

Duboko učenje za segmentaciju tumora mozga iz MRI slika

Raguž, Maroje

Master's thesis / Diplomski rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:200:268639>

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

Download date / Datum preuzimanja: **2024-11-30**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA OSIJEK**

Sveučilišni studij

**DUBOKO UČENJE ZA SEGMENTACIJU TUMORA
MOZGA IZ MRI SLIKA**

Diplomski rad

Maroje Raguž

Osijek, 2023.

SADRŽAJ

1. UVOD	1
2. PREGLED PODRUČJA TEME	2
2.1. U-NET arhitektura	2
2.2. DeepMedic arhitektura.....	2
2.3. DeepLab arhitektura	3
2.4. PSPNet arhitektura.....	4
2.5. SegNet arhitektura.....	4
3. KLINIČKA POZADINA	5
4. MAGNETSKA REZONANCIJA (MRI)	7
4.1. Prikaz mozga na MRI slikama	9
4.1.1. GD pojačavajući tumor.....	9
4.1.2. Peritumoralni edem.....	10
4.1.3. Nekrotična jezgra tumora bez povećanja (NCR/NET)	10
5. KONVOLUCIJSKE NEURONSKE MREŽE	11
5.1. U-Net arhitektura.....	14
6. KORIŠTENE TEHNOLOGIJE	17
6.1. Python	17
6.2. PyTorch biblioteka.....	17
6.3. Keras	17
6.4. Google Colaboratory.....	17
6.5. ITK-SNAP	18
7. OPIS IZRADE MODELA	19
7.1. Opis skupa podataka	19
7.2. Predobrada podataka	20
7.3. Izrada modela i treniranje	21
7.4. Analiza Rezultata	23
8. ZAKLJUČAK	26

LITERATURA	28
SAŽETAK.....	30
ABSTRACT	31
ŽIVOTOPIS.....	32

1. UVOD

Maligne bolesti, nakon kardiovaskularnih bolesti, drugi su najčešći uzrok smrti u Republici Hrvatskoj. Tumori nastaju abnormalnom diobom stanica, a razlikujemo dobroćudne i zloćudne. Zloćudni tumori mozga, iako se češće pojavljuju u starijoj životnoj dobi, jedno su od najčešćih zloćudnih oboljenja kod djece mlađe od 19 godina. Ne postoji način prevencije tumora mozga, a neki od glavnih simptoma su glavobolje, napadaji te problemi s vidom [1]. Za ispravno planiranje radioterapije, praćenje progresije, procjenu ishoda i metoda liječenja tumora mozga, potrebna je točna procjena relativnog volumena njegovih subkomponenti. Kako bi se to ostvarilo potrebno je točno ocrtavanje tumora. Ručna segmentacija, osim što oduzima puno vremena, podložna je ljudskim greškama. Varijabilnosti izgleda tumora i potreba za pregledom više slika iz različitih MRI (engl. *Magnetic Resonance Imaging*) sekvenci radi ispravne klasifikacije tipa tkiva rezultiraju značajnom razlikom između različitih interpretacija istog tumora [2]. Zbog toga potrebno je početi koristiti strojno učenje i obradu slike u medicinske svrhe. Automatska segmentacija ubrzala bi segmentaciju subkomponenti tumora mozga iz 3D MRI slika te bi bila od velike pomoći radiolozima jer bi im omogućila da se više posvete daljnjem liječenju pacijenta. U sklopu ovog rada bit će napravljen model koji će, pomoću U-NET arhitekture, segmentirati tumor mozga iz MRI slika.

Drugo poglavlje daje pregled područja rada te opisuje trenutne tehnologije korištene za segmentaciju tumora mozga iz MRI slika. U trećem poglavlju opisana je klinička pozadina, razlika između primarnih i sekundarnih tumora, vrste primarnih tumora, metode uspostavljanja dijagnoze tumora mozga, kao i načini liječenja. U četvrtom poglavlju opisan je način dobivanja slika pomoću magnetske rezonance i njihove najvažnije karakteristike. Opisan je i način prikaza mozga na MRI slikama (GD pojačavajući tumor, peritumoralni edem, nekrotična jezgra tumora bez povećanja (NCR/NET)). U petom poglavlju opisan je način rada konvolucijskih neuronskih mreža i U-net arhitekture. Šesto poglavlje opisuje tehnologije koje su korištene prilikom razvoja sustava za segmentaciju (Python, Pytorch biblioteke, Keras, Google Colab, ITK snap). Posljednje poglavlje objašnjava korake izrade modela, način obrade i procesiranje ulaznih podataka te analizira dobivene rezultate.

2. PREGLED PODRUČJA TEME

Segmentacija tumora mozga iz MRI slika važna je u medicinskoj dijagnozi jer ubrzava točno ocrtavanje tumora čime značajno olakšava rad liječnicima i osigurava više vremena za brigu o pacijentima. Isto tako, na ovaj način potencijalno omogućuje da se jedan tumor uvijek interpretira na isti način. U posljednjih nekoliko godina, za segmentaciju tumora mozga iz MRI slika, razvijene su različite metode i arhitekture neuronskih mreža.

2.1. U-NET arhitektura

Jedna od najčešće korištenih arhitektura u segmentaciji tumora mozga je U-Net arhitektura. Općenito u odnosu na prethodne arhitekture, prednosti U-Net arhitekture su smanjeni broj slika potrebnih za treniranje modela. Pomoću 3D U-Net arhitekture, koja je proširenja 2D U-Net arhitekture, moguće je segmentirati 3D slike [3]. U-Net arhitektura dobila je svoje ime po svojem karakterističnom obliku, koji podsjeća na slovo "U". Ova arhitektura sastoji se od dva glavna dijela: kodera i dekoderu. U prvoj polovini mreže, odnosno u koderu, slika se postupno smanjuje koristeći konvolucijske slojeve i pooling operacije. Ovo smanjenje rezolucije omogućava mreži da izluči važne značajke iz slike na višim razinama apstrakcije. Ovaj dio se često naziva "kontekstualni dio" jer omogućava mreži da razumije šire okoline objekata na slici. U drugoj polovini mreže, odnosno dekoderu, koristi se upsampling i konvolucija kako bi se povećala rezolucija slike. Ovdje dolazi do kombinacije niskorazinske i visokorazinske informacije, što pomaže u preciznoj segmentaciji objekata. Ovaj dio se često naziva "lokalni dio" jer omogućava mreži da stvori detaljne segmentacije. Ovakav način rada U-Net arhitekture omogućava preciznu segmentaciju objekata u slikama.


