

Neuronski prijenos stila

Tot, Rea

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Humanities and Social Sciences / Sveučilište u Zagrebu, Filozofski fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:131:301795>

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

Download date / Datum preuzimanja: **2024-07-22**



Sveučilište u Zagrebu
Filozofski fakultet
University of Zagreb
Faculty of Humanities
and Social Sciences

Repository / Repozitorij:

[ODRAZ - open repository of the University of Zagreb
Faculty of Humanities and Social Sciences](#)



SVEUČILIŠTE U ZAGREBU
FILOZOFSKI FAKULTET
ODSJEK ZA INFORMACIJSKE I KOMUNIKACIJSKE ZNANOSTI
SMJER INFORMATIKA - ISTRAŽIVAČKI
Ak. god. 2023./2024.

Rea Tot

Neuronski prijenos stila

Diplomski rad

Mentor: dr. sc. Ivan Dunder, docent

Zagreb, travanj 2024.

Izjava o akademskoj čestitosti

Izjavljujem da je ovaj rad rezultat mog vlastitog rada koji se temelji na istraživanjima te objavljenoj i citiranoj literaturi. Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava. Također izjavljujem da nijedan dio rada nije korišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

(potpis)

Sadržaj

| | | |
|--------|---|----|
| 1. | Uvod | 1 |
| 2. | Umjetna inteligencija..... | 3 |
| 2.1. | Povijesni pregled umjetne inteligencije | 4 |
| 2.2. | Umjetna inteligencija danas | 6 |
| 2.3. | Polja umjetne inteligencije | 7 |
| 3. | Strojno učenje | 9 |
| 3.1. | Strojno učenje i tradicionalno programiranje | 10 |
| 3.2. | Proces treniranja u strojnom učenju | 12 |
| 3.3. | Metode strojnog učenja..... | 14 |
| 3.3.1. | Nadzirano strojno učenje..... | 15 |
| 3.3.2. | Nenadzirano strojno učenje | 16 |
| 3.3.3. | Podržano strojno učenje | 17 |
| 4. | Umjetne neuronske mreže i duboko učenje | 19 |
| 4.1. | Umjetne neuronske mreže..... | 19 |
| 4.1.1. | Biološki i umjetni neuron..... | 20 |
| 4.1.2. | Osnovna arhitektura umjetnih neuronskih mreža | 21 |
| 4.2. | Proces treniranja umjetnih neuronskih mreža | 23 |
| 4.2.1. | Važni pojmovi | 23 |
| 5. | Duboko učenje | 29 |
| 5.1. | Odnos umjetnih neuronskih mreža i dubokog učenja..... | 29 |
| 5.2. | Hijerarhijsko učenje značajki | 30 |
| 5.2.1. | Konvolucijske neuronske mreže | 32 |
| 6. | Neuronski prijenos stila | 38 |
| 6.1. | Neuronski algoritam umjetničkog stila..... | 38 |
| 6.2. | Uvod u neuronski prijenos stila | 40 |

| | |
|-------------------------------|----|
| 6.2.1. Osnovni principi | 41 |
| 7. Praktični dio rada | 44 |
| 7.1. Odabir tehnologija | 48 |
| 7.2. Implementacija | 49 |
| 7.3. Rezultati | 54 |
| Zaključak | 60 |
| Literatura | 61 |
| Popis slika..... | 70 |
| Sažetak..... | 72 |
| Summary..... | 73 |

1. Uvod

U posljednjih nekoliko godina, umjetna inteligencija (engl. *artificial intelligence*) doživjela je izvanredan napredak, čime se pozicionirala kao ključno i utjecajno područje u suvremenom svijetu. U kontekstu različitih područja umjetne inteligencije, strojno (engl. *machine learning*) i duboko učenje (engl. *deep learning*) istaknuli su se kao posebno moćni alati koji su revolucionirali polje te promijenili dinamiku same industrije svojom sposobnošću obrade i učenja iz velike količine podataka. Ovaj napredak omogućio je razvoj umjetnih neuronskih mreža (engl. *artificial neural networks*), među kojima su posebno utjecajne konvolucijske neuronske mreže (engl. *convolutional neural networks*) (Taye, 2023). Konvolucijske neuronske mreže, kao vrsta umjetnih neuronskih mreža, ističu se zahvaljujući svojoj efikasnoj detekciji i interpretaciji vizualnih uzoraka u slikama, što je potaknulo stvaranje alata poput neuronskog prijenosa stila (engl. *neural style transfer*) (Singh et al., 2021).

Neuronski prijenos stila je tehnika koja kombinira stil jedne slike sa sadržajem druge, što rezultira stiliziranim slikama. Ova tehnika koristi snagu dubokog učenja i konvolucijskih neuronskih mreža kako bi „izvukla“ stilske karakteristike iz jedne slike i spojila ih s karakteristikama sadržaja druge slike. Koristeći trenirane neuronske mreže, stilske i sadržajne karakteristike se kombiniraju kako bi se generirala nova slika koja zadržava sadržaj jedne slike, a istovremeno inkorporira stilske karakteristike druge (Singh et al., 2021).

Cilj ovog diplomskog rada jest pružiti razumijevanje teme neuronskog prijenosa stila, obuhvaćajući primarno teorijski okvir, ali i praktičnu implementaciju. Struktura rada obuhvaća dva glavna dijela: teorijski i praktični. Teorijski dio rada pruža pregled umjetne inteligencije, te tako i strojnog i dubokog učenja. Istražuju se koncepti i načela na kojima se temelje umjetna inteligencija i strojno i duboko učenje te se postavlja podloga za detaljniji uvid u kasnijim dijelovima rada. Također, teorijski dio se bavi konceptom umjetnih neuronskih mreža i njihovom sposobnošću detekcije složenih uzoraka iz velikih količina podataka. Fokus se zatim „prebacuje“ na neuronski prijenos stila, objašnjavajući teoriju uključenu u ovom procesu.

Praktični dio rada usmjeren je na zadatak implementacije neuronskog prijenosa stila s pomoću prethodno istreniranog modela VGG-19. Za provedbu implementacije koristi se TensorFlow biblioteka za strojno učenje unutar Google Colaboratory okruženja. TensorFlow pruža opsežan skup alata i resursa za izgradnju i treniranje modela dubokog učenja, stoga predstavlja idealan izbor za izvedbu projekta. Sam proces implementacije uključuje angažman prethodno

istreniranog modela konvolucijskih neuronskih mreža, ekstrakciju značajki iz ulaznih slika te realizaciju algoritma za integraciju stilskih i sadržajnih karakteristika. Rad završava prikazivanjem rezultata dobivenih iz implementacije neuronskog prijenosa stila.

Ovaj diplomski teži pružiti pregled i praktičnu primjenu neuronskog prijenosa stila. Kombinirajući teorijske temelje umjetne inteligencije, strojnog učenja i dubokog učenja s praktičnom primjenom neuronskog prijenosa stila, ovaj diplomski rad nastoji pružiti uvid u sposobnosti i potencijalne primjene neuronskog prijenosa stila u području računalnog vida i obrade slika.

2. Umjetna inteligencija

Umjetna inteligencija predstavlja multidisciplinarno područje posvećeno razvoju inteligentnih sustava i računalnih entiteta sposobnih za izvršavanje zadataka koji su tradicionalno zahtijevali ljudske kognitivne sposobnosti (Copeland, 2023). Njezin osnovni cilj leži u automatizaciji kognitivnih zadataka karakterističnih za ljudsku inteligenciju (Chollet, 2018), čime se emulira ljudska kognicija (Petersson, 2023). To obuhvaća razvoj i usavršavanje algoritama, modela i sustava opremljenih sposobnošću percepcije, zaključivanja, učenja i donošenja odluka temeljenih na podacima. Takvi napori omogućuju obradu složenih zadataka, obuhvaćajući domene poput rješavanja problema, donošenja odluka, razumijevanja i prevođenja (Seljan & Dunder, 2014) prirodnog jezika, prepoznavanja uzoraka i kreativnih nastojanja (Ali et al., 2023).

Područje umjetne inteligencije privuklo je značajnu pažnju, što je rezultiralo brzim razvojem i mnoštvom primjena u različitim industrijskim sektorima. Kako ističu Russel i Norvig u svom djelu „*Umjetna inteligencija: Moderni pristup*“, disciplina se redovito svrstava među najzanimljivija i najbrže rastuća područja, pridonoseći značajnim ekonomskim dobitima svake godine. Prognoze stručnjaka za umjetnu inteligenciju Kai-Fu Lee-a predviđaju neviđen utjecaj, nadmašujući povijesne posljedice prethodnih tehnoloških revolucija. Također, intelektualni horizonti i granice umjetne inteligencije ostaju širom otvoreni, pružajući ogroman potencijal za otkrivanje i razvoj novih metoda za rješavanje različitih izazova u raznim područjima (Russell & Norvig, 2021).

Umjetna inteligencija obuhvaća širok raspon područja, pokrivajući opće kognitivne funkcije poput učenja, zaključivanja i percepcije, kao i specijalizirane zadatke poput igranja igara, dokazivanja teorema, kreativnog izražavanja, autonomne navigacije vozila i medicinske dijagnoze. Prilagodljivost i svestranost umjetne inteligencije omogućuju joj izvanrednu učinkovitost i važnost. Kako su opisali Russell i Norvig (2021), „Umjetna inteligencija relevantna je za bilo koji intelektualni zadatak; to je uistinu univerzalno polje.“ Umjetna inteligencija nadilazi disciplinske granice, potvrđujući svoj status kao univerzalno područje koje se preklapa s disciplinama poput računalnih znanosti, matematike, psihologije, neuroznanosti i lingvistike, kako bi stvorila algoritme, modele i okvire koji omogućuju strojevima da iskazuju inteligentno ponašanje (Russell & Norvig, 2021).

Glavni cilj umjetne inteligencije leži u stvaranju inteligentnih sustava opremljenih sposobnošću autonomne percepcije, razumijevanja, zaključivanja, učenja i odlučivanja, oponašajući ljudske kognitivne sposobnosti. Ovo obuhvaća razvoj računalnih entiteta sposobnih za procesiranje velikih skupova podataka, izvlačenje bitnih spoznaja, prilagodbu dinamičnim okruženjima i izvršavanje zadataka s preciznošću i učinkovitošću (Xu et al., 2021).

2.1. Povijesni pregled umjetne inteligencije

Definicije i koncepti povezani s umjetnom inteligencijom danas su rezultat gotovo stoljetnog znanstvenog istraživanja, obuhvaćajući i postignuća i neuspjehe (Journal of Information Technology & Software Engineering, 2011) (Buchanan, 2005).

Korijeni suvremenog istraživanja umjetne inteligencije sežu u 1956. godinu, na konferenciji na Sveučilištu Dartmouth u SAD-u (Kelleher, 2019). Inicirana od strane Johna McCarthyja, ova konferencija okupila je istraživače iz različitih akademskih područja kako bi uspostavili temelje za nadolazeću disciplinu umjetne inteligencije (Warwick, 2012). Konferencija je istaknula ideju da se različiti aspekti učenja i inteligencije mogu precizno opisati, otvarajući put za strojeve da emuliraju te procese (Russell & Norvig, 2021). Ondje su prikazane različite istraživačke teme, uključujući dokazivanje matematičkih teorema, obradu prirodnog jezika, teoriju igara, strojno učenje iz primjera i osnovna načela neuronskih mreža. Atmosfera na Dartmouthu bila je obilježena optimizmom, jer su znanstvenici vjerovali u potencijal iskorištavanja računalne snage i algoritama. Izraz „umjetna inteligencija“ obuhvatio je tu kolektivnu viziju, simbolizirajući težnju za stvaranjem entiteta sposobnih za pokazivanje inteligentnog ponašanja sličnog ljudskom (Kelleher, 2019).

Završetkom konferencije, istraživanja umjetne inteligencije dobila su zamah te su nastavila napredovati, a računala su postala važni alati koji su odigrali ključnu ulogu u implementaciji i poboljšanju algoritama i tehnika umjetne inteligencije (Warwick, 2012). Konferencija i radovi koje je inspirirala postavili su temelje za istraživanje umjetne inteligencije i postavili okvire za umjetne neuronske mreže, algoritme učenja i općenito računalni pristup inteligenciji. Ukratko, područje se razvilo i doživjelo značajan napredak zahvaljujući poboljšanju računalne moći, dostupnosti velikih skupova podataka i inovacijama u algoritmima, što je dovelo do razvoja sofisticiranijih tehnika, aplikacija i područja umjetne inteligencije kakve poznajemo danas (Russell & Norvig, 2021) (Patterson & Gibson, 2017).

U narednim godinama, ostvaren je značajan napredak. Mnogi znanstvenici i istraživači koristili su umjetnu inteligenciju za dokazivanje matematičkih teorema i rješavanje algebarskih problema. Među tim naporima ističe se „Logic Theorist“, računalni program koji su osmislili Allen Newell, Herbert A. Simon i Cliff Shaw, koji je uspješno dokazao 38 od prvih 52 teorema u „Principia Mathematica“ te pružio bolje definirane dokaze za neke od njih. Ti su uspjesi potaknuli optimistične vizije među pionirima umjetne inteligencije, potičući vjerovanje da su potpuno inteligentni strojevi na vidiku (Xu et al., 2021).

Međutim, put prema inteligenciji strojeva ekvivalentnoj ljudskoj pokazao se izazovnim. Programi su se suočili s izazovima, a računalni resursi bili su nedovoljni za rješavanje sve složenijih problema. Stoga je opala podrška za projektima umjetne inteligencije koji nisu ispunjavali očekivanja. Kako se polje suočavalo s rastućim jazom između očekivanja i tehnološke izvedivosti, uslijedila su razdoblja skepticizma i povlačenja financijskih sredstava za akademska istraživanja, poznata kao „zime umjetne inteligencije“ (Patterson & Gibson, 2017).

21. stoljeće donijelo je obnovljeni zanos za umjetnu inteligenciju, potaknut napretkom u strojnom učenju i neuronskim mrežama. Strojno učenje, karakterizirano učenjem računala iz podataka bez eksplicitnog programiranja, pojavilo se kao pokretač napretka. Duboko učenje, podskup strojnog učenja inspiriran arhitekturom ljudskog mozga, revolucioniralo je sposobnosti umjetne inteligencije prepoznavanjem složenih uzoraka u velikim skupovima podataka.

Napredak u tehnologijama velikih podataka i računalne snage poboljšao je učinkovitost izvlačenja značajki iz velikih skupova podataka, potičući razvoj novih struktura neuronskih mreža i metoda treniranja (Kelleher, 2019).

2.2. Umjetna inteligencija danas

„Umjetna inteligencija prilagođava se svijetu oko nas, učeći i mijenjajući se kako napreduje“ (Oxford, n.d.). Umjetna inteligencija prožima različite industrije i svakodnevni život, potičući značajne napretke. Ona igra ključnu ulogu u različitim industrijama te predstavlja transformacijsku silu s dubokim implikacijama za industrije, društvene strukture i složeni odnos između umjetne i ljudske inteligencije (Russell & Norvig, 2021).

Od svojih skromnih početaka 1950-ih godina, područje umjetne inteligencije doživjelo je izvanredan napredak, čime je postalo ključno područje suvremenih istraživanja. Praktične primjene umjetne inteligencije u stvarnom svijetu nadmašile su kognitivne sposobnosti ljudskog mozga na različite načine. Umjetna inteligencija svjedočila je značajnim prekretnicama i postignućima, poput povijesnog trenutka kada je računalni sustav Deep Blue 11. svibnja 1997. pobijedio tadašnjeg svjetskog šahovskog prvaka Garryja Kasparova. Dodatno, pojava AlphaGo-a 2016. godine, stvorenog od strane istraživačke tvrtke za umjetnu inteligenciju, DeepMind, u vlasništvu Google-a, privukla je znatan interes pobjedom nad svjetskim prvakom u igri Go, Leeom Sedolom. S više od 200 milijuna gledatelja, ovaj događaj predstavljao je prekretnicu za područje umjetne inteligencije i strojnog učenja zbog izazova koje igra Go pruža umjetnoj inteligenciji zbog mnogobrojnih mogućih poteza. Ova postignuća prvenstveno su rezultat pomicanja granica postojeće tehnologije, a ne oslanjanja na novo izumljene oblike tehnologija. Povećanje računalne snage odigralo je ključnu ulogu u prevladavanju ranijih izazova s kojima su se suočavali sustavi umjetne inteligencije (Russell & Norvig, 2021).

U suvremenom svijetu, područje umjetne inteligencije se brzo razvija, s impresivnim tehnološkim napretkom i raširenim uspjehom u različitim industrijama. Sposobnost umjetne inteligencije da omogući računalima i strojevima obavljanje složenih zadataka koji su tradicionalno bili povezani s ljudskom inteligencijom revolucionirala je brojna područja. Glasovni asistenti, autonomna vozila, dijagnostika zdravstvenih problema i optimizacija poslovnih procesa samo su neki od primjera gdje umjetna inteligencija redefinira konvencionalne granice. Umjetna inteligencija etablirala se kao revolucionarna sila u različitim industrijama i domenama (Littman et al., 2021).

Russell i Norvig navode sljedeće podatke: „Do 2019. godine AI sustavi navodno su se susreli ili premašili performanse na ljudskoj razini u šahu, Go-u, pokeru, Pac-Manu, Jeopardy-u!,

detekciji objekata na ImageNetu, prepoznavanju govora u ograničenoj domeni, prijevodu s kineskog na engleski u ograničenoj domeni, igrama Quake III, Dota 2, StarCraft II, raznim Atari igrama, otkrivanju raka kože, otkrivanju raka prostate, savijanju proteina i dijagnozi dijabetičke retinopatije.“. Ovi uspjesi generirali su ogroman interes za umjetnu inteligenciju među studentima, tvrtkama, investitorima, vladama, medijima i širom javnošću. Umjetna inteligencija nastavlja brzo napredovati, potaknuta stalnim istraživanjem i razvojem u svim svojim područjima (Russell & Norvig, 2021).

Definicija umjetne inteligencije i dalje se dinamično razvija, zajedno s pojavom novih pristupa poput strojnog učenja, dubokog učenja i neuronskih mreža. Ovi metodološki pristupi proširuju mogućnosti umjetne inteligencije, gurajući ju u „neistražene teritorije“ računalne inteligencije (Laskowski & Tucci, 2023).

2.3. Polja umjetne inteligencije

Kroz nove istraživačke napretke, umjetna inteligencija proširuje svoje područje na širok raspon teorija, metoda, tehnologija i specijaliziranih potpodručja. Ova potpodručja su složena i međusobno povezana i često preklapajuća, jer napredak u jednom području utječe na druga (SoftwareTestingHelp, 2023) (Petersson, 2023).

Autori često nude vlastite definicije različitih područja unutar umjetne inteligencije. Među njima se posebno ističu: strojno učenje, umjetne neuronske mreže, duboko učenje, kognitivno računalstvo, obrada prirodnog jezika i računalni vid (DatabaseTown, n.d.)

