus on human–computer interaction. Foundations and Trends® in Human–Computer Interaction, 9(3-4), 151-308.* 2016

[78] DRACHEN A., NACKE L. E., YANNAKAKIS G., PEDERSEN A. L., *Correlation between heart rate, electrodermal activity and player experience in first-person shooter games. In Proceedings of the 5th ACM SIGGRAPH Symposium on Video Games (pp. 49-54). ACM. 2010*

[79] NACKE L. E., *An introduction to physiological player metrics for evaluating games. In Game Analytics,* 2013

[80] FREY J., MÜHL C., LOTTE F., HACHET M. *Review of the use of electroencephalography as an evaluation method for human-computer interaction. Proc. PhyCS,* 2014

[81] FREY J., DANIEL, M., CASTET J., HACHET M., & LOTTE F., *Framework for electroencephalography-based evaluation of user experience. In Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems (pp. 2283-2294). ACM.,* 2016

[82] MÜHL C., ALLISON B., NIJHOLT A., CHANEL G., *A survey of affective brain computer interfaces: principles, state-of-the-art, and challenges. Brain-Computer Interfaces,* 2014

[83] TONDELLO G. F., ORJI R., NACKE, L. E. *Recommender systems for personalized gamification. In Adjunct Publication of the 25th Conference on User Modeling, Adaptation and Personalization ,* 2017

[84] DIGNUM V, BALDONI M., BAROGLIO C., CAON M., CHATILA R., DENNIS L., GENOVA G., KLIEß M., LOPEZ-SANCHEZ M., MICALIZIO R., PAVON´ J,. SLAVKOVIK M., SMAKMAN10, MARLIES VAN STEENBERGEN M., TEDESCHI S, VAN DER TORRE L., VILLATA S., DE WILDT T, HAIM G., *Ethics by Design: necessity or curse?, 2018* https://www.aies-conference.com/2018/contents/papers/main/AIES_2018_paper_68.pdf

[85] UMETANI N., IGARASHI T., MITRA N.J., *Guided Exploration of Physically Valid Shapes for Furniture Design. Communications of the ACM,* 2015

[86] ADZIC J., BEHRMANN M., DANET P., GEELS K., HRASNICA H., JIMÉNEZ D, POLITÉCNICA DE KOIDL K., PARNALL J., PERKIS A., TURRIN E., *Towards the future - Social media, NEM White Paper,* 2017

[87] ROGYNSKYY O., *Making sense of the GDPR & Artificial Intelligence paradox,* 2019 https://www.itproportal.com/features/making-sense-of-the-gdpr-and-artificial-intelligence-paradox/

[88] CARNEIRO L., GOYANES M., *AI inventions: how to address the ownership issue,* 2019 https://www.lexology.com/library/detail.aspx?g=9d710b33-eed0-4277-95d2-74743ab0bbf6

[89] HARARI, Y., *Homo deus: A brief history of tomorrow,* 2016

[90] LEBUDA I., GLĂVEANU V. P., *The Palgrave Handbook of Social Creativity Research,* 2019

„Pod punom odgovornošću pismeno potvrđujem da je ovo moj autorski rad čiji niti jedan dio nije nastao kopiranjem ili plagiranjem tuđeg sadržaja. Prilikom izrade rada koristio sam tuđe materijale navedene u popisu literature ali nisam kopirao niti jedan njihov dio, osim citata za koje sam naveo autora i izvor te ih jasno označio znakovima navodnika. U slučaju da se u bilo kojem trenutku dokaže suprotno, spreman sam snositi sve posljedice uključivo i poništenje javne isprave stečene dijelom i na temelju ovoga rada“.

U Zagrebu, datum.

Ime Prezime

Prilog

Diplomski rad može imati priloge, ali se oni ne prilažu uz pisanu verziju diplomskog rada već se mogu priložiti na diplomskom ispitu ukoliko povjerenstvo na diplomskom ispitu tako odluči. Važno je čuvati svu poratnu dokumentaciju koja je nastala pri izradi diplomskog rada.
S unutarnje strane na zadnjim koricama originala, kao i svake kopije diplomskog rada, pričvršćuje se CD s kompletnim diplomskim radom u izvornom formatu (npr. .docx) i .pdf formatu sa svom popratnom dokumentacijom i programima. Pri čemu je obvezno da na tom CD- u postoji i dokument koji opisuje kako se rezultat njegova diplomskog rada (softver ili hardver) koristi (ili kako se npr. izvode mjerenja koja je opisao u radu). Ako se radi o softveru nužno je opisati i kako se programska podrška instalira.