2.2. DeepMedic arhitektura

DeepMedic je duboka neuronska mreža koja je posebno dizajnirana za obradu medicinskih slika, posebno za segmentaciju struktura u medicinskim slikama, poput MRI (magnetske rezonancije) i CT (računalne tomografije). Ova arhitektura kombinira duboki konvolucijski model s konceptom „skip-connections“ kako bi se ostvarila visoka preciznost u segmentaciji, čineći je izuzetno korisnom u kliničkoj dijagnostici i istraživanju. Način rada DeepMedic arhitekture uključuje tri osnovne metodologije. Prva metodologija uključuje dvostruku putanju (engl. dual pathway) kako bi analizirao slike na različitim razinama apstrakcije. Ova dvostruka putanja sastoji se od dvaju glavnih dijelova: "lokalni" i "globalni" put. Lokalni put koristi plitki konvolucijski model koji analizira visokorazinske informacije na manjim prostornim razmjerima. To pomaže u preciznoj

segmentaciji detaljnih struktura. Globalni put je dublji i širi model koji analizira niskorazinske značajke na većim prostornim razmjerima. Ovo pomaže u boljem razumijevanju šireg konteksta slike. Druga metodologija odnosi se na upotrebu „skip connections-a“ što omogućava informacijama da se prenose iz lokalnog puta u globalni put i obrnuto. Ova povezanost između različitih razina apstrakcije pomaže u kombiniranju lokalnih i globalnih informacija, što rezultira boljom preciznošću u segmentaciji. Konačno, treća metodologija, uključuje ensemble pristup pri kojemu se više modela trenira i njihovi rezultati se kombiniraju kako bi se postigla još veća preciznost. DeepMedic arhitektura je često korištena za segmentaciju tumora mozga iz MRI slika [4].

2.3. DeepLab arhitektura

Još jedna arhitektura koja se koristi za segmentaciju je DeepLab arhitektura. DeepLab v1, za točnije određivanje granica segmentacije, koristi uvjetno slučajno polje. Kod DeepLab v1 dolazi do problema ukoliko se na istoj slici nalaze isti objekti, ali u različitoj veličini. Taj problem riješen je kod DeepLab v2. Postoje još i DeepLab v3 i DeepLab v3+. DeepLab v3 rješava problem višeklasne segmentacije. DeepLab v3+, dodavanjem dekodera za pročišćavanje rezultata segmentacije, omogućava bolju segmentaciju na rubovima. Slika 2.1. prikazuje strukturu DeepLab v3+ arhitekture [5].




Sl. 2.1. Struktura DeepLab v3+ arhitekture [5]

2.4. PSPNet arhitektura

Arhitektura PSPNet (*engl. Pyramid Scene Parsing Network*) je još jedna duboka neuronska mreža koja se koristi za semantičku segmentaciju slika. Ova arhitektura je posebno dizajnirana za razumijevanje scena u slikama i označavanje različitih objekata i regija na slikama. Osnovni način rada PSPNet arhitekture temelji se na tome da se provjerava globalni kontekst slike kako bi odredila predviđanja na lokalnoj razini. Sama PSPNet arhitektura koder-dekoder oblik, pri čemu koder služi za izdvajanje značajki iz slike, dok dekoder predviđa klasu piksela. Izgled PSPNet arhitekture prikazan je na slici 2.2.

2.5. SegNet arhitektura

SegNet je još jedna duboka neuronska mreža koja se koristi za semantičku segmentaciju slika. Ova arhitektura se ističe po svojoj jednostavnosti i efikasnosti, a koristi se za označavanje različitih objekata i regija na slikama. SegNet je arhitektura sastoji se od kodera i dekodera i segmentira sliku na razini piksela. Koder je mrežni model koji koristi VGG16 arhitekturu kako bi analizirao podatke o objektu. Novost koju uvodi SegNet je u tome što dekoder ima veliki indeks sažimanja, koji se prenosi koderu kako bi nelinearno uzimao uzorke podataka koji ulaze u dekoder. Zbog toga za uzimanje uzoraka nije potrebno učenje. Zatim se koristi konvolucijski filter koji se može trenirati [5]. SegNet se često koristi u aplikacijama vezanim uz autonomna vozila, praćenje objekata i analizu slika.



Sl. 2.2. PSPNet arhitektura

3. KLINIČKA POZADINA

Tumor mozga predstavlja nekontrolirani rast stanica u mozgu ili u njegovoj blizini. Tumori se mogu pojaviti u tkivu mozga, kao i u blizini moždanog tkiva, uključujući živce, hipofizu, pinealnu žlijezdu i membrane koje prekrivaju površinu mozga. U Republici Hrvatskoj, u 2020. godini, dijagnosticirano je 418 primarnih zloćudnih tumora mozga. Većina, njih 80%, kod osoba starijih od 50 godina [1].

Tumori mozga mogu biti primarni i sekundarni. Primarni tumori su oni koji nastaju od parenhima ili drugih tvorbi u lubanjskoj šupljini. Postoje brojne vrste primarnih tumora mozga. Nekima od njih, zbog položaja koji otežava njegovo potpuno uklanjanje za testiranje, nemoguće je odrediti točnu vrstu. Gliomi su jedan od najčešćih tipova primarnih tumora mozga. Smatra se da rastu iz glija stanica, ali točno podrijetlo glioma nije poznato. Gliomima se dodjeljuje stupanj diferenciranosti tumora ili „gradus“ tumora koji opisuje agresivnost tumora. Što je veći gradus tumora to je tumor agresivniji i očekuje se da će se brzo širiti. Za razliku od većine tumora koji ne počinju unutar mozga ili središnjeg živčanog sustava (SŽS), tumorima mozga nije dodijeljen stadij. Stadij opisuje je li se i u kojoj mjeri primarni tumor proširio na ostale dijelove tijela. Pošto se primarni tumori mozga, poput glioma, rijetko šire izvan mozga, nije im potrebno dodjeljivati stadij [6]. Astrocitni tumori najčešći su tip glioma. U tablici 2.1. prikazane su vrste astrocitnih tumora te njihov tumorski gradus.

