

Primjena neuronskih mreža pri prepoznavanju slika

Pečar, Maja

Undergraduate thesis / Završni rad

2021

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:131:478733>

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
Ak. god. 2020./2021.

Maja Pečar

Primjena neuronskih mreža pri prepoznavanju slika

Završni rad

Mentor: doc. dr. sc. Ivan Dunder

Zagreb, rujan 2021.

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..... | 2 |
| 2.1. Turingov test | 2 |
| 2.2. AI okruženje..... | 3 |
| 2.3. Strojno učenje | 3 |
| 2.3.1. Skup podataka..... | 3 |
| 2.3.2. Vrste strojnog učenja | 4 |
| 2.4. Duboko učenje | 4 |
| 2.5. Računalni vid | 5 |
| 3. Umjetne neuronske mreže..... | 7 |
| 3.1. Komponente umjetnih neuronskih mreža | 9 |
| 3.1.1. Neuron..... | 9 |
| 3.1.2. Težinski faktori | 10 |
| 3.1.3. Propagacijska funkcija | 10 |
| 3.1.4. Sumacijska funkcija | 10 |
| 3.1.5. Aktivacijska funkcija | 11 |
| 3.1.6. Output funkcija | 11 |
| 3.1.7. Funkcija učenja | 11 |
| 3.2. Metode učenja | 12 |
| 3.2.1. Nadzirano učenje | 12 |
| 3.2.2. Nenadzirano učenje..... | 13 |
| 3.2.3. Ojačano učenje..... | 14 |
| 3.3. Topologije umjetnih neuronskih mreža | 14 |
| 3.3.1. Perceptron | 14 |

| | |
|--|----|
| 3.3.2. Feedforward mreža | 15 |
| 3.3.3. Potpuno povezana mreža | 16 |
| 3.3. Konvolucijske neuronske mreže | 17 |
| 3.3.1. Arhitektura konvolucijske neuronske mreže | 18 |
| 3.3.1.1. Konvolucijski sloj..... | 18 |
| 3.4.1.2. Pooling sloj | 19 |
| 3.4.1.3. Potpuno povezani sloj..... | 19 |
| 4. Primjena i praktičan rad | 19 |
| 4.1. Uvoz biblioteka | 19 |
| 4.1.1. TensorFlow | 20 |
| 4.1.2. NumPy | 21 |
| 4.2. Učitavanje slika | 21 |
| 4.3. Učitavanje modela za duboko učenje..... | 22 |
| 4.4. Pretprocesiranje slike | 22 |
| 4.5. Stvaranje predikcija..... | 23 |
| 5. Zaključak..... | 25 |
| 6. Literatura..... | 26 |
| 7. Popis slika..... | 28 |

1. Uvod

Umjetna inteligencija kao ideja ima korijene koji sežu daleko u prošlost, ali kao formalno područje proučavanja postoji tek od 1956. godine kada je na konferenciji na Dartmouth Collegeu, u New Hampshireu, taj termin skovan. Konferencija je organizirana u namjeri da spoji istraživače iz različitih područja kako bi se stvorilo novo područje s ciljem izrade inteligentnih strojeva čija inteligencija naliči ljudskoj (Haenlein i Kaplan, 2019, str. 7)

Nakon te konferencije slijedio je period velikih inovacija u području koji je trajao gotovo dva desetljeća. Frank Rosenblatt, Charles Wightman i njihovi suradnici 1957. godine razvijaju prvi uspješni neurokompjuter Mark I perceptron. Bernard Widrow i Marcian Hoff 1960. godine predstavljaju ADALINE – prvu komercijalno korištenu umjetnu neuronsku mrežu. Joseph Weizenbaum između 1964. i 1966. godine razvija prvi chatbot ELIZU itd (Kriesel, 2007, str. 10).

Istraživanje umjetnih neuronskih mreža pokrenula je teorija učenja kanadskog psihologa Donalda Hebba, fokusirana na repliciranje funkcioniranja neurona ljudskog mozga, izložena u njegovoj knjizi *Organizacija ponašanja* 1949. godine. Teorija se temeljila na ideji da se neuronske veze osnažuju svaki put kada se koriste (Haenlein i Kaplan, 2019, str. 8). Zahvaljujući tome, i istraživanjima i inovacijama koje su zatim slijedile, danas – više od sedamdeset godina kasnije – umjetne neuronske mreže predstavljaju integralni dio tehnološkog napretka.

Cilj pisanja ovog rada je približavanje teorijskih temelja umjetnih neuronskih mreža koji će se zatim koristiti za demonstraciju jednog od načina njihove primjene, konkretno, za prepoznavanje slika. Prvi dio rada bavit će se temama umjetne inteligencije, strojnog učenja i umjetnih neuronskih mreža, a drugi dio primjenom neuronskih mreža za prepoznavanje slika.

2. Umjetna inteligencija

Inteligencija u psihologiji se definira kao „sposobnost mišljenja koja omogućuje snalaženje u novim prilikama u kojima se ne koriste nagonско ponašanje ni učenjem stečene navike, vještine i znanja“ (Hrvatska enciklopedija, 2021). Vrste i razine inteligencije raznih živih bića znatno variraju. Prema psihologu Howardu Gardneru, i njegovom modelu višestrukih inteligencija, ljudi posjeduju čak 8 različitih vrsti inteligencije: lingvističku, logičko-matematičku, prostornu, glazbenu, tjelesno-kinestetičku, intrapersonalnu, interpersonalnu i naturalističku (Cherry, 2021).

John McCarthy (2007), jedan od začetnika umjetne inteligencije i autor tog termina, umjetnu inteligenciju definira kao „znanost i inženjering inteligentnih strojeva, posebice inteligentnih računalnih programa“. Intelligentni stroj ili računalni program je onaj koji pokazuje karakteristike ljudske inteligencije; s time na umu je i dizajniran. Umjetna inteligencija obuhvaća istraživanja ljudskog mozga, učenja i donošenja odluka, a rezultati tih istraživanja zatim se primjenjuju u izradi računalnih sustava.

Cilj umjetne inteligencije je dizajniranje sustava koji će samostalno moći učiti, rješavati kompleksne probleme i, u konačnici, ubrzati rad poslova koje bi inače radili ljudi. Umjetna inteligencija posuđuje mnoge prakse i koncepte od drugih disciplina. Koristi se načelima i konceptima logike, prepoznavanja uzoraka, heuristike, filozofije, psihologije, matematike, lingvistike itd. (Kaliraj i Devi, 2021, str. 8-11).

2.1. Turingov test

Najpoznatija metoda mjerenja ljudske inteligencije je IQ test. IQ test mjeri logičko zaključivanje, prostornu percepciju, pamćenje itd. Najpoznatija metoda mjerenja inteligencije računala je Turingov test koji je 1950-e predložio Alan Turing, matematičar i kriptanalitičar. On je osmišljen kako bi se testiralo može li računalo zavarati ljude da je čovjek.

Princip testa je jednostavan. U jednoj sobi je inteligentno računalo, u drugoj čovjek, a ispitivač treba pogoditi koji od njih je računalo kroz komunikaciju putem tipkovnice. Ispitivač ima dvije tipkovnice; jednu za razgovor s računalom, a jednu za razgovor s čovjekom, ali bez saznanja koja

je spojena s čovjekom, a koja s računalom koje samo imitira čovjeka. Sadržaj poruka je jedini način na koji se može razaznati tko je tko (Sabouret, 2020, str. 16-17).