- **Strojno učenje** - uključuje razvoj algoritama i modela koji računalima omogućuju učenje iz podataka bez eksplicitnog programiranja. Koristeći metodologije poput nadziranog, nenadziranog i pojačanog učenja, strojevi mogu automatski identificirati uzorke, predviđati ishode, klasificirati objekte i prilagoditi se novim ulaznim podacima. Učenje iz podataka omogućilo je napredak u područjima poput prepoznavanja slika i govora, obrade prirodnog jezika, sustava preporuka i otkrivanja prijevara (Tucci & Burns, 2023)
- **Umjetne neuronske mreže** - vrsta strojnog učenja koje oponašaju neuronsku arhitekturu ljudskog mozga putem međusobno povezanih jedinica. Te jedinice, slične neuronima, olakšavaju međusoban prijenos informacija te pronalaze bitne obrasce iz neoznačenih skupova podataka (Bigelow, 2023).

- **Duboko učenje** - podskup strojnog učenja koji koristi višeslojne umjetne neuronske mreže za modeliranje i razumijevanje složenih uzoraka prisutnih u podacima. Inspirirano strukturom i funkcijom ljudskog mozga, algoritmi dubokog učenja su pokazali izvanrednu učinkovitost u područjima poput računalnog vida, razumijevanja prirodnog jezika i generativnog modeliranja. To je dovelo do napretka u područjima poput prepoznavanja lica, autonomne vožnje, virtualnih asistenata i umjetničkog stvaranja (Gillis et al., 2023)
- **Kognitivno računalstvo (engl. *cognitive computing*)** - teži omogućiti „glatku“ interakciju između ljudi i strojeva, simulirajući ljudske procese poput tumačenja slika i govora (Yasar et al., 2023)
- **Obrada prirodnog jezika (engl. *natural language processing*)** - usredotočena je na omogućavanje strojevima razumijevanje i generiranje ljudskog jezika. Ovo obuhvaća analizu, razumijevanje i generiranje ljudskog jezika, što dovodi do aplikacija za prevođenja jezika, analize sentimenta i chatbotova (Gillis et al., 2024).
- **Računalni vid (engl. *computer vision*)** - daje računalnim sustavima sposobnost percipiranja i tumačenja vizualnih podataka. Primjenjuje se u područjima poput detekcije objekata, segmentacije slika, prepoznavanje lica i autonomnih vozila. Oslanja se na prepoznavanje uzoraka i upotrebu složenih algoritama dubokog učenja za prepoznavanje i interpretaciju vizualnog sadržaja (Yasar & Lutkevich, 2023).

Sveukupno gledano, područje umjetne inteligencije svjedočilo je značajnom rastu i diverzifikaciji, pri čemu su različita područja doprinijela napretku u različitim domenama i primjenama. Strojno učenje i duboko učenje posebno su istaknuti kao ključni pokretači napretka umjetne inteligencije (Xu et al., 2021).

3. Strojno učenje

Jedna od čestih zablude koja okružuje računalne sustave jest njihova percipirana nesposobnost za učenje i prilagodbu. Iako su određeni sustavi zaista ograničeni na izvršavanje prethodno programiranih zadataka, značajan podskup posjeduje izvanrednu sposobnost učenja iz iskustva i prilagođavanja svog ponašanja sukladno tome. Ključni aspekt umjetne inteligencije leži upravo u sposobnosti računala da uče (Warwick, 2012).

Ljudi koriste podatke kako bi stekli uvide o svijetu i donijeli informirane odluke. Međutim, moderno preobilje informacija često nadmašuje ljudske kognitivne kapacitete što rezultira preopterećenjem informacija. U odgovoru na tu izazovnu situaciju, sustavi umjetne inteligencije, vješti u pohrani i obradi ogromnih količina podataka, postaju korisni i neizostavni alati za otkrivanje značajnih uzoraka, međusobnih poveznica i odnosa u složenim skupovima podataka (Warwick, 2012). Strojno učenje, kao temeljna grana umjetne inteligencije, pruža računalnim programima sposobnost stjecanja znanja i autonomnog poboljšavanja svoje funkcionalnosti putem iskustvenog učenja, na taj način oponašajući aspekte ljudskog kognitivnog razvoja (Sakarkar et al., 2021) (Alpaydin, 2016). Strojno učenje definira se kao „područje proučavanja koje računalima daje sposobnost učenja bez izričitog programiranja“ (Patterson & Gibson, 2017). U svakodnevnom govoru, učenje znači „stjecanje znanja proučavanjem, iskustvom ili poučavanjem“ (Patterson & Gibson, 2017). No, unutar područja strojnog učenja, to znači korištenje algoritama za stvaranje strukturnih opisa iz primjera podataka, dajući računalima sposobnost da nauče o strukturama koje predstavljaju informacije u sirovim podacima (Patterson & Gibson, 2017).

U računalnoj domeni, pojam iskustva povezan je s podacima, a glavni cilj strojnog učenja jest razvoj algoritama koji samostalno konstruiraju modele na temelju opaženih uzoraka podataka (Zatezalo & Dunder, 2021a), bez potrebe za izričitim programiranjem. Ovaj iterativni proces, poznat kao obuka ili treniranje, podrazumijeva korištenje tih algoritama za iterativno usavršavanje modela kroz izlaganje podacima, što na kraju rezultira sustavima sposobnima za obradu ulaznih podataka i generiranje korisnih uvida i predikcija. Skupovi podataka, koji obuhvaćaju zbirke varijabli i njihovih odgovarajućih vrijednosti, služe kao temelj na kojemu rade algoritmi strojnog učenja. Važno je istaknuti da razmjera i kvaliteta dostupnih podataka bitno utječu na učinkovitost rješenja strojnog učenja, pri čemu veći, raznovrsniji skupovi podataka često rezultiraju boljim performansama modela (Zhou, 2021). Konačni cilj strojnog učenja jest iterativno poboljšanje prediktivne točnosti i pouzdanosti rezultata, čime se

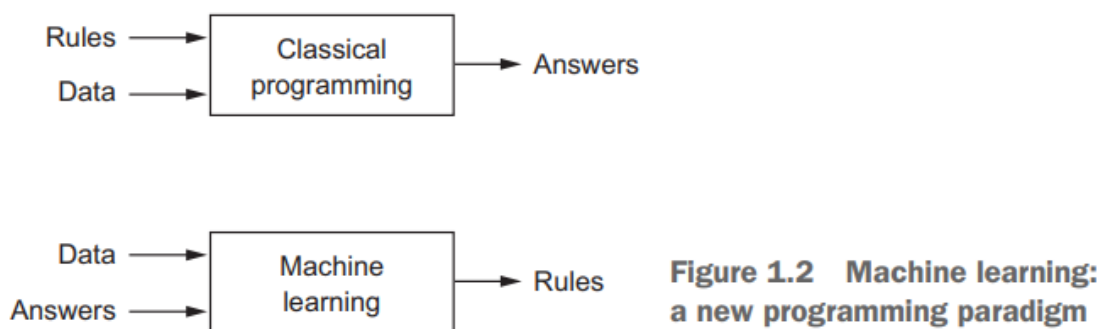
omogućava autonomno generiranje korisnih uvida i informirano donošenje odluka od strane računalnih sustava. Pružajući računalima sposobnost da odrede optimalne postupke ili donesu korisne zaključke bez eksplicitnih programskih uputa, strojno učenje predstavlja važnu promjenu kako u industrijskim aplikacijama tako i u interakciji između ljudi i računala. Potreba za ovakvim pristupom proizašla je iz spoznaje da je za rješavanje složenih problema bilo učinkovitije stvoriti sustav koji je sposoban samostalno generirati algoritam, bez prethodne definicije, za rješavanje navedenog problema (Alpaydin, 2016). Strojno učenje je snaga koja je uistinu revolucionirala industrije i transformira ljudsku interakciju s tehnologijom (Soori et al., 2023).

3.1. Strojno učenje i tradicionalno programiranje

Strojno učenje predstavlja dinamičan i transformacijski aspekt umjetne inteligencije. Ono predstavlja vrhunac računalnih sposobnosti koje omogućuju strojevima da izvlače uvide iz podataka i iterativno poboljšavaju svoje performanse. Strojno učenje označava paradigmatički pomak u obradi informacija od strane računala. Korijeni strojnog učenja mogu se pratiti sve do sredine 20. stoljeća kada su vizionari poput Arthura Samuela skovali pojam, postavljajući temelj za sustave sposobne autonomno stjecati znanje, oslobođene eksplicitnih programskih uputa (Warwick, 2012).

Strojno učenje proizišlo je iz temeljnog pitanja: mogu li računala prevladati okvire prethodno određenih uputa i samostalno stjecati vještine u izvođenju određenih zadataka? Ovo pitanje otvorilo je vrata novom pristupu programiranju. U konvencionalnom programiranju, programeri oblikuju kod koji obuhvaća pravila prilagođena za obradu određenih skupova podataka. Taj kod zatim obrađuje ulazni skup podataka, rezultirajući očekivanim izlazima. Međutim, područje strojnog učenja odstupa od tog tijeka. Umjesto pridržavanja eksplicitnih uputa, računalima se predočavaju primjeri ishoda, tj. rezultata, odnosno primjeri onoga što želimo da računalo postigne. Na ovaj način se eliminira potreba za unaprijed definiranim pravilima. Ti primjeri, često sastavljeni od podataka označenih kategorijama ili klasifikacijama, služe kao ulazni podaci za algoritme strojnog učenja kako bi sintetizirali nove uvide i riješili nove izazove (Institute of Data, 2023). Na temelju ovih ulaznih primjera, strojno učenje ne generira konkretan rezultat, već daje algoritam, odnosno program, koji je sposoban za donošenje novih zaključaka i rješavanje novih problema. Ukratko, tradicionalno programiranje podrazumijeva izradu pravila (programa) uz podatke, koji se potom obrađuju

kako bi generirali odgovore. Podaci i njihovi odgovarajući anticipirani odgovori čine osnovu, a pravila se formuliraju kao posljedica toga. Nasuprot tome, unutar područja strojnog učenja, unaprijed se predočavaju podaci i njihovi anticipirani odgovori, čime se stvara osnova, iz koje se pravila deduciraju kao ishod. Ta deducirana pravila potom se mogu primijeniti na nove podatke, stvarajući time inovativne odgovore. Ovaj odnos slikovno je prikazan na slici 1. (Chollet, 2018).



Slika 1 Odnos klasičnog programiranja i strojnog učenja (Chollet, 2018)

Središnja privlačnost strojnog učenja proizlazi iz sposobnosti omogućavanja računalima da uče iz velikih skupova podataka. Kako korpus dostupnih podataka raste, tako raste i potencijal strojnog učenja, generirajući sve suptilnije i dublje uvide. U suštini, strojno učenje potiče razvoj algoritama i modela koji sustavima omogućuju sposobnost učenja i donošenja odluka autonomno, time smanjujući potrebu za ljudskom intervencijom. Unošenjem opsežnih skupova podataka, strojevi mogu izvući značajne zaključke i olakšati stvaranje točnih prognoza ili odluka utemeljenih na empirijskim dokazima (Chollet, 2018).

Efikasnost i snaga strojnog učenja proizlazi iz prilagodljivosti i kontinuiranog poboljšanja kako susreće nove podatke, čineći ga nezaobilaznim alatom za rješavanje različitih zadataka koji bi bili nepraktični ili neostvarivi korištenjem konvencionalnih metoda. Ta moć čini strojno učenje sveprisutnom snagom u raznim industrijama i sektorima, uključujući zdravstvo, financije i marketing (Russell & Norvig, 2021). Nadalje, doseg strojnog učenja obuhvaća spektar domena uključujući obradu prirodnog jezika, prepoznavanje slika i govora, otkrivanje prijevara, medicinsku dijagnostiku, financijsko prognoziranje i druge. Posljednjih godina javljaju se značajni koraci u području strojnog učenja, potaknuti rastućom računalnom snagom, prevalencijom velikih skupova podataka i pojavom pionirskih algoritamskih okvira (Kelleher, 2019).

3.2. Proces treniranja u strojnom učenju

Strojno učenje predstavlja domenu koja se bavi razvojem i evaluacijom algoritama osmišljenih kako bi omogućili računalnim sustavima da izvlače ili nauče funkcije iz skupova podataka s primjerima. Osnovni princip strojnog učenja leži u pretraživanju raznolikog spektra potencijalnih funkcija kako bi se konačno pronašla najprikladnija funkcija koja objašnjava i opisuje odnose među atributima unutar skupa podataka (Kelleher, 2019). Algoritam strojnog učenja može se konceptualizirati kao proceduralni okvir, sličan receptu ili programu, kojim upravljaju računala. U okviru ove sfere, algoritam preuzima ključnu ulogu u pregledu skupa podataka, identifikaciji ponavljajućih uzoraka i sintetiziranju istih u korisne uvide (Kelleher, 2019). Za stvaranje sustava sposobnih za učenje i postizanje određenih rezultata, nužno je stvaranje modela. Model predstavlja krajnji rezultat interakcije između algoritma strojnog učenja i korpusa ulaznih podataka, utjelovljujući znanje asimilirano od strane algoritma. S obzirom na intrinzičnu povezanost između algoritma strojnog učenja i rezultirajućeg modela, algoritam služi kao vodič kroz kojeg se obrađuje skup podataka, što na kraju dovodi do stvaranja modela (Brownlee, 2016). Proces treniranja modela strojnog učenja obično se odvija kroz sedam sekvencijalnih faza, kako je detaljno opisano u nastavku. Ovaj okvir temelji se na širokom rasponu znanstvenih rasprava (Goodfellow et al., 2016).

Proces treniranja u strojnom učenju uključuje iterativnu optimizaciju parametara modela (ili težina) na temelju promatranih podataka kako bi se minimizirala određena ciljna funkcija (ili funkcija gubitka). Ovaj proces omogućuje modelu da nauči obrasce i odnose unutar podataka, omogućujući mu da precizno predviđa ili donosi odluke o neviđenim podacima (Sarker, 2021a).

- **Prikupljanje podataka** – Prikupljanje podataka je početni korak u procesu strojnog učenja. Važnost ovog koraka proizlazi iz činjenice da modeli strojnog učenja nisu izuzeti od pravljenja grešaka, a pouzdanost i učinkovitost krajnjeg prediktivnog modela ovise o kvaliteti i obilju podataka koje sustav koristi (Radišić et al., 2023). Stoga je ključno koristiti dovoljno veliki skup podataka kako bi model mogao učinkovito primijeniti naučeno na novim, dosad neviđenim podacima (Seljan et al., 2023). Dinamika ove faze ovisi o opsegu i zahtjevima samog projekta (Banoula, 2023).
- **Priprema podataka** – Nakon prikupljanja podataka, podaci se temeljito pripremaju kako bi se osigurala njihova pogodnost za daljnju analizu. Ova faza obuhvaća niz

pripremnih postupaka usmjerenih na smanjenje faktora koji bi mogli utjecati na krajnji model. Ključan dio pripreme podataka jest namjerna permutacija redoslijeda podataka kako bi se u unijela nasumičnost, koja štiti od nepoželjne pristranosti koja bi mogla iskriviti analitičke zaključke. Nadalje, ovom fazom se nameće obavezni odabir atributa koji će biti prisutni u izgradnji modela. Izabrani atributi izravno utječu na vremenske okvire izvršenja i rezultate. Identifikacija potencijalnih neuravnoteženosti u podacima je također ključna. Neuravnoteženost podataka odnosi se na neujednačenu distribuciju podataka među različitim željenim ishodima. Suočavanje s takvim podacima osigurava uravnoteženu reprezentaciju, sprečavajući nepoželjnu sklonost prema ishodu koji je nesrazmjerno zastupljen, što je nepoželjno. Podaci se dijele na dva dijela, jedan za treniranje modela, koji čini većinu početnog skupa podataka, i drugi za evaluaciju, tj. testiranje modela. Standardni omjer podataka za treniranje prema evaluaciji je obično 80:20. Ova faza, ovisno o osobinama skupa podataka, može zahtijevati dodatne pripreme postupke, uključujući uklanjanje duplikata i slične operacije (Banoula, 2023).

- **Odabira modela** – nakon pripreme podataka slijedi odabir odgovarajućeg modela na temelju prirode problema, karakteristika podataka i željenih rezultata. Ovdje je moguć niz modela, svaki prilagođen određenim zahtjevima (Banoula, 2023).
- **Treniranje modela** – Ova ključna faza predstavlja srž strojnog učenja. U ovoj fazi prethodno obrađeni skup podataka koristi se kako bi se postupno i iterativno poboljšala prediktivna sposobnost modela. Prije samog treniranja, potrebno je inicijalizirati težinske parametre. Ovi težinski parametri početno se postavljaju s nasumičnim vrijednostima i služe kao faktori koji utječu na povezanost između ulaza i izlaza. Tijekom treniranja algoritam ih samostalno kalibrira tijekom svakog koraka treniranja (Banoula, 2023).
- **Evaluacija** – Nakon treniranja modela slijedi njegova evaluacija. Glavni zadatak je testirati performanse modela kako bi se utvrdilo ispunjava li propisane kriterije. Kao što je već navedeno, početni skup podataka je podijeljen, a u ovom slučaju drugi segment, namijenjen evaluaciji, dobiva na važnosti. Evaluacija uključuje testiranje modela na prethodno neviđenim podacima, podacima koji do tada nisu bili korišteni tijekom procesa treniranja. Ova faza služi kao mjerilo stvarne učinkovitosti modela. Preciznost modela koja iznosi 50% ili manje označava njegovu neprimjerenost za praktičnu primjenu. Nasuprotno tome, model koji postiže preciznost predviđanja veću

od 90% ulijeva povjerenje u njegovu buduću uporabu u stvarnom svijetu (Banoula, 2023).

- **Podešavanje parametara** – U slučaju nezadovoljavajućih rezultata evaluacije ili prepoznavanja potrebe za poboljšanjem, dostupna je faza podešavanja parametara. Ovaj korak omogućuje prilagodbu parametara modela kako bi se omogućilo njegovo poboljšanje nakon treniranja. Mogu se primijeniti različite strategije kako bi se ublažili nepoželjni događaji unutar modela. Prvo, može se razmotriti povećanje iteracija treniranja, poznatih kao epohe. Osim toga, moguće je podešavanje parametra stope učenja, vrijednosti koja množi gradijent kako bi ga postupno približila globalnom ili lokalnom minimumu kako bi se minimizirala funkcija gubitka. Važno je voditi računa i biti precizan prilikom mijenjanja ovih parametara, budući da i male varijacije mogu znatno utjecati na vremenske okvire izvršenja. Kalibracija ovih parametara predstavlja izazovni zadatak, zahtijeva iterativno istraživanje kako bi se odredile optimalne vrijednosti, s obzirom na inherentnu varijabilnost određenog projekta (Banoula, 2023).
- **Predikcija ili zaključivanje** – Posljednja faza, predikcija ili zaključivanje, završava proces strojnog učenja. U ovom trenutku, model je spreman za upotrebu i aktivno se koristi kako bi se postigli željeni rezultati (Banoula, 2023).

Kontinuum strojnog učenja odvija se kroz pažljivo osmišljenu sekvencu koja obuhvaća prikupljanje i pripremu podataka, odabir modela, treniranje, evaluaciju, podešavanje parametara, te zaključivanje. Svaka faza ima svoju važnu i neizostavnu ulogu u stvaranju učinkovitih modela strojnog učenja sposobnih za rješavanje različitih stvarnih problema (Goodfellow et al., 2016).