Tablica 2.1. Vrste Astrocitnih tumora i njih tumorski gradus

TUMOR	TUMORSKI GRADUS			
	I	II	III	IV
Subependimalni astrocitom velikih stanica	x			
Pilocitični astrocitom	x			
Pilomiksoidni astrocitom		x		
Difuzni astrocitom		x		
Pleomorfni ksantocitom		x		
Anaplastični astrocitom			x	
Glioblastom				x
Glioblastom velikih stanica				x
Gliosarkom				x

Druga vrsta glioma su oligodendrogliomi. Najčešće se pojavljuju u frontalnim režnjevima i jedni su od najsporijih rastućih glioma. Oligodendrogliome karakterizira gubitak dijela kromosoma 1p ili kromosoma 19q. Oni su kategorizirani kao oligodendrogliomi stupnja diferenciranosti tumora 2, koji se smatra niskim stupnjem ili kao oligodendrogliomi stupnja diferenciranosti tumora 3, koji

se smatraju tumorima visokog stupnja s anaplastičnim značajkama [7]. Difuzni gliomi središnje linije tumori su velikog tumorskog gradusa (tumorski gradus III i IV) i najčešće se javljaju kod djece [7].

Posljednja vrsta glioma su ependiomi. Rijetko se pojavljuju kod odraslih osoba, a nastaju u mozgu, moždanom deblu ili kralježničnoj moždini. Ependiomi se mogu klasificirati kao subependimom (tumorski gradus I), ependimom (tumorski gradus II), anaplastični ependimom (tumorski gradus III) i ependimoblastom (tumorski gradus IV) [7].

Osim iz glija stanica, tumori mozga mogu proizaći iz raznih drugih stanica i tkiva pa tako razlikujemo:

- Meningeomi – jedan od najčešćih primarnih tumora mozga. Ukoliko raste i pritišće mozak ili leđnu moždinu može izazvati ozbiljne simptome [6]
- Tumori pinealane žlijezde i hipofize – tumori koji nastaju u pinealnoj žlijezdi ili hipofizi
- Primarni limfom SŽS-a - oblik limfoma koji se može proširiti na spinalnu tekućinu i oči [6]
- Meduloblastom – najčešći zloćudni tumor SŽS dječje dobi. Kliničke smetnje su kraćeg trajanja, a izazvane su pritiskom tumora na okolne neuralne strukture [8]
- Švanom – benigni tumor koji nastaje iz Schwannovih stanica [6]

Sekundarni tumori mozga ili metastaze na mozgu su tumori koji su započeli na drugom dijelu tijela, poput pluća ili dojke, a zatim se proširili na mozak.

Simptomi tumora mozga nastaju kada je mozak izložen pritisku ili kada je moždano tkivo razoreno. Simptomi se javljaju neovisno o tome je li tumor zloćudan (malign) ili dobroćudan (benigan). Simptomi najviše ovise o položaju, brzini rasta i veličini tumora. Prvi simptom tumora mozga je česta ili stalna glavobolja. Ostali simptomi koji se javljaju su vrtoglavica, dvoslike, gubitak ravnoteže te u nekim slučajevima i epileptični napadaji. Kod sekundarnih tumora mozga osoba može imati simptome koji se odnose na udaljeni rak (krvavi kašalj kod raka pluća).


Za dijagnozu tumora mozga najčešće se koriste MRI i CT. Kod meningeoma i tumora hipofize postoji mogućnost detekcije tumora običnim rendgenogramom lubanje i mozga, ali se preferira detekcija pomoću CT-a i MRI-a jer je moguće odrediti veličinu tumora kao i njegov smještaj [9]. Odluku o načinu liječenja tumora donose se na temelju dobi i fizičkog stanja pacijenta, malignosti, položaju i vrsti tumora. Liječenje može zahtijevati samo nadzor, ali najčešće uključuje operaciju, radioterapiju, kemoterapiju ili kombinaciju navedenih metoda. Preferirana metoda kod primarnih tumora mozga je operacija popraćena radioterapijom ili kemoterapijom [10].

4. MAGNETSKA REZONANCIJA (MRI)

Prvi uspješan pokus nuklearne magnetske rezonancije u kondenziranoj tvari proveli su Bloch i Purcell za koji su dobili Nobelovu nagradu 1952. godine. Taj pokus uspostavio je temelje magnetske rezonancije koja se koristi u biomedicinskim znanostima. Otprilike 20 godina poslije njihovog pokusa, dani su prijedlozi korištenja nuklearne magnetske rezonancije za stvaranje slika. U početku je kratica bila NMRI, gdje slovo „N“ predstavlja riječ nuklearna, koja je kasnije, ponajviše zbog zabrinutosti koju izaziva sama riječ, izbačena iz kratice. Ovaj način snimanja rasprostranjen je zbog svoje fleksibilnosti i osjetljivosti na širok raspon svojstava tkiva [11].

MRI je tehnika koja pomoću magnetski polja i radio valova proizvodi tomografske slike. Za razliku od CT-a, koji procjenjuje jedan parametar tkiva, MRI analizira višestruke karakteristike tkiva kao npr. gustoću vodikovih protona, vremenske relaksacije T1 i T2 tkiva i protok krvi unutar tkiva. MRI ima najbolji kontrast mekog tkiva. Većinu tkiva moguće je razlikovati po vremenima relaksacije T1 i T2. To su značajke trodimenzionalnog molekularnog okruženja koje okružuje svaki proton. T1 je mjera koja označava koliko brzo se tkivo može magnetizirati. T2 pokazuje koliko brzo određeno tkivo gubi svoju magnetizaciju. Protok krvi smanjuje i povećava intenzitet signala unutar krvnih žila [12].

MRI se temelji na sposobnosti protona u tijelu da apsorbiraju i emitiraju energiju radio valova kada se tijelo nalazi unutar jakog magnetskog polja. Različita tkiva apsorbiraju i otpuštaju energiju različitim i karakterističnim brzinama. Slika 4.1. prikazuje shemu generiranja MRI signala.



Sl. 4.1. Shema generiranja MRI signala [12]

MR snimke dobivaju se stavljanjem pacijenta u statičko magnetsko polje jačine 0,02 do 4 Tesla. Mali broj tkivnih protona poravnava se s glavnim magnetskim poljem i postepeno se pomiče iz svog prvobitnog položaja primjenom gradijenata radiofrekvencije. Kada se gradijent radio

frekvencije prekine, pomaknuti protoni ponovno se poravnaju s glavnim magnetskim poljem, oslobađajući mali impuls energije koji se detektira, lokalizira i zatim obrađuje računalnim algoritmom. Navedeni impulsi se dalje frekvencijskim kodiranjem lokaliziraju u smjeru x osi, a faznim kodiranjem po y osi.