2.2. AI okruženje

AI okruženje sačinjava 5 velikih komponenti (Kaliraj i Devi, 2021, str. 11-12):

1. stroj,
2. ljudska inteligencija,
3. strojno učenje,
4. Internet svega (engl. Internet of Everything ili skraćeno IoE),
5. znanost o podacima i inženjering.

2.3. Strojno učenje

Strojno učenje (engl. machine learning ili skraćeno ML) je grana umjetne inteligencije koja se bavi računalnim algoritmima koji omogućuju računalnim programima učenje te samopoboljšanje kroz iskustvo (Sakarkar i sur., 2021, str. 25). Iskustvo, u računalnim sustavima, podrazumijeva podatke, a glavni zadatak strojnog učenja je razviti algoritme za učenje koji će samostalno graditi modele s tim podacima, bez da su za to eksplicitno programirani. Proces korištenja tih algoritama za izgradnju modela iz podataka naziva se treniranjem. ML sustavi procesiraju dane podatke, a zatim ih koriste za stvaranje predikcija (Zhou, 2021, str. 2-3).

2.3.1. Skup podataka

Skup ili set podataka (engl. dataset) je zbirka podataka, odnosno varijabli i njihovih vrijednosti. Za razvoj ML rješenja potrebne su velike količine podataka. Podaci se dijele na različite tipove, a to su: liste, skupovi, matrice, slike, video, zvuk te stabla i grafikoni (Sakarkar i sur., 2021, str. 33-34).

2.3.2. Vrste strojnog učenja

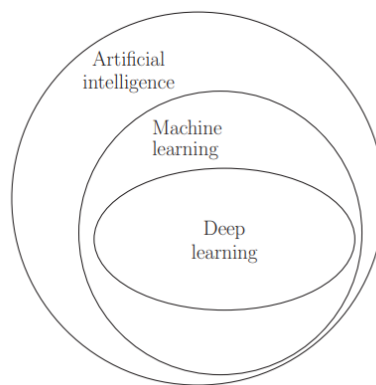
Strojno učenje se dijeli na tri vrste (Sakarkar i sur., 2021, str. 39):

1. nadzirano učenje,
2. nenadzirano učenje i
3. ojačano učenje.

Detaljnije će se ove vrste strojnog učenja razraditi u nastavku rada.

2.4. Duboko učenje

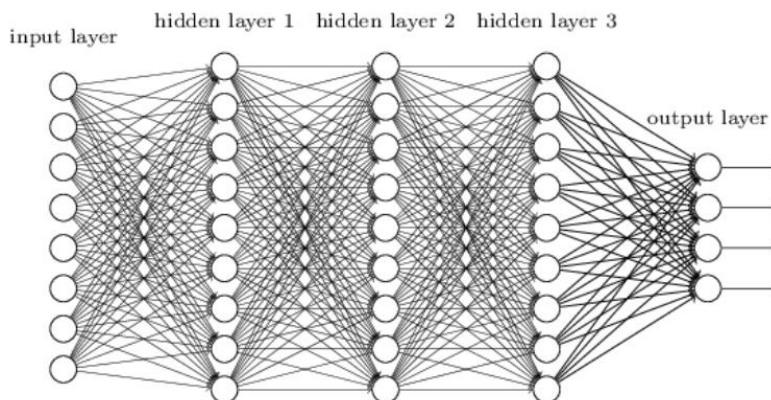
Duboko ili dubinsko učenje je grana umjetne inteligencije koja se bavi izradom velikih modela neuronskih mreža koje su sposobne donositi odluke temeljene na podacima. Proizašlo je iz istraživanja umjetne inteligencije i strojnog učenja, a omogućava identifikaciju i ekstrakciju uzoraka iz velikih skupova podataka (Kelleher, 2019, str. 1-5). Odnos između dubokog učenja, strojnog učenja i umjetne inteligencije ilustriran je na Slici 1¹. Za razliku od drugih tradicionalnih metoda strojnog učenja, duboko učenje primjenjuje pristup automatskog učenja značajki iz sirovih podataka (Kelleher, 2019, str. 35).



Slika 1: Ilustracija odnosa između dubokog učenja, strojnog učenja i umjetne inteligencije

¹ preuzeto iz knjige Deep Learning

Duboko učenje temelji se na primjeni modela neuronskih mreža čiji su neuroni organizirani u slojeve: input sloj, više skrivenih slojeva i output sloj. Mreže za duboko učenje su neuronske mreže koje u pravilu imaju velik broj skrivenih slojeva neurona. Minimalan broj slojeva potreban da se mreža smatra dubokom je dva, ali takve mreže većinom imaju puno više slojeva od toga (Kelleher, 2019, str. 65-68). Slika 2² prikazuje kako otprilike izgleda mreža s tri skrivena sloja. Više o neuronskim mrežama bit će dano u nastavku rada.



Slika 2: Ilustracija neuronske mreže sa tri skrivena sloja

2.5. Računalni vid

Računalni vid je područje umjetne inteligencije i strojnog učenja koje se bavi razvojem tehnika koje računalima pomažu vidjeti i razumjeti sadržaj digitalnih slika i videa. Teži automatiziranoj ekstrakciji korisnih informacija iz slika (Brownlee, 2019, str. 4-5)

Metode računalnog vida pokušavaju replicirati kompleksnost ljudskog vida i omogućiti računalima identifikaciju i procesiranje objekata na način sličan ljudskom. Računalni vid temelji se na prepoznavanju uzoraka, a kako bi računalo naučilo prepoznavati uzorke u slikama mora biti istrenirano na mnoštvu slika (Mihajlović, 2019).

Računalni vid koristi se za detekciju, klasifikaciju i segmentaciju objekata, segmentaciju i prepoznavanje slika, analizu videa, itd. (Mihajlović, 2019). Primjena metoda računalnog vida

² prema <http://neuralnetworksanddeeplearning.com/chap5.html>

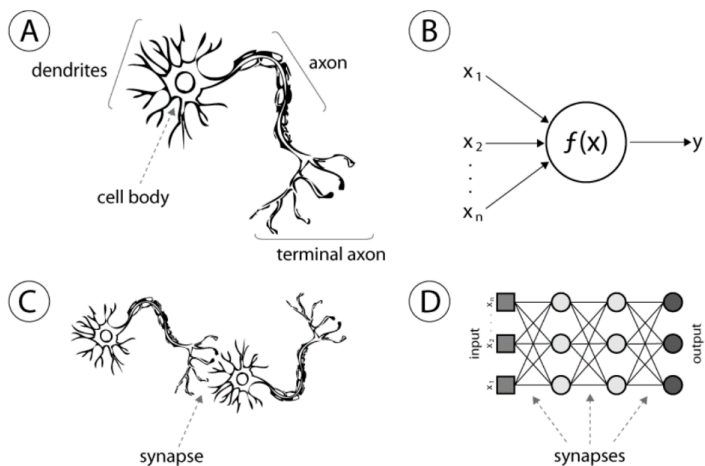
pokazala se uspješnom za rješavanje problema u području nadzora, optičkog prepoznavanja znakova (OCR), izgradnji 3D modela (Reljić i sur., 2019) i još brojnim drugim (Brownlee, 2019, str. 6-7).

3. Umjetne neuronske mreže

Umjetne neuronske mreže su sustavi procesiranja informacija koji se baziraju na primjeni umjetnih neurona dizajniranih po uzoru na neuronske mreže ljudskog mozga u procesu obrade informacija. Predstavljaju jednu od najpopularnijih metoda strojnog učenja, a temelje se na pretpostavkama da se:

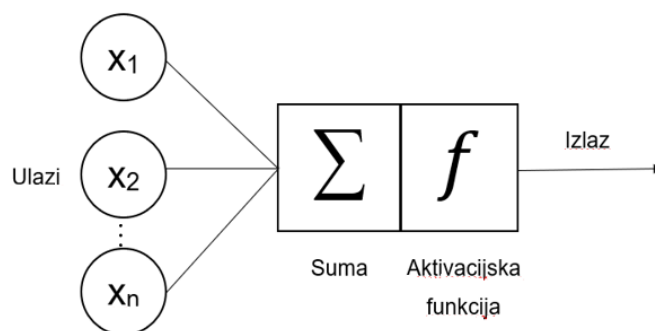
1. procesiranje informacija odvija u neuronima,
2. signali razmjenjuju među neuronima preko spojnih veza,
3. svaka veza ima pripisanu težinu koja umnaža signal i
4. svaki neuron primjenjuje aktivacijsku funkciju u svoj mrežni input kako bi odredio svoj signalni output (Fausett, 1994, str. 3).

Neuroni su osnovna jedinica živčanog sustava ljudi. Oni nam omogućuju da razmišljamo, pamtimo, učimo iz iskustva itd. Međusobno su spojeni pomoću svojih aksona i dendrita preko kojih šalju signale ili informacije drugim neuronima. Mjesto spajanja dvaju neurona, tj. mjesto spajanja aksona jednog i dendrita drugog neurona, naziva se *sinapsa*, a snaga tog sinaptičkog kontakta varira, ovisno o izvanjskim stimulansima. Ta promjena označava kako proces učenja funkcionira kod ljudi, a umjetne neuronske mreže pokušavaju simulirati upravo taj biološki mehanizam (Aggarwal, 2018, str. 1).



Slika 3: Neuroni i neuronske mreže

Slika 3³ prikazuje upravo kako se neuroni ljudskog živčanog sustava, slično kao i umjetni neuroni, spajaju jedan za drugog, tvoreći mrežu. U mreži, zatim, primaju i šalju informacije drugim neuronima. Kod umjetnih neuronskih mreža, dendriti bi, dakle, bili ulaz jednog neurona do kojeg dolaze izlazi iz drugih neurona, iz prethodnog sloja (x_1-x_n). Zatim se računa suma svih ulaza nad kojom se poziva aktivacijska funkcija, koja mreži omogućuje nelinearnost, čija se vrijednost prosljeđuje na sljedeći sloj (Krambeger i sur., 2019, str. 26). To je prikazano na Slici 4 (rad autora).



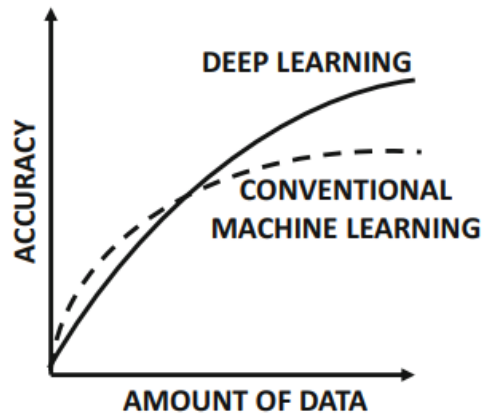
Slika 4: Shema umjetnog neurona

Umjetne neuronske mreže, za razliku od nekih drugih klasičnih modela strojnog učenja, posjeduju višu razinu apstrakcije te više osnovnih računskih jedinica (engl. computation unit). Kada bi se umjetne neuronske mreže koristile bez spajanja tih jedinica, njihov algoritam bio bi poput klasičnog modela strojnog učenja. Prava moć umjetnih neuronskih mreža izvire upravo iz tog načina spajanja i međuovisnosti računskih jedinica (Aggarwal, 2018, str. 2).

Na Slici 5⁴ možemo vidjeti kako točnost algoritma umjetnih neuronskih mreža raste s količinom podataka u odnosu na neke druge konvencionalne metode strojnog učenja. Što je više računске snage i podataka to su umjetne neuronske mreže više efikasne u odnosu na druge metode.

³ prema <https://www.linkedin.com/pulse/part-1-all-artificial-neural-networks-intuition-amsal-gilani>

⁴ preuzeto iz knjige Neural Networks and Deep Learning, str. 3



Slika 5: Usporedba točnosti tipičnog ML algoritma i točnosti algoritma neuronske mreže s obzirom na količinu podataka

Cilj umjetnih neuronskih mreža je rješavanje problema na način na koji bi ih ljudski mozak rješavao, ali brže i efikasnije. Upravo zbog te brzine rješavanja problema, umjetne neuronske mreže se danas koriste za obavljanje širokog spektra poslova, kao na primjer za prevođenje, prepoznavanje slika i govora, medicinsku dijagnozu, predviđanje prometa itd.

3.1. Komponente umjetnih neuronskih mreža

3.1.1. Neuron

Osnovna jedinica umjetne neuronske mreže je neuron. On predstavlja jednu procesnu jedinicu unutar mreže. Svi neuroni unutar mreže su međusobno spojeni usmjerenom vezom i imaju svoju težinu (Kriesel, 2007, str. 33), a organizirani su u slojeve. Ti slojevi se generalno dijele na:

1. input slojeve,
2. skrivene slojeve i
3. output slojeve (Alexander, 2020, str. 8-9).

3.1.2. Težinski faktori

Neuroni uglavnom istovremeno primaju više inputa, a svaki taj input ima svoju pripisanu težinu koja utječe na sumacijsku funkciju procesnog elementa. Težina inputa, koja predstavlja adaptivni koeficijent, ovisi o važnosti tog inputa za mrežu i utječe na jačinu utjecaja koju on ima u produkciji neuronskog odgovora. Ona se može prilagoditi s obzirom na potrebe neuronske mreže (Anderson i McNeill, 1992, str. 22).

3.1.3. Propagacijska funkcija

Propagacijska funkcija zaprima outpute drugih neurona te ih transformira, s obzirom na njihove pripisane težine, u mrežni input (engl. network input). Mrežni input je, stoga, rezultat propagacijske funkcije, a nadalje se procesira pomoću aktivacijske funkcije (Kriesel, 2007, str. 34-35).

3.1.4. Sumacijska funkcija

Sumacijska funkcija je proces računanja težinskog zbroja (eng. weighted sum) svih inputa. Inputi i njihove pripisane težine, u matematičkom smislu, su zapravo vektori, a cjelokupni input signal je njihov unutarnji produkt (engl. inner product). On se dobije množenjem korespondirajućih komponenata tih vektora. Produkt dvaju vektora zapravo predstavlja njihovu mjeru sličnosti. Kada su vektori istoga smjera, unutarnji produkt je maksimalan, a kad su suprotnog smjera onda je minimalan. Sumacijska funkcija ovisi o odabranoj arhitekturi mreže. Ona može biti i kompleksnija od prije objašnjene jednostavne sumacije. Inputi i težinski zbrojevi produkata mogu se kombinirati na nekoliko načina, ovisno o unutrašnjim algoritmima (Anderson i McNeill, 1992, str. 22-23).

3.1.5. Aktivacijska funkcija

Svaki neuron unutar neuronske mreže je, u određenoj mjeri, uvijek aktivan, a njegova reakcija na input vrijednosti ovisi o njegovom aktivacijskom stanju koje indicira u kojoj mjeri je aktivan. Aktivacijska funkcija neurona reagira osobito snažno ako je blizu granične vrijednosti (engl. threshold value). Granična vrijednost je jedinstveno dodijeljena svakom neuronu, a označava poziciju maksimalne vrijednosti gradijenta aktivacijske funkcije.

Aktivacijska funkcija odlučuje o aktivaciji neurona s obzirom na mrežni input i graničnu vrijednost te transformira mrežni input i aktivacijsko stanje (zajedno s graničnom vrijednosti) u novo aktivacijsko stanje. Granična vrijednost može se mijenjati kroz proces učenja (Kriesel, 2007, str. 35-36). Aktivacijska funkcija također se naziva i transfernom funkcijom.

3.1.6. Output funkcija

Svaki procesni element zaprima više inputa, ali šalje samo jedan output, a taj output signal može poslati stotinama drugih neurona. Output funkcija neurona računa vrijednosti (iz aktivacijske funkcije) koje će zatim prenijeti drugim neuronima (Kriesel, 2007, str. 38).

Osim ako je drugačije određeno, output će dati rezultate aktivacijske funkcije. Neke mrežne topologije, međutim, modificiraju rezultate aktivacijske funkcije da dopuštaju natjecanje među neuronima. Natjecanje će odrediti koji neuron će biti aktivan ili pružiti output te koji će procesni element sudjelovati u procesu učenja (Anderson i McNeill, 1992, str. 25).

3.1.7. Funkcija učenja

Proces učenja neuronskih mreža odvija se uz pomoć algoritma koji može mijenjati, odnosno trenirati, neuronsku mrežu tako da producira željeni output za dani input (Kriesel, 2007, str. 38). Neuronske mreže uče kroz primjere pa je za kvalitetno učenje potrebno osigurati kvalitetne primjere za procesiranje. Svrha funkcije učenja je modifikacija težina inputa procesnih elemenata kako bi se došlo do željenih rezultata.

Učenje neuronske mreže obavlja se pomoću propagacije unazad (engl. back-propagation). Za učenje potrebno je poznavati inpute i očekivane outpute kako bi se greške uočile i ispravile. Funkcija koja računa pogrešku zove se funkcija gubitka (engl. loss function), a potrebno je koristiti ispravnu varijantu te funkcije, sukladno problemu koji se treba riješiti. Funkcija gubitka koristi se za izračun greške između željenih i dobivenih rezultata, a dijeli se na regresijski i klasifikacijski gubitak. Nakon računanja gubitka računa se gradijent koji ukazuje na to u kojem smjeru treba mijenjati vrijednosti te ih propagirati unazad po mreži (Krambeger i sur., 2019, str. 27-28).

3.2. Metode učenja

Neuronske mreže se kroz učenje mijenjaju kako bi se prilagodile novim uvjetima, odnosno, mijenjaju se kada se promijene njihove komponente. One mogu učiti kroz razvijanje novih veza, brisanje postojećih, mijenjanje težina veza, razvijanjem novih neurona itd. Različiti autori na različite načine dijele metode učenja umjetnih neuronskih mreža, ali najčešće su one podijeljene na:

1. nadzirano učenje (engl. supervised learning);
2. nenadzirano učenje (engl. unsupervised learning); i
3. ojačano učenje (engl. reinforcement learning).

3.2.1. Nadzirano učenje

Nadzirano učenje koristi ML algoritam koji trenira na već označenim skupovima podataka. Algoritmu je dan skup podataka iz kojeg on traži veze između varijabli u tom skupu. Cilj nadziranog učenja je naučiti funkciju za mapiranje (engl. mapping function) kako input treba biti uparen s outputom, koristeći dostupne podatke (Sakarkar i sur., 2021, str. 39-43).

Kod primjene nadziranog učenja na neuronskim mrežama output neuronske mreže se uspoređuje sa željenim outputom, a težina veze, koja je inicijalno nasumično određena, se prilagođava kako bi ubuduće producirala rezultat bliži onom željenom. Težina inputa u nadziranom učenju se mijenja sve dok se ne postigne prihvatljiva točnost u predviđanju. Za

treniranje algoritama za prepoznavanje slika većinom se koristi nadzirano učenje jer pokazuje bolje rezultate.

Skup podataka za treniranje (engl. training set) kod nadziranog učenja sastoji se od uzorka inputa (engl. input pattern), ali i točnih rezultata, u obliku precizne aktivacije svih output neurona. Outputi neuronske mreže se, zbog toga, direktno mogu uspoređivati s točnim rješenjima, težine veza se mogu mijenjati s obzirom na tu točnost, a mreža može izračunati precizan vektor pogreške. Konačni cilj je istrenirati neuronsku mrežu da sama može samostalno pružiti predviđanja za slične, ali nepoznate, uzorke inputa (Kriesel, 2007, str. 53).

Nadzirano učenje se, prema tome, odvija u ovih 5 koraka:

1. ulazak uzorka inputa i aktivacija input neurona;
2. propagacija inputa i generacija outputa;
3. uspoređivanje dobivenog outputa sa željenim outputom i računanje vektora pogreške;
4. računanje korekcije mreže s obzirom na vektor pogreške; i
5. primjena korekcije (Kriesel, 2007, str. 53).

3.2.2. Nenadzirano učenje

Za razliku od nadziranog učenja, nenadzirano učenje primjenjuje neoznačene skupove podataka što znači da se algoritam ne može osloniti na oznake kako bi pronašao egzaktnu prirodu veza između podataka. To je u jednu ruku i njegova prednost jer to znači da se skup podataka ne treba posebno pripremati da bude čitljiv računalu. Manjak oznaka rezultira stvaranjem skrivenih struktura, a veze između podataka algoritam percipira na apstraktan način. Stvaranje skrivenih struktura kod nenadziranog učenja čini nenadzirano učenje više primjenjivo od nadziranog učenja jer se algoritam samostalno može prilagoditi danim podacima (Sakarkar i sur., 2021, str. 43-44).

Kod nenadziranog učenja neuronska mreža samostalno pokušava identificirati uzorke u inputima te generirati klase uzoraka bez podataka o željenom outputu. Takve mreže ne koriste nikakve vanjske utjecaje pri prilagođavanju težina veze, već same traže „zakonitosti“ i trendove u input signalima (Kriesel, 2007, str. 52). Jedan od primjera nenadziranog učenja je grupiranje (eng.

clustering) na temelju većeg broja neoznačenih podataka koji se grupiraju u skupine, a unutar skupine sadrže određene zajedničke karakteristike (Seljan i sur., 2020).

3.2.3. Ojačano učenje

Ojačano ili podržano učenje primjenjuje algoritam koji se sam poboljšava i uči iz novih situacija koristeći se metodom pokušaja i pogrešaka. Utemeljeno je u psihologiji, u konceptu uvjetovanja, gdje se povoljni outputi potiču i nagrađuju, a nepovoljni kažnjavaju. Kod povoljnog outputa, nagrada ovisi o postotku efektivnosti (Sakarkar i sur., 2021, str. 46).

Kod ojačanog učenja mreža zaprima logičku ili realnu vrijednost nakon izvršenja neke sekvence. Ona definira jesu li rezultati ispravni ili pogrešni. Skup podataka za trening sastoji se od uzoraka inputa te vrijednosti koje mreža zaprima nakon izvršenja sekvence (Kriesel, 2007, str. 53). Ojačano učenje, kao metoda učenja, nalazi se negdje između nadziranog i nenadziranog učenja (Alexander, 2020, str 11).

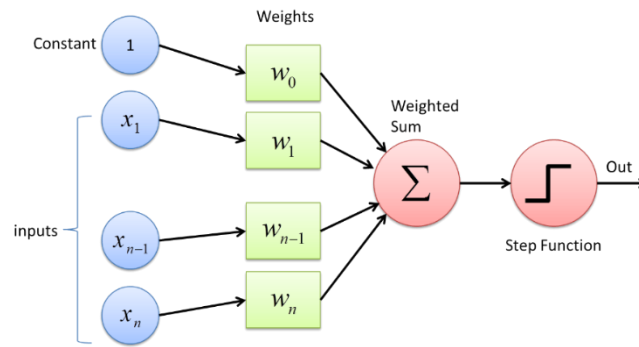
3.3. Topologije umjetnih neuronskih mreža

Neuroni unutar umjetne neuronske mreže mogu biti organizirani na različite načine. Različito povezivanje umjetnih neurona rezultira različitim strukturama ili topologijama mreže. Neke od njih biti će objašnjene u nastavku.

3.3.1. Perceptron

Perceptron je najjednostavnija umjetna neuronska mreža koja sadrži jedan input sloj i jedan output čvor (Aggarwal, 2018, str. 5). On je algoritam koji se koristi za učenje binarnih klasifikatora. Binarni klasifikatori odlučuju pripada li input specifičnoj klasi.

Funkcioniraju na način da prvo input vrijednosti pomnože s njihovim pripisanim težinama i tako dobiju ponderirani zbroj koji se zatim primjenjuje na aktivacijsku funkciju koja producira output (DeepAI, 2019). Perceptron je prikazan na Slici 6⁵.



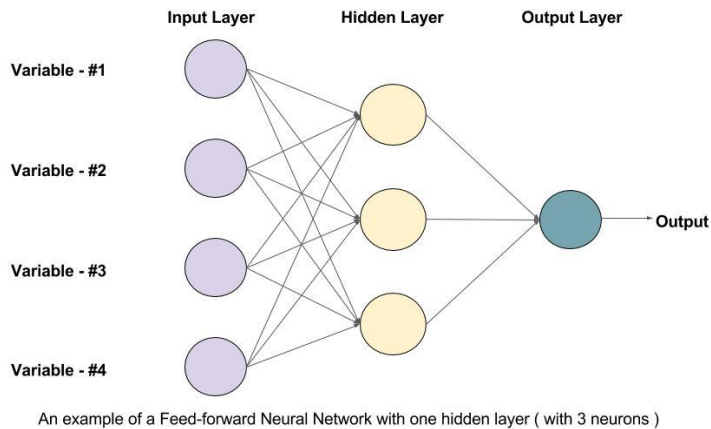
Slika 6: Perceptron

3.3.2. Feedforward mreža

U feedforward mreži svaki neuron u jednom sloju direktno je usmjereno povezan samo sa neuronima sljedećeg sloja prema output sloju. Slojevi feedforward mreže su jasno odvojeni. Sastoje se od jednog input sloja, jednog output sloja i više skrivenih slojeva za procesiranje (Kriesel, 2007, str. 39). Feedforward mreže su zapravo samo višeslojni perceptroni. Feedforward mreža s jednim skrivenim slojem prikazana je na Slici 7⁶.

⁵ prema <https://deepai.org/machine-learning-glossary-and-terms/perceptron>

⁶ prema <https://learnopencv.com/understanding-feedforward-neural-networks/>

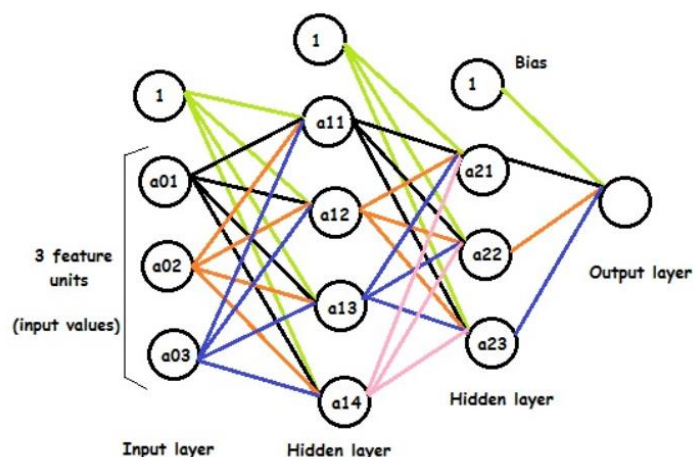


Slika 7: Feedforward neuronska mreža s jednim skrivenim slojem

3.3.3. Potpuno povezana mreža

Potpuno povezani slojevi neuronske mreže su oni slojevi u kojima su svi inputi jednog sloja spojeni sa svakom aktivacijskom jedinicom sljedećeg sloja, pri čemu je aktivacijska jedinica onaj čvor ili ona jedinica koja implementira aktivacijsku funkciju. U popularnim modelima strojnog učenja, zadnjih nekoliko slojeva mreže čine potpuno povezani slojevi što objedinjuje podatke ekstrahirane iz prethodnih slojeva u konačni izlaz (Singh, 2019). Neuronska mreža s potpuno povezanim slojevima prikazana je na Slici 8⁷.

⁷ prema <https://iq.opengenus.org/fully-connected-layer/>



Slika 8: Neuronska mreža s potpuno povezanim slojevima

3.3. Konvolucijske neuronske mreže

Konvolucijske neuronske mreže (engl. convolutional neural networks ili skraćeno CNN) su mreže koje zapravo primjenjuju oblik računalnog vida za klasifikaciju slika i detekciju objekata. Inspirirane su razumijevanjem rada mačjeg vizualnog korteksa Davida Hubela i Torstena Wieselera prema kojem se činilo da određeni dijelovi vidnog polja pobuđuju određene neurone (Aggarwal, 2018, str. 40). Sukladno tome, cilj dizajna konvolucijskih neuronskih mreža bio je stvoriti mrežu u kojoj će neuroni u prvim slojevima izdvojiti lokalne vizualne značajke, a neuroni u kasnijim kombinirati te značajke kako bi formirali značajke višeg reda. Lokalne vizualne značajke su značajke čiji doseg je ograničen na skup susjednih piksela u slici (Kelleher, 2019, str. 160).

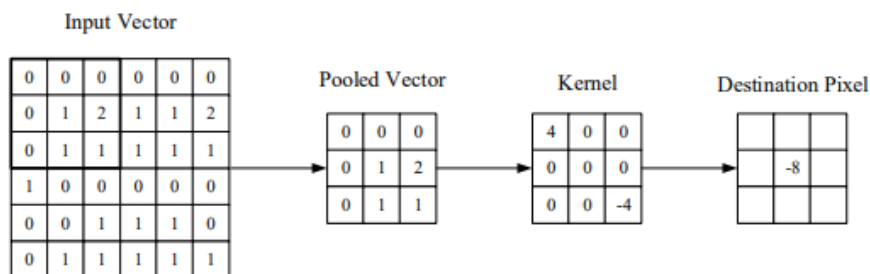
Kod konvolucijskih neuronskih mreža svaki sloj mreže je trodimenzionalan; ima prostornu širinu i dubinu koja odgovara broju značajki. Središnji koncept konvolucijske neuronske mreže je konvolucijski sloj. Taj sloj vrši konvoluciju, linearnu operaciju koja uključuje množenje skupova težina s inputom (Brownlee, 2019, str. 109).

3.3.1. Arhitektura konvolucijske neuronske mreže

Arhitektura konvolucijske neuronske mreže je organizirana s obzirom na to da će se input sastojati od slika. Za razliku od standardnih umjetnih neuronskih mreža, neuroni u slojevima konvolucijske mreže su spojeni samo s malim dijelom sloja koji mu prethodi. Kao što je već prije navedeno, slojevi konvolucijske neuronske mreže organizirani su u tri dimenzije: prostornu dimenziju inputa, odnosno visinu i širinu, i dubinu. Dubina se ne odnosi na broj slojeva mreže, već na dimenziju aktivacijskog volumena. Konvolucijska mreža sastoji se od tri tipa slojeva: konvolucijskih, pooling i potpuno povezanih slojeva (O'Shea i Nash, 2015, str. 3-4).

3.3.1.1. Konvolucijski sloj

Konvolucijski sloj temelji se na primjeni takozvanih jezgri (engl. kernels), koje su male prostorne dimenzionalnosti, ali se šire po cijeloj dubini inputa. Kada podaci dođu do konvolucijskog sloja, sloj primjenjuje filtere kako bi izradio 2D aktivacijsku mapu koja je vizualno prikazana u Slici 9⁸. Konvolucijski slojevi mogu znatno smanjiti kompleksnost modela optimizacijom svojih outputa (O'Shea i Nash, 2015, str. 5-6).



Slika 9: Ilustracija konvolucijskog sloja konvolucijske neuronske mreže

⁸ preuzeto iz rada „An Introduction to Convolutional Neural Networks“

3.4.1.2. Pooling sloj

Pooling sloj smanjuje dimenzionalnost reprezentacije i tako smanjuje broj parametara i kompleksnost modela. Operira nad svakom aktivacijskom mapom u inputu skaliranjem njene dimenzionalnosti, obično kroz max-pooling slojeve. Tim procesom aktivacijska mapa se smanjuje na 25% njene izvorne veličine, a volumen dubine ostaje isti (O'Shea i Nash, 2015, str. 8).

3.4.1.3. Potpuno povezani sloj

Potpuno povezani sloj sadrži neurone koji su direktno povezani s neuronima dvaju susjednih slojeva bez da su spojeni sa slojevima u njima. Oni funkcioniraju na način tipičan za tradicionalnu umjetnu neuronsku mrežu (O'Shea i Nash, 2015, str. 8).

4. Primjena i praktičan rad

Za praktični dio ovog rada koristit će se programski jezik Python, a cilj je primijeniti teorijsko znanje o području u pisanju programa za prepoznavanje slika. Za testiranje modela koristit će se slika mačke, konkretno Egipatske mau.

4.1. Uvoz biblioteka

Biblioteke su zbirke datoteka ili modula koje sadrže funkcije za korištenje u programima. Python ima i velik broj ugrađenih biblioteka, ali postoji još puno drugih biblioteka koje se mogu dodatno instalirati. Prije početka korištenja biblioteka ona se treba uvesti naredbom „import“. To je prikazano na Slici 10.

Biblioteke potrebne za praktičan dio ovog rada su TensorFlow i NumPy.

```
In [3]: import tensorflow as tf

In [4]: import numpy as np
```

Slika 10: Uvoz biblioteka u Python

4.1.1. TensorFlow

TensorFlow je *end-to-end* platforma otvorenog koda za razvoj i treniranje modela strojnog učenja. Razvili su ga istraživači i inženjeri Google Brain tima u svrhu istraživanja strojnog učenja i neuronskih mreža (GitHub, 2019). Naziv je dobio po tenzorima, tipiziranim višedimenzionalnim poljima, koji su fundamentalna struktura podataka TensorFlowa. Nasljednik je DistBeliefa koji je Google koristio od 2011. godine.

TensorFlow posjeduje brojne fleksibilne i sveobuhvatne alate i biblioteke za jednostavnu i prilagodljivu izradu aplikacija baziranih na strojnom učenju, a pruža stabilno Python i C++ aplikacijsko programsko sučelje (Tensorflow, 2019) i jednostavnu programsku apstrakciju temeljenu na protoku podataka (eng. dataflow). Visokorazinsko sučelje korisnicima omogućuje prilagodbu različitih arhitektura modela i optimizaciju algoritama bez mijenjanja jezgre sustava (Abadi i sur., 2016, str. 265).

Temelji dizajna TensorFlowa su:

1. dataflow grafovi primitivnih operatora;
2. odgođeno izvršenje; i
3. apstrakcija za heterogene akceleratora.

Za razliku od prije spomenutog DistBeliefa, TensorFlow se sastoji od relativno puno složenih slojeva, a njegov model predstavlja individualne matematičke operatore (npr. množenje matrica) kao čvorove u dataflow grafovima. Isto kao i DistBelief, TensorFlow koristi dataflow reprezentaciju za svoj model, a taj pristup olakšava stvaranje novih slojeva pomoću njegovog sučelja. TensorFlow aplikacije uglavnom imaju dvije faze: u prvoj se program definira kao

simbolički dataflow graf, a u drugoj se izvršava optimizirana verzija programa. Odgađanjem izvođenja programa dok cijeli ne bude dostupan, on optimizira fazu izvođenja koristeći globalne informacije o izračunu. Akceleratori posebne namjene za duboko učenje pospješuju značajno poboljšanje izvođenja te uštedu energije. Kako bi podržao te akcelerate, Tensorflow ima definiranu zajedničku apstrakciju za različite uređaje (Abadi i sur., 2016, str. 267-268).

TensorFlow je naširoko korišten za istraživanja u području strojnog učenja pa se tako koristi i u produkciji nekoliko Googlovihi usluga (Abadi i sur., 2016, str. 265).

4.1.2. NumPy

NumPy je Python biblioteka otvorenog koda koja omogućuje numeričko računanje u Pythonu (NumPy, n.d.). Koristi se za rad s objektima polja (engl. array object) koji su primjerice i do pedeset puta brži za procesiranje u odnosu na Pythonove liste. Podržava širok raspon hardverskih i računalnih platformi. Napisan je jednim dijelom u Pythonu, a dijelovi koji zahtijevaju brzo procesiranje pisani su u C++ programskom jeziku (W3Schools, n.d.).

4.2. Učitavanje slika

Postoji više metoda učitavanja slika. Za potrebe ovog rada, za učitavanje slika koristit će se TensorFlow, odnosno Keras. Keras je aplikacijsko programsko sučelje za Tensorflow napisano u Python programskom jeziku. Učitavanje slike uz pomoć Kerasa prikazano je na Slici 11.

```

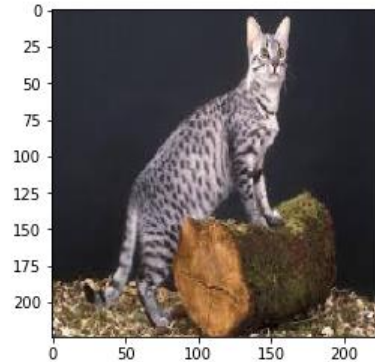
In [45]: from tensorflow.keras.preprocessing import image
img = image.load_img(filename, target_size = (224,224))

In [46]: import matplotlib.pyplot as plt

In [47]: plt.imshow(img)

Out[47]: <matplotlib.image.AxesImage at 0x167d0125460>

```



Slika 11: Učitavanje slike uz pomoć TensorFlowa

4.3. Učitavanje modela za duboko učenje

Za potrebe ovog rada koristit će se MobileNet model dubokog učenja koji se primjenjuje za potrebe računalnog vida. On se temelji na pojednostavljenoj arhitekturi koja koristi dubinski razlučive konvolucije za izgradnju modela dubokih neuronskih mreža. Prilagođen je za klasifikaciju i detekciju, a dolazi s već istreniranim težinama veza (Keras, n.d.). Koristi se i za izradu, treniranje i testiranje modela dubokog učenja te za predikciju. Učitavanje MobileNet modela dubokog učenja prikazano je na Slici 12.

```

In [60]: mobile = tf.keras.applications.mobilenet_v2.MobileNetV2()

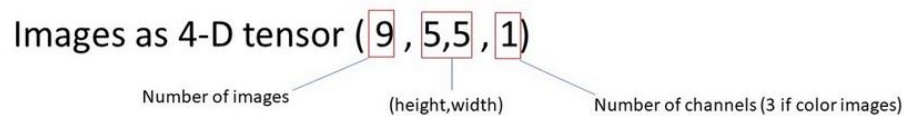
```

Slika 12: Učitavanje modela za duboko učenje

4.4. Pretprocesiranje slike

Slike su u suštini samo trodimenzionalni tenzori koji se mogu prikazati uz pomoć 3D matrice. Prve dvije dimenzije odnose se na visinu i širinu slike, a treći na broj kanala boja slike. Ako se radi o slici u boji onda će broj kanala biti 3; jedan za svaku boju u RGB modelu boja. Za duboko

učenje potrebna je četvrta dimenzija koja predstavlja broj slika u skupu. Skup slika stoga predstavlja 4D tenzor koji je sačinjen od slika iste visine, širine i broja kanala (Kheloufi, 2021). Primjer slike kao 4D tenzora može se vidjeti na Slici 13⁹. Na Slici 14 prikazano je pretprocesiranje slike, tj. kako model pretvara sliku iz 3D tenzora u 4D tenzor kako bi bila spremna za obradu.



Slika 13: Četiri dimenzije 4D tenzora

```
In [63]: resized_img = image.img_to_array(img)
         final_image = np.expand_dims(resized_img, axis=0)
         final_image = tf.keras.applications.mobilenet.preprocess_input(final_image)

In [64]: final_image.shape

Out[64]: (1, 224, 224, 3)
```

Slika 14: Pretprocesiranje slike

4.5. Stvaranje predikcija

Model stvara predikcije o tome što se nalazi u slici i izražava to kao vjerojatnost da se taj objekt nalazi u slici. Ispisuje prvih 5 predikcija s najvećom vjerojatnošću. U konkretnom slučaju, model je točno previdio da je na slici Egipatska mačka sa sigurnošću od 95,51%. To je prikazano na Slici 15.

⁹ prema <https://medium.com/analytics-vidhya/preprocess-image-data-for-machine-learning-37df531583d8>

```
In [65]: predictions = mobile.predict(final_image)

In [66]: print(predictions)

[[5.57879048e-06 2.92781733e-05 3.88797707e-06 1.19886563e-05
 6.50761058e-06 1.05262707e-05 3.43218130e-06 4.61762011e-06
 6.34779917e-06 1.03051843e-05 8.96883648e-06 3.09804273e-06
 7.84674285e-06 2.47951925e-06 6.56084012e-06 7.30737247e-06
 1.10664087e-05 9.56369786e-06 4.68885219e-06 5.49551169e-06
 2.96127619e-05 1.83278607e-05 1.74773515e-06 5.05033358e-06
 4.60514602e-05 1.82855929e-05 4.72658503e-05 2.67148844e-05
 3.80200731e-06 5.43898459e-05 1.44151181e-05 3.27929083e-05
 6.86723070e-05 2.86512818e-06 7.86788860e-06 1.92688567e-05
 1.48602412e-05 6.47003571e-06 2.39470362e-04 7.27237511e-06
 2.44806483e-06 1.40456992e-04 7.15860078e-05 1.98479520e-05
 1.65873334e-05 4.50610642e-05 1.00348543e-05 5.14339699e-05
 3.65857659e-06 7.03470641e-06 5.91340904e-06 1.23192032e-04
 7.61652336e-06 1.34511765e-05 1.34923539e-05 1.29961136e-05
 1.25514839e-06 7.39191591e-06 7.66831363e-06 3.44499895e-05
 1.15127004e-05 2.01538114e-06 5.66871950e-06 8.52920275e-05
 9.80648292e-06 5.34234505e-06 4.89892263e-05 1.50406595e-05
 9.90119443e-05 1.95243483e-05 7.14421958e-06 1.36603430e-05
 6.57141618e-06 3.09163952e-05 9.48808702e-06 2.20739412e-06
 7.87878787e-06 7.87878787e-06 7.87878787e-06 7.87878787e-06]

In [67]: from tensorflow.keras.applications import imagenet_utils

In [68]: results = imagenet_utils.decode_predictions(predictions)

In [69]: print(results)

[[('n02124075', 'Egyptian_cat', 0.95510435), ('n02128757', 'snow_leopard', 0.008850143), ('n02128385', 'leopard', 0.0051122904), ('n02127052', 'lynx', 0.0044882074), ('n02130308', 'cheetah', 0.0025661509)]]
```

Slika 15: Ispis predikcija modela

5. Zaključak

Umjetna inteligencija kao područje predstavlja plodno tlo za proučavanje i inovaciju. Svijet u kojemu danas živimo obiluje tehnologijom koja je nastala kao rezultat razvoja umjetne inteligencije. Računala, roboti, samovozeći automobili, virtualni asistenti i algoritmi za preporuke samo su neki od primjera, a za pretpostaviti je da će se udio takve tehnologije sve više povećavati kako područje napreduje.

Prepoznavanje slika jedna je od najpristupačnijih primjena umjetne inteligencije. Kao područje, postalo je toliko efektivno upravo zato što implementira duboko učenje. Za određene potrebe, računalni vid već sada je postao efektivniji od ljudskog. Neuronske mreže kao centralni dio algoritama za prepoznavanje slika imaju mogućnost automatizirati razne poslovne procese i tako povećati produktivnost. Njihova trenutna primjena u sigurnosti i nadzoru, vizualnom internet pretraživanju, društvenim mrežama, analizi slika, automobilske industriji i drugim područjima pokazuje raznolikost njihove primjene, ali i ukazuje na mogućnost za rast u mnogim drugim područjima.

Umjetne neuronske mreže, kao metoda strojnog učenja, čine se kao prikladne za rješavanje brojnih problema. Pod uvjetom da će se uz njih razvijati i procesna snaga, očekuje se da će neuronske mreže u budućnosti ovladati gotovo svim domenama života.

6. Literatura

1. Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M., Kudlur, M., Levenberg, J., Monga, R., Moore, S., Murray, D., Steiner, B., Tucker, P., Vasudevan, V., Warden, P., i Wicke, M. (2016). *TensorFlow: A system for large-scale machine learning*. Preuzeto 27.8.2021. s <https://arxiv.org/pdf/1605.08695.pdf>.
2. Brownlee, J. (2019). *Deep Learning for Computer Vision: Image Classification, Object Detection, and Face Recognition in Python*. Machine Learning Mastery.
3. Aggarwal, C. C. (2018). *Neural Networks and Deep Learning: A Textbook*. Springer.
4. Alexander, D. (2020). *Neural networks: History and Applications*. Nova Science Publishers.
5. Anderson, D., i McNeill, G. (1992). *Artificial Neural Networks Technology*. Kaman Sciences Corporation.
6. Cherry, K. (2021). *Gardner's Theory of Multiple Intelligences*. Preuzeto 18.8.2021. s <https://www.verywellmind.com/gardners-theory-of-multiple-intelligences-2795161>
7. DeepAI. (2019). *Perceptron*. Preuzeto 2.9.2021. s <https://deepai.org/machine-learning-glossary-and-terms/perceptron>.
8. Fausett, L. V. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice-Hall.
9. GitHub. (2019). *Keras*. Preuzeto 14.9.2021. s <https://github.com/keras-team/keras>.
10. GitHub. (2019). *Tensorflow*. Preuzeto 27.8.2021. s <https://github.com/tensorflow/tensorflow>.
11. Haenlein, M., i Kaplan, A. (2019). A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review*, 61(4), 5–14.
12. Hrvatska enciklopedija. (2021). *Inteligencija*. Preuzeto 18.8.2021. s <https://www.enciklopedija.hr/natuknica.aspx?ID=27600>
13. Kaliraj, P., i Devi, T. (2021). *Artificial Intelligence Theory, Models, And Applications*. Auerbach Publications.

14. Kelleher, J. D. (2019). *Deep learning*. The MIT Press.
15. Keras. (n.d.). *MobileNet and MobileNetV2*. Preuzeto 28.8.2021. s <https://keras.io/api/applications/mobilenet/>
16. Kheloufi, A. (2021). *Preprocess Image Data For Machine Learning*. Preuzeto 28.8.2021. s <https://medium.com/analytics-vidhya/preprocess-image-data-for-machine-learning-37df531583d8>
17. Krambeger, T., Nožica, B., Dodig, I. i Cafuta, D. (2019). Pregled tehnologija u neuronskim mrežama. *Polytechnic and design*, 7 (1), 25-32.
18. Kriesel, D. (2007). *A Brief Introduction to Neural Networks*.
19. McCarthy, J. (2007). What Is Artificial Intelligence? Preuzeto 19.8.2021. s <http://jmc.stanford.edu/articles/whatisai.html>
20. Mihajlovic, I. (2019). *Everything You Ever Wanted To Know About Computer Vision*. Preuzeto 31.8.2021. s <https://towardsdatascience.com/everything-you-ever-wanted-to-know-about-computer-vision-heres-a-look-why-it-s-so-awesome-e8a58dfb641e>.
21. NumPy. (n.d.). *NumPy*. Preuzeto 27.8.2021. s <https://numpy.org/about/>.
22. O'Shea, K., i Nash, R. (2015). An Introduction to Convolutional Neural Networks. *ArXiv*, abs/1511.08458.
23. Reljić, I., Dunder, I., Seljan, S. (2019). Photogrammetric 3D Scanning of Physical Objects: Tools and Workflow. *TEM Journal* 8 (2), 383-388.
24. Sabouret, N. (2020). *Understanding Artificial Intelligence*. CRC Press.
25. Sakarkar, G., Patil, G., i Dutta, P. (2021). *Machine Learning Algorithms Using Python Programming*. Nova Science Publishers.
26. Seljan, S.; Miloloža, I.; Pejić Bach, M. (2020). e-Government in European countries: gender and ageing digital divide. *Interdisciplinary Management Research XVI*, 1581-1602.
27. Singh, S. P. (2019). *Fully Connected Layer: The brute force layer of a Machine Learning model*. Preuzeto 2.9.2021. s <https://iq.opengenus.org/fully-connected-layer/>.
28. TensorFlow. (2019). *TensorFlow*. Preuzeto 27.8.2021. s <https://www.tensorflow.org/>.
29. W3Schools. (n.d.). *Introduction to NumPy*. Preuzeto 27.8.2021. s https://www.w3schools.com/python/numpy/numpy_intro.asp.
30. Zhou, Z. (2021). *Machine Learning*. Springer Singapore.

7. Popis slika

| | |
|---|----|
| Slika 1: Ilustracija odnosa između dubokog učenja, strojnog učenja i umjetne inteligencije | 4 |
| Slika 2: Ilustracija neuronske mreže sa tri skrivena sloja..... | 5 |
| Slika 3: Neuroni i neuronske mreže | 7 |
| Slika 4: Shema umjetnog neurona..... | 8 |
| Slika 5: Usporedba točnosti tipičnog ML algoritma i točnosti algoritma neuronske mreže s obzirom na količinu podataka..... | 9 |
| Slika 6: Perceptron | 15 |
| Slika 7: Feedforward neuronska mreža s jednim skrivenim slojem..... | 16 |
| Slika 8: Neuronska mreža s potpuno povezanim slojevima..... | 17 |
| Slika 9: Ilustracija konvolucijskog sloja konvolucijske neuronske mreže..... | 18 |
| Slika 10: Uvoz biblioteka u Python..... | 20 |
| Slika 11: Učitavanje slike uz pomoć TensorFlowa | 22 |
| Slika 12: Učitavanje modela za duboko učenje..... | 22 |
| Slika 13: Četiri dimenzije 4D tenzora | 23 |
| Slika 14: Pretprocesiranje slike | 23 |
| Slika 15: Ispis predikcija modela | 24 |

Primjena neuronskih mreža u prepoznavanju slika

Sažetak:

Umjetne neuronske mreže, kao jedan od najuspješnijih pristupa obrade podataka, rastu u upotrebi unutar svih znanstvenih područja. Prepoznavanje slika jedna je od najpristupačnijih primjena neuronskih mreža. Cilj ovog završnog rada je prikazati teorijsku podlogu prepoznavanja slika uz pomoć primjene umjetnih neuronskih mreža kod strojnog učenja te primjena ranije navedene teorije u praksi. Prvi dio rada odnosi se na teorijski aspekt i razvoj neuronskih mreža, a drugi na njihovu praktičnu primjenu pri prepoznavanju slika.

Ključne riječi: umjetne neuronske mreže, prepoznavanje slika, konvolucijske neuronske mreže, strojno učenje, duboko učenje

Application of neural networks in image recognition

Summary:

Artificial neural networks, as one of the most successful approaches to data processing, grow in use in all the scientific areas. Image recognition is one of the most accessible applications of neural networks. The goal of this undergraduate thesis is to present the theoretical basis of image recognition with the help of the application of artificial neural networks in machine learning and the application of the aforementioned theory in practice. The first part of the thesis deals with the theoretical aspect and development of neural networks, whereas the second with their practical application in image recognition.

Key Words: artificial neural networks, image recognition, convolutional neural networks, machine learning, deep learning