3.3. Metode strojnog učenja

Metode strojnog učenja tradicionalno se klasificiraju u tri različite paradigme ovisno o prirodi ulaznih signala tijekom procesa učenja i povratnim informacijama koje se pružaju sustavu koji se oslanja na strojno učenje (Russell & Norvig, 2021). Te kategorizacije obuhvaćaju nadzirano učenje (engl. *supervised learning*), nenadzirano učenje (engl. *unsupervised learning*) i podržano učenje (engl. *reinforcement learning*).

U kontekstu nadziranog učenja, model se obučava kroz primjere temeljene na prethodno označenim skupovima podataka, omogućujući algoritmu da razazna obrasce i

međusobne odnose. Suprotno tome, nenadzirano učenje omogućuje modelu samostalno otkrivanje skrivenih struktura i obrazaca prisutnih u neoznačenim skupovima podataka. S druge strane, podržano učenje djeluje po principu iterativnog usavršavanja, pri čemu model dinamički prilagođava svoje ponašanje na temelju sustava nagrada i kazni koje iterativno dobiva od svoje okoline, s ciljem optimizacije predefinirane ciljne funkcije (Goodfellow et al., 2016).

3.3.1. Nadzirano strojno učenje

Nadzirano strojno učenje predstavlja dominantnu paradigmu u području strojnog učenja (Kelleher, 2019), koju karakterizira oslanjanje na označene skupove podataka za treniranje modela. Unutar tog okvira, svaki podatak u skupu podataka pažljivo je anotiran od strane stručnjaka s odgovarajućim ciljnim vrijednostima, potičući vođeni proces učenja. Ova temeljita označavanja obogaćuju algoritam učenja neophodnim povratnim informacijama, olakšavajući istraživanje odnosa, uzoraka i suptilnosti koje postoje unutar korpusa podataka. Na primjer, skup podataka može sadržavati slike životinja (poput pasa i mačaka), uz pripadajuće oznake koje govore sustavu koja životinja se nalazi na svakoj slici. Primarni cilj nadziranog učenja jest da model stekne sposobnost, nakon faze treniranja, neovisno prepoznati i kategorizirati ulazne podatke, pridružujući im odgovarajuće oznake (npr. pas ili mačka) (Russell & Norvig, 2021). To podrazumijeva izgradnju snažnog modela iterativnim korištenjem algoritama, gdje model uči na temelju označenih podataka. Sukcesivno, tijekom faze zaključivanja, stečeno znanje modela omogućuje mu da generalizira svoje učenje i donese informirane predikcije za neviđene ulazne primjere (Lawton, 2023).

Praktične primjene nadziranog strojnog učenja obiluju u različitim područjima, od složenih kategorizacija e-pošte (Seljan et al., 2023) do suptilnih klasifikacija teksta (Katalinić et al., 2023) (Kovač et al., 2022) i slika. Nadalje, njegova korisnost proteže se na sofisticirane napore poput analize govora i analize suptilnih jezičnih konstrukcija. Štoviše, modeli obučeni kroz nadzirani modalitet služe kao sredstva u prediktivnoj analitici, koristeći prošle stručne odluke kao temelj za predviđanje budućih radnji ili ishoda (IBM, n.d.) (Kelleher, 2019) (Goodfellow et al., 2016). Uloga nadziranog učenja proteže se i na zahtjevne zadatke poput analize govora i razmatranja suptilnih jezičnih konstrukcija.

U suštini, nadzirano učenje predstavlja strateški pristup koji koristi označene skupove podataka kako bi vodio proces učenja, omogućavajući modelima da donose precizne predikcije na temelju naučenih uzoraka i odnosa (Goodfellow et al., 2016).

3.3.2. Nenadzirano strojno učenje

Nenadzirano učenje se razlikuje od nadziranog učenja po svojoj uporabi korpusa ulaznih podataka koji su lišeni eksplicitnih oznaka; naime, sustav nenadziranog učenja prima ulazni skup neoznačenih podataka. Unutar ove paradigme strojnog učenja, algoritmi nastoje analizirati i grupirati te neoznačene podatke kako bi autonomno otkrili obrasce i zajedničke karakteristike, bez ljudske intervencije (Russell & Norvig, 2021). Poznato po izvanrednoj sposobnosti otkrivanja sličnosti i razlika unutar neoznačenih skupova podataka, nenadzirano učenje ističe se kao moćan alat u domenama poput segmentacije korisnika, prepoznavanja slika i analize podataka (IBM Cloud Education, n.d.).

Algoritmi strojnog učenja, korišteni za analizu podataka i grupiranje, zaduženi su za identificiranje značajki ključnih za povezivanje sličnih instanci u koherentne skupine. Ove skupine, nedefinirane na početku i oblikovane analizom podataka, predstavljaju integralne komponente nastojanja u nenadziranom učenju. Primjerice, podatkovni znanstvenik može algoritmu dati ciljan broj grupa na temelju stručnosti u domeni, bez izričitog određivanja relativnih veličina ili specifičnih karakteristika instanci unutar svake skupine (Kelleher, 2019). Ovaj fleksibilan pristup nalazi primjenu u različitim domenama, obuhvaćajući zadatke grupiranja, otkrivanja anomalija i smanjenja dimenzionalnosti. Grupiranje i smanjenje dimenzionalnosti predstavljaju uobičajene ciljeve u nastojanjima nenadziranog učenja. Grupiranje ima za cilj spojiti slične podatke, otkrivajući prirodne skupine ili grupe unutar skupa podataka, dok tehnike smanjenja dimenzionalnosti nastoje predstaviti složene podatke u prostoru niže dimenzije zadržavajući bitne informacije. Posebno korisno u scenarijima s obimnim skupovima podataka u kojima je ručno označavanje nepraktično ili financijski neisplativo, nenadzirano učenje naglašava svoju važnost kao svestrana i nezaobilazna komponenta među metodologijama strojnog učenja (IBM Cloud Education, n.d.).

Modeli umjetne inteligencije generirani putem nenadziranog učenja izbjegavaju potrebu za izravnom ljudskom intervencijom, budući da je postupak treniranja uglavnom automatiziran. Iako određene metodologije mogu emulirati ljudske pedagoške principe, strogo pridržavanje

ljudskih metoda poučavanja nije preduvjet. Naprotiv, modeli umjetne inteligencije izvedeni iz nenadziranog učenja često se koriste za zadatke opisne analitike, uključujući sažimanje sadržaja, klasifikaciju, izdvajanje značajki, identifikaciju obrazaca i kategorizaciju podataka (IBM Cloud Education, n.d.) (Lawton, 2023).

3.3.3. Podržano strojno učenje

Podržano učenje predstavlja metodu unutar strojnog učenja koja počiva na pretpostavci da se računalni sustav može trenirati putem izvođenja radnji unutar određenog okruženja, s ciljem optimiziranja kumulativnih signala nagrađivanja stvorenih tijekom sekvencijalnih interakcija. U ovom procesu, sustav izvodi radnje unutar svojeg operativnog okruženja i za svaki pokušaj dobiva povratne signale koji mu ukazuju na ispravnost ili neispravnost izvršenja. Kroz proces kontinuirane prilagodbe i učenja, sustav nastoji maksimizirati nagrade dok minimizira negativnu povratnu informaciju. Podržano učenje se stoga oslanja na iterativni model treniranja, obilježen ciklusima testiranja, procjene nagrada i ispravaka pogrešaka (Russell & Norvig, 2021).

U ovakvim scenarijima, model nastoji otkriti obrasce ponašanja koji pridonose maksimiziranju nagrada unutar danog okruženja (Kelleher, 2019). Ta simbioza između modela i njegovog okruženja daje sposobnost izvođenja radnji i, sukladno tome, primanje nagrada ili kazni, čime se tijekom vremena poboljšavaju njegove sposobnosti donošenja odluka. Glavni cilj podržanog učenja je naučiti mapiranje između trenutnog promatranja okruženja, vlastitog unutarnjeg stanja (memorije) i određivanje radnji koje se trebaju poduzeti. Afirmativni signali nagrađivanja, tj. pozitivna nagrada služe jačanju mapiranja iz relevantnih promatranja i stanja prema određenoj radnji, dok negativni signali, tj. kazna oslabljuje navedeno mapiranje (Kelleher, 2019). Ovaj tip učenja često se koristi za zadatke poput igranja računalnih igara i robotike (Autoblocks, n.d.).

Jedan primjer učinkovitosti podržanog učenja demonstriran je od strane Googleove tvrtke DeepMind Technologies, koja je pokazala svoju sposobnost upotrebom podržanog učenja za treniranje dubokog modela za ovladavanje sedam Atari računalnih igara (Mnih et al., 2013). Inherentna struktura računalnih igara pruža idealnu platformu za podržano učenje, budući da sustav može sudjelovati u uzastopnim iteracijama protiv računalnog sustava, omogućavajući mu da autonomno izoštri svoje strategije upravljanja, bez potrebe za obimnim skupovima

podataka s označenim primjerima i odgovarajućim radnjama. DeepMind sustav je pokazao izuzetnu vještinu u tim igrama, nadmašujući prethodne računalne sustave u šest od sedam igara te čak nadmašujući ljudske stručnjake u tri igre (Kelleher, 2019).

Trio nadziranog, nenadziranog i podržanog strojnog učenja predstavlja temelje umjetne inteligencije i strojnog učenja. Zajedno potiču inovaciju, omogućujući strojevima da navigiraju kroz složenu okolinu podataka s novom razinom kognitivne sposobnosti, te se kao takvi koriste u drugim poljima umjetne inteligencije (Lawton, 2023).

4. Umjetne neuronske mreže i duboko učenje

Umjetne neuronske mreže i duboko učenje predstavljaju bitne paradigme unutar područja umjetne inteligencije, revolucionirajući način na koji strojevi percipiraju, uče i zaključuju. U neprestano razvijajućem krajoliku umjetne inteligencije, umjetne neuronske mreže i duboko učenje predstavljaju nov način na koji strojevi shvaćaju i interpretiraju podatke. Ukorijenjene u inspiraciji iz neuronske strukture ljudskog mozga, umjetne neuronske mreže su temeljne građevne jedinice koje otvaraju put za složenije područje dubokog učenja (Singh, 2024). Duboko učenje, karakterizirano mrežama s više skrivenih slojeva, proširuje mogućnosti tradicionalne umjetne neuronske mreže omogućujući izvlačenje hijerarhijskih značajki iz složenih skupova podataka. Zajedno, umjetne neuronske mreže i duboko učenje omogućuju strojevima da autonomno uče hijerarhijske reprezentacije iz podataka, otkrivajući obrasce koji su nekad bili izvan dosega tradicionalnih računalnih pristupa (Goodfellow et al., 2016).


U središtu ove istraživačke aktivnosti leži emulacija neuronske arhitekture ljudskog mozga, otvarajući put strojevima da samostalno uoče obrasce i informacije, te da se autonomno prilagođavaju. Duboko učenje istražuje složene arhitekture s više slojeva, omogućujući izvlačenje hijerarhijskih značajki (Goodfellow et al., 2016).

4.1. Umjetne neuronske mreže

Umjetne neuronske mreže su računalni modeli izvorno inspirirani strukturom i funkcionalnošću bioloških neuronskih mreža, posebice mrežom međusobno povezanih neurona u ljudskom mozgu koji obrađuju i prenose informacije. Umjetne neuronske mreže nastoje izgraditi funkcionalne i prilagodljive računalne sustave sposobne učiti složene obrasce iz podataka (Singh, 2024).

4.1.1. Biološki i umjetni neuron

Kao što je navedeno, umjetne neuronske mreže inspirirane su složenom arhitekturom i dinamičnim funkcionalnostima bioloških neuronskih mreža, poput povezanog skupa neurona koji se nalaze u ljudskom mozgu. S milijardama međusobno povezanih neurona koji komuniciraju putem električnih i kemijskih signala, mozak omogućuje percepciju, učenje i donošenje odluka. U srži svake neuronske mreže nalazi se temeljni gradivni blok – neuron (Ujević Andrijić & Bolf, 2019).



Slika 2 Biološki neuron (Andrijić & Bolf, 2019)

Kao što je vidljivo na slici 2., biološki se neuron sastoji od tri osnovna dijela: tijela stanice (jezgra), dendrita i aksona. Tijelo stanice sadrži genetski materijal ključan za oblikovanje karakteristika neurona. Dendriti, koji se granaju oko tijela stanice, služe kao vodiči za primanje impulsa od susjednih neurona, dok akson, dugo i tanko vlakno, prenosi te signale drugim neuronima. Svaki neuron predstavlja diskretnu jedinicu unutar neuronske mreže, uspostavljajući veze sa susjednim neuronima kako bi formirao složenu mrežu razmjene informacija. Sinapse, spojevi između neurona, igraju ključnu ulogu u prijenosu signala. Omogućujući i električno i kemijsko signaliziranje, sinapse olakšavaju prijenos impulsa duž neuronskih krugova, ovisno o veličini signala i pragu za neuronalnu ekscitaciju (Ujević Andrijić & Bolf, 2019). Uobičajeno neuroni zadržavaju mirovno stanje sve dok ih ne potaknu elektrokemijski impulsi koji se prenose putem dendritičkih sinapsi. Kada premaše određeni prag, neuroni generiraju akcijske potencijale, električne impulse koji se šire duž aksona kako bi izazvali reakcije susjednih neurona. Nasuprot tome, nedovoljno jaki signali održavaju neurone u mirovanju. Aktiviranje neurona slijedi jednostavno pravilo: ili će ostati u stanju mirovanja ili će postati aktivni. Umjetni neuroni se također pridržavaju ovih operativnih principa (Warwick, 2012).

Umjetne neuronske mreže nastoje emulirati funkcionalnost bioloških neurona putem upotrebe umjetnih neurona. Sastavljene od međusobno povezanih slojeva, ove mreže djeluju moduliranjem sinaptičkih težina, omogućujući prilagodljivo učenje, prepoznavanje uzoraka, prediktivno modeliranje i donošenje odluka. Ova sposobnost učenja i obrade informacija na način koji podsjeća na biološke neuronske mreže doprinosi izvanrednim sposobnostima umjetnih neuronskih mreža. Umjetni neuroni primaju ulazne vrijednosti, obrade ih, te daju izlazne vrijednosti (Patterson & Gibson, 2019).

4.1.2. Osnovna arhitektura umjetnih neuronskih mreža

Umjetni neuroni su računalne jedinice koje obrađuju informacije, a predstavljaju temeljne komponente unutar neuronskih mreža, tvoreći kompleksne, međusobno povezane slojeve ključne za obradu i prijenos informacija. Ti slojevi, obično podijeljeni u tri glavne strukture – ulazni sloj, jedan ili više skrivenih slojeva i završni izlazni sloj – upravljaju kognitivnim operacijama mreže (Patterson & Gibson, 2019).

- **Ulazni sloj** - Služi kao početna točka interakcije. On se sastoji od neurona koji direktno primaju sirove ulazne podatke. Svaki neuron simbolizira određenu značajku ili atribut ulaznog skupa podataka, zadužen isključivo za prihvrat sirovih podataka.

Svaki čvor unutar ulaznog sloja odgovara komponenti vektora značajki, djelujući kao kanal za protok sirovih ulaznih podataka bez uključivanja u računalne operacije. Njegova osnovna funkcija je olakšati neprekinuti prijenos ulaza do sljedećih skrivenih slojeva.

Ukratko, ulazni sloj ne samo što služi kao početna točka za operacije neuronske mreže, već i predstavlja svestrano sučelje sposobno prilagoditi se različitim formatima podataka. Njegova temeljita organizacija ulaznih podataka olakšava kasnije procesiranje, time podržavajući sposobnost mreže da iz sirovih informacija izvuče složene obrasce i značajke (Ognjanovski, 2020).

- **Skriveni slojevi** - Smješteni između ulaznih i izlaznih slojeva, skriveni slojevi mogu obuhvatiti jedan ili više slojeva. Neuroni unutar tih slojeva provode manipulaciju podataka i ekstrakciju značajki putem ponderiranih veza, olakšavajući stjecanje hijerarhijskih reprezentacija podataka.

Uključivanje više skrivenih slojeva omogućuje mreži razlikovanje složenijih hijerarhijskih reprezentacija podataka. Svaki čvor unutar skrivenog sloja prima ulaze iz prethodnih slojeva, primjenjuje ponderirane koeficijente i zatim rezultat izlaže aktivacijskoj funkciji.


Skriveni sloj, ili slojevi, djeluju kao posrednici informacija unutar kognitivne strukture mreže. Omogućujući stjecanje složenih relacijskih struktura i istaknutih značajki podataka, dubina i kompleksnost tih slojeva ovise o broju skrivenih slojeva i međusobnoj povezanosti neurona. Integracija više skrivenih slojeva pojačava sposobnosti mreže za obradu podataka (Ognjanovski, 2020).

- **Izlazni sloj** - Izlazni sloj odgovoran je za generiranje konačnih predikcija ili klasifikacija. Njegova konfiguracija (arhitektura), određena brojem neurona koje obuhvaća, odražava broj klasa u kategoričkim zadacima ili potrebnu dimenzionalnost izlaznog prostora.

Važno je istaknuti da se njegova strukturna izvedba prilagođava zahtjevima specifičnima za zadatak. Primjerice, u scenarijima binarne klasifikacije, izlazni sloj obično se sastoji od dva neurona, od kojih svaki predstavlja različitu klasu, čime se olakšava razgraničenje diskretnih kategorija (Ognjanovski, 2020).

U osnovi, dok ulazni sloj služi kao kanal za sirove, tj. neobrađene podatke, a skriveni slojevi obavljaju složeni zadatak manipulacije i transformacije podataka, izlazni sloj predstavlja sposobnost donošenja odluka neuronske mreže, što rezultira generiranjem konačnih predikcija ili klasifikacija ključnih za rješavanje zadatka (Patterson & Gibson, 2017) (AWS, n.d.).

Osnovna arhitektura neuronske mreže vizualno je prikazana na slici 3.



Slika 3 Ilustracija jednostavne neuronske mreže (Kelleher, 2019)

Svaka jedinica prikazana na gornjem dijagramu simbolizira neuron koji usmjerava transformaciju ulaznih vrijednosti u odgovarajuće izlazne reprezentacije. Strelice označavaju tok informacija kroz mrežu, prikazujući prijenos izlaza jednog neurona kako bi poslužio kao ulaz drugom neuronu. Ovaj jednosmjerni tok informacija, obično s lijeva na desno, opisuje način na koji mreža funkcionira (Kelleher, 2019).

4.2. Proces treniranja umjetnih neuronskih mreža

Treniranje umjetnih neuronskih mreža predstavlja složeni pothvat, ključan za omogućavanje ovih računalnih modela da izvlače uvide iz podataka i donose informirane predikcije kroz iterativno podešavanje parametara na temelju uvida dobivenih iz podataka (Patterson & Gibson, 2017). Sljedeći dio će produbiti razumijevanje procesa treniranja, no valja napomenuti da opisan postupak pruža samo pregled treniranja umjetnih neuronskih mreža, opisujući njezine osnovne faze i postupke (AWS, n.d.).

4.2.1. Važni pojmovi

Kako bi se lakše razumio proces treniranja umjetnih neuronskih mreža, korisno je najprije definirati neke od temeljnih pojmova koji utječu na proces treniranja (Patterson & Gibson, 2017): težinski faktor, pristranost i aktivacijska funkcija.