Moguće je promatrati tri ravnine na MRI slikama. One se određuju položajem i orijentacijom magnetskog polja u odnosu na pacijenta. Te ravnine su:

1. Aksijalna ravnina – u ovoj ravnini MRI slike se prikazuju u horizontalnom pogledu. Aksijalna ravnina dijeli tijelo na gornju i donju polovicu.
2. Sagitalna ravnina – MRI slike u ovoj ravnini prikazuju se u bočnom pogledu. Ravnina dijeli tijelo na desnu i lijevu polovicu.

Koronalna ravnina – u ovoj ravnini MRI slike prikazuju se u prednjom pogledu. Ravnina dijeli tijelo na prednju (ventralnu) i stražnju (dorsalnu) stranu

Slika 4.2. prikazuje MRI snimke mozga promatrane iz aksijalne, sagitalne i koronalne ravnine [13].

Glavne prednosti MRI-a su jako dobar prikaz mekih tkiva i organa, mogućnost prikaza slike u svim željenim ravninama te ne korištenje ionizirajućeg zračenja. Zbog tih prednosti moguće je jasnije razlikovati granice između bijele i sive tvari mozga, patološki edem od normalnog



Sl. 4.2. prikaz MRI slike mozga u a)sagitalnoj, b) aksijalnoj i c) koronalnoj ravnini

moždanog parenhima, zonu infiltracije tumorskim procesom kao i niz drugih morfoloških karakteristika bitnih za procjenu stanja proširenosti i vrsta patoloških procesa.

Najčešći problem koji se javlja prilikom snimanja MR-om je pokret pacijenta. MRI dobiva više slika po nizu i ukoliko se pacijent pomakne tijekom jedne sekvence, sve sekvence će biti lošije snimljene. Zbog toga je vrlo važno da se prije snimanja pacijent osjeća ugodno kako bi se smanjila mogućnost pokreta. Drugi problem koji se javlja je klaustrofobija pacijenta. U nekim slučajevima


ovaj problem može se riješiti sedativima. Postoje i magneti otvorenog tipa za pacijente s ovim problemom, međutim, kvaliteta slike je u tom slučaju puno lošija. Još neki od nedostataka su visoka cijena pregleda te pacijenti s ugrađenim elektrostimulatorima i različitim implantantima nisu pogodni za pregled [14].

4.1. Prikaz mozga na MRI slikama

Pregled mozga i kralježnice magnetskom rezonancijom ima mnogo prednosti u odnosu na CT snimanje. MRI ima mogućnost boljeg definiranja patoloških procesa i njihovih učinaka na susjedne strukture. Često je moguće, bez primjene intravenskog kontrastnog sredstva, ustanoviti prohodnost intrakranijalnih žila. Većina pregleda mozga uključuje pregled T1 i T2 sekvence. T1 sekvence najbolje pokazuju veličinu ventrikula i kongenitalne malformacije, dok T2 sekvence najbolje prikazuju patološka stanja [12].

4.1.1. GD pojačavajući tumor

GD kratica označava gadolinij, metal srebrnog izgleda koji pripada skupini rijetkih zemnih elemenata. On skraćuje T1 i T2 vrijeme relaksacije jezgri vodika unutar lokalnog magnetskog polja. Neophodan je za pružanje kvalitetnih magnetskih usluga jer pojačava razliku između krvnih žila i okolnih tkiva. U puno većoj mjeri skraćuje vrijeme T1 nego T2. Najčešće se koristi za identifikaciju poremećaja krvno-moždane barijere, za dokumentiranje obrazaca pojačanja lezija ili naglašavanje strukture organa. Slika 4.3. prikazuje prikaz tumora mozga bez dodavanja gadolinija (lijeva slika) i nakon dodavanja gadolinija (desna slika) [15].




Sl. 4.3. prikaz tumora mozga bez dodatka (lijevo) i nakon dodatka(desno) gadolinija

4.1.2. Peritumoralni edem

Edem mozga oticanje je mozga koje se može dogoditi bilo gdje u mozgu, a ovo je prirodna reakcija tijela na ozljedu. Edem uključuje pojavu tekućine u mozgu, točnije moždanom tkivu što povećava pritisak unutar lubanje koji se naziva intrakranijalni tlak. Ukoliko se edem nalazi u okolici tumora tada se naziva peritumoralni edem. Posljedica peritumoralnog edema može biti oštećenje ili odumiranje moždanih stanica. Na slici 4.4. prikazano je nastajanje i rast peritumoralnog edema [16].

4.1.3. Nekrotična jezgra tumora bez povećanja (NCR/NET)


Nekrotične jezgre su tumori koji umiru iznutra prema van i čine savršeno okruženje za širenje raka. Prilično su uobičajen fenomen, ali tek se od nedavno povezuju s metastazama raka. Mrtve zone tumora imaju propusne krvne žile i regrutiranje imunoloških stanica, a neke od njih pomažu širenju stanica raka [17].



Sl. 4.4. Nastajanje i rast peritumoralnog edema (a-d) [16].

5. KONVOLUCIJSKE NEURONSKE MREŽE


Konvolucijske neuronske mreže (*engl. Convolutional Neural Networks - CNN*) vrsta su dubokih neuronskih mreža u kojima se protok informacija odvija samo u jednom smjeru, od ulaza prema izlazu. CNN-ovi se najčešće koriste za obradu slika i govora. Inspirirane su strukturom vizualnog korteksa u ljudskom mozgu, koji se sastoji od izmjeničnih slojeva jednostavnih i složenih stanica. Postoje razne vrste CNN arhitekture, međutim, najčešće se sastoje od slojeva konvolucijskih filtera, slojeva sažimanja i potpuno povezanih slojeva. Primjer tijeka klasifikacije slike pomoću CNN prikazan je na slici 5.1. [18].



Sl. 5.1. Primjer tijeka klasifikacije slike pomoću CNN [18].


Prvi sloj konvolucijske neuronske mreže je konvolucijski sloj i obavlja većinu transformacija podataka. Sadrži ulaznu aktivacijsku mapu koja je u prvom sloju mreže ulazna slika. Svaki konvolucijski sloj sadrži filtere ili jezgre (*engl. kernel*) fiksne dimenzije koje pohranjuju vrijednosti težina filtera. Jezgra prelazi preko cijele slike i dobiva značajku tog dijela slike na način da se svaki piksel jezgre i slike na mjestu preklapanja množi te se dobiveni rezultati množenja zbroje. Potrebno je i definirati korak pomaka filtera (*engl. stride*) kako bi se mogla definirati točna veličina izlaza konvolucijskog sloja. Korak pomaka filtera označava koliko se piksela filter treba pomaknuti u jednom trenutku. Primjenom konvolucije slika može izgubiti na dimenzionalnosti. Ukoliko je potrebno spriječiti gubitak dimenzionalnosti, slici se može dodati ispunjavanje (*engl. padding*) koje popunjava sliku na rubovima radi očuvanja dimenzije. Postoje razne tehnike popunjavanja, ali najčešće se koristi nepromijenjeno popunjavanje (mapa značajki dopunjava se

nulama oko rubova) zbog jednostavnosti i računalne učinkovitosti. Slika 5.2. prikazuje primjer primjene konvolucijskog filtera [5].



Sl. 5.2. Primjer primjene konvolucije [5].


Nakon konvolucijskog sloja slijedi sloj sažimanja. U tom sloju smanjuju se dimenzije ulaznih podataka bez gubitka informacija. Najčešće se koristi maksimalno sažimanje (engl. *max pooling*), gdje se uzima maksimalna vrijednost iz podskupa ulaznih podataka te prosječno sažimanje (engl. *average pooling*). Primjer maksimalnog i prosječnog sažimanja prikazan je na slici 5.3.



Sl. 5.3. Primjer maksimalnog i prosječnog sažimanja [5].

Nakon nekoliko slojeva konvolucije i sažimanja dolaze slojevi potpuno povezanih neurona. Cilj slojeva konvolucije i sažimanja je izdvajanje značajki. Sloj potpuno povezanih neurona tumači te značajke i obavlja zaključivanje. U ovom sloju svaki neuron prethodnog sloja povezan je s neuronom trenutnog sloja, a pomoću izlaznih vektora donosi se konačna odluka. Svaki neuron sadrži svoju aktivacijsku funkciju. Aktivacijske funkcije koriste se za uvjetovanje aktivnosti neurona u neuronskoj mreži. One omogućuju mreži da nauči nelinearne funkcije koje su prisutne u mnogim problemima. Najpoznatije aktivacijske funkcije su Sigmoid, Tanh i ReLU (engl. *Rectified Linear Unit*) [5].


Sigmoid funkcija pretvara unos u vrijednost iz intervala $[0,1]$. Sigmoid funkcija pretvara velike brojeve u 1, dok male brojeve pretvara u 0. Ukoliko je ulaz u funkciju 0, vrijednost funkcije je 0,5. Graf sigmoid aktivacijske funkcije prikazan je na slici 5.4.



Sl. 5.4. Graf sigmoid aktivacijske funkcije

Hiperbolična tangentna funkcija, *tanh*, aktivacijska je funkcija koja daje vrijednost iz intervala $[-1,1]$. Zbog lakšeg treniranja i često boljih rezultata predviđanja, koristi se češće od sigmoid aktivacijske funkcije.

Najveći nedostatak *sigmoid* i *tanh* aktivacijske funkcije je u tome što se funkcije zasićuju i imaju ograničenu osjetljivost. Navedene probleme rješava ReLU aktivacijska funkcija. Graf ReLU funkcije prikazan je na slici 5.5. [19].




Sl. 5.5. Graf ReLU aktivacijske funkcije

ReLU aktivacijsku funkciju karakterizira to da funkcija vraća nula, ukoliko je ulaz manji ili jednak nuli. Ukoliko je ulaz veći od nula, tada je izlaz taj broj.

5.1. U-Net arhitektura

U-Net arhitektura [20] je duboka neruonska neuronska mreža razvijena za segmentaciju biomedicinskih slika. Za razliku od klasičnih konvolucijskih mreža koje za ulaz imaju sliku, a izlaz je klasa kojoj slika pripada, kod biomedicinskih slika nije dovoljno samo odrediti postoji li bolest ili ne, već je često potrebno i lokalizirati područje bolesti. U-Net rješava taj problem klasifikacijom na svakom pikselu pa tako ulaz i izlaz imaju istu veličinu. Mreža je dobila naziv U-Net zbog svoje arhitekture koji je u obliku slova „U“. S lijeve strane U-Net arhitekture nalazi se mreža kodera. Njezina je zadaća izvlačenje značajki iz slika kroz niz blokova kodera. Svaki blok kodera sastoji se od 2 konvolucijska sloja s ReLU aktivacijskom funkcijom. Nakon konvolucijskih slojeva, u bloku kodera, dolazi 2x2 sloj sažimanja pa se tako dimenzionalnost slike u svakom bloku prepolovi. Nakon 4 bloka kodera nalazi se sloj koji spaja koder i enkoder. Zbog toga što povezuje koder i dekoder te prenosi značajke između njih, ovaj sloj se još naziva i most. Sastoji se od dva konvolucijska sloja s ReLU aktivacijskom funkcijom. Konvolucijski slojevi se primjenjuju na izlazu kodera, a proširuju se prema gore (engl. *up-sampling*) kako bi se povećala dimenzionalnost.

S desne strane U-Net arhitekture nalazi se mreža dekodera, ujedno i posljednji sloj U-Net arhitekture. On proizvodi konačnu segmentiranu sliku na temelju značajki predanih iz kodera. Sastoji se od sloja za up-sampling te dva konvolucijska sloja s Relu aktivacijskom funkcijom. Posljednji sloj dekodera sadrži dodatni konvolucijski sloj sa sigmoid aktivacijskom funkcijom koja daje masku segmentacije [21]. Izgled U-Net Arhitekture prikazan je na slici 5.6.



Sl. 5.6. U-Net arhitektura

Prednosti U-Net arhitekture u odnosu na druge arhitekture neuronskih mreža uključuju:

- Precizna segmentacija: U-Net je posebno uspješan u preciznoj segmentaciji objekata na slikama, što ga čini korisnim u medicinskoj dijagnostici, gdje je važno izolirati i analizirati specifične regije interesa na slikama.
- Manji broj parametara: U-Net arhitektura obično ima manji broj parametara u usporedbi s drugim dubokim mrežama, što je čini bržom i efikasnijom u treniranju.
- Fleksibilnost: Može se prilagoditi različitim zadacima segmentacije i obrade slika putem promjene broja slojeva i filtera.

Nedostaci U-Net arhitekture u odnosu na druge arhitekture neuronskih mreža uključuju:

- Potreba za velikim skupom podataka: Kao i mnoge duboke neuronske mreže, U-Net zahtijeva veliki skup podataka za treniranje kako bi postigao visoku preciznost. Ovo može biti izazov, posebno u medicinskim aplikacijama gdje su skupovi podataka često ograničeni.

- Vrijeme treniranja: Iako je U-Net efikasan u smislu broja parametara, treniranje dubokih neuronskih mreža može zahtijevati znatno vrijeme, posebno ako se koriste velike slike i složeni modeli.
- Potrebna ekspertiza: Implementacija i podešavanje U-Net arhitekture za specifične zadatke zahtijeva duboko razumijevanje neuronskih mreža.

Prema tome, U-Net arhitektura je moćna arhitektura za segmentaciju slika s mnogim prednostima, ali zahtijeva dobar skup podataka i stručno znanje za optimalno iskorištavanje njezinih prednosti. S obzirom na uspješnost u mnogim aplikacijama, U-Net postaje ključna arhitektura u području računalnog vida i medicinske obrade slika i dijagnostike.

6. KORIŠTENE TEHNOLOGIJE

U ovom poglavlju ukratko su opisane tehnologije korištene pri izradi modela.

6.1. Python

Python je programski jezik visoke razine koji je stvoren 1990. godine. Ima vrlo jednostavnu sintaksu koja je čitljiva i laka za naučiti. Podržava module i pakete, što potiče modularnost programa i ponovnu upotrebu koda. Otklanjanje pogrešaka u Python programima je jednostavno. Kada se otkrije pogreška, program baca iznimku. Ukoliko se iznimka ne uhvati ispisuje se trag stoga. Python se često koristi i kod strojnog učenja. Strojno učenje sposobnost je računala da uči bez eksplicitnog programiranja. Python sadrži preko 415 000 biblioteka s velikim rasponom područja koja uključuju biblioteke za automatizaciju, analizu podataka, strojno učenje, mobilne aplikacije, testiranje, obradu slike i mnoge druge [22].

6.2. PyTorch biblioteka

PyTorch je biblioteka za strojno učenje otvorenog koda koja se koristi za razvoj modela dubokog učenja temeljenog na neuronskim mrežama. Razvila ju je Meta AI istraživačka grupa. Osim s Python programskim jezikom, biblioteka je kompatibilna i s C++ programskim jezikom. Koristi dinamičko izračunavanje, što omogućuje izradu složenijih arhitektura. PyTorch koristi temeljne koncepte Python programskog jezika kao što su klase, strukture i petlje što ga čini jednostavnim za razumijevanje [23].

6.3. Keras


Keras je API (engl. *Application Programming Interface*) za umjetne neuronske mreže. Fokusira se na brzinu otklanjanja pogrešaka, lakoću implementiranja i održavanja te konciznost koda. Sadrži često korištene elemente neuronskih mreža kao što su slojevi, aktivacijske funkcije, optimizatori te niz alata za rad sa slikovnim podacima. Osim za standardne neuronske mreže, Keras podržava i konvolucijske neuronske mreže. Otvorenog je koda te je kod dostupan na platformi github [24].

6.4. Google Colaboratory

Google Colaboratory ili skraćeno Google Colab je proizvod Google Research-a koji omogućuje pisanje i izvršavanje python koda putem preglednika. Pruža besplatan pristup računalnim resursima, uključujući i GPU (Graphics processing unit), pa je pogodan za analizu podataka i

strojno učenje. Google Colab omogućuje kombiniranje izvršnog koda, teksta, HTML koda, slika u jednoj bilježnici (engl. *notebook*) koja predstavlja jedan projekt na Google Colab-u. Colab bilježnice se pohranjuju na Google Drive račun. Moguće je koristiti popularne Python biblioteke za analizu i vizualizaciju podataka. Također je moguće bazu podataka slika za model strojnog učenja, trenirati i evaluirati model [25].

6.5. ITK-SNAP



Sl. 6.1. izgled sučelja ITK-SNAP aplikacije

ITK-SNAP je interaktivna aplikacija koja omogućuje korisnicima navigaciju trodimenzionalnim medicinskim slikama, ručno ocrtavanje područja od interesa i izvođenje automatske segmentacije slike. Najčešće se koristi za rad s MRI i CT slikama. Izgled sučelja ITK-SNAP aplikacije [26] prikazan je na slici 6.1. .

7. OPIS IZRADE MODELA

U ovom poglavlju opisan je skup podataka, njegova podjela i predobrada, postupak izrade modela neuronske mreže, odabir hiperparametara kod treniranja te su analizirani dobiveni rezultati.

7.1. Opis skupa podataka

Za skup podataka korišten je BraTS2020 (engl. *Multimodal Brain Tumor Segmentation Challenge 2020*) skup podataka. Skup podataka se sastoji od 369 direktorija od kojih svaki sadrži 5 datoteka. Sadrži 4 sekvence MRI slika te pripadajuću masku. Sekvence MRI slika su:


- T1 weighted
- T2 weighted
- T1 native
- Flair

Maska je zapravo segmentacija tumora na slikama MRI-a koju su ručno radila do četiri ocjenjivača koristeći isti protokol za označavanje. Njihove oznake odobrili su i iskusni neuroradiolozi.

Maska se sastoji od 4 sloja. Prvi sloj predstavlja pozadinu, drugi sloj predstavlja nekrotičnu jezgru tumora bez povećanja (NCR/NET), treći sloj predstavlja peritumoralni edem, a četvrti predstavlja GD pojačavajući tumor. Sve četiri sekvence i maska pohranjeni su u NIfTI (engl. Neuroimaging Informatics Technology Initiative) formatu.

Općenito, NIfTI format je standardni format za pohranu MRI i CT slika. NIfTI format napravljen je kao zamjena za ANALYZE format koji se do tada koristio. Problem s ANALYZE formatom bio je nedostatak informacija o prostornoj orijentaciji. Slika pohranjena u ANALYZE formatu sastoji se od datoteke zaglavlja s nastavkom .hdr koja sadrži metapodatke i datoteke s nastavkom .img koja sadrži stvarne podatke o slici. Tijekom uvođenja NIfTI formata željela se zadržati kompatibilnost s ANALYZE formatom te zbog toga slike spremljene u NIfTI formatu također koriste .hdr i .img datoteke. Pošto se greške u gubitku podataka češće javljaju kada se radi s dvije datoteke nego s jednom, NIfTI format omogućuje pohranu slike kao jedinstvenu datoteku s nastavkom .nii. Slike često znaju imati velika područja pozadine koje zauzimaju puno prostora za pohranu, ali imaju malo informacija. Isto se odnosi na slike koje opisuju maske ili područja interesa. Slike u NIfTI formatu se komprimiraju kako bi zauzimale manje prostora za pohranu, istovremeno zadržavajući sve bitne informacije. Komprimirane slike imaju nastavak .nii.gz te su u tom formatu slike svih sekvenci i maski u ovom skupu podataka. Za rad s datotekama u NIfTI


formatu u Pythonu koristi se nibabel biblioteka. Četiri sekvence MRI slika i maska prikazani su na slici 7.1.



Sl. 7.1. Četiri sekvence MRI slike i pripadajuća maska [27]

7.2. Predobrada podataka

Sve slike iz skupa podataka su dimenzija $240*240*155$. Pošto su slike velikih dimenzija i trebalo bi puno računalne snage i memorije kako bi se iste mogle učitati u memoriju i trenirati, potrebno je napraviti predobradu podataka. Primijećeno je kako većinu slike, sekvence ili maske, čini pozadina. Pozadina ne sadrži značajne informacije potrebne za segmentiranje tumora mozga pa su iz tog razloga slike izrezane na dimenzije $128*128*128$ čime je znatno smanjena količina memorije koju slika zauzima. Primjer slike prije i poslije smanjivanja dimenzija prikazan je na slici 7.2.



Sl. 7.2. Slika prije i nakon smanjivanja dimenzija

Kako je već prije rečeno, skup podataka sadrži četiri sekvence MRI slike. Idealno bi bilo kombinirati sve četiri slike te da to bude ulazni podatak za neuronsku mrežu. Ako bi se kombinirale sve 4 slike, tada bih ulazni podatak bio dimenzija $128 \times 128 \times 128 \times 4$ gdje 4 predstavlja broj kanala (T1 weighted, T1 native, T2 weighted i Flair). Zbog ograničenosti računalnih resursa nije bilo moguće koristiti slike ovih dimenzija. Iz tog razloga, kombinirane su samo tri sekvence. Najbolji rezultat ostvaren je kombinacijom T1 weighted, T2 weighted i Flair sekvence pa je ona korištena kao ulaz u neuronsku mrežu.

Za daljnju obradu podataka korišten je MinMaxScaler. On uzima svaku značajku i skalira ju u zadanom rasponu. Standardni raspon je $[0,1]$, ali je moguće i samostalno definirati donju i gornju granicu intervala. Za potrebe ovog zadatke korišten je standardni interval.

Nakon provedene obrade, podaci su podijeljeni na podatke za treniranje (80% ukupnog broja podataka), podatke za validaciju (10% ukupnog broja podataka) te podatke za testiranje (10% ukupnog broja podataka).

7.3. Izrada modela i treniranje

Za treniranje neuronske mreže korištena je U-Net arhitektura. Koder i dekoder se sastoje od 4 bloka. Svaki blok sadrži 2 konvolucijska sloja koja koriste ReLU aktivacijsku funkciju i jedan sloj

sažimanja (2x2x2). Raspon filtera konvolucijskih slojeva mreže kreće se od 16 do 256. Mreža sadrži 5 645 828 parametara od kojih se svi mogu trenirati.

Jedan od problema koji se pojavljuje prilikom treniranja mreže je prekomjerno prilagođavanje (engl. *overfitting*). Prekomjerno prilagođavanje je nepoželjno ponašanje kada model strojnog učenja daje točna predviđanja za podatke za treniranje, ali ne i za nove podatke. Do prekomjernog prilagođavanja dolazi kada se model ne može generalizirati na sve podatke, već umjesto toga preblizu odgovara skupu podataka za trening. Razlozi zbog kojih dolazi do prekomjernog prilagođavanja su:

- Premala količina podataka za trening
- Podaci za treniranje sadrže veliku količinu nevažnih informacija
- Model se predugo trenira na jednom uzorku skupa podataka

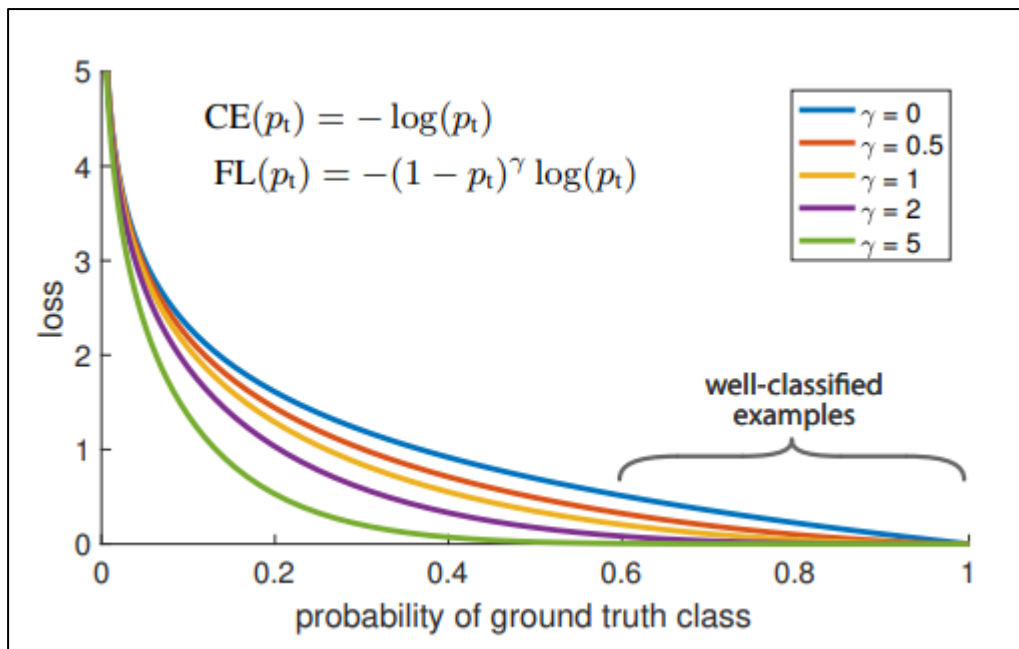
Za prevenciju pretjeranog prilagođavanja korištene su tehnika ispadanja podataka (engl. *dropout*) i tehnika ranog zaustavljanja (engl. *early stopping*). Kod tehnike ispadanja podataka, nasumično odabrani neuroni se zanemaruju tijekom treninga te se na taj način sprječava prekomjerno prilagođavanje. Tehnika ranog zaustavljanja prati poboljšanje odabrane metrike. Ukoliko se metrika prestane poboljšavati, prekida se proces treninga kako ne bi došlo do prekomjernog prilagođavanja [24].

Adam optimizacijska funkcija korištena je za treniranje modela. Stopa učenja funkcije (engl. *learning rate*) iznosila je 0.0001. Eksponencijalna stopa pada za prvi moment iznosi 0.5, a za drugi 0.999. Za funkciju gubitka korištene su *Dice loss* i *Categorical focal loss* funkcije, odnosno njihova kombinacija. *Dice loss* funkcija gubitka mjeri preklapanje između stvarne segmentacije slike i predviđene segmentacije, a izračunava se prema formuli 7-1.

$$Dice\ loss = 1 - \frac{točno\ pozitivni}{2 * točno\ pozitivni + lažno\ pozitivni + lažno\ negativni} \quad (7-1)$$

Categorical focal loss je funkcija gubitka koja se koristi kada postoji više klasa koje mogu biti izlaz modela. Cilj je smanjiti težinu doprinosa lakih primjera i veći fokus pridati težim primjerima. Ova funkcija gubitka nastala je kao nadogradnja na *Categorical cross-entropy loss* funkciju gubitka, s dodanim faktorom (γ) koji smanjuje doprinos gubitku iz lakih i povećava ga za teže

primjere. Slika 7.3. prikazuje graf gubitka *Categorical focal loss* funkcije kao i formule za izračunavanje *Categorical focal loss* i *Categorical cross-entropy loss*.



Sl. 7.3. Graf gubitka *Categorical focal loss* funkcije


Iz navedenog se može primijeniti da su, za $\gamma = 1$, *Categorical focal loss* i *Categorical cross-entropy loss* identični.

Za trening modela u ovom radu korištene su metrike *Dice coefficient* i *Jaccard indeks*. Model se trenira 100 epoha s mogućnosti ranog zaustavljanja ukoliko se gubitak nad validacijskim skupom ne smanji.

7.4. Analiza Rezultata


Model je postavljen da se trenira 100 epoha, ali zbog ranog zaustavljanja trening je završen nakon 32 epohe. Nakon treniranja provedena je evaluacija nad testnim skupom podataka. *Jaccard indeks* iznosi 0.7123, *Dice coefficient* iznosi 0.7956, a iznos gubitka je 0.2151. Ovi rezultati mogu se interpretirati na granici između prihvatljivih i dobrih rezultata.

Matrica zabune predviđanja za nasumično odabranu sliku prikazana je na slici 7.4. Na slici je vidljivo da se najveća pogreška događa kod označavanja GD pojačavajućeg tumora. Najbolji rezultati ostvareni su kod nekrotične jezgre tumora bez povećanja.



Sl. 7.4. Matrica zabune nasumično odabrane slike iz testnog skupa podataka

Slika 7.5. prikazuje testnu sliku, originalnu segmentaciju te predviđenu segmentaciju.



Sl. 7.5. Testna slika, originalna segmentacija, predviđena segmentacija.

Analizom slike, kao i drugih parametara rezultata testiranja, može se utvrditi kako segmentacija nije dovoljno precizna da bi se koristila umjesto ručne ljudske segmentacije, ali može poslužiti za

okviran pronalazak mjesta i tipa tumora. Također, može se primijetiti da se zbog smanjivanja dimenzija slika, radi ograničenih računalnih resursa, gubi dio rubnih značajki.

8. ZAKLJUČAK

Tumori mozga predstavljaju nekontrolirani rast stanica u mozgu, a pojavljuju se većinom kod osoba starijih od 50 godina. Razlikujemo primarne, one koji nastaju u lubanjskoj šupljini te sekundarne, one koji su nastali na drugom dijelu tijela te su se kasnije proširili na mozak. Kako bih se dijagnosticirao tumor mozga koristi se najčešće magnetska rezonanca, iako je neke vrste moguće otkriti i pomoću CT-a. MRI snimke pacijenta dobivaju se tako da se pacijent stavi u magnetsko polje jačine 0.02 do 4 tesla. Na MRI slikama moguće je promatrati tri ravnine. To su aksijalna (dijeli tijelo na gornju i donju polovicu), sagitalna (dijeli tijelo na lijevu i desnu polovicu) te koronalna (dijeli tijelo na prednju i stražnju stranu). Kod prikaza mozga na MRI slikama razlikujemo GD pojačavajući tumor, peritumoralni edem te nekrotičnu jezgru tumora bez povećanja. Da bi se tumor mozga mogao ispravno liječiti, važno je točno ocrtavanje tumora. Ručna segmentacija oduzima puno vremena te je podložna ljudskim pogreškama. Zbog toga je potrebno razvijate sustave za automatsku segmentaciju i ocrtavanje tumora pomoću strojnog učenja.

U ovome radu, implementiran je sustav za automatsku segmentaciju tumora baziran na U-Net arhitekturi. U-Net je konvolucijska neuronska mreža koja je nastala za segmentaciju biomedicinskih slika. Klasifikacijom svakog piksela, rješava se potreba lokaliziranja područja bolesti na slikama. U-Net arhitektura sastoji se od kodera, mosta te enkodera, koji zajedno tvore arhitekturu u obliku slova "U" po čemu je arhitektura i dobila ime. Za izradu modela korišteni su Python, Keras, Google Colaboratory te ITK-snap.

Prije početka treniranja bilo je potrebno napraviti predobradu skupa podataka. Tri sekvence magnetske rezonance (T1 weighted, T2 weighted i Flair) kombinirane su u jednu datoteku te je ona predstavljala ulaz u mrežu. Ulazna slika je također izrezana na dimenzije 128x128x128 umjesto inicijalnih dimanzija 240x240x240 s ciljem olakšavanja treniranja neuronske mreže. Koder i dekoder se sastoje od 4 bloka, od kojih svaki sadrži 2 konvolucijska sloja i jedan sloj sažimanja. Za funkciju gubitka korištena je kombinacija *Dice loss* i *Categorical focal loss* funkcije. Za trening korištene su metrike *Dice coefficