

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

ZAVRŠNI RAD br. 1984

**KLASIFIKACIJA STUPNJA ALZHEIMEROVE DEMENCIJE
TEMELJEM SNIMKI MAGNETSKE REZONANCE MOZGA I
METODA DUBOKOG UČENJA**

Karin Brajdić

Zagreb, lipanj 2025.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

ZAVRŠNI RAD br. 1984

**KLASIFIKACIJA STUPNJA ALZHEIMEROVE DEMENCIJE
TEMELJEM SNIMKI MAGNETSKE REZONANCE MOZGA I
METODA DUBOKOG UČENJA**

Karin Brajdić

Zagreb, lipanj 2025.

ZAVRŠNI ZADATAK br. 1984

Pristupnica: **Karin Brajdić (0036546665)**
Studij: Elektrotehnika i informacijska tehnologija i Računarstvo
Modul: Računarstvo
Mentor: izv. prof. dr. sc. Alan Jović

Zadatak: **Klasifikacija stupnja Alzheimerove demencije temeljem snimki magnetske rezonance mozga i metoda dubokog učenja**

Opis zadatka:

Snimke magnetske rezonance (MRI) važan su izvor informacija za otkrivanje i dijagnozu većeg broja bolesti organizma. Liječnicima bi od značajne dodatne pomoći bio automatizirani sustav koji bi ispravno određivao stupanj demencije temeljem MRI-ja mozga. Cilj ovog završnog rada je izrada klasifikacijskog modela dubokog učenja za nekoliko stupnjeva Alzheimerove demencije temeljem MRI-ja mozga. Kao skup za učenje modela potrebno je upotrijebiti neki od skupova podataka koje su kvalitetno označili liječnici (npr. <https://www.kaggle.com/datasets/aryansinghal10/alzheimers-multiclass-dataset-equal-and-augmented>, <https://www.kaggle.com/datasets/yasserhessein/dataset-alzheimer>). Klasifikacijski model treba biti zasnovan na nekoj od arhitektura dubokih neuronskih mreža primjerenoj zadatku (npr. konvolucijske neuronske mreže, konvolucijske neuronske mreže s dodatnim mehanizmom pažnje). U radu je potrebno teorijski opisati metode predobrade MRI snimki i metode dubokog učenja. Nakon toga, potrebno je izabrati prikladan model (jedan ili više njih) te ga naučiti na odgovarajućem skupu podataka. Rezultate na zasebnom testnom skupu podataka potrebno je prikazati odgovarajućim mjerama za evaluaciju modela strojnog učenja te ih komentirati. Implementaciju je potrebno napraviti u programskom jeziku po vlastitom izboru, a za izgradnju modela može se u slučaju nedostatka vlastitih sklopovskih resursa koristiti dostupna web rješenja (npr. Google Colab).

Rok za predaju rada: 23. lipnja 2025.

Sadržaj

Uvod.....	1
1. Opis problema i skupa podataka	2
1.1. Alzheimerova demencija.....	2
1.2. MRI	3
1.3. Opis skupa podataka.....	4
2. Duboke neuronske mreže.....	5
2.1. Konvolucijske neuronske mreže (CNN)	6
2.1.1. Konvolucijski sloj	7
2.1.2. Sloj sažimanja (Pooling layer)	8
2.1.3. Potpuno povezani sloj (Fully-connected layer).....	9
3. Metode predobrade slika.....	10
4. Izrada rješenja	12
4.1. Obrada podataka.....	12
4.2. Izrada modela	15
4.3. Evaluacija modela	17
4.3.1. Točnost i funkcija gubitka	17
4.3.2. Matrica konfuzije i izvještaj o klasifikaciji	18
Zaključak.....	22
Literatura	23
Sažetak	26
Abstract	27

Uvod

Neurodegenerativna Alzheimerova bolest najčešći je uzrok demencije, jednog od najvećih problema današnjeg zdravstva. Prema podacima Svjetske zdravstvene organizacije, 2022. godine u svijetu je s demencijom živjelo oko 55 milijuna ljudi, od kojih 60 do 80% boluje od Alzheimerove bolesti. Predviđa se da će taj broj do 2030. narasti za gotovo 50%, što dodatno ukazuje na važnost intenzivnog istraživanja ove bolesti [1]. S obzirom da za Alzheimerovu bolest još uvijek ne postoji lijek, rana dijagnostika i praćenje razvoja bolesti od ključne su važnosti za usporavanje njezine progresije i poboljšanje kvalitete života oboljelih.

Jedan od najvažnijih alata u dijagnostici Alzheimerove bolesti je snimka magnetske rezonance (MRI) mozga, pomoću koje liječnici identificiraju karakteristične morfološke promjene u moždanom tkivu i donose odluke o prisutnosti, odnosno stupnju razvoja bolesti [3]. Takva liječnička dijagnostika zahtijeva iskustvo i objektivnost te je podložna greškama i krivim tumačenjima, pogotovo u ranim fazama bolesti kada promjene u tkivu mogu biti vrlo suptilne i teško uočljive.

Implementacijom strojnog učenja, odnosno modela dubokih neuronskih mreža, moguće je razviti automatizirani sustav klasifikacije slika. Cilj ovoga rada je primjenom konvolucijskih neuronskih mreža izraditi model za klasifikaciju stupnja Alzheimerove demencije na temelju MRI slika mozga kako bi se proces dijagnostike bolesti ubrzao, olakšao i učinio što preciznijim i pouzdanijim. Pritom se nastoji prikazati jedno od područja primjene dubokog učenja u medicinskoj dijagnostici i evaluirati uspješnost mogućnosti pravilne i istinitosne klasifikacije modela.

Uz uvod, zaključak, popis literature te sažetak na hrvatskom i engleskom jeziku, rad sadrži četiri glavna poglavlja. Prvo poglavlje sadrži medicinski uvod u problematiku Alzheimerove bolesti i opis korištenog skupa podataka. Drugo poglavlje posvećeno je teorijskoj podlozi i definiciji dubokih neuronskih mreža, dok treće poglavlje iznosi metode predobrade slika za potrebe izrade modela neuronske mreže. Posljednje, četvrto poglavlje detaljno opisuje postupak izrade i evaluacije modela, od obrade podataka, preko izgradnje modela, do analize i tumačenja rezultata.

1. Opis problema i skupa podataka

1.1. Alzheimerova demencija

Demencija podrazumijeva bolesti karakterizirane smanjenjem mogućnosti pamćenja i kognitivnih funkcija koje nastaju zbog oštećenja moždanih stanica. Ona utječe na čovjekovu svakodnevicu, smanjuje sposobnost razmišljanja i komunikacije te utječe na ponašanje. Jedna vrsta demencije je Alzheimerova demencija koja nastaje kao posljedica Alzheimerove bolesti.

Alzheimerova demencija je ireverzibilna i progresivna neurodegenerativna bolest središnjeg živčanog sustava koja rezultira odumiranjem moždanih stanica i gubitkom kognitivnih funkcija. Patološke promjene kod oboljelih osoba očituju se u nakupinama uvijenih niti (neurofibrilarna vretena) unutar neurona i proteina beta-amiloida (senilni plak) izvan neurona koji blokiraju međusobnu komunikaciju i procese potrebne za preživljavanje živčanih stanica što uzrokuje njihovo odumiranje i postupno smanjenje volumena mozga [6].

Uzrok bolesti još nije u potpunosti poznat i klinički početak ovog poremećaja je najčešće neprimjetan jer su prvi simptomi blagi i bolest se razvija postupno. Zbog toga je vrlo važna rana dijagnostika jer, iako za demenciju još uvijek ne postoji lijek, njezin se razvoj može usporiti i kontrolirati. U rijetkim slučajevima, početak može biti iznenađan i uzrokovan nekim tjelesnim oboljenjem ili emocionalnim šokom.


Ako osoba oboli od Alzheimerove demencije, tijekom progresije bolesti može se podijeliti u tri stadija:

1. Rani (blagi) stadij – u početnoj fazi bolesti javljaju se blagi simptomi poput oštećenja pamćenja i sjećanja za nedavne događaje, orijentacije u prostoru i otežane komunikacije.
2. Umjereni (srednji) stadij – simptomi se pogoršavaju, češće su smetnje u govoru i komunikaciji, otežano je obavljanje svakodnevnih funkcija poput oblačenja i održavanja higijene, zaboravljaju se naučene vještine i često dolazi do agresivnog ponašanja.

3. Kasni (teški) stadij – oboljela osoba zahtijeva sveobuhvatnu brigu i njegu, ne prepoznaje osobe, ne može ili vrlo teško komunicira i vrši higijenske potrebe te može ostati nepokretna ili dobiti epileptičke napade. [2]

1.2. MRI

Alzheimerovu demenciju je moguće dijagnosticirati magnetskom rezonancom (MRI) mozga. Njezina je primjena ključna u klasifikaciji stupnja razvoja i praćenju progresije bolesti [3]. Prilikom analize slika nastoje se uočiti specifični obrasci atrofije moždanog tkiva, posebice u regiji medijalnog temporalnog režnja (Slika 1.), odnosno hipokampusa, parahipokampalne vijuge i entorinalnog korteksa, koji su najosjetljiviji i najpogodniji dio mozga za razvoj Alzheimerove bolesti. U ranom stadiju demencije, MRI može pokazati suptilne promjene u strukturi mozga, posebno u hipokampusu i entorinalnom korteksu, čak i prije nego što se pojave teži kognitivni simptomi. Budući je to dio mozga zaslužan za pamćenje i prostornu orijentaciju, od ključne je važnosti za čovjeka. Mjerenje volumena, odnosno volumetrija hipokampusa koristi se kao glavni biomarker za ranu dijagnostiku i praćenje bolesti te je vrlo pouzdan s 80-85% osjetljivosti i specifičnosti.




Slika 1

Slika 1. Građa medijalnog temporalnog režnja [4]

Osim toga, može se analizirati debljina moždane kore, odnosno kortikalna debljina i obrasci gubitka sive tvari, posebice u emporoparijetalnim regijama pomoću čega se mogu razlikovati ostali oblici demencije od Alzheimerove demencije [5].

1.3. Opis skupa podataka

Za klasifikaciju stupnja Alzheimerove demencije korišten je Alzheimer's Disease Multiclass Images Dataset preuzet sa stranice Kaggle ([Alzheimer's Disease Multiclass Images Dataset](#)). Skup podataka čini 44,000 anotiranih MRI snimaka mozga u .JPG formatu podijeljenih u četiri grupe po stupnju napredovanja bolesti: 12,800 NonDemented (nema znakove bolesti), 11,200 VeryMildDemented (rani, vrlo blagi simptomi bolesti), 10,000 MildDemented (očiti simptomi, blaga bolest) i 10,000 ModerateDemented (izraženiji simptomi, umjerena bolest) (Slika 2.). Na svakoj je slici prikaz samo moždanog tkiva bez kosti lubanje i ostalih tkiva.




Slika 2. Primjeri MRI slika svake klase iz skupa podataka

2. Duboke neuronske mreže

Kao sastavni dio strojnog učenja, duboko učenje karakterizira korištenje velikog broja slojeva neuronskih mreža. Zovu se neuronske mreže jer simuliraju način na koji neuroni u ljudskom mozgu obrađuju informacije i donose zaključke [7]. One su jedne od najvažnijih modela strojnog učenja jer omogućuju rješavanje raznih složenih problema poput klasifikacije, prepoznavanja obrazaca i predviđanja. Neuronske mreže uče putem iskustva, što znači da im povećanjem skupa podataka za učenje raste točnost i učinkovitost.

Neuronska mreža sastoji se od međusobno povezanih slojeva neurona (čvorova), pri čemu svaki čvor ima svoju težinu w i prag aktivacije *bias* – vrijednost na kojoj se neuron aktivira i šalje izlazni signal sljedećem sloju mreže. Strukturu mreže čine ulazni, skriveni i izlazni sloj (Slika 3.), a ukoliko mreža sadrži više od jednog skrivenog sloja, tada govorimo o **dubokoj neuronskoj mreži** [17].



Slika 3. Slojevi neuronske mreže [8]

Svaki čvor u neuronskoj mreži može se zamisliti kao model linearne regresije s formulom

$$z = \sum w_i x_i + bias \quad (1)$$

gdje su:

x_i – ulazni podatak,

w_i – težina čvora koja određuje važnost varijable,

$bias$ – prag aktivacije

Izlaz neurona određuje aktivacijska funkcija f , matematička funkcija (2) koja unosom nelinearnosti u model odlučuje hoće li se neuron aktivirati i proslijediti podatke sljedećem sloju u mreži. Najčešće aktivacijske funkcije su ReLU, sigmoid, tangens hiperbolni (tanh) i softmax [18].

$$a = f(z) \quad (2)$$

Kod klasifikacijskih zadataka koriste se označeni skupovi podataka za učenje, gdje se točnost modela evaluira pomoću funkcije gubitka (npr. srednje kvadratne pogreške – MSE). Cilj je minimizirati ovu funkciju kroz iterativno prilagođavanje težina i pomaka, čime se model "uči" i konvergira prema lokalnom minimumu pogreške.

Mreža može biti unaprijedna (engl. *feedforward*), što znači da se signali prosljeđuju samo od ulaznog prema izlaznom sloju bez povratnih veza, ali model se može naučiti i algoritmom propagacije pogreške unatrag (engl. *error backpropagation*) u kojem se pogreška širi od izlaznog prema ulaznom sloju, a putem se računa pogreška svakog neurona pomoću koje se naposljetku prilagođavaju parametri modela.

Postoje razne vrste neuronskih mreža, od kojih su najčešće korištene konvolucijske neuronske mreže (engl. *Convolutional Neural Networks* – CNN), koje se primarno upotrebljavaju za klasifikaciju i obradu slika u sklopu računalnog vida, te rekurentne neuronske mreže (engl. *Recurrent Neural Networks* – RNN), vrlo učinkovite u obradi prirodnog jezika i prepoznavanju govora [8].


2.1. Konvolucijske neuronske mreže (CNN)

Konvolucijske neuronske mreže posebno su uspješne u obradi slikovnih, govornih i glasovnih signala te su najčešće rješenje za probleme računalnog vida kao što su klasifikacija i prepoznavanje objekata i uzoraka na slikama. Sastoje se od tri glavna sloja: konvolucijski sloj, sloj sažimanja (engl. *pooling layer*) i potpuno povezani sloj (engl. *fully connected layer*). Konvolucijski sloj koristi filter koji prolazi kroz sliku i pronalazi uzorke poput rubova, tekstura ili jednostavnih oblika. Nakon toga, sloj sažimanja smanjuje dimenzionalnost podataka pritom

zadržavajući najvažnije informacije. Na kraju, potpuno povezani sloj objedinjuje sve izdvojene značajke i donosi konačnu odluku o klasifikaciji slike. Sa svakim dodatnim slojem mreža postaje kompleksnija, prvi slojevi razlučuju samo osnovne značajke poput boje i rubova, a svaki sljedeći prepoznaje sve složenije uzorke, oblike i strukture, naposljetku prepoznajući cijele objekte.

2.1.1. Konvolucijski sloj

Konvolucijski sloj u neuronskoj mreži ključan je za razlučivanje i izdvajanje značajki iz ulaznih podataka, točnije slike. On obavlja proces konvolucije, aplicira funkciju klizećeg prozora (engl. *filter*, *kernel*) na matricu piksela ulazne slike s ciljem prepoznavanja uzoraka i značajki važnih za kasniju klasifikaciju ili detekciju objekata [11]. **Ulaz** u konvolucijski sloj je trodimenzionalna matrica piksela koja predstavlja visinu, širinu i dubinu slike, primjerice RGB kanali. **Filter** je dvodimenzionalno polje težina, najčešće dimenzija 3x3, koji tijekom učenja prilagođava svoje vrijednosti težina kako bi prepoznao određene uzorke na slici.



Slika 4. Primjena filtra u konvolucijskom sloju [9]

Filter se pomiče po matrici piksela (ulaznoj slici) za određeni broj piksela, odnosno pomak (engl. *stride*) sve do prolaska preko cijele matrice te u svakom koraku računa skalarni produkt (engl. *dot product*) od vrijednosti piksela matrice i težine filtera (Slika 4.), a rezultat se pohranjuje u izlazno polje zvanu **mapa značajki** (engl. *feature map*, *activation map*, *convolved*

feature). Krajnji rezultat je nova matrica koja prikazuje gdje su na ulaznoj slici prepoznati određeni uzorci.

Prilikom izgradnje konvolucijskog sloja potrebno je definirati tri parametra:

1. Broj filtera – određuje koliko različitih značajki će biti razlučeno
2. Pomak – broj piksela za koji se filter pomakne u svakom koraku
3. Dopuna (engl. *Padding*) – način na koji se obrađuju rubovi slike koji nisu poravnati s filterom
 - a. *Zero padding* – elementi izvan ulazne matrice se postavljaju na 0
 - b. *Valid padding* – bez paddinga, može se odbaciti zadnja konvolucija
 - c. *Same padding* – omogućuje da izlazna matrica bude iste dimenzije kao ulazna
 - d. *Full padding* – dodavanje nula na rubove ulazne matrice čime se povećava dimenzija izlazne [9]

Nakon svake operacije konvolucije, na dobivenu mapu značajki primjenjuje se nelinearna aktivacijska funkcija, najčešće ReLU, koja omogućuje mreži modeliranje nelinearnih odnosa u podacima i poboljšava sposobnost učenja složenih obrazaca.

Dodavanjem konvolucijskih slojeva mreža postepeno izgrađuje sve složenije razine značajki. Prvi slojevi prepoznaju jednostavne elemente i uzorke poput rubova i tekstura, dok dublji slojevi kombiniraju te informacije kako bi prepoznali sve kompleksnije oblike i cijele objekte na slici.

2.1.2. Sloj sažimanja (engl. *Pooling layer*)

U konvolucijskoj neuronskoj mreži nakon konvolucijskog sloja slijedi sloj sažimanja čija je glavna zadaća reducirati broj parametara koji se prenose u sljedeći sloj mreže i time smanjiti dimenzionalnost podataka. To se postiže filterom koji na ulazne vrijednosti primjenjuje agregacijsku funkciju te se rezultati upisuju u izlazno polje. Agregacijska funkcija je matematička funkcija koja sažima skup vrijednosti u jednu jedinstvenu vrijednost.

Najčešće korištene vrste sažimanja su maksimum (engl. *max pooling*) i prosjek (engl. *average pooling*). Uporabom maksimuma, filter u svakom koraku prolaska preko ulaznih vrijednosti odabire maksimalnu vrijednost piksela unutar receptivnog polja, dok prosjek u

svakom koraku prolaska izračunava srednju vrijednost piksela unutar receptivnog polja. Korištenjem sloja sažimanja reducira se kompleksnost, povećava efikasnost i smanjuje rizik od prenaučenosti modela [9]. Također, povećava se robusnost modela na manje varijacije i translacije u ulaznim podacima što je posebno korisno kod analize slika.

2.1.3. Potpuno povezani sloj (engl. *Fully-connected layer*)

Završni sloj prije izlaznog u konvolucijskoj neuronskoj mreži je potpuno povezani sloj. Izlaz prijašnjih slojeva, koji je višedimenzionalna matrica značajki, izravnavana se (engl. *flatten*) u jednodimenzionalni vektor koji postaje ulaz za potpuno povezani sloj. U ovome sloju svaki je čvor povezan sa svim čvorovima iz prethodnog sloja čime se omogućuje da svaka značajka izdvojena u prijašnjim slojevima utječe na donošenje završne odluke mreže. Drugim riječima, potpuno povezani sloj je poveznica izdvojenih značajki u mreži i konačne odluke modela [21]. Nakon što se sve naučene značajke povežu, mreža postaje spremna za zaključivanje i klasifikaciju podataka u izlaznom sloju.

Izlazni sloj generira konačnu klasifikaciju modela. On ima jedan neuron (čvor) za svaku od mogućih klasa. Na izlazne vrijednosti potpuno povezanog sloja primjenjuje se odgovarajuća aktivacijska funkcija. Za višeklasnu klasifikaciju najčešće se koristi funkcija softmax funkcija koja normalizira izlaze tako da njihova suma bude jednaka 1, kako bi se dobile vjerojatnosti pripadnosti svakoj klasi. Kod binarne klasifikacije koristi se sigmoidna funkcija, a za regresijske zadatke linearna funkcija. Konačni rezultat izlaznog sloja je predikcija modela, odnosno oznaka klase kojoj slika pripada ili numerička vrijednost za regresiju.

3. Metode predobrade slika

Predobrada podataka vrlo je bitan korak u razvoju modela dubokog učenja, pogotovo kada se radi o slikama koje će se koristiti za klasifikaciju pomoću modela konvolucijske neuronske mreže. Metode koje se upotrebljavaju za predobradu slika osiguravaju da svi podaci odgovaraju arhitekturi mreže i omogućuju stvaranje robusnijih i preciznijih modela. Pravilna predobrada doprinosi konzistentnosti, efikasnosti, stabilnosti i brzini rada modela, što je vrlo važno za optimiziranje performansi i osiguravanje sposobnosti generalizacije za različite skupove podataka.

Proces predobrade počinje učitavanjem slika, odnosno skupa podataka iz odgovarajućih direktorija. Prvi korak, **promjena veličine slike** (engl. *resizing*), jedan je od najvažnijih koraka, jer arhitektura konvolucijskih neuronskih mreža zahtijeva da sve ulazne slike budu konzistentne veličine kako bi ih mreža mogla efikasno obraditi. Ovo se postiže korištenjem funkcija poput `resize()` ili `rescale()`.

Kada su slike odgovarajuće veličine, potrebno je prilagoditi vrijednosti piksela koje u slikama mogu biti od 0 do 255, gdje 0 predstavlja crnu boju, a 255 bijelu. Za optimalno funkcioniranje modela neuronske mreže potrebno je skalirati te vrijednosti raspon od 0 do 1 normalizacijom ili standardizacijom. **Normalizacija** se provodi dijeljenjem svih vrijednosti piksela s 255, a **standardizacija** oduzimanjem srednje vrijednosti od svake vrijednosti piksela i dijeljenjem rezultata sa standardnom devijacijom svih piksela. Standardizacija omogućuje bolje rukovanje sa stršećim vrijednostima i reducira varijancu podataka, što poboljšava stabilnost učenja modela, ali se ipak češće koristi normalizacija jer je jednostavnija.

Treba odrediti **format slike**, odnosno provjeriti jesu li slike u sivim tonovima (engl. *grayscale*) ili u boji (RGB format). Slike u sivim tonovima imaju samo jedan kanal, dok RGB slike imaju tri kanala (crveni, zeleni, plavi). Slike u sivim tonovima zahtijevaju manje memorije i brže se obrađuju, ali se njihovim korištenjem može izgubiti dio informacija koje slike u boji mogu zadržati.

Kako bi se povećala raznolikost i broj uzoraka za učenje, koristi se **proširivanje skupa podataka** (engl. *data augmentation*). Postupak podrazumijeva primjenu slučajnih transformacija na postojeći skup podataka poput rotacije, okretanja, obrezivanja, zumiranja, promjene svjetlosti, kontrasta ili saturacije. Ovim postupkom umjetno se proširuje skup za

učenje i dobivaju dodatne varijacije među ulaznim podacima, što sprječava prenaučenosť i poboljšava sposobnost generalizacije modela.

Za smanjenje šuma u podacima koriste se tehnike **zaglađivanja** i **filtriranja**. Time se sa slika uklanjaju neželjeni i nepotrebni detalji, a čuvaju samo glavne, relevantne značajke čime se smanjuje utjecaj slučajnih varijacija. Funkcije poput `GaussianBlur()`, `medianBlur()` i `bilateralFilter()` služe kao filter i zamjenjuju vrijednost svakog piksela primjerice srednjom vrijednošću ili medijanom piksela iz njegove okoline.

Za uspješnu klasifikaciju potrebno je **kodirati oznake** (engl. *label encoding*) ciljne kategorije svake slike koje će se koristiti u izlaznom sloju mreže. Ovisno o namjeni mreže, oznake mogu biti binarne za klasifikaciju s dvije klase, kategorijske za prisutnost više klasa ili brojčane za regresiju s kontinuiranim ishodima. [13] Kodiranje se provodi pomoću biblioteka kao što su NumPy, pandas ili scikit-learn.

Na posljjetku, sve predobrađene slike i pripadajuće oznake treba spremići u odgovarajućem formatu, primjerice korištenjem biblioteka NumPy, pandas, PyTorch ili TensorFlow biblioteka, što omogućuje efikasno učitavanje tijekom učenja modela.

4. Izrada rješenja

Cilj ovog rada bila je izrada modela konvolucijske neuronske mreže za klasifikaciju MRI slika mozga koji će za dani skup podataka pravilno klasificirati stupanj oboljenja od Alzheimerove demencije. Model neuronske mreže ostvaren je u programskom jeziku Python, u razvojnoj okolini Google Colab. Za rukovanje s podacima i izgradnju modela korištene su biblioteke NumPy, matplotlib, TensorFlow, Keras i Seaborn te zipfile, os i shutil za rad s datotekama u kojima se nalaze skupovi podataka.

NumPy je standardna biblioteka u Pythonu koja se koristi za rad s numeričkim podacima i višedimenzionalnim nizovima, odnosno omogućuje izvođenje raznih matematičkih operacija nad velikim skupovima podataka zbog čega se pri izradi raznih modela strojnog učenja koristi za pripremu ulaznih skupova podataka, obradu rezultata modela te primjerice uz pomoć biblioteke matplotlib za vizualizaciju podataka.

Najvažnija biblioteka za izradu modela dubokog učenja je TensorFlow i njegov API Keras koji omogućuje jednostavnu i efikasnu izgradnju, učenje i evaluaciju modela neuronske mreže. Keras sadrži ključne komponente poput slojeva i modela, osnovne gradivne jedinice svake mreže, te omogućuje brzo definiranje konvolucijskih, potpuno povezanih i drugih slojeva, kao i jednostavnu primjenu optimizatora i funkcija za zaustavljanje učenja [16].

Prilikom tumačenja uspješnosti modela najkorisnije su biblioteke scikit-learn koja sadrži sve potrebne alate za evaluaciju poput izračuna matrice konfuzije i sažetka najbitnijih pokazatelja uspješnosti modela te Seaborn za vizualizaciju tih statističkih podataka uporabom raznih grafova.

4.1. Obrada podataka

Nakon učitavanja datoteka koje sadrže slike namijenjene izgradnji modela, slijedi vrlo važan korak predobrade slika (Slika 5.). Iako su slike u skupu podataka već bile slične veličine, svim slikama je promijenjena dimenzija na 224x224 piksela kako bi se osigurala konzistentnost i kompatibilnost s arhitekturom neuronske mreže. Provjerom je utvrđeno da su slike u RGB formatu, što je zadržano zbog veće detaljnosti koju ovaj format omogućuje u analizi. Nakon

toga, slike su normalizirane, odnosno vrijednosti piksela su skalirane u raspon od 0 do 1, što poboljšava stabilnost i učinkovitost procesa učenja modela.

Prema navedenom opisu preuzetog skupa podataka na stranici Kaggle, slike su već djelomično obrađene, pri čemu je na njima zadržano samo relevantno moždano tkivo, bez kosti lubanje i ostalih okolnih tkiva, što je smanjilo potrebu za detaljnijom obradom, odnosno primjenom filtera za smanjenje šuma. To je pokazalo i krajnje testiranje učinkovitosti mreže, gdje su rezultati dobiveni nakon primjene već opisanih filtera za smanjenje šuma bili gotovo identični onima bez primijenjenog filtera. Stoga su oni izostavljeni iz konačnog procesa predobrade, čime je optimirana efikasnost cijelog postupka.

```
classes = ['NonDemented', 'VeryMildDemented', 'MildDemented', 'ModerateDemented']
img_size = (224, 224)

# PREDOBRAĐA SLIKA
input_path = os.path.join(extract_path, "combined_images")
for cls in classes:
    class_dir = os.path.join(input_path, cls)
    processed_class_dir = os.path.join(preprocessed_path, cls)
    os.makedirs(processed_class_dir, exist_ok=True)

    for img_name in os.listdir(class_dir):
        img_path = os.path.join(class_dir, img_name)
        img = load_img(img_path, target_size=img_size) # resize
        img_array = img_to_array(img) / 255.0 # normalizacija
        save_img(os.path.join(processed_class_dir, img_name), img_array)
```

Slika 5. Predobrada slika

Nakon predobrade MRI snimki, sljedeći korak je njihova podjela u skup za učenje, skup za validaciju i skup za testiranje (Slika 6.). Originalni skup podataka organiziran je u četiri direktorija, pri čemu ime svakog odgovara jednoj klasi bolesti. Zbog toga se iz svakog od četiri direktorija izdvaja određeni postotak slika i kopira u direktorij jednog od tri skupa kako bi na kraju skup za učenje sadržavao 60% (26.400) slika, te skup za validaciju i skup za testiranje svaki po 20% (8.800).

```

for cls in classes:
    class_dir = os.path.join(preprocessed_path, cls)
    images = os.listdir(class_dir)

    train_images, temp_images = train_test_split(images, test_size=0.4, random_state=42) # 60% za učenje
    val_images, test_images = train_test_split(temp_images, test_size=0.5, random_state=42) # 20% za testiranje, 20% za validaciju

    # Kopiranje skupova u svoje foldere
    for subset, image_list in zip(["train", "validate", "test"], [train_images, val_images, test_images]):
        subset_dir = os.path.join(splitted_path, subset, cls)
        os.makedirs(subset_dir, exist_ok=True)
        for img_name in image_list:
            shutil.copy(os.path.join(class_dir, img_name), os.path.join(subset_dir, img_name))

```

Slika 6. Podjela slika u skup za učenje, validaciju i testiranje

Zadnji korak pripreme podataka je učitavanje i formatiranje skupa korištenjem TensorFlow funkcije `image_dataset_from_directory()` kako bi se podaci mogli u određenom obliku prosljeđivati kao ulaz modelu dubokog učenja (Slika 7.). Funkcija učitava slike iz direktorija `train`, `validate` i `test` koji sadrže poddirektorije organizirane prema klasama, te zahvaljujući parametru `labels='inferred'` se na temelju njihovih imena automatski određuje oznaka za svaku sliku. Budući da se radi o višeklasnoj klasifikaciji, parametar `label_mode='categorical'` omogućuje da se oznake klase pretvore u one-hot vektore, odnosno vektore duljine jednake broju klasa, gdje je indeks klase slike postavljen na 1, a ostale su 0. Svaka slika se prilikom učitavanja skalira na već zadanu veličinu od 224x224 piksela, čime se osigurava konzistentnost ulaznih podataka. Parametar `batch_size` određuje da se istovremeno obrađuje 32 slike, što je standardna praksa za učenje i evaluaciju dubokih neuronskih mreža. Slike iz skupova za učenje i validaciju se nasumično učitavaju (`shuffle=True`) kako bi se postigla bolja generalizacija modela, dok se kod skupa za testiranje redosljed slika ne mijenja (`shuffle=False`) radi konzistentnosti evaluacije.

Krajnji rezultat su tri TensorFlow dataset objekta (`train_dataset`, `validate_dataset` i `test_dataset`), koji sadrže predobrađene slike organizirane u batcheve s pripadajućim oznakama klase. Oni će se koristiti u svim fazama izgradnje modela, od učenja do evaluacije.

```

batch_size = 32

train_dataset = tf.keras.utils.image_dataset_from_directory(
    directory=os.path.join(splitted_path, "train"),
    labels='inferred',
    label_mode='categorical',
    image_size=img_size,
    batch_size=batch_size,
    shuffle=True
)

```

Slika 7. Primjer formatiranja ulaza iz skupa podataka *train*

4.2. Izrada modela

Model konvolucijske neuronske mreže za klasifikaciju MRI slika izrađen je korištenjem Keras Sequential modela, koji omogućuje ručno dodavanje i određivanje parametara svakog sloja [12] (Slika 8.). Prvi dio mreže sastoji se od četiri para konvolucijskih slojeva Conv2D i slojeva sažimanja MaxPooling2D. Prvi konvolucijski sloj koristi 32 filtera veličine 3x3 piksela (što znači da se u tom sloju uče 32 značajke) [22], aktivacijsku funkciju ReLu i definira dimenzije ulaznih podataka od 224x224x3 piksela, što odgovara RGB slikama. Svaki sljedeći konvolucijski sloj udvostručuje broj filtera na 64, 128 i 256 filtera, što je uobičajena tehnika prilikom izgradnje konvolucijskih mreža zbog toga što se povećanjem dubine mreže omogućuje izdvajanje sve složenijih značajki te kako bi se očuvala prostorna količina informacija u sloju sažimanja koji slijedi. Nakon svakog konvolucijskog sloja primjenjuje se sloj sažimanja koji reducira broj parametara i time prepolovi dimenzionalnost podataka. Budući da funkciji nisu zadani dodatni parametri, ne primjenjuje se dopuna (engl. *padding*), a korak pomicanja filtera poprima zadanu vrijednost (2,2).

Prije implementacije potpuno povezanog sloja potrebno je funkcijom `Flatten()` pretvoriti višedimenzijske matrice značajki, izlaze prijašnjeg sloja, u jednodimenzijski vektor koji će biti ulaz u potpuno povezanom sloju. Potpuno povezani sloj čine tri potpuno povezana (engl. *Dense*) sloja, prvi i drugi redom s 512 i 256 neurona i ReLU aktivacijskom funkcijom, te izlazni sloj s 4 neurona koji predstavljaju 4 ciljne klase i poacijskom funkcijom softmax za dobivanje vjerojatnosti pripadnosti svakoj od četiri klase. Nakon svakog *Dense* sloja izvršava se sloj isključivanja neurona (engl. *Dropout*) s parametrom 0.3, koji određuje da se tijekom učenja modela nasumično odbaci 30%, čime se sprječava prenaučenosť.

```

model = models.Sequential([
    layers.Conv2D(32, (3,3), activation='relu', input_shape=(224, 224, 3)),
    layers.MaxPooling2D(),
    layers.Conv2D(64, (3,3), activation='relu'),
    layers.MaxPooling2D(),
    layers.Conv2D(128, (3,3), activation='relu'),
    layers.MaxPooling2D(),
    layers.Conv2D(256, (3,3), activation='relu'),
    layers.MaxPooling2D(),

    layers.Flatten(),
    layers.Dense(512, activation='relu'),
    layers.Dropout(0.3),
    layers.Dense(256, activation='relu'),
    layers.Dropout(0.3),
    layers.Dense(4, activation='softmax') # 4 klase
])

```

Slika 8. Implementacija slojeva neuronske mreže

Nakon što su definirani svi slojevi mreže, potrebno je napraviti kompilaciju modela pomoću `model.compile()` (Slika 9.) koji će definirati na koji način će model učiti [22]. Prvi parametar, `optimizer`, koristi se za prilagodbu težina modela tijekom učenja s ciljem smanjenja funkcije gubitka. U ovom se modelu koristi Adam optimizator, najčešće korišten i najefikasniji optimizator za duboko učenje. Optimizatoru je zadan hiperparametar stopa učenja (engl. *learning rate*) u vrijednosti 0.0001 koja određuje brzinu učenja iz pogrešaka tijekom optimizacije funkcije gubitka. Drugi parametar, `loss`, određuje funkciju gubitka koja mjeri razliku distribucije vjerojatnosti između predviđenih i stvarnih vrijednosti ciljne klase, u ovom slučaju kategorička unakrsna entropija (engl. *categorical_crossentropy*) koja se koristi prilikom višeklasne klasifikacije gdje su oznake *one-hot* vektori. Zadnjim predanim parametrom zadano je da se tijekom učenja i evaluacije modela koristi točnost (engl. *accuracy*), odnosno postotak točno klasificiranih primjera.

```

optimizer = Adam(learning_rate=0.0001)
model.compile(optimizer=optimizer, loss='categorical_crossentropy', metrics=['accuracy'])

```

Slika 9. Kompilacija modela

Posljednji korak u izradi modela je učenje konvolucijske neuronske mreže (Slika 10.) na skupu podataka za učenje, što omogućuje funkcija `model.fit()` [22]. Funkcija kao parametre prima skup za učenje i skup za validaciju kako bi model tijekom učenja mogao istovremeno evaluirati svoju točnost, te broj epoha (engl. *epochs*) koji određuje broj prolazaka kroz cijeli skup za učenje. Model u svakoj od 10 epoha koristi prethodno definiranu funkciju

gubitka i optimizator te na temelju pogrešaka nastalih prilikom klasifikacije ažurira svoje težine. Nakon završetka svake epohe, model se evaluira na validacijskom skupu. Izračunate vrijednosti gubitka i točnosti pohranjuju se u objekt history, što služi za kasniju analizu i usporedbu modela.

```
history = model.fit(train_dataset, validation_data=validate_dataset, epochs=10)
```

Slika 10. Učenje neuronske mreže

4.3. Evaluacija modela

4.3.1. Točnost i funkcija gubitka

Točnost je vrlo jednostavna i često upotrebljavana metrika za procjenu uspješnosti modela strojnog učenja. U kontekstu modela konvolucijske neuronske mreže, izračunava se kao omjer broja točno predviđenih klasa i ukupnog broja predviđenih klasa te poprima vrijednost između 0 i 1. **Funkcija gubitka** je matematička funkcija koja mjeri razliku između stvarnih vrijednosti i predviđenih vrijednosti modela čime iskazuje koliko su predviđene klase različite od stvarnih vrijednosti. Cilj svakog modela je maksimizirati točnost, a minimizirati funkciju gubitka.

Iako se model pomoću funkcija točnosti i gubitka evaluira na kraju svake epohe prilikom procesa učenja, prava mjera uspješnosti modela procjenjuje se nakon završetka učenja na skupu za testiranje, točnije na do tada neviđenim podacima koji simuliraju stvarne situacije. Evaluacija se provodi i na skupu za učenje što iskazuje koliko je model dobro naučio podatke na kojima je učen, te na validacijskom skupu koji nam daje uvid u sposobnost generalizacije modela (Slika 11.).

```
train_loss, train_accuracy = model.evaluate(train_dataset)
val_loss, val_accuracy = model.evaluate(validate_dataset)
test_loss, test_accuracy = model.evaluate(test_dataset)
```

Slika 11. Evaluacija modela pomoću točnosti i funkcije gubitka

Prilikom evaluacije izrađenog modela rezultati pokazuju vrlo visoku točnost od 99% i veoma nisku funkciju gubitka od 0.03 na skupu za učenje, što ukazuje na činjenicu da je model vrlo uspješno naučio prepoznati uzorke prilikom učenja. Na validacijskom skupu točnost iznosi

92%, a gubitak 0.23, dok na testnom skupu model postiže točnost od 93% i gubitak od 0.22. Iz priloženih rezultata (Slika 12.) može se zaključiti da model odlično generalizira i klasificira nove, neviđene podatke. Mala razlika u postotku točnosti između skupa za učenje i validacijskog skupa ukazuje na to da model nije prenaučan.

```
Train accuracy:    0.99
Train loss:        0.03
Validation accuracy: 0.92
Validation loss:    0.23
Test accuracy:     0.93
Test loss:         0.22
```

Slika 12. Rezultati evaluacije

4.3.2. Matrica konfuzije i izvještaj o klasifikaciji

Detaljnija evaluacija uspješnosti klasifikacijskog modela provodi se analizom matrice konfuzije i izvještaja o klasifikaciji, pomoću kojih je moguće prikazati efikasnost za svaku klasu i usporediti različite modele [15]. Matrica konfuzije je tablični prikaz rezultata modela koji nastaje uspoređivanjem broja predviđenih i stvarnih (ciljnih) klasa. U slučaju višeklasne klasifikacije, matrica je dimenzija $K \times K$, gdje je K broj različitih vrijednosti ciljne varijable, odnosno klasa. Svako polje matrice konfuzije prikazuje broj primjera za koje je model stvarnu klasu predvidio kao određenu klasu. Dijagonalna polja matrice sadrže broj točno klasificiranih primjera za svaku klasu, dok ostala polja prikazuju pogrešne klasifikacije, odnosno koliko je puta model zamijenio jednu klasu s drugom. Matrica konfuzije omogućuje detaljnu analizu pogrešaka u klasifikaciji za svaku klasu, odnosno prikazuje koje klase model zamjenjuje za druge. Na temelju matrice konfuzije mogu se izračunati metrike koje su sastavni dio izvještaja o klasifikaciji – preciznost, odziv i F1-mjera. **Preciznost** (engl. *precision*) mjeri proporciju pozitivnih, odnosno ispravnih klasifikacija i računa se kao omjer ispravno klasificiranih primjera neke klase (engl. *true positive*, TP) i ukupnog broja primjera koje je model klasificirao u tu klasu (engl. TP + *false positive*, FP) (3). **Odziv** (engl. *recall*) mjeri proporciju stvarnih pozitivnih vrijednosti koje su ispravno klasificirane i računa se kao omjer ispravno klasificiranih primjera neke klase (TP) i ukupnog broja stvarnih primjera te klase (engl. TP + *false negative*, FN) [14] (4).


$$Preciznost = \frac{TP}{TP+FP} \quad (3)$$

$$Odziv = \frac{TP}{TP+FN} \quad (4)$$

Kombinacija te dvije metrike, F1-mjera (engl. *F1-score*), je harmonijska sredina između preciznosti i odziva (5), što znači da F1-mjera daje veću težinu nižoj od te dvije vrijednosti. Na taj način F1-mjera uravnotežuje preciznost i odziv i sprječava da visoka vrijednost jedne metrike prikrije slabost druge [10].

$$F1 - mjera = 2 \frac{preciznost \times odziv}{preciznost + odziv} \quad (5)$$

Analizom matrice konfuzije izračunate na temelju klasifikacije skupa za testiranje (Slika 13.), za izrađeni model može se zaključiti da je vrlo uspješan u klasifikaciji MRI snimki mozga u četiri kategorije. Elementi dijagonale matrice imaju najveće vrijednosti, što pokazuje da model u većini slučajeva ispravno klasificira primjere u pripadajuće ciljne klase. Najuspješnija je klasifikacija primjera klase NonDemented, za koju je model postigao gotovo savršenu preciznost, pošto je broj pogrešnih klasifikacija u odnosu na ukupan broj primjera te klase zanemarivo malen. Ova visoka razina točnosti u razlikovanju zdravih od oboljelih mozgova izuzetno je važna jer smanjuje lažno pozitivne i još bitnije, lažno negativne dijagnoze. Najčešće pogreške se događaju pri klasifikaciji primjera u klasu MildDemented koja se u određenom broju primjera zamjenjuje s klasama VeryMildDemented i ModerateDemented. Takve pogreške su razumljive, s obzirom na to da su razlike u promjenama moždanog tkiva između ovih stadija bolesti često vrlo suptilne i teško ih je razlučiti. Izuzev toga, model pokazuje vrlo dobru preciznost i za ove klase te se vidi jasna razlika između broja ispravno i pogrešno klasificiranih primjera. S obzirom da je broj primjera svake klase u skupu podataka bio sličan, rezultati evaluacije matricom konfuzije su pouzdani i nepristrani te potvrđuju da model vrlo uspješno generalizira na nove podatke.



Slika 13. Matrica konfuzije

Analiza izvještaja o klasifikaciji (Slika 14.) potvrđuje visoku uspješnost modela u klasificiranju MRI snimki mozga u četiri klase, odnosno stadija Alzheimerove demencije. U izvještaju se posebno ističe sposobnost modela da klasificira odsustvo bolesti, odnosno klasu NonDemented, gdje postiže gotovo savršenu preciznost, odziv i F1-rezultat u vrijednosti od 0.99. Za klasu VeryMildDemented model postiže vrlo dobru preciznost (0.89) i odziv (0.93), što znači da u 93% primjera ispravno prepoznaje najraniju fazu bolesti, uz relativno niski postotak pogrešake od 11%. Slično, za klasu ModerateDemented preciznost (0.93) i odziv (0.92) su sličnih vrijednosti što pokazuje da model dosljedno prepoznaje umjerene promjene, što ima smisla s obzirom na veći broj primjera ove klase u testnom skupu. Klasa MildDemented ima nešto niže, ali i dalje zadovoljavajuće vrijednosti s preciznošću od 0.90 i odazivom od 0.88. Ta se problematika već mogla uvidjeti prilikom analize matrice konfuzije, a posljedica je poteškoća pri razlikovanju suptilnih promjena moždanog tkiva među srodnim kategorijama. Visoki F1-rezultati koji poprimaju vrijednosti od 0.89 do 0.92 za sve kategorije potvrđuje da su preciznost i odziv visoki i uravnoteženi.

Classification Report:				
	precision	recall	f1-score	support
VeryMildDemented	0.89	0.93	0.91	2000
NonDemented	0.99	0.99	0.99	2000
ModerateDemented	0.93	0.92	0.92	2560
MildDemented	0.90	0.88	0.89	2240
accuracy			0.93	8800
macro avg	0.93	0.93	0.93	8800
weighted avg	0.93	0.93	0.93	8800

Slika 14. Izvještaj o klasifikaciji za model

Arhitektura korištena u ovom radu odabrana je na temelju analize i usporedbe relevantnih istraživačkih i znanstvenih radova koji se bave klasifikacijom MRI slika mozga za detekciju Alzheimerove bolesti. Većina tih radova koristi duboko učenje, koje je zahvaljujući brzom napretku tehnika oslikavanja mozga (engl. *neuroimaging*) nedavno privuklo značajnu znanstvenu pažnju. Modeli dubokog učenja, odnosno konvolucijske neuronske mreže, pokazale su se najučinkovitije za obradu podataka dobivenih tehnikama oslikavanja mozga vezanih uz Alzheimerovu bolest zbog toga što omogućuju automatsko izdvajanje značajki iz slikovnih podataka, što rezultira visokom preciznošću i točnošću u detekciji i klasifikaciji bolesti [15].

Usporedba s pristupima iz drugih radova pokazuje da je predloženi model konkurentan s drugima. Primjerice, rad [23] koristi slične sekvencijalne konvolucijske blokove, ali uvodi paralelne staze s različitim veličinama filtera, čime postiže iznimno visoku točnost od 99%. Međutim, takav pristup zahtijeva znatno složeniju arhitekturu s više parametara i duže vrijeme treniranja. Osim njega, [23] koristi slične parametre pri izradi mreže, ali primjenjuje sekvencijalni dizajn u 3D prostoru čime postiže točnost od 91,2%, što je vrlo slično rezultatu od 93% dobivenom u ovom radu. To sugerira da optimizirani 2D pristup može biti računski učinkovitija alternativa bez značajnog gubitka točnosti. Arhitekturom najbližnji model [24] ispituje "vanilla" sekvencijalni konvolucijski model, koji postiže točnost od 89%, što je 4% niže od rezultata postignutog u ovome radu. Razlika ukazuje na važnost odabira i optimizacije hiperparametara i predobrade podataka. Zaključno, rezultati pokazuju da konvolucijski model razvijen u ovom radu, uz odgovarajuću optimizaciju arhitekture i parametara, može postići vrlo visoku točnost i biti konkurentan naprednijim arhitekturama.

Zaključak

Cilj ovog rada bio je razvoj klasifikacijskog modela temeljenog na dubokom učenju koji uspješno klasificira MRI snimke mozga prema stupnju oboljenja od Alzheimerove demencije. U uvodnome dijelu opisana je medicinska pozadina Alzheimerove demencije te važnost rane dijagnostike, pri čemu važnu ulogu ima upotreba MRI snimaka mozga. Opisana je struktura skupa podataka u kojem su MRI slike raspoređene u četiri kategorija ovisno o stadiju bolesti, te su definirani ključni teorijski pojmovi iz područja dubokog učenja, s naglaskom na konvolucijske neuronske mreže i metode predobrade slika koje se koriste za pripremu ulaznih podataka. Podaci korišteni pri izradi modela preuzeti su sa stranice Kaggle, iz skupa podataka pod nazivom „Alzheimer's Disease Multiclass Images Dataset“.

Prilikom razvoja modela konvolucijske neuronske mreže, provedena je predobrada slika koje su potom korištene za učenje, validaciju i testiranje modela. Evaluacija modela provedena je uz pomoć metrika točnosti, funkcije gubitka, matrice konfuzije i izvještaja o klasifikaciji, koji su pokazali da model postiže visoke vrijednosti točnosti prilikom klasifikacije sve četiri klase, odnosno stadija bolesti. Posebno se istaknula sposobnost razlučivanja oboljele od zdrave osobe, dok su pogreške klasifikacije srodnih stadija minimalne. Model se pokazao vrlo učinkovitim pri generalizaciji novih, neviđenih podataka, što ukazuje na njegov potencijal za primjenu u stvarnim kliničkim uvjetima.

Ovaj rad demonstrira mogućnost primjene dubokog učenja u medicinskoj dijagnostici te nudi rješenje koje može unaprijediti ranu dijagnostiku i praćenje razvoja Alzheimerove demencije, čime se smanjuje subjektivnost, a povećava točnost i brzina dijagnoze. Za daljnji razvoj modela, trebalo bi implementirati naprednije arhitekture i proširiti skup podataka koji će biti u skladu s medicinskom praksom.

Literatura

- [1] *Dementia statistics*, Alzheimer's Disease International. Poveznica: <https://www.alzint.org/about/dementia-facts-figures/dementia-statistics/>
- [2] *Alzheimerova demencija: Dokle smo stigli i što nas kao društvo očekuje?*, Affidea, (2021, srpanj). Poveznica: <https://affidea.hr/novosti/alzheimerova-demencija/>
- [3] Poliklinika Dijagnostika 2000, *Uloga magnetske rezonance u otkrivanju Alzheimerove bolesti*, Adiva (2023, travanj). Poveznica: <https://www.adiva.hr/lifestyle/psiha-i-emocije/uloga-magnetske-rezonance-u-otkrivanju-alzheimerove-bolesti/>
- [4] Tracey I., Graff Leknes S., *Hippocampus and Entorhinal Complex: Functional Imaging*, Springer Nature Link, (2013). Poveznica: https://link.springer.com/referenceworkentry/10.1007/978-3-642-28753-4_1763
- [5] Meštrović, A. *Magnetska rezonancija u evaluaciji demencija*. Diplomski rad. Sveučilište u Zagrebu Medicinski fakultet, 2018.
- [6] Job, L. *Alzheimerova bolest ranog početka*. Diplomski rad. Sveučilište u Zagrebu Medicinski fakultet, 2017.
- [7] Pečar M. *Primjena neuronskih mreža pri prepoznavanju slika*. Završni rad. Sveučilište u Zagrebu Filozofski fakultet, 2021.
- [8] *What is a neural network?*, IBM, (2021, listopad). Poveznica: <https://www.ibm.com/think/topics/neural-networks>
- [9] *What are convolutional neural networks?*, IBM, Nepoznato. Poveznica: <https://www.ibm.com/think/topics/convolutional-neural-networks>
- [10] Murel J., Kavlakoglu E., *What is a confusion matrix?*, IBM, (2024, siječanj). Poveznica: [What is a confusion matrix? | IBM](#)
- [11] Keita Z., *An Introduction to Convolutional Neural Networks (CNNs)*, Datacamp, (2023, studeni). Poveznica: <https://www.datacamp.com/tutorial/introduction-to-convolutional-neural-networks-cnns>
- [12] Khanna S., *How to preprocess and train a CNN (Step-by-step)*, Kaggle, (2021). Poveznica: <https://www.kaggle.com/code/vesuvius13/how-to-preprocess-and-train-a-cnn-step-by-step>
- [13] Gogancea G., Rehan H., *How can you preprocess image data for a neural network?*, LinkedIn, (Nepoznato). Poveznica: <https://www.linkedin.com/advice/0/how-can-you-preprocess-image-data-neural-network-a4n9c>

- [14] McDonough M., *precision and recall*, Britannica, (Nepoznato). Poveznica: <https://www.britannica.com/science/precision-and-recall>
- [15] Nassir N., *Alzheimer's Magnetic Resonance Imaging Classification Using Deep and Meta-Learning Models*, Arxiv, (2024, svibanj). Poveznica: <https://arxiv.org/html/2405.12126v1>
- [16] Keras: *The high-level API for TensorFlow*, TensorFlow, (Nepoznato). Poveznica: <https://www.tensorflow.org/guide/keras>
- [17] *Convolutional neural network*, Wikipedia, (2025, lipanj). Poveznica: https://en.wikipedia.org/wiki/Convolutional_neural_network
- [18] Mishra M., *Convolutional Neural Networks, Explained*, towards data science, (2020, kolovoz). Poveznica: <https://towardsdatascience.com/convolutional-neural-networks-explained-9cc5188c4939/>
- [19] Pramoditha R., *Coding a Convolutional Neural Network (CNN) Using Keras Sequential API*, towards data science, (2022, lipanj). Poveznica: <https://towardsdatascience.com/coding-a-convolutional-neural-network-cnn-using-keras-sequential-api-ec5211126875/>
- [20] *Convolutional Neural Networks (CNNs / ConvNets)*, Stanford, (Nepoznato). Poveznica: <https://cs231n.github.io/convolutional-networks/>
- [21] *What is the role of the fully connected layer in a CNN?*, Eitca, (2023, kolovoz). Poveznica: <https://eitca.org/artificial-intelligence/eitc-ai-dlptfk-deep-learning-with-python-tensorflow-and-keras/convolutional-neural-networks-cnn/introduction-to-convolutional-neural-networks-cnn/examination-review-introduction-to-convolutional-neural-networks-cnn/what-is-the-role-of-the-fully-connected-layer-in-a-cnn/>
- [22] Kromydas B., *Implementing a CNN in TensorFlow & Keras*, LearnOpenCV, (2023, siječanj). Poveznica: <https://learnopencv.com/implementing-cnn-tensorflow-keras/>
- [23] El-Assy i sur., *A novel CNN architecture for accurate early detection and classification of Alzheimer's disease using MRI data*, Scientific Reports, (2024, veljača). Poveznica: <https://www.nature.com/articles/s41598-024-53733-6>
- [24] Vo N.T. i sur., *3D Brain MRI Classification for Alzheimer's Diagnosis Using CNN with Data Augmentation*, Arxiv, (2025, svibanj). Poveznica: <https://arxiv.org/html/2505.04097v1>

- [25] Chen J., Hong Y., Weiner O., *A Comparative Study of CNN Models in Alzheimer's Detection*, Stanford, (Nepoznato). Poveznica: <https://cs231n.stanford.edu/2024/papers/a-comparative-study-of-cnn-models-in-alzheimers-detection.pdf>

Sažetak

Klasifikacija stupnja Alzheimerove demencije temeljem snimki magnetske rezonance mozga i metoda dubokog učenja

Ovaj rad istražuje primjenu konvolucijskih neuronskih mreža za automatsku klasifikaciju MRI snimki mozga prema četiri stadija Alzheimerove demencije. Korišten je skup podataka Alzheimer's Disease Multiclass Images Dataset (Kaggle), a prije učenja modela provedena je predobrada slika. Opisana je izgradnja klasifikacijskog modela neuronske mreže. Evaluacija modela je provedena korištenjem točnosti (93%) i funkcije gubitka, te analizom matrice konfuzije koja je pokazala izvrsnost rada modela prilikom razlikovanja zdravih od oboljelih te vrlo visok odziv (0.88 – 0.99) za svaku klasu.

Ključne riječi: strojno učenje, duboko učenje, konvolucijske neuronske mreže, klasifikacija slika, Alzheimerova demencija, MRI snimke

Abstract

Classification of the degree of Alzheimer's dementia based on magnetic resonance imaging of the brain and deep learning methods

This study explores the application of convolutional neural networks for the automated classification of MRI brain images into four stages of Alzheimer's disease. The Alzheimer's Disease Multiclass Images Dataset (Kaggle) was used, and image preprocessing was performed prior to model training. The construction of the neural network classification model is described in detail. The model was evaluated using accuracy (93%), loss function, and confusion matrix analysis, which demonstrated the model's exceptional performance in distinguishing healthy from sick individuals, along with very high recall values (0.88–0.99) for each class.

Keywords: machine learning, deep learning, convolutional neural networks, image classification, Alzheimer's dementia, MRI images