- **Težinski faktori** - predstavlja numeričke vrijednosti povezane s vezama koje povezuju neurone unutar neuronske mreže. Svaka veza opremljena je težinom koja određuje veličinu i utjecaj koji jedan neuron ima na drugi. Ti faktori igraju ključnu ulogu u reguliranju protoka signala između neurona, olakšavajući prilagodbu mreže i poboljšavajući operativnu učinkovitost usklađivanjem s ulaznim podacima i specifičnim ciljevima. Inicijalizirani nasumičnim vrijednostima, ti faktori tijekom faze treniranja prolaze kroz iterativna prilagođavanja kako bi zadovoljili naredne zahtjeve umjetne neuronske mreže. Ti adaptivni procesi su neophodni za dinamiku učenja mreže i poboljšanje njezine izvedbe tijekom sukcesivnih iteracija procesa učenja. Težine se nalaze kako između ulaznih podataka i neurona, tako i među međusobno povezanim neuronima, određujući snagu i

smjer protoka informacija unutar mreže. U osnovi, težinski faktori upravljaju snagom sinaptičkih veza, definirajući opseg utjecaja jednog neurona na drugi (D'Agostino, 2022).

- **Pristranosti** - predstavljaju dodatne numeričke parametre povezane s pojedinačnim neuronima unutar mreže, djelujući kao vrsta „pomaka“. Dok težine reguliraju opseg međuneuronske povezanosti, pristranosti unose fleksibilnost i prilagodljive sposobnosti u prediktivne sposobnosti mreže. Prije nego što ulazni podaci prođu kroz aktivacijsku funkciju, pristranosti se integriraju u ukupni zbroj ulaznih signala. Ova nadogradnja omogućava mreži generiranje vrijednosti koje nisu nula, čak i kada su sve ulazne značajke nula, omogućujući otkrivanje uzoraka koji možda nisu izravno povezani s određenim ulaznim vrijednostima (D'Agostino, 2022).

- **Aktivacijske funkcije** - matematičke operacije primijenjene na izlazima pojedinačnih neurona unutar neuronske mreže. Primarna svrha aktivacijskih funkcija je unijeti nelinearnost u mrežu, omogućujući joj učinkovito modeliranje složenih odnosa između ulaznih i izlaznih varijabli. Takve nelinearnosti su neizostavne, jer stvarni podaci često pokazuju složene, nelinearne strukture koje linearni modeli ne mogu adekvatno obuhvatiti. Bez aktivacijskih funkcija, neuronska mreža bi bila ograničena samo na linearnu kombinaciju svojih ulaza. Te funkcije djeluju kao matematički operatori koji djeluju na ukupnost ulaznih podataka, težina i pristranosti, određujući sklonost neurona za aktivaciju na temelju transformiranih vrijednosti. Taj mehanizam omogućava besprijekoran protok podataka kako kroz unutarnje slojeve mreže, tako i prema konačnom izlazu (D'Agostino, 2022).

4.2.1.1. Proces treniranja

Pored postupaka prikupljanja i pripreme ulaznih podataka, proces treniranja uključuje sljedeće korake (Goodfellow et al., 2016) (Elmsley, 2019):

- **Inicijalizacija** - Inicijalizacijski proces u obuci umjetnih neuronskih mreža ključan je jer utvrđuje početne vrijednosti težina i pristranosti, te je zbog toga ključan jer oblikuje „smjer kretanja“ mreže tijekom treniranja i na kraju utječe na njenu dinamiku konvergencije i performanse.
- **Algoritam propagacije unaprijed** (engl. *forward propagation*) - Proces treniranja umjetnih neuronskih mreža podrazumijeva niz međusobno povezanih faza, pri čemu

propagacija unaprijed predstavlja temeljnu komponentu. Propagacija unaprijed organizira prolazak ulaznih podataka kroz mrežu, pri čemu se aktivacije i izlazi sekvencijalno računaju preko njezinih hijerarhijskih slojeva.

Počevši od ulaznog sloja, ulaz sirovih podataka inicira proces. Svaki neuron unutar naknadnih slojeva sudjeluje u izračunu ponderirane agregacije svojih ulaza, integrirajući parametre stečene učenjem. Ta agregacija prolazi kroz modulaciju putem aktivacijske funkcije. Dok podaci prolaze kroz mrežu, dolazi do iterativnog usavršavanja i apstrakcije preko uzastopnih slojeva. Duboki slojevi unutar mreže sintetiziraju osnovne značajke kako bi stvorili kompleksnije, postupno transformirajući ulazne podatke u sve prepoznatljivije i značajnije reprezentacije. Kulminacija faze algoritma propagacije unaprijed leži na izlaznom sloju, gdje mreža generira izlazne vrijednosti zasnovane na spoznajama izvedenim iz mapiranja ulaza na izlaze. Te izlazne vrijednosti se stavljaju nasuprot stvarnim ciljnim vrijednostima, pružajući povratnu informaciju ključnu za vođenje daljnjeg kalibriranja parametara mreže kroz nadolazeće faze treniranja (Luhaniwal, 2023).

Ulazni podaci usmjereni su prema ulaznom sloju, a sljedeći slojevi izračunavaju izlaz svakog neurona na temelju agregiranog učinka ulaza i aktivacijske funkcije.

- **Računanje funkcije gubitka** - Funkcija gubitka bavi se kvantifikacijom razlike između predviđenih izlaza mreže i stvarnih vrijednosti cilja. Ovo neslaganje često nazvano „gubitkom“ ili „pogreškom“, preuzima temeljnu ulogu u evaluaciji učinkovitosti mreže te upravljanju naporima optimizacije parametara kako bi se minimizirale prediktivne devijacije.

Tijekom treniranja, nakon faze propagacije unaprijed, predviđanja mreže stavljaju se nasuprot stvarnim ciljnim vrijednostima. Disparitet između tih predviđanja i ciljeva kvantificira se putem predefinirane funkcije gubitka. Izračunata metrika gubitka služi kao kvantitativna mjera vjernosti mreže prema podacima korištenima za treniranje. Povišene vrijednosti gubitka ukazuju na izražene disparitete između predviđanja i stvarnih vrijednosti, dok umanjene vrijednosti gubitka sugeriraju bliže podudaranje izlaza mreže i stvarnih ciljeva.

Bitno je napomenuti da funkcija gubitka pruža povratne informacije tijekom sljedeće faze algoritma propagacije unatrag, obavještavajući o prilagodbama parametara, poput prilagodbi težina i pristranosti, u smjeru koji minimizira gubitak. Kroz iterativni proces fino podešen na temelju izračunatih gubitaka, mreža postupno poboljšava svoje prediktivne sposobnosti,

postupno se približavajući točnijim predviđanjima na neviđenim podacima (DataRobot AI Platform, 2018).

- **Algoritam propagacije unatrag (algoritam povratne propagacije)** (engl. *backpropagation*) - Uključuje iterativno prilagođavanje parametara mreže, posebno težina i pristranosti, kako bi se umanjile razlike između predviđenih izlaza i stvarnih ciljnih vrijednosti.

Ona potiče retrogradno širenje signala pogreške kroz mrežu. Ovaj proces uključuje derivaciju gradijenta funkcije gubitka u odnosu na svaki parametar mreže primjenom pravila derivacije. Nakon što se izračunaju gradijenti, parametri mreže podvrgavaju se iterativnom prilagođavanju, potpomognutom tehnikama optimizacije poput gradijentnog spusta. Ovaj iterativni proces optimizacije traje dok se ne postigne konvergencija, koju karakterizira minimalna pogreška između predviđanja i stvarnih ciljeva.

Sveukupno, propagacija unatrag opskrbljuje umjetne neuronske mreže s kapacitetom da apsorbiraju razlike između predviđenih i stvarnih rezultata, iterativno podešavajući parametre kako bi se minimalizirala pogreška, time potičući poboljšanu generalizaciju i prediktivnu točnost na neviđenim podacima (McGonagle et al., n.d.).

- **Gradijentni spust** (engl. *gradient descent*) - Gradijentni spust predstavlja ključni optimizacijski algoritam neophodan u procesu treniranja umjetnih neuronskih mreža. Njegova svrha leži u iterativnom prilagođavanju parametara mreže, uključujući težine i pristranosti, kako bi se sustavno minimizirala unaprijed određena funkcija gubitka.

Proces započinje derivacijom gradijenta funkcije gubitka u odnosu na svaki parametar. Taj gradijent osvjetljava i smjer i veličinu najizraženijeg uzdizanja funkcije gubitka unutar prostora parametara. Kretanjem u suprotnom smjeru od gradijenta, algoritam teži silaziti niz najstrmiji nagib funkcije gubitka, postupno smanjujući gubitak. Tijekom svake iteracije gradijentnog spusta, ažuriranje parametara odvija se oduzimanjem dijela gradijenta, nazvanog stopa učenja, pomnoženog sa samim gradijentom. Ovaj postupak osigurava da su prilagodbe parametara usmjerene na smanjenje gubitka uz kontrolu veličine koraka. Gradijentni spust se nastavlja iterativno sve dok se ne ispuni predefrirani kriterij zaustavljanja, poput postizanja određenog broja iteracija ili postizanja zadovoljavajućeg stupnja konvergencije. Tijekom ovog iterativnog postupka, pažljivo kalibriranje stope učenja ima iznimnu važnost jer upravlja njezinom osjetljivom ravnotežom između brzine konvergencije i stabilnosti (Donges, n.d.)

- **Iteracija** - Koraci obuhvaćeni treniranjem se ponavljaju kroz više iteracija ili epoha dok treniranje ne dosegne predefinirani kriterij zaustavljanja. Svaka iteracija uključuje propagaciju unaprijed za izračunavanje predikcija, računanje gubitka za kvantifikaciju greške, propagaciju unatrag za izračunavanje gradijenata, gradijentni spust za ažuriranje parametara i ažuriranje parametara za prilagodbu težina i pristranosti mreže.

Tijekom svake iteracije, mreža postupno usavršava svoje unutarnje reprezentacije, postupno učeći o složenim uzorcima i odnosima prisutnima u skupu podataka za treniranje. Trajanje i obujam iterativnog učenja (treniranja) ovise o nekoliko čimbenika, uključujući složenost zadatka, količinu i kvalitetu skupa podataka za treniranje, te unaprijed definirane kriterije konvergencije (Taye, 2023).

- **Validacija i testiranje** - Proces validacije i testiranja ključne su faze unutar procesa treniranja umjetnih neuronskih mreža, koje označavaju kritične stupnjeve za procjenu i ocjenu prediktivne učinkovitosti modela.

Validacija preuzima posredničku ulogu tijekom treniranja, olakšavajući procjenu izvedbe modela na zasebnom skupu podataka odvojenom od podataka za treniranje. Uobičajeno, dio dostupnog skupa podataka dodjeljuje se za svrhu validacije, i različit je od skupa podataka za treniranje. Model se postupno evaluira na ovom skupu za validaciju tijekom cijelog procesa treniranja. Metrike izvedbe izračunate na skupu za validaciju, uključujući metrike poput točnosti, preciznosti, odziva ili gubitka, služe kao mjere za procjenu sposobnosti generalizacije modela i otkrivanje pojava pretreniranja ili podtreniranja. Uvide dobivene iz rezultata validacije često koristimo za prilagodbu hiperparametara ili usavršavanje postupka treniranja kako bi se optimizirala prediktivna učinkovitost modela. S druge strane, testiranje predstavlja zaključnu fazu evaluacije, uključujući procjenu prediktivne izvedbe modela na neviđenim podacima kako bi se utvrdila njegova sposobnost generalizacije na nove, neviđene primjere. Poseban testni skup podataka, neovisan o skupovima za treniranje i validaciju, koristi se isključivo u tu svrhu. Obučeni model primjenjuje se na testni skup podataka, nakon čega se pažljivo izračunavaju metrike izvedbe i uspoređuju sa stvarnim oznakama istinitosti. Procjene izvedbe na testnom skupu pružaju pouzdanu procjenu stvarne izvedbe modela i njegovu sposobnost generiranja točnih predikcija u praktičnim primjenama (Prמודitha, 2022) (Hieda, n.d.).

Zaključno, umjetne neuronske mreže predstavljaju moćan računalni okvir inspiriran strukturom i funkcijom ljudskog mozga. Njihova svestranost i prilagodljivost čine ih

neprocjenjivim alatima u različitim domenama, od prepoznavanja slika i govora do obrade prirodnog jezika i autonomnih sustava. Kako istraživanje napreduje i kako se razvijaju nove arhitekture i algoritmi, potencijalne primjene umjetnih neuronskih mreža nadilaze konvencionalne granice umjetne inteligencije i osnažuju područja znanstvenog istraživanja, industrijske inovacije i tehnološkog napretka (Goodfellow et al., 2016).

5. Duboko učenje

Nadograđujući temelj umjetnih neuronskih mreža, duboko učenje omogućuje strojevima da autonomno prepoznaju složene obrasce i reprezentacije izravno iz sirovih podataka. Duboko učenje je usredotočeno na neuronske mreže koje se odlikuju s više skrivenih slojeva povezanih neurona – duboke neuronske mreže. Te mreže posjeduju izvanrednu sposobnost izvlačenja suptilnih uzoraka i reprezentacija iz velikih skupova podataka, često s minimalnim ljudskim intervencijama ili eksplicitnim oblikovanjem značajki (IBM, n.d.).

Pojam dubine u kontekstu dubokog učenja odnosi se na strukturalnu složenost arhitektura neuronskih mreža, koja je određena mnoštvom slojeva koji čine mrežu. Za razliku od plitkih arhitektura, koje obuhvaćaju ograničen broj slojeva, duboke mreže karakterizira značajan porast slojeva (nekoliko desetaka, stotina ili čak tisuća). Svaki sloj unutar duboke neuronske mreže „nadgleda“ različitu fazu računanja, pri čemu ulazni podaci prolaze kroz složene transformacije putem mnoštva ponderiranih veza i aktivacijskih funkcija (Sarker, 2021b). Dubina neuronske mreže bitna je za njezinu sposobnost da obuhvati suptilne obrasce i međusobne odnose inherentne u strukturi podataka. Duboke arhitekture manifestiraju poboljšanu sposobnost prepoznavanja nijansiranih značajki i hijerarhijskih struktura, čime omogućuju stjecanje apstraktnih, visokih razina reprezentacija. Ova hijerarhijska ekstrakcija značajki pokazuje se neophodnom u nizu domena, poput klasifikacije slika, obrade prirodnog jezika i prepoznavanja govora, u kojima podaci često pokazuju složene i hijerarhijske osobine (Goodfellow et al., 2016).

5.1. Odnos umjetnih neuronskih mreža i dubokog učenja

Umjetne neuronske mreže čine ključan podskup unutar šireg polja dubokog učenja, a karakteriziraju ih višestruki skriveni slojevi. Umjetne neuronske mreže, ukorijenjene u konceptu oponašanja strukture i funkcije bioloških neuronskih mreža, služe kao temeljni elementi unutar metodologije dubokog učenja (AWS, n.d.-a).

Odnos između umjetnih neuronskih mreža i dubokog učenja je jako usko povezan; umjetne neuronske mreže služe kao osnovni gradivni blokovi za stvaranje složenih struktura dubokog učenja. U središtu ove veze leži ideja da umjetne neuronske mreže samostalno uče hijerarhijske

reprezentacije, što omogućuje modelima dubokog učenja automatsko otkrivanje i razumijevanje složenih uzoraka i odnosa u velikim skupovima podataka. Zahvaljujući slojevitoj strukturi, arhitekture dubokog učenja olakšavaju postupno apstrahiranje i poboljšanje značajki kroz slojeve, što rezultira izvlačenjem visokih, apstraktnih reprezentacija ključnih za precizno predviđanje ili klasifikaciju (Goodfellow et al., 2016).

5.2. Hijerarhijsko učenje značajki

Hijerarhijsko učenje u dubokom učenju odnosi se na proces kojim neuronska mreža uči izvlačiti sve apstraktnije i složenije reprezentacije podataka kroz višestruke slojeve računanja. U svojoj srži, hijerarhijsko učenje imitira hijerarhijsku obradu informacija u ljudskom mozgu, gdje se nižerazinske značajke kombiniraju kako bi formirale višerazinske koncepte. Ovaj pristup omogućuje modelima dubokog učenja automatsko otkrivanje značajnih uzoraka i odnosa unutar podataka bez eksplicitnog programiranja (Taye, 2023).

Proces hijerarhijskog učenja započinje sirovim ulaznim podacima, koji se obično predstavljaju kao numeričke vrijednosti. U zadacima obrade slika, primjerice, ulazni podaci mogu se sastojati od intenziteta piksela, dok se u zadacima obrade prirodnog jezika ulazni podaci mogu sastojati od ugrađenih riječi ili vektora s jedinicom aktivacije koji predstavljaju riječi.

Kako ulazni podaci prolaze kroz slojeve neuronske mreže, svaki sloj provodi transformacije na podacima, izvlačeći sve apstraktnije značajke. Niže razine mreže obično uče detektirati jednostavne uzorke ili značajke, poput rubova ili tekstura u slučaju slika, dok više razine uče kombinirati ove značajke kako bi predstavile složenije koncepte, poput objekata ili scena.

Hijerarhijsko učenje djeluje na temelju sljedećih principa:

- **Niske značajke** - U početnim fazama duboke neuronske mreže, neuroni se specijaliziraju za prepoznavanje osnovnih značajki poput rubova, boja i tekstura.

Ove osnovne značajke kombiniraju se na različite načine kako bi formirale nešto složenije obrasce, omogućavajući mreži da predstavlja jednostavne strukture u podacima.

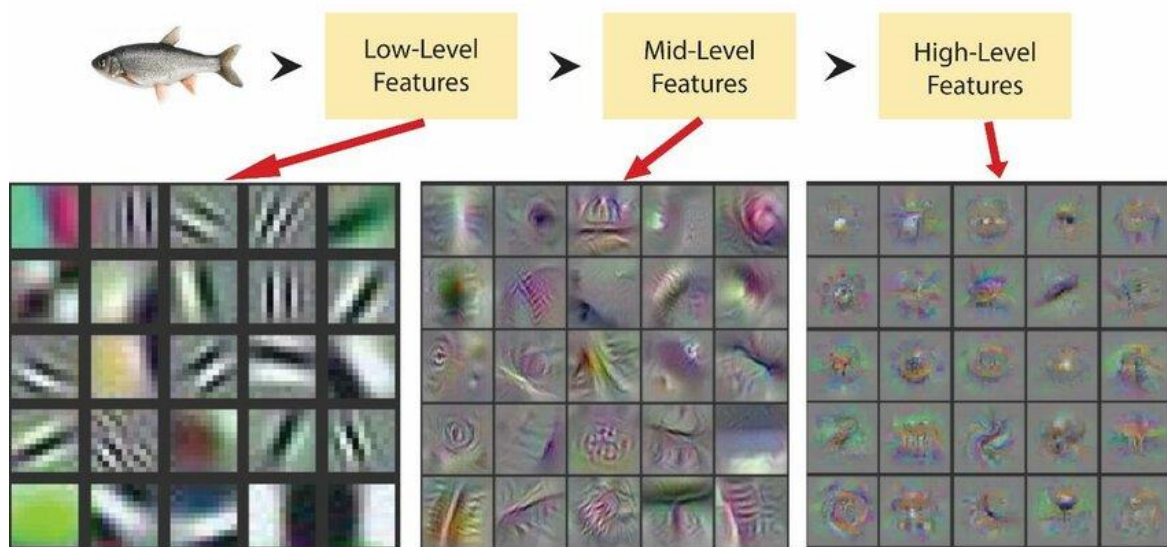
- **Srednje značajke** - Kako podaci prolaze kroz srednje slojeve, neuroni se razvijaju kako bi prepoznali nijansirane značajke kombinirajući niske reprezentacije.

Ove srednje značajke mogu uključivati oblike, teksture i kombinacije osnovnih elemenata, omogućujući mreži da razumije složenije strukture unutar ulaznih podataka.

- **Visoke značajke** - Posljednji slojevi mreže usredotočuju se na predstavljanje visokih značajki koje su još apstraktnije i reprezentativne za opće uzorke u podacima.

Ove visoke značajke nastaju kao kombinacije srednjih značajki i ključne su za sposobnost mreže da donese točne predikcije ili klasifikacije.

Stjecanjem hijerarhijskog razumijevanja značajki, arhitekture dubokog učenja mogu učinkovito dešifrirati i predstaviti složene strukture ugrađene u podatke. Hijerarhijsko učenje olakšava prisutnost nelinearnih aktivacijskih funkcija, primijenjenih na izlazu svakog neurona unutar mreže. Iterativnom primjenom transformacija kroz više slojeva, modeli dubokog učenja mogu otkriti hijerarhijske reprezentacije koje predstavljaju osnovnu strukturu podataka (Taye, 2023) (Goodfellow et al., 2016). Ovaj hijerarhijski način učenja značajki može se primijetiti na slici 4.



Slika 4 Prikaz hijerarhijskog učenja značajki (Elyasi, 2020)

Ovo hijerarhijsko učenje značajki može se dobro uočiti u jednoj od arhitektura dubokih neuronskih mreža – konvolucijskih neuronskih mreža.

5.2.1. Konvolucijske neuronske mreže

Konvolucijske neuronske mreže (engl. *Convolutional Neural Network, CNN*) postale su temelj u području računalnog vida, mijenjajući način na koji strojevi percipiraju i tumače vizualne podatke. Kroz svoju hijerarhijsku arhitekturu nadahnutu organizacijom vizualnog korteksa u ljudskom mozgu, konvolucijske neuronske mreže se ističu u učenju složenih uzoraka i reprezentacija izravno iz neobrađenih slika. Svaki sloj u konvolucijskoj neuronskoj mreži omogućuje joj progresivno izdvajanje i apstrahiranje značajki iz ulazne slike, drugim riječima, omogućuje hijerarhijsko učenje značajki (Craig & Awati, 2024).

Ova sposobnost hijerarhijskog učenja značajki omogućuje konvolucijskim neuronskim mrežama učinkovito razumijevanje prostornih hijerarhija i lokalnih ovisnosti unutar slika, što ih čini prikladnima za širok raspon zadataka računalnog vida, uključujući klasifikaciju slika, detekciju objekata, semantičku segmentaciju i generiranje slika. Taj se proces odvija kroz arhitekturu mreže, gdje se različiti slojevi usredotočuju na izvlačenje određenih aspekata ulaza. U suštini, konvolucijske neuronske mreže služe kao moćni alati za automatsko vizualno razumijevanje, omogućujući strojevima analizu i interpretaciju vizualnih podataka s ljudskom preciznošću i učinkovitošću (Goodfellow et al., 2016).

Arhitektura konvolucijskih neuronskih mreža uobičajeno uključuje naizmjenične konvolucijske i grupirajuće slojeve, koji se završavaju s jednim ili više potpuno povezanih slojeva. Konvolucijski slojevi predvode izdvajanje značajki, dok grupirajući slojevi smanjuju prostorne dimenzije i poboljšavaju računalnu učinkovitost. Potpuno povezani slojevi kombiniraju izdvojene značajke, obavljajući složene zadatke rasuđivanja i klasifikacije (IBM, n.d.-a).

5.2.1.1. Slojevi konvolucijskih neuronskih mreža

Osnovni slojevi konvolucijskih neuronskih mreža uključuju konvolucijski sloj, sloj sažimanja i potpuno povezani sloj (Panwar, 2020).

- **Konvolucijski sloj** (engl. *convolutional layer*) – U središtu konvolucijskih neuronskih mreža jedna je od najvažnijih operacija u području dubokog učenja – konvolucija. Ova osnovna matematička operacija omogućuje mrežama izdvajanje ključnih značajki iz

kompleksnih ulaznih podataka poput slika. Konvolucijski postupak omogućuje mreži otkrivanje različitih obrazaca i prostornih odnosa u ulaznim podacima, poput rubova, tekstura i geometrijskih oblika, rezultirajući stvaranjem mapa značajki. Ovdje su potrebni ulazni podaci, filter/jezgra (engl. *kernel*) te mapa značajki (engl. *feature map*) (Šarčević, 2022).

Zamislimo ulazne podatke kao sliku u boji, koja je predstavljena kao trodimenzionalna matrica piksela. Ova trodimenzionalna reprezentacija odgovara visini, širini i dubini slike, odnosno RGB (crvena, zelena, plava) kanalima. Kako bi otkrile značajke, konvolucijske mreže koriste filtere ili jezgre, koji se kreću po receptivnim poljima slike i provjeravaju prisutnost željenih obrazaca. Ovaj proces poznat je kao konvolucija, a rezultira stvaranjem mapa značajki koje ističu bitne informacije. Svaki filter predstavlja dvodimenzionalni niz težina koji predstavlja određeni aspekt slike. Iako se filteri mogu razlikovati po veličini, često se koriste matrice dimenzija 3x3, što također određuje veličinu receptivnog polja. Filter se primjenjuje na područje slike, a skalarni produkt između ulaznih piksela i filtera rezultira pojedinačnim izlazom koji tvori mapu značajki. Nakon obrade jednog područja slike, filter se pomakne na sljedeće područje, ponavljajući proces dok ne obuhvati cijelu sliku. Krajnji rezultat ovog procesa je stvaranje mapa značajki, koje predstavljaju ključne elemente slike. Kako podaci prolaze kroz slojeve konvolucijske mreže, mreža postupno prepoznaje sve veće i složenije obrasce, sve do potpune identifikacije ciljnog objekta ili entiteta. Filteri u dubljim slojevima specijalizirani su za detekciju niskorazinskih značajki poput rubova, tekstura i jednostavnih oblika, dok svaki filter reagira na specifične obrasce unutar svog receptivnog polja (Šarčević, 2022).

Ukratko, konvolucijski slojevi konvolucijskih neuronskih mreža predstavljaju ključni mehanizam za izdvajanje i analizu značajki u slikama, čime se omogućava mrežama da identificiraju i klasificiraju objekte te obavljaju složene vizualne zadatke s visokom razinom točnosti i efikasnosti IBM (n.d.-a).

- **Sloj sažimanja** (engl. *pooling layer*) – Slojevi sažimanja predstavljaju ključnu komponentu unutar arhitekture konvolucijskih neuronskih mreža, i strateški su pozicionirani kako bi pročistili i saželi ekstrahirane značajke iz prethodnih konvolucijskih slojeva. Ti slojevi djeluju neovisno na svakoj mapi značajki, koristeći mehanizme maksimalnog ili prosječnog grupiranja kako bi učinkovito smanjili prostorne dimenzije dok istovremeno zadržavaju bitne značajke. Maksimalno

sažimanje (udruživanje), kao prevladavajuća tehnika, selektivno zadržava najviše aktivacije unutar nepreklopljenih regija, efikasno komprimirajući prostorni prikaz mape značajki na temelju veličine prozora za sažimanje. Prozor za sažimanje je veličina prozora koja se koristi tijekom operacije sažimanja. On određuje prostorni opseg na kojem se primjenjuje sažimanje na ulaznu značajku. Nasuprot tome, prosječno sažimanje izračunava srednju vrijednost unutar svake regije, pružajući glađi učinak smanjenja (Šarčević, 2022).

Parametri koji upravljaju ponašanjem slojeva za sažimanje, poput veličine prozora za grupiranje i koraka, ključni su za određivanje opsega i ritma grupiranja preko mapa značajki. Međutim, značaj slojeva za sažimanje nadilazi samo smanjenje dimenzionalnosti. Ti slojevi imaju ključnu ulogu u promicanju invarijantnosti na translaciju – mogućnost mreže da prepozna uzorke na slici bez obzira gdje se nalaze, olakšavanju generalizacije značajki i pružanju regularizacije radi suzbijanja pretreniranja. Smanjenjem prostornih dimenzija podataka dok se istovremeno zadržavaju ključne značajke, slojevi za sažimanje doprinose poboljšanju invarijantnosti na translaciju mreže i smanjenju računalnog opterećenja.

Osim toga, u dubljim slojevima mreže, slojevi za sažimanje kombiniraju i integriraju lokalne značajke izvučene iz ranijih slojeva, omogućavajući mreži da percipira šire prostorne kontekste. Ovaj hijerarhijski proces učenja ne samo da potiče invarijantnost na translaciju, već i smanjuje osjetljivost na točno pozicioniranje značajki, olakšavajući prepoznavanje uzoraka na različitim lokacijama unutar ulaza (Šarčević, 2022).

Ukratko, sloj za sažimanje u konvolucijskim neuronskim mrežama predstavlja ključnu komponentu koja učinkovito uzorkuje podatke, poboljšava invarijantnost na translaciju, smanjuje računalno opterećenje i olakšava izvlačenje neophodnih značajki ključnih za precizno prepoznavanje i klasifikaciju slika IBM (n.d.-a).


- **Potpuno povezan sloj** (engl. *fully connected layer*) – Potpuno povezani sloj predstavlja ključnu komponentu unutar konvolucijskih neuronskih mreža. Za razliku od konvolucijskih i slojeva za sažimanje, koji uglavnom obrađuju prostorne odnose unutar ulaznih podataka, potpuno povezani slojevi kombiniraju izlaze iz prethodnih slojeva, povezujući svaki neuron iz prijašnjeg sloja sa svakim neuronom u sljedećem sloju (Šarčević, 2022).

Unutar potpuno povezanog sloja, svaki neuron u trenutnom sloju uspostavlja veze sa svakim neuronom u sljedećem sloju, čime se formira gusta matrica međusobnih veza. Ova

karakteristika implicira da svaka značajka izvučena u prethodnom sloju doprinosi ulazu svakog neurona u trenutnom sloju. S računalnog stajališta, potpuno povezani sloj izvršava matrično množenje, praćeno dodavanjem pristranosti, uz često korištenje aktivacijske funkcije radi uvođenja nelinearnosti. Strateški pozicionirani prema kasnijim fazama arhitekture mreže, potpuno povezani slojevi zaduženi su za prepoznavanje složenih obrazaca unutar prostora značajki i donošenje konačnih predikcija ili odluka. Oni igraju ključnu ulogu u izdvajanju visokorazinskih značajki iz nižerazinskih reprezentacija koje su stekli prethodni slojevi. Ti slojevi su ključni za detektiranje nijansiranih odnosa između značajki i izvođenje zadataka poput klasifikacije, regresije ili bilo kojeg drugog procesa donošenja odluka na višoj razini, temeljenih na naučenim reprezentacijama (Šarčević, 2022).

U suštini, potpuno povezani slojevi u konvolucijskim neuronskim mrežama igraju neizostavnu ulogu u izdvajanju visokorazinskih apstrakcija i donošenju konačnih predikcija na temelju naučenih reprezentacija. Oni omogućuju mreži prepoznavanje složenih obrazaca u podacima i neophodni su za izvođenje zadataka poput klasifikacije i regresije (Bodapati & Veeranjanyulu, 2018) IBM (n.d.-a).

Prikaz konvolucijske neuronske mreže i njenih slojeva vidljiv je na slici 5.




Slika 5 Konvolucijska neuronska mreža (SuperAnnotate, 2023)

5.2.1.2. Primjeri

Popularne arhitekture konvolucijskih neuronskih mreža odigrale su ključnu ulogu u razvoju područja dubokog učenja, svaka pridonoseći jedinstvenim inovacijama u području računalnog vida. Ovdje ćemo raspravljati o nekoliko istaknutih arhitektura CNN-a, uključujući LeNet, AlexNet te VGGNet (GfG, 2023):

- **LeNet** - Predstavljena od strane Yanna LeCuna i suradnika 1998. godine, LeNet je bila jedna od pionirskih arhitektura konvolucijskih neuronskih mreža za zadatak klasifikacije slika, a uspješno se koristila za prepoznavanje rukom pisanih znamenaka, posebno za prepoznavanje brojeva.

Primjer ovoga može se primijetiti na slici 6 gdje je naznačeno kako je „ulaz u mrežu slika dimenzija 32x32 piksela na kojoj se nalazi rukom napisana znamenka. Nakon primjene konvolucijskog sloja dobiva se 6 izlaznih mapa značajki koje su dimenzija 28x28. Mape značajki tada prolaze kroz sloj sažimanja u kojemu se dimenzije smanjuju na 14x14. Nakon toga opet slijedi konvolucijski sloj koji generira 16 mapa značajki koje su dimenzija 10x10 i još jedan sloj sažimanja koji mape značajki svodi na dimenzije 5x5. Zatim se primjenjuju 2 potpuno povezana sloja, jedan od 120 i drugi 84 neurona. Zadnji sloj sadrži 10 neurona koji označavaju klasu znamenaka od 0 do 9“ (Šarčević, 2022).



Slika 6 Arhitektura LeNet-5 mreže (DataScienceCentral, 2018)

- **AlexNet** - Predložena od strane Alexa Krizhevskog, Ilya Sutskevera i Geoffreya Hintonu 2012. godine, AlexNet je arhitektura konvolucijske neuronske mreže koja je stekla široku pažnju osvajanjem natjecanja ImageNet Large Scale Visual Recognition Challenge (ILSVRC) 2012. godine.

Karakterizira ju duboka arhitektura koja se sastoji od pet konvolucijskih slojeva praćenih slojevima maksimalnog sažimanja i tri potpuno povezana sloja (Šarčević, 2022).

- **VGGNet** - Razvijena od strane Visual Geometry Group (VGG) na Sveučilištu Oxford 2014. godine, VGGNet je poznata po svojoj jednostavnosti i uniformnoj arhitekturi, a osmišljena je kako bi se povećala dubina konvolucijske neuronske mreže u svrhu povećanja performansi modela. Mrežu su predstavili Andrew Zisserman i Karen Simonyan u znanstvenom radu naziva "Very Deep Convolutional Networks for Large-Scale Image Recognition".

Kao skup podataka za treniranje korištena je ImageNet baza podataka, koja sadrži više od 14 milijuna slika podijeljenih u oko 1.000 klasa, te je unatoč svojoj jednostavnosti, VGGNet mreža postigla impresivne rezultate na navedenom skupu podataka.

Sastoji se od više konvolucijskih slojeva s malim 3x3 filterima i slojevima maksimalnog sažimanja, praćenih potpuno povezanim slojevima na kraju. Kao ulaz u mrežu uzima se slika dimenzija 224x224. Nakon toga slijedi konvolucijski sloj u kojem se na sliku primjenjuje filter dimenzija 3x3. Arhitekture VGGNet-a imaju nazive prema njihovoj dubini, poput VGG-16 i VGG-19, koji imaju 16 odnosno 19 slojeva s težinama (Šarčević, 2022).

Ove arhitekture konvolucijskih neuronskih mreža značajno su doprinijele napretku zadataka računalnog vida, pokazujući važnost dizajna modela i arhitekturnih inovacija u postizanju najboljih performansi. Svaka arhitektura ima svoje prednosti i inovacije, prilagođavajući se različitim zahtjevima i izazovima u području dubokog učenja.

Ukratko, konvolucijske neuronske mreže su moćna vrsta neuronske mrežne arhitekture dizajnirane za obradu strukturiranih podataka, posebno slika i videozapisa. One su revolucionirale zadatke računalnog vida i imaju primjene u širokom spektru domena, uključujući klasifikaciju slika, detekciju objekata, segmentaciju slika, prepoznavanje lica, analizu medicinskih slika i slično. Kontinuirana istraživanja i inovacije u arhitekturi konvolucijskih neuronskih mreža doveli su do značajnog napretka u tehnologiji računalnog vida, otvarajući put za nove primjene u umjetnoj inteligenciji, kao što je neuronski prijenos stila.

6. Neuronski prijenos stila

Spoj umjetne inteligencije, dubokog učenja, i konvolucijskih neuronskih mreža donio je revolucionarnu eru umjetničkog izričaja, označavajući promjenu paradigme u stvaranju i manipulaciji vizualnog sadržaja. U središtu ovog transformacijskog presjeka nalazi se neuronski prijenos stila – inovativna tehnika koja spaja umjetnu inteligenciju s umjetnosti (Singh et al., 2021).

Neuronski prijenos stila predstavlja spoj dubokog učenja s umjetničkim izražavanjem, koristeći konvolucijske neuronske mreže za rastavljanje složenosti vizualnih uzoraka. Konvolucijske neuronske mreže igraju ključnu ulogu u prepoznavanju i izdvajanju suptilnih značajki, pridonoseći dubokom razumijevanju sadržaja algoritma. Prilikom sintetiziranja raznovrsnih vizualnih elemenata, poput sadržaja i stila, konvolucijske neuronske mreže razlažu detalje, identificirajući objekte i njihov raspored u prostoru, te zasebno analiziraju stilističke nijanse. Amalgamacija sadržaja i stila u neuronskom prijenosu stila predstavlja primjenu neuronskih mreža u kreativnoj manipulaciji slika. Umjesto jednostavnog preklapanja, neuronski prijenos stila uključuje duboko razumijevanje sastavnih elemenata, razaznavanje prepoznatljivog sadržaja i stilskih nijansi (Singh et al., 2021).

Ova inovativna tehnika predstavlja inovaciju računalne umjetnosti, koristeći naučene hijerarhijske reprezentacije kako bi obične fotografije obogatila s karakterističnim stilovima (Jing et al., 2020).

6.1. Neuronski algoritam umjetničkog stila


Iako ova metoda potječe iz ranih istraživanja 2000-ih, metodologija neuronskog prijenosa stila stekla je značajnu pozornost i doradu nakon revolucionarnog rada Gatysa i njegovih suradnika 2015. godine. Njihov rad „Neuronski algoritam umjetničkog stila“ predstavio je transformacijsku tehniku koja koristi duboke neuronske mreže kako bi rastavila i ponovno spojila sadržajne i stilističke značajke slika.

Ovaj rad je predstavio neuronski prijenos stila kao metodologiju vođenu podacima sposobnu za dinamičko inkorporiranje različitih umjetničkih stilova u digitalnu sliku. Ovo predstavlja značajan napredak u spajanju računalnih tehnika s umjetničkim izražavanjem. Osnovna ideja

njihove metode leži u razdvajanju i naknadnom ponovnom spajanju sadržaja i stila slika korištenjem konvolucijskih neuronskih mreža. Iskorištavajući saznanja iz istraživanja neuronskih mreža, posebno korištenje prethodno treniranih konvolucijskih neuronskih mreža za zadatke prepoznavanja slika, Gatys i njegov tim primijetili su da konvolucijske neuronske mreže trenirane za prepoznavanje objekata inherentno prepoznaju i sadržaj i stil slika unutar svojih naučenih reprezentacija značajki. Sadržaj se odnosi na osnovnu strukturu i semantičke informacije slike, dok stil obuhvaća teksturu, boje i druge vizualne obrasce.

Da bi postigli neuronski prijenos stila, Gatys i suradnici predložili su dvostupanjski proces. Prvo su koristili prethodno treniranu konvolucijsku neuronsku mrežu, poput VGGNet mreže, kako bi izvukli reprezentacije značajki iz sadržajnih i stilskih slika. Odabrali su više slojeva unutar konvolucijskih neuronskih mreža kako bi uhvatili i niske i visoke značajke potrebne za očuvanje sadržajnih i stilskih informacija. Zatim su definirali funkcije gubitka kako bi kvantificirali razliku između reprezentacija značajki generirane slike i ciljnih sadržajnih i stilskih slika. Gubitak sadržaja osiguravao je vjernost sadržaju predmetne slike, dok je gubitak stila osiguravao da se stil referentnih slika vjerno reproducira. Ukupni gubitak bio je ponderirana suma gubitka sadržaja i gubitka stila. Korištenjem optimizacije gradijentnog spusta, Gatys i suradnici iterativno su prilagođavali vrijednosti piksela generirane slike kako bi minimizirali ukupni gubitak. Ovaj iterativni proces rezultirao je stvaranjem vizualno privlačnih slika koje su na suptilan način kombinirale sadržaj jedne slike sa stilom druge. Finim podešavanjem ravnoteže između sadržaja i stila putem hiperparametara i težina gubitka, mogli su postići estetski privlačne rezultate koji su zadržavali semantički sadržaj ulazne slike dok su ga istovremeno obogatili željenim umjetničkim stilom.

Rad Gatysa et al. (2015) potaknuo je široko zanimanje za neuronski prijenos stila i potaknuo daljnja istraživanja u području. Njihova metoda bila je temelj za mnoge primjene u digitalnoj umjetnosti, obradi slika i stvaranju vizualnog sadržaja, te je vidljiva na slici 6.



Slika 7 Rad Gatys et al., (Gatys et al., 2015)

6.2. Uvod u neuronski prijenos stila

Pojava neuronskog prijenosa stila predstavlja ključni trenutak u kojem se susreću područja umjetne inteligencije i umjetničkog izražavanja. Ova metodologija koristi snagu dubokih neuronskih mreža kako bi dinamički spojila sadržaj jedne slike sa stilskim nijansama druge. Odstupajući od konvencionalnih tehnika oslonjenih na ručno izvlačenje značajki i predefinirane predloške, neuronski prijenos stila koristi inherentne sposobnosti neuronskih mreža kako bi direktno iz sirovih podataka raspoznale složene obrasce i reprezentacije. Optimizacijom predefiniраниh funkcija gubitaka koje pažljivo balansiraju očuvanje sadržaja i integraciju stila, algoritmi neuronskog prijenosa stila obogaćuju slike umjetničkom suštinom raznih stilova. U svojoj srži, neuronski prijenos stila oslanja se na sposobnost konvolucijskih neuronskih mreža da izvuku složene hijerarhijske reprezentacije iz slika. Ove reprezentacije, dobivene iz konvolucijskih neuronskih mreža treniranih na velikim skupovima podataka za klasifikaciju slika, sadrže bogate sadržajne i stilističke detalje. Optimizirajući ulaznu sliku iterativno kako bi minimizirali kompozitnu funkciju gubitka, koja uključuje gubitak sadržaja, gubitak stila i često gubitak ukupne varijacije, neuronski prijenos stila preoblikuje ulaznu sliku tako da se ona sastoji od sadržaja jedne, te stila druge slike (Gatys et al., 2015).

6.2.1. Osnovni principi

Proces neuronskog prijenosa stila obično se sastoji od tri ključna koraka: izdvajanje značajki sadržaja i stila iz ulaznih slika, definiranje funkcije gubitka kako bi se kvantificirala razlika između generirane slike i željenog izlaza, te optimizacija generirane slike kako bi se minimizirala ova funkcija gubitka.

- **Reprezentacija sadržaja** - Značajke sadržaja se izdvajaju iz slike sadržaja korištenjem prethodno treniranih konvolucijskih neuronskih mreža, poput VGGNet-a. Te značajke predstavljaju informacije visoke razine o sadržaju prisutnom na slici, prepoznajući objekte, oblike i strukture. Obično se koriste značajke iz jednog ili više srednjih slojeva konvolucijske neuronske mreže kako bi se sačuvali kako niskorazinski tako i visokorazinski detalji slike sadržaja (Kouidri, 2023).
- **Reprezentacija stila** - Značajke stila se izdvajaju iz slike stila koristeći prethodno treniranu konvolucijsku neuronsku mrežu. Međutim, umjesto fokusiranja na samu sliku sadržaja, značajke stila prepoznaju teksture, boje i uzorke koji definiraju umjetnički stil. To se postiže računanjem Gramove matrice značajki na svakom sloju konvolucijske neuronske mreže, time prepoznajući korelacije između različitih značajki (Kouidri, 2023).
- **Funkcija gubitka** - Funkcija gubitka u neuronskom prijenosu stila sastoji se od dva glavna dijela: gubitka sadržaja i gubitka stila. Ti se gubici obično ponderiraju i kombiniraju kako bi se formirala ukupna funkcija gubitka (Kouidri, 2023).

Gubitak sadržaja - Unutar okvira neuronskog prijenosa stila, funkcija gubitka sadržaja igra ključnu ulogu u očuvanju strukturne kohezije i bitnih karakteristika inherentnih ulaznoj slici sadržaja. Ova kritična komponenta zadužena je za kvantificiranje razlike između značajki izvučenih iz sadržaja u sintetiziranoj slici i onih izvučenih iz ciljane slike sadržaja. Njegova važnost leži u provođenju detaljne usporedbe aktivacija u specifičnim slojevima prethodno trenirane konvolucijske neuronske mreže, koje se primjenjuju na ulazne slike sadržaja i dobivenog stiliziranog izlaza.

Funkcija gubitka sadržaja služi kao metrika za kvantificiranje koliko dobro generirana slika čuva sadržaj originalne slike sadržaja. Usporedbom značajki izvučenih između slojeva prethodno trenirane duboke neuronske mreže, funkcija gubitka sadržaja osigurava da generirana slika zadrži ključne sadržajne značajke prisutne u slici sadržaja. Ova usporedba

ključna je za vođenje procesa optimizacije u algoritmima neuronskog prijenosa stila, jer osigurava da generirane slike zadrže bitne sadržaje dok istovremeno uključuju željeni umjetnički stil.

Jednostavno rečeno, gubitak sadržaja uspoređuje generiranu sliku s izvornom slikom sadržaja kako bi se osiguralo da generirana slika sadrži njene karakteristike.

Gubitak stila - Funkcija gubitka stila predstavlja temeljni stup u okviru sustava neuronskog prijenosa stila, igrajući ključnu ulogu u obuhvaćanju složenih nijansi i karakterističnih teksturnih uzoraka vezanih uz odabrani umjetnički stil. Ovaj ključni element kvantificira razlike u stilskim atributima između sintetizirane slike i ciljanog umjetničkog stila detaljnom analizom statističkih svojstava značajki izvučenih iz različitih slojeva prethodno obučene konvolucijske neuronske mreže. Putem izračuna Gram matrice, koja obuhvaća međusobne odnose između značajki iz svakog sloja, funkcija gubitka stila vješto obuhvaća nijanse teksture, boje i prostornih odnosa koji definiraju željeni umjetnički stil. Naknadno, proces optimizacije nastoji minimizirati tu razliku, usmjeravajući sintetiziranu sliku prema usvajanju stilskih karakteristika kodiranih unutar referentne slike stila.

Tako, kroz iterativno usavršavanje, funkcija gubitka stila usmjerava neuronsku mrežu u generiranju vizualno privlačnih rezultata koji vjerno oponašaju željeni umjetnički stil, uz očuvanje inherentnog semantičkog sadržaja ulazne slike.

Ukratko, gubitak stila mjeri razliku između značajki stila generirane slike i slike stila, potičući generiranu sliku da usvoji stilske karakteristike slike stila (Kouidri, 2023).

- **Optimizacija** - Proces optimizacije uključuje iterativno ažuriranje vrijednosti piksela generirane slike kako bi se minimizirala ukupna funkcija gubitka. To se obično radi pomoću gradijentnog spusta. Prilagođavanjem vrijednosti piksela generirane slike, algoritam postupno sintetizira sliku koja istovremeno kombinira sadržaj jedne slike i stil druge (Kouidri, 2023).

U svojoj srži, neuronski prijenos stila temelji se na spajanju sadržaja i stila iz dvije različite slike, postignute kroz složenu manipulaciju njihovih pojedinačnih reprezentacija značajki. Ova složena tehnika snažno se oslanja na sposobnosti konvolucijskih neuronskih mreža za ekstrakciju visokorazinskih značajki koje obuhvaćaju sadržajne i stilističke karakteristike. Proučavanjem mapa značajki generiranih preko različitih slojeva konvolucijskih neuronskih mreža, algoritam razlučuje nijansirane detalje sadržaja dok vješto prepoznaje bit odabranog umjetničkog stila. Reprezentacija sadržaja nastoji očuvati strukturnu cjelovitost ulazne slike,

osiguravajući da rezultirajući stilizirani izlaz ostane prepoznatljiv. Nasuprot tome, reprezentacija stila nastoji obuhvatiti teksturu, paletu boja i prostorni raspored značajki koje definiraju željeni umjetnički stil. Kroz iterativne procese optimizacije, algoritam iterativno prilagođava vrijednosti piksela ulazne slike kako bi minimizirao razliku između njezinih reprezentacija sadržaja i stila te onih izvedenih iz referentne slike, što kulminira u harmoničnoj sintezi sadržaja i stila u konačnom izlazu (Jing et al., 2020).

7. Praktični dio rada

Praktični dio ovog diplomskog rada ima za cilj prikazati implementaciju neuronskog prijenosa stila uz pomoć prethodno treniranog modela. Ova implementacija koristi TensorFlow biblioteku za strojno učenje unutar Google Colaboratory okruženja. Sedam umjetničkih djela poznatih slikara odabrano je kao ulazne slike stila, uključujući:

„Veliki val“ (engl. *The Great Wave off Kanagawa*) Hokusai-a,

„Kompozicija 7“ (engl. *Composition 7*) Kandinskog,

„Zvezdano nebo“ (engl. *Starry Night*) Van Gogha,


„Vrisak“ (engl. *The Scream*) Muncha,

„Boca ruma“ (engl. *Still Life with a Bottle of Rum*) Picassa,

„Krajoлик s crnom figurom“ (engl. *Landscape with Black Figure*) de Souza-Cardosa i

„Udnie“ Picaba.

Također, dva fotografska prikaza korištena su kao ulazne slike sadržaja: Eiffelov toranj i dvorac Neuschwanstein. Korištenje slike prikazane su na slikama 8, 9, 10, 11, 12, 13, 14, 15 te 16, a u nastavku slijedi opis implementacijskog procesa.



Slika 8 Eiffelov toranj (lajornadadeoriente.com.mx, n.d.)



Slika 9 Dvorac Neuschwanstein (CnTraveler, 2023)




Slika 10 Veliki Val, Hokusai (Wikipedia: The Great Wave off Kanagawa (n.d.))



Slika 11 Kompozicija 7, Kandinsky (Wikipedia: Composition 7, n.d.)



Slika 12 Zvezdano Nebo, Van Gogh (Wikipedia: Starry Night, n.d.)




Slika 13 Vrisak, Munch (Wikipedia: The Scream, n.d.)



Slika 14 Boca ruma, Picasso (Wikipedia: Still Life with a Bottle of Rum, n.d.)



Slika 15 Udnie, Picasso (Wikipedia: Udnie, n.d.)



Slika 16 Krajoblik s crnom figurom, de Souza-Cardoso (Wikiart: Landscape with Black Figure, n.d.)

7.1. Odabir tehnologija

Za svrhu izvršavanja ovog praktičnog dijela rada, korišten je Python, uz pomoć TensorFlow-a te Google Colaboratory okruženja. Python je programski jezik poznat zbog svoje raznolikosti i obilja biblioteka prilagođenih za obradu strojnog učenja i slike. TensorFlow, temelj u području okvira za duboko učenje (Zatezalo & Dunder, 2021b), važan je zbog svoje integracije s prethodno obučanim modelima poput VGG-19, što olakšava postupak implementacije. Nadalje, odluka o korištenju Google Colaboratory-ja kao okruženja za razvoj motivirana je njegovom besplatnom ponudom GPU resursa, što omogućuje ubrzanje treniranja modela i eksperimentiranje bez potrebe za lokalnim hardverskim resursima (Python, n.d.) (TensorFlow, n.d.) (Colab.google, n.d.).

7.2. Implementacija

Prvi korak uključivao je uvoz potrebnih biblioteka. Biblioteka `functools` uvezena je prvenstveno radi korištenja dekoratora `lru_cache`, koji služi za keširanje rezultata funkcija, posebice učitavanja slika u ovom kontekstu. Keširanjem rezultata funkcija izbjegavaju se redundantni izračuni, čime se poboljšava računalna učinkovitost i smanjuje vrijeme obrade. Moduli `matplotlib.gridspec` i `matplotlib.pyplot` iz biblioteke `matplotlib` koriste se za organizaciju više grafikona i prikazivanje slika. Također, pružaju funkcionalnosti za organiziranje i prikazivanje slika na strukturiran i vizualno privlačan način, što je bitno za vizualizaciju rezultata procesa prijenosa stila. NumPy je uveden radi potencijalnih potreba za numeričkim izračunima ili za manipulacijom nizova koji nisu eksplicitno obuhvaćeni u skripti. NumPy nudi širok spektar matematičkih i numeričkih funkcija, što ga čini svestranim alatom za znanstveno računanje. Biblioteka TensorFlow služi kao primarni okvir za izvođenje dubokih operacija učenja, uključujući učitavanje i manipulaciju slika. U kontekstu ove skripte, TensorFlow se koristi za različite zadatke poput učitavanja prethodno obučениh modela, izvođenja operacija prijenosa stila i optimizacije stiliziranih slika. Modul `TensorFlow_hub` olakšava učitavanje prethodno obučениh modela s URL-ova. U kontekstu ove skripte, omogućuje učinkovito učitavanje prethodno obučениg modela koji se koristi za prijenos stila, čime se pojednostavljuje proces dobivanja i integracije modela u radnu strukturu skripte.

```
[ ] import functools
import os

from matplotlib import gridspec
import matplotlib.pyplot as plt
import numpy as np
import tensorflow as tf
import tensorflow_hub as hub
```

Slika 17 Prikaz koda (vlastita izrada)

Na slici 17 vidljiv je uvoz potrebnih biblioteka. Ukupno gledano, uvoz ovih biblioteka pruža temeljni okvir potreban za izvođenje naknadnih operacija uključenih u proces neuronskog prijenosa stila, osiguravajući učinkovito izvršenje i robusnu funkcionalnost skripte.

Zatim slijedi definiranje funkcija za učitavanje i vizualizaciju slika, vidljivo na slici 18. Funkcija `crop_center` uzima ulaznu sliku i izrezuje je na središte, osiguravajući da rezultirajuća slika ima iste dimenzije duž širine i visine. Izračunava pomak potreban za centriranje slike na temelju njezinog oblika, a zatim koristi funkciju `tf.image.crop_to_bounding_box` iz TensorFlow-a za izvođenje operacije izrezivanja. Na kraju vraća izrezanu sliku. Sljedeća funkcija, `load_image` učitava sliku s određenog URL-a, dekodira je i pretvara u TensorFlow tenzor. Prvo dohvaća sliku s URL-a koristeći funkciju `tf.keras.utils.get_file` iz TensorFlow-a, zatim dekodira sliku pomoću `tf.io.decode_image`. Slika se pretvara u TensorFlow tenzor s pomičnom točkom i proširuje kako bi uključila dimenziju serije. Zatim poziva funkciju `crop_center` da izreže sliku na središte, te mijenja veličinu slike na određenu `image_size` dok čuva njezinu razmjernu dimenziju. Na kraju vraća predobrađeni tenzor slike. Funkcija `display_images` koristi se za vizualizaciju liste slika zajedno s njihovim odgovarajućim naslovima. Prima listu slika i njihove naslove kao ulaz i stvara rešetku podgrafika pomoću `gridspec.GridSpec` iz `matplotlib`-a. Zatim iterira kroz slike, prikazujući svaku u podgrafu s odgovarajućim naslovom. Rezultirajući grafikon prikazuje se pomoću naredbe `plt.show()`.

Općenito, ove funkcije imaju ključnu ulogu u predobradi slika, učitavanju slika s URL-ova i vizualizaciji rezultata, što su bitni koraci u projektu neuronskog prijenosa stila.

```
def center_crop(image):
    shape = image.shape
    new_shape = min(shape[1], shape[2])
    offset_y = max(shape[1] - shape[2], 0) // 2
    offset_x = max(shape[2] - shape[1], 0) // 2
    cropped_image = tf.image.crop_to_bounding_box(
        image, offset_y, offset_x, new_shape, new_shape)
    return cropped_image

@functools.lru_cache(maxsize=None)
def load_image(image_url, image_size=(256, 256), preserve_aspect_ratio=True):
    filename = os.path.basename(image_url)[-128:]
    image_path = tf.keras.utils.get_file(filename, image_url)
    decoded_image = tf.io.decode_image(
        tf.io.read_file(image_path),
        channels=3, dtype=tf.float32)[tf.newaxis, ...]
    cropped_image = center_crop(decoded_image)
    resized_image = tf.image.resize(cropped_image, image_size, preserve_aspect_ratio=True)
    return resized_image

def display_images(images, titles=('',)):
    num_images = len(images)
    image_sizes = [image.shape[1] for image in images]
    figure_width = (image_sizes[0] * 6) // 320
    plt.figure(figsize=(figure_width * num_images, figure_width))
    grid_spec = gridspec.GridSpec(1, num_images, width_ratios=image_sizes)
    for i in range(num_images):
        plt.subplot(grid_spec[i])
        plt.imshow(images[i][0], aspect='equal')
        plt.axis('off')
        plt.title(titles[i] if len(titles) > i else '')
    plt.show()
```

Slika 18 Prikaz koda (vlastita izrada)

Slijedi učitavanje korištenih slika, vidljivo na slici 19. Naime, postavio se `output_image_size` kako bismo sugerirali da će izlazne slike biti kvadratnog oblika s dimenzijama određenim tim parametrom. Slično tome, `style_img_size` postavljen je na (256, 256), što ukazuje na to da će slika stila biti promijenjena na fiksnu veličinu od 256x256 piksela.

```
content_img_size = (output_image_size, output_image_size)
style_img_size = (256, 256)

content_image = load_image(content_image_url, content_img_size)
style_image = load_image(style_image_url, style_img_size)
display_images([content_image, style_image], ['Sadržaj', 'Stil'])
```

Slika 19 Prikaz koda (vlastita izrada)

Zatim se poziva funkcija `load_image` kako bi se učitala i predobradila slika sadržaja `content_image_url`. Slika se prilagođava na određenu veličinu `content_img_size` kako bi odgovarala potrebnim dimenzijama za prijenos stila. Na sličan način, učitava se i predobrađuje sliku stila iz `style_image_url` i podešava se na fiksnu veličinu definiranu parametrom `style_img_size`. Konačno, `display_images([content_image, style_image], [Sadržaj, Stil])` koristi se za prikazivanje slike sadržaja i slike stila pomoću prethodno definirane funkcije `display_images`. Ovo pruža vizualni uvid u slike prije nego što se primijeni algoritam neuronskog prijenosa stila.

```
hub_handle = 'https://tfhub.dev/google/magenta/arbitrary-image-stylization-v1-256/2'  
hub_module = hub.load(hub_handle)
```

Slika 20 Prikaz koda (vlastita izrada)

Segment koda vidljiv na slici 20 obuhvaća korištenje TensorFlow Hub-a, repozitorija prethodno obučeni modela strojnog učenja i resursa, posebno se fokusirajući na učitavanje prethodno obučeni modela za stilizaciju proizvoljnih slika. Ovdje je `hub_handle` definiran kao URL koji upućuje na određeni prethodno obučeni model za stilizaciju proizvoljnih slika. Taj URL služi kao jedinstveni identifikator za pristup modelu pohranjenom u TensorFlow Hub-u. Zatim se koristi funkcija `hub.load()` za učitavanje prethodno obučeni modela specificiranog pomoću `hub_handle`. Ova funkcija dohvaća model iz TensorFlow Hub-a i inicijalizira ga za upotrebu unutar trenutnog koda ili aplikacije. Nakon učitavanja, varijabla `hub_module` sadrži prethodno obučeni model, olakšavajući daljnju upotrebu u postupku neuronskog prijenosa stila ili u drugim srodnim zadacima.

Ukratko, ovaj segment koda olakšava učitavanje prethodno obučeni modela za stilizaciju proizvoljnih slika iz TensorFlow Hub-a, omogućavajući korisnicima pristup i primjenu najnovijih tehnika stilizacije na njihovim slikama.

```
outputs = hub_module(tf.constant(content_image), tf.constant(style_image))  
stylized_image = outputs[0]
```

Slika 21 Prikaz koda (vlastita izrada)

Dio koda na slici 21 koristi prethodno učitan model za stilizaciju slika iz TensorFlow Hub-a kako bi generirao stiliziranu sliku kombinirajući sadržajnu sliku i sliku stila. Ovdje se koristi učitan model (`hub_module`) kao funkcija koja se primjenjuje na dvije ulazne slike – sadržajnu sliku (`content_image`) i sliku stila (`style_image`). Obje slike se pretvaraju u TensorFlow

konstante (`tf.constant()`) kako bi se mogle koristiti kao ulazi za model. Kada se model primijeni na ove ulazne slike, generiraju se izlazne slike koje sadrže kombinaciju sadržaja i stila. Nakon primjene modela, generirane izlazne slike pohranjuju se u varijablu `outputs`. Budući da je `outputs` višedimenzionalni tenzor koji sadrži različite informacije, koristimo indeksiranje `[0]` kako bismo dobili prvu stiliziranu sliku iz dobivenog skupa rezultata. Ta stilizirana slika zatim se pohranjuje u varijablu `stylized_image` radi daljnje analize, prikaza ili upotrebe u aplikaciji.

```
display_images([content_images[content_name], style_images[style_name], stylized_image],
               titles=['Sadržaj', 'Stil', 'Rezultat'])
```

Slika 22 Prikaz koda (vlastita izrada)

Kod na slici 22 koristi funkciju `display_images` kako bi prikazao tri slike: originalnu sadržajnu sliku, sliku stila i stiliziranu sliku. Ova funkcija olakšava vizualizaciju rezultata neuronskog prijenosa stila i omogućuje usporedbu između ulaznih i izlaznih slika.

Funkcija `display_images` definirana je na sljedeći način: `display_images([content_images[content_name], style_images[style_name], stylized_image], titles=['Sadržaj', 'Stil', 'Rezultat'])`. Ovdje se poziva funkcija `display_images` s tri argumenta: Lista slika `[content_image, style_image, stylized_image]`: Ova lista sadrži tri slike koje će biti prikazane. Prva slika je originalna sadržajna slika (`content_image`), druga slika je slika stila (`style_image`), a treća slika je rezultat stilizacije (`stylized_image`).


Argument `titles=['Sadržaj', 'Stil', 'Rezultat']`: Ovaj argument specificira naslove koji će biti prikazani iznad svake slike. Prva slika će imati naslov „Sadržaj“, druga slika će imati naslov „Stil“, dok će treća slika imati naslov „Rezultat“.

Kada se funkcija `display_images` izvrši s ovim argumentima, rezultat će biti prikaz tri slike u jednom prozoru, svaka sa svojim naslovom kako je specificirano. Ovo omogućuje korisniku da usporedi sve tri slike na jednom mjestu i ocijeni rezultate neuronskog prijenosa stila. Dobiveni rezultati vidljivi su u sljedećem dijelu rada.

7.3. Rezultati

Ukratko, praktičan dio rada koji se odnosi na neuralni prijenos stila kulminirao je istraživanjem umjetničke sinteze, spajajući prepoznatljive znamenitosti, Eiffelov toranj i dvorac Neuschwanstein, sa stilskim karakteristikama umjetničkih djela. Integrirajući stilove iz odabranih umjetničkih djela: „Veliki val“ Hokusai-a, „Kompoziciju 7“ Kandinskog, „Zvezdano nebo“ Van Gogha, „Vrisak“ Muncha, „Bocu ruma“ Picassa, „Krajolik s crnom figurom“ de Souza-Cardosa i „Udnie“ Picaba – praktičan dio demonstrirao je stapanje sadržaja i stila, te su dobiveni sljedeći rezultati, koji prvo prikazuju Neuschwanstein, te zatim Eiffelov toranj s odabranim djelima te rezultat programa.

Na slici 23 prikazan je rezultat neuronskog prijenosa stila nad dvorcem Neuschwanstein i djelom „Kompozicija 7“. Slika 24 prikazuje rezultat neuronskog prijenosa stila nad dvorcem Neuschwanstein i djelom „Krajolik s crnom figurom“. Slika 25 prikazuje rezultat neuronskog prijenosa stila nad dvorcem Neuschwanstein i djelom „Boca ruma“. Slika 26 prikazuje rezultat neuronskog prijenosa stila nad dvorcem Neuschwanstein i djelom „Vrisak“. Na slici 27 vidljiv je rezultat neuronskog prijenosa stila nad dvorcem Neuschwanstein i djelom „Udnie“, a slika 28 prikazuje rezultat neuronskog prijenosa stila nad dvorcem Neuschwanstein s djelom „Zvezdana noć“. Slika 29 prikazuje rezultat neuronskog prijenosa stila nad dvorcem Neuschwanstein s djelom „Veliki val“.



Slika 23 Neuschwanstein i Kompozicija 7 (vlastita izrada)

Sadržaj



Stil



Rezultat




Slika 24 Neuschwanstein i Krajolik s crnom figurom (vlastita izrada)


Sadržaj



Stil



Rezultat




Slika 25 Neuschwanstein i Boca ruma (vlastita izrada)

Sadržaj




Stil




Rezultat




Slika 26 Neuschwanstein i Vrisak (vlastita izrada)



Slika 27 Neuschwanstein i Udnie (vlastita izrada)




Slika 28 Neuschwanstein i Zvezdana noć (vlastita izrada)



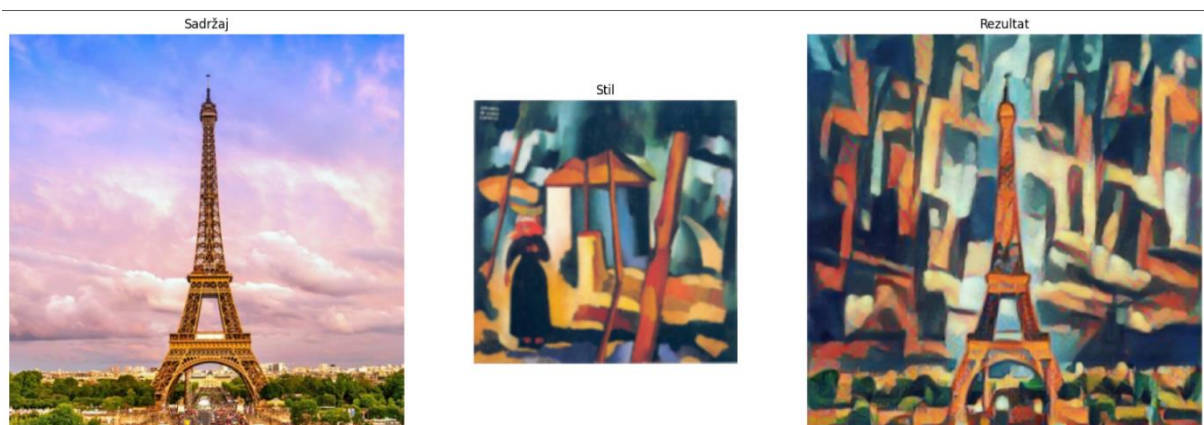
Slika 29 Neuschwanstein i Veliki val (vlastita izrada)

Na slici 30 prikazan je rezultat neuronskog prijenosa stila nad Eiffelovim tornjem i djelom „Kompozicija 7“. Slika 31 prikazuje rezultat neuronskog prijenosa stila nad Eiffelovim tornjem i djelom „Krajolik s crnom figurom“. Slika 32 prikazuje rezultat neuronskog prijenosa stila Eiffelovog toranja i djela „Boca ruma“. Slika 33 prikazuje rezultat neuronskog prijenosa stila


nad Eiffelovim tornjem i djelom „Vrisak“. Na slici 34 vidljiv je rezultat neuronskog prijenosa stila nam Eiffelovim tornjem i djelom „Udnie“, a slika 35 prikazuje Eiffelov toranj s djelom „Zvezdana noć“. Slika 36 prikazuje rezultat neuronskog prijenosa stila nad Eiffelovim tornjem i djelom „Veliki val“.





Slika 30 Eiffelov toranj i Kompozicija 7 (vlastita izrada)






Slika 31 Eiffelov toranj i Krajoлик s crnom figurom (vlastita izrada)





Slika 32 Eiffelov toranj i Boca ruma (vlastita izrada)



Slika 33 Eiffelov toranj i Vrisak (vlastita izrada)




Slika 34 Eiffelov toranj i Udnie (vlastita izrada)



Slika 35 Eiffelov toranj i Zvezdana noć (vlastita izrada)


Sadržaj



Stil



Rezultat



Slika 36 Eiffelov toranj i Veliki val (vlastita izrada)

Zaključak

Umjetna inteligencija predstavlja transformacijsku paradigmu u računalnoj znanosti, obuhvaćajući širok spektar tehnika i metodologija usmjerenih na omogućavanje računalima obavljanje zadataka koji tipično zahtijevaju ljudsku inteligenciju. Unutar područja umjetne inteligencije, strojno učenje služi kao temeljni stup, usredotočujući se na razvoj algoritama i modela koji omogućuju računalima učenje iz podataka i donošenje predviđanja ili odluka na temelju tih podataka. Duboko učenje javlja se kao područje unutar strojnog učenja, karakterizirano upotrebom umjetnih neuronskih mreža s više slojeva kako bi se iz kompleksnih skupova podataka izvukli složeni uzorci i reprezentacije. Konvolucijske neuronske mreže, specijalizirana forma umjetnih neuronskih mreža, ističu se u zadacima koji uključuju prepoznavanje i obradu slika, zahvaljujući svojoj sposobnosti prepoznavanja prostornih hijerarhija značajki.

Neuronski prijenos stila predstavlja zanimljivu primjenu unutar područja dubokog učenja, sjedinjujući umjetničke karakteristike s računalnim vidom. Ova inovativna tehnika olakšava stvaranje slika spajanjem sadržaja jedne slike sa stilskim odrednicama druge. Neuronski prijenos stila ne samo da naglašava potencijal umjetne inteligencije za stvaranje estetski privlačnih vizuala, već također otvara nove puteve za umjetničko istraživanje. Dok se neuronski prijenos stila razvija, potaknut napretkom u dubokom učenju i specijaliziranim metodologijama poput konvolucijskih neuronskih mreža, omogućuje pojedincima jednostavno manipuliranje i stiliziranje slika. Neuronski prijenos stila otvara put za novi pristup interakcije između ljudi i računala.

Literatura

Ali, S., Abuhmed, T., El-Sappagh, S., Muhammad, K., Alonso-Moral, J. M., Confalonieri, R., Guidotti, R., Del Ser, J., Díaz-Rodríguez, N., & Herrera, F. (2023). *Explainable artificial intelligence (XAI): What we know and what is left to attain trustworthy artificial intelligence*. *Information Fusion*, 99, 101805. Preuzeto 7. siječnja 2024. s <https://doi.org/10.1016/j.inffus.2023.101805>

Alpaydin, E. (2016). *Machine Learning: The New AI (The MIT Press Essential Knowledge series)*. The MIT Press.

Autoblocks (n.d.). *What is reinforcement learning (RL)?: Autoblocks Glossary*. Preuzeto 17. svibnja 2023. s <https://www.autoblocks.ai/glossary/reinforcement-learning>

AWS (n.d.). *What is a neural network? - artificial neural network explained* – AWS. Preuzeto 18. lipnja 2023. s <https://aws.amazon.com/what-is/neural-network/>

AWS (n.d.-a). *What's the Difference Between Deep Learning and Neural Networks?* – AWS. Preuzeto 18. lipnja 2023. s <https://aws.amazon.com/compare/the-difference-between-deep-learning-and-neural-networks/>

Banoula, M. (2023). *Machine learning steps: A complete guide*. Simplilearn.com. Preuzeto 13. travnja 2023. s <https://www.simplilearn.com/tutorials/machine-learning-tutorial/machine-learning-steps>

Bigelow, S. J. (2023). *Machine learning vs. neural networks: What's the difference?: TechTarget*. Enterprise AI. Preuzeto 23. studenog 2023. s <https://www.techtarget.com/searchenterpriseai/answer/Machine-learning-vs-neural-networks-Whats-the-difference>

Bodapati, J. D., & Veeranjanyulu, N. (2018). Feature extraction and classification using deep convolutional Neural Networks. *Journal of Cyber Security and Mobility*. Preuzeto 18. lipnja 2023. s <https://doi.org/10.13052/2245-1439.825>

Brownlee, J. (2016). *Master Machine Learning Algorithms: Discover How They Work and Implement Them From Scratch*. MachineLearningMastery.

Buchanan, B. G. (2005). *A (Very) Brief History of Artificial Intelligence*. *AI Magazine*, 26(4), 53–60. Preuzeto 12. travnja 2023. s <https://doi.org/https://doi.org/10.1609/aimag.v26i4.1848>

Burns, E. (2023). *Artificial intelligence (AI)*. TechTarget. Preuzeto 5. travnja 2023. s <https://www.techtarget.com/searchenterpriseai/definition/AI-Artificial-Intelligence>

Chollet, F. (2018). *Deep Learning with Python*. Manning Publications Co.

CnTraveler (2023). The 26 Most Beautiful Castles in Europe. CnTraveler.com. Preuzeto 1. travnja 2024. s <https://i.pinimg.com/474x/cd/3a/97/cd3a9700500099f5001781211da539cd--beautiful-buildings-beautiful-homes.jpg>

Colab.google (n.d.). Preuzeto 3. prosinca 2023. s <https://colab.google/>

Copeland, B. J. (2023). *Artificial Intelligence*. Encyclopædia Britannica. Preuzeto 12. travnja 2023. s <https://www.britannica.com/technology/artificial-intelligence>

Craig, L., & Awati, R. (2024). *What is a Convolutional Neural Network (CNN)?*. Enterprise AI. Preuzeto 20. veljače 2024. s <https://www.techtarget.com/searchenterpriseai/definition/convolutional-neural-network>

D'Agostino, A. (2022). *Introduction to neural networks-weights, biases and activation*. Medium. Preuzeto 23. studenog 2023. s <https://medium.com/mllearning-ai/introduction-to-neural-networks-weights-biases-and-activation-270ebf2545aa>

DatabaseTown (n.d.). *7 main areas of Artificial Intelligence (AI)*. Preuzeto 12. travnja 2023. s <https://databasetown.com/7-main-areas-of-artificial-intelligence-ai/>

DataRobot AI Platform (2024). *Introduction to loss functions*. Preuzeto 26. veljače 2024. s <https://www.datarobot.com/blog/introduction-to-loss-functions/>

DataScienceCentral (2018). *LeNet-5-A Classic CNN Architecture*. DataScienceCentral.com. Preuzeto 1. travnja 2024. s <https://www.datasciencecentral.com/lenet-5-a-classic-cnn-architecture/>

Donges, N. (n.d.). *Gradient descent in Machine Learning: A basic introduction*. Built In. Preuzeto 24. studenog 2023. s <https://builtin.com/data-science/gradient-descent>

Elmsley, A. (2019). *Thinking artificially: Artificial Neural Networks, part I* Medium. Preuzeto 31. ožujka 2024. s <https://medium.com/the-sound-of-ai/thinking-artificially-artificial-neural-networks-part-i-fb0ea78a9f6>

Elyasi, N. (2020). *Tda in classification alongside with neural nets*. ResearchGate.com. Preuzeto 1. travnja 2024. s https://www.researchgate.net/figure/Patterns-extraction-in-different-layers-of-a-neural-net_fig2_343987422

Gatys, L. A., Ecker, A. S., & Bethge, M. (2015). *A Neural Algorithm of Artistic Style*. Preuzeto 5. travnja 2023. s <https://arxiv.org/abs/1508.06576>

GfG (2023). *Convolutional Neural Network (CNN) architectures*. GeeksforGeeks. Preuzeto 23. studenog 2023. s <https://www.geeksforgeeks.org/convolutional-neural-network-cnn-architectures/>

Gillis, A. S., Burns, E., & Brush, K. (2023). *What is deep learning and how does it work?: Definition from TechTarget*. Enterprise AI. Preuzeto 20. studenog 2023. s <https://www.techtarget.com/searchenterpriseai/definition/deep-learning-deep-neural-network>

Gillis, A. S., Lutkevich, B., & Burns, E. (2024). *What is natural language processing?: Definition from TechTarget*. Enterprise AI. Preuzeto 20. veljače 2024. s <https://www.techtarget.com/searchenterpriseai/definition/natural-language-processing-NLP>

Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep Learning*. The MIT Press.

Hieda, N. (n.d.). *How neural networks are trained*. Preuzeto 25. studenog 2023. https://ml4a.github.io/ml4a/how_neural_networks_are_trained/

IBM (n.d.). *What is machine learning?* IBM.com. Preuzeto 17. svibnja 2023. s <https://www.ibm.com/topics/machine-learning>

IBM (n.d.-a). *What are convolutional neural networks?* IBM.com. Preuzeto 22. studenog 2023. s <https://www.ibm.com/topics/convolutional-neural-networks>

IBM Cloud Education (n.d.). *What is unsupervised learning?* IBM.com. Preuzeto 17. svibnja 2023. s <https://www.ibm.com/topics/unsupervised-learning>

Institute of Data (2023). *Machine learning vs Traditional Programming: Choosing the right approach for your projects.* Preuzeto 12. studenog 2023. s <https://www.institutedata.com/blog/machine-learning-vs-traditional-programming-choosing-the-right-approach-for-your-projects/>

Jing, Y., Yang, Y., Feng, Z., Ye, J., Yu, Y., & Song, M. (2020). Neural style transfer: A Review. *IEEE Transactions on Visualization and Computer Graphics*, 26(11), 3365–3385. Preuzeto 4. prosinca 2023. s <https://doi.org/10.1109/tvcg.2019.2921336>

Journal of Information Technology & Software Engineering. (2011). *Artificial-intelligence-open-access.* Longdom. Preuzeto 12. travnja 2023. s <https://www.longdom.org/peer-reviewed-journals/artificialintelligenceopenaccess-36559.html>

Katalinić, J., Dunder, I., Seljan, S. (2023). *Polarizing Topics on Twitter in the 2022 United States Elections.* Information 2023, 14, 609. <https://doi.org/10.3390/info14110609>

Kelleher, D. J. (2019). *Deep Learning.* The MIT Press.

Koudri, A. (2023). *Neural Style Transfer: Unveiling the Art of Digital Transformation.* Ikomia.ai. Preuzeto 1. travnja 2024. s <https://www.ikomia.ai/blog/neural-style-transfer-guide>

Kovač, A., Dunder, I., Seljan, S. (2022). *An overview of machine learning algorithms for detecting phishing attacks on electronic messaging services.* 45th Jubilee International Convention on Information, Communication and Electronic Technology (MIPRO), Opatija, Croatia, 2022, pp. 954–961

La Jornada De Oriente (n.d.). lajornadadeoriente.com.mx Preuzeto 1. travnja 2024. s <https://www.lajornadadeoriente.com.mx/wp-content/uploads/2024/02/Copia-de-Copia-de-Imagen-LJO-17-1068x1068.jpg>

Laskowski, N., & Tucci, L. (2023). *What is artificial intelligence and how does ai work?: Definition from TechTarget.* Enterprise AI. Preuzeto 2. siječnja 2024. s <https://www.techtarget.com/searchenterpriseai/definition/AI-Artificial-Intelligence>

Lawton, G. (2023). *4 types of learning in machine learning explained*. Enterprise AI. Preuzeto 11. prosinca 2023. s <https://www.techtarget.com/searchenterpriseai/tip/Types-of-learning-in-machine-learning-explained>

Littman, M., Ajunwa, I., Berger, G., Boutilier, C., Currie, M., Doshi-Velez, F., Hadfield, G., Horowitz, M. C., Isbell, C., Kitano, H., Levy, K., Lyons, T., Mitchell, M., Shah, J., Sloman, S., Vallor, S., & Walsh, T. (2021). *Gathering Strength, Gathering Storms: The One Hundred Year Study on Artificial Intelligence (AI100) 2021 Study Panel Report*. Preuzeto 7. studenog 2023. sa Stanford University, <http://ai100.stanford.edu/2021-report>

Luhaniwal, V. (2023). *Forward propagation in Neural Networks -simplified math and code version*. Medium. Preuzeto 11. prosinca 2023. s <https://towardsdatascience.com/forward-propagation-in-neural-networks-simplified-math-and-code-version-bbcfef6f9250>

McGonagle, J., Shalkouski, G., & Williams, C. (n.d.). *Backpropagation*. Brilliant Math & Science Wiki. Preuzeto 19. studenog 2023. s <https://brilliant.org/wiki/backpropagation/>

Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D., & Riedmiller, M. (2013). *Playing Atari with deep reinforcement learning*. Preuzeto 3. siječnja 2023. s arXiv.org. <https://arxiv.org/abs/1312.5602>

Ognjanovski, G. (2020). *Everything you need to know about neural networks and backpropagation - machine learning made easy and fun*. Medium. Preuzeto 11. prosinca 2023. s <https://towardsdatascience.com/everything-you-need-to-know-about-neural-networks-and-backpropagation-machine-learning-made-easy-e5285bc2be3a>

Oxford (n.d.) *What is AI? - shorthandstories.com*. Preuzeto 12. travnja 2023. s <https://oxford.shorthandstories.com/ai-what-is-it/index.html>

Panwar, H. (2020). *Convolutional Neural Network : Basic concepts*. Medium. Preuzeto 12. prosinca 2023. s <https://medium.com/analytics-vidhya/convolutional-neural-network-basis-concepts-e059a76d9161>

Patterson, J., & Gibson, A. (2017). *Deep Learning: A Practitioner's Approach*. O'Reilly.

Petersson, D. (2023). *AI vs. Machine learning vs. Deep learning: Key differences*. TechTarget. Preuzeto 5. travnja 2023. s <https://www.techtarget.com/searchenterpriseai/tip/AI-vs-machine-learning-vs-deep-learning-Key-differences>

Pramoditha, R. (2022). *Overview of a neural network's learning process*. Medium. Preuzeto 19. prosinca 2023. s <https://medium.com/data-science-365/overview-of-a-neural-networks-learning-process-61690a502fa>

Python (n.d.). *About*. Python.org. Preuzeto 1. travnja 2024. s <https://www.python.org/about/>

Radišić, B., Seljan, S., Dunder, I. (2023). *Impact of missing values on the performance of machine learning algorithms*. CEUR Workshop Proceedings: Recent Trends and Applications in Computer Science and Information Technology (RTA-CSIT 2023), 56-62.

Russell, S., & Norvig, P. (2021). *Artificial intelligence: a modern approach*. Pearson. Fourth edition.

Sakarkar, G., Patil, G., & Dutta, P. (2021). *Machine Learning Algorithms Using Python Programming*. Nova Science Publishers.

Sarker, I. H. (2021a). *Machine learning: Algorithms, real-world applications and research directions - SN computer science*. SpringerLink. Preuzeto 12. studenog 2023. s <https://link.springer.com/article/10.1007/s42979-021-00592-x>

Sarker, I. H. (2021b). *Deep learning: A comprehensive overview on techniques, taxonomy, applications and Research Directions*. SN computer science. Preuzeto 13. studenog 2023. s <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8372231/>

Seljan, S., Dunder, I. (2014). *Combined Automatic Speech Recognition and Machine Translation in Business Correspondence Domain for English-Croatian*. Journal of Computer, Information, Systems and Control Engineering 8 (11), 1069

Seljan, S., Tolj, N., Dunder, I. (2023). *Information Extraction from Security-Related Datasets*. 46th ICT and Electronic Convention - MIPRO 2023, 595-600

Singh, A., Jaiswal, V., Joshi, G., Sanjeeve, A., Gite, S., & Kotecha, K. (2021). *Neural style transfer: A critical review*. IEEE Access, 9, 131583–131613. Preuzeto 5. prosinca 2023. s <https://doi.org/10.1109/access.2021.3112996>

Singh, G. (2024). *Introduction to artificial neural networks*. Analytics Vidhya. Preuzeto 25. studenog 2023. s <https://www.analyticsvidhya.com/blog/2021/09/introduction-to-artificial-neural-networks/>

SoftwareTestingHelp. (2023). *What is Artificial Intelligence: Definition & Sub-Fields of AI*. SoftwareTestingHelp.com. Preuzeto 9. prosinca 2023. s <https://www.softwaretestinghelp.com/what-is-artificial-intelligence/>

Soori, M., Arezoo, B., & Dastres, R. (2023). *Artificial Intelligence, Machine Learning and deep learning in advanced robotics, a review*. Cognitive Robotics, 3, 54–70. Preuzeto 3. siječnja 2024. s <https://doi.org/10.1016/j.cogr.2023.04.001>

SuperAnnotate (2023). *Convolutional Neural Networks: 1998-2023 Overview*. SuperAnnotate.com. Preuzeto 1. travnja 2024. s <https://www.superannotate.com/blog/guide-to-convolutional-neural-networks>

Šarčević, M. (2022). Prijenos Obilježja slike Primjenom Konvolucijske neuronske mreže. Preuzeto 11. siječnja 2024. s <https://repositorij.etfos.hr/islandora/object/etfos:3621/datastream/PDF/view>

Taye, M. M. (2023). *Understanding of machine learning with Deep Learning: Architectures, workflow, applications and future directions*. Computers, 12(5), 91. Preuzeto 3. siječnja 2024. s <https://doi.org/10.3390/computers12050091>

TensorFlow (n.d.). *Introduction to tensorflow*. Preuzeto 3. prosinca 2023. s <https://www.tensorflow.org/learn>

Tucci, L., & Burns, E. (2023). *What is machine learning and how does it work? in-depth guide*. Enterprise AI. Preuzeto 3. prosinca 2024. s <https://www.techtarget.com/searchenterpriseai/definition/machine-learning-ML>

Ujević Andrijić, Ž., & Bolf, N. (2019). *Osvježimo znanje: Umjetne neuronske mreže*. Kemija u industriji, 68 (5-6), 219-220. Preuzeto 14. studenog 2023. s <https://hrcak.srce.hr/220716>

Warwick, K. (2012). *Artificial Intelligence – The Basics*. Routledge.

Wikiart: Landscape with Black Figure (n.d.). *Landscape with Black Figure*. WikiArt.org. Preuzeto 1. travnja 2024. s <https://www.wikiart.org/en/amadeo-de-souza-cardoso/landscape-with-black-figure-1915>

Wikipedia: Composition 7 (n.d.). *Composition 7*. Wikipedia.com. Preuzeto 1. travnja 2024. s https://en.wikipedia.org/wiki/Composition_VII#/media/File:Vassily_Kandinsky,_1913_-_Composition_7.jpg

Wikipedia: Starry Night (n.d.). *Starry Night*. Wikipedia.com. Preuzeto 1. travnja 2024. s https://en.wikipedia.org/wiki/The_Starry_Night#/media/File:Van_Gogh_-_Starry_Night_-_Google_Art_Project.jpg

Wikipedia: Still Life with a Bottle of Rum (n.d.). *Still Life with a Bottle of Rum*. Wikipedia.com. Preuzeto 1. travnja 2024. s https://upload.wikimedia.org/wikipedia/en/7/7f/Pablo_Picasso%2C_1911%2C_Still_Life_with_a_Bottle_of_Rum%2C_oil_on_canvas%2C_61.3_x_50.5_cm%2C_Metropolitan_Museum_of_Art%2C_New_York.jpg

Wikipedia: The Great Wave off Kanagawa (n.d.). *The Great Wave off Kanagawa*. Wikipedia.com. Preuzeto 1. travnja 2024. s https://en.wikipedia.org/wiki/The_Great_Wave_off_Kanagawa#/media/File:Tsunami_by_hokusai_19th_century.jpg

Wikipedia: The Scream (n.d.). *The Scream*. Wikipedia.com. Preuzeto 1. travnja 2024. s https://en.wikipedia.org/wiki/The_Scream#/media/File:Edvard_Munch,_1893,_The_Scream,_oil,_tempera_and_pastel_on_cardboard,_91_x_73_cm,_National_Gallery_of_Norway.jpg

Wikipedia: Udnie (n.d.). *Udnie*. Wikipedia.com. Preuzeto 1. travnja 2024. s [https://en.wikipedia.org/wiki/Udnie#/media/File:Francis_Picabia,_1913,_Udnie_\(Young_American_Girl,_The_Dance\),_oil_on_canvas,_290_x_300_cm,_Mus%C3%A9e_National_d%E2%80%99Art_Moderne,_Centre_Georges_Pompidou,_Paris.jpg](https://en.wikipedia.org/wiki/Udnie#/media/File:Francis_Picabia,_1913,_Udnie_(Young_American_Girl,_The_Dance),_oil_on_canvas,_290_x_300_cm,_Mus%C3%A9e_National_d%E2%80%99Art_Moderne,_Centre_Georges_Pompidou,_Paris.jpg)

Xu, Y., Liu, X., Cao, X., Huang, C., Liu, E., Qian, S., Liu, X., Wu, Y., Dong, F., Qiu, C.-W., Qiu, J., Hua, K., Su, W., Wu, J., Xu, H., Han, Y., Fu, C., Yin, Z., Liu, M., ... & Zhang, J. (2021). Artificial intelligence: A powerful paradigm for scientific research. *The Innovation*, 2(4). Preuzeto 13. svibnja 2023. s <https://doi.org/https://doi.org/10.1016/j.xinn.2021.100179>

Yasar, K., & Lutkevich, B. (2023). *What is machine vision?: TechTarget*. Enterprise AI. Preuzeto 18. studenog 2023. s <https://www.techtarget.com/searchenterpriseai/definition/machine-vision-computer-vision>

Yasar, K., Gillis, A. S., & Botelho, B. (2023). *What is cognitive computing?: TechTarget*. Enterprise AI. Preuzeto 18. studenog 2023. s <https://www.techtarget.com/searchenterpriseai/definition/cognitive-computing>

Zatezalo, I., Dunder I., (2021b). *Online service for accessible machine learning of prediction models*. Zbornik radova Međimurskog veleučilišta u Čakovcu, vol. 12, no. 2, 2021.

Zatezalo, I., Dunder, I. (2021a). *Development of a mobile application for flag identification based on artificial neural networks*. Zbornik Veleučilišta u Rijeci, Vol. 10 (2022), No.1, pp. 393-409

Zhou, Z.-H. (2021). *Machine Learning*. Springer.

Popis slika

| | |
|--|----|
| Slika 1 Odnos klasičnog programiranja i strojnog učenja (Chollet, 2018) | 11 |
| Slika 2 Biološki neuron (Andrijić & Bolf, 2019) | 20 |
| Slika 3 Ilustracija jednostavne neuronske mreže (Kelleher, 2019) | 22 |
| Slika 4 Prikaz hijerarhijskog učenja značajki (Elyasi, 2020) | 31 |
| Slika 5 Konvolucijska neuronska mreža (SuperAnnotate, 2023)..... | 35 |
| Slika 6 Arhitektura LeNet-5 mreže (DataScienceCentral, 2018) | 36 |
| Slika 7 Rad Gatys et al., (Gatys et al., 2015)..... | 40 |
| Slika 8 Eiffelov toranj (lajornadadeoriente.com.mx, n.d.)..... | 44 |
| Slika 9 Dvorac Neuschwanstein (CnTraveler, 2023)..... | 45 |
| Slika 10 Veliki Val, Hokusai (Wikipedia: The Great Wave off Kanagawa (n.d.) | 45 |
| Slika 11 Kompozicija 7, Kandinsky (Wikipedia: Composition 7 , n.d.) | 45 |
| Slika 12 Zvezdano Nebo, Van Gogh (Wikipedia: Starry Night, n.d.) | 46 |
| Slika 13 Vrisak, Munch (Wikipedia: The Scream, n.d.) | 46 |
| Slika 14 Boca ruma, Picasso (Wikipedia: Still Life with a Bottle of Rum, n.d.) | 47 |
| Slika 15 Udnie, Picabia (Wikipedia: Udnie, n.d.) | 47 |
| Slika 16 Krajolik s crnom figurom, de Souza-Cardoso (Wikiart: Landscape with Black Figure, n.d.) | 48 |
| Slika 17 Prikaz koda (vlastita izrada)..... | 49 |
| Slika 18 Prikaz koda (vlastita izrada)..... | 51 |
| Slika 19 Prikaz koda (vlastita izrada)..... | 51 |
| Slika 20 Prikaz koda (vlastita izrada)..... | 52 |
| Slika 21 Prikaz koda (vlastita izrada)..... | 52 |
| Slika 22 Prikaz koda (vlastita izrada)..... | 53 |
| Slika 23 Neuschwanstein i Kompozicija 7 (vlastita izrada)..... | 54 |
| Slika 24 Neuschwanstein i Krajolik s crnom figurom (vlastita izrada) | 55 |
| Slika 25 Neuschwanstein i Boca ruma (vlastita izrada)..... | 55 |
| Slika 26 Neuschwanstein i Vrisak (vlastita izrada) | 55 |
| Slika 27 Neuschwanstein i Udnie (vlastita izrada) | 56 |
| Slika 28 Neuschwanstein i Zvezdana noć (vlastita izrada) | 56 |
| Slika 29 Neuschwanstein i Veliki val (vlastita izrada) | 56 |
| Slika 30 Eiffelov toranj i Kompozicija 7 (vlastita izrada)..... | 57 |

| | |
|---|----|
| Slika 31 Eiffelov toranj i Krajolik s crnom figurom (vlastita izrada) | 57 |
| Slika 32 Eiffelov toranj i Boca ruma (vlastita izrada)..... | 57 |
| Slika 33 Eiffelov toranj i Vrisak (vlastita izrada) | 58 |
| Slika 34 Eiffelov toranj i Udnie (vlastita izrada) | 58 |
| Slika 35 Eiffelov toranj i Zvezdana noć (vlastita izrada)..... | 58 |
| Slika 36 Eiffelov toranj i Veliki val (vlastita izrada) | 59 |

Neuronski prijenos stila

Sažetak

Umjetna inteligencija je posljednjih godina napredovala značajnom brzinom i tako postala jedna od važnijih tema u suvremenom svijetu. Jedna grana umjetne inteligencije istaknula se kao vrlo značajnom i utjecajnom – duboko učenje. Duboko učenje je moćan alat unutar umjetne inteligencije koji je omogućio stvaranje umjetnih neuronskih mreža, a s njima i konvolucijskih neuronskih mreža. Konvolucijske neuronske mreže vrlo su učinkovite u analizi i prepoznavanju vizualnih uzoraka na slikama, što se može vidjeti u procesu neuronskog prijenosa stila. Neuronski prijenos stila je tehnika koja kombinira stil jedne slike sa sadržajem druge što rezultira stiliziranom i vizualno privlačnom slikom. Cilj ovog diplomskog rada je bio pružiti teorijski okvir i cjelovito razumijevanje koncepta neuronskog prijenosa stila. Ovaj diplomski rad sastoji se od dva dijela: teorijskog i praktičnog. Teorijski dio pruža pregled umjetne inteligencije i strojnog učenja, kao i pregled koncepta dubokog učenja. Također, dubinski se ulazi u teorijski i praktični aspekt neuronskog prijenosa stila. Praktični dio diplomskog rada odnosi se na implementaciju neuronskog prijenosa stila uz pomoć prethodno treniranog modela. Implementacija je provedena korištenjem biblioteke za strojno učenje TensorFlow u okruženju Google Colaboratory. Rezultati implementacije prikazani su u zadnjem dijelu rada.

Ključne riječi: umjetna inteligencija, duboko učenje, konvolucijske neuronske mreže, neuronski prijenos stila, Python

Neural style transfer

Summary

In recent years, artificial intelligence has rapidly advanced and has become one of the most important topics in the modern world. One branch of artificial intelligence has stood out as really influential – deep learning. Deep learning is a powerful tool within artificial intelligence that has allowed for the creation of artificial neural networks, and with them, convolutional neural networks. Convolutional neural networks are highly effective in analyzing and recognizing visual patterns in images, which can be seen in neural style transfer. Neural style transfer is a technique that combines the style of one image with the content of another, resulting in a stylized and visually appealing image. The aim of this thesis was to provide a theoretical framework and a comprehensive understanding of the concept of neural style transfer. This thesis is comprised of two parts: a theoretical and a practical part. The theoretical part provides an overview of artificial intelligence and machine learning, as well as an overview of the concept of deep learning. Also, it delves into the theoretical and practical aspects of neural style transfer. The practical part of the thesis is concerned with the implementation of neural style transfer using a pre-trained model. This implementation is done using the TensorFlow machine learning library in the Google Colaboratory environment. The results of the implementation are presented in the last part of the thesis.

Key words: artificial intelligence, deep learning, convolutional neural networks, neural style transfer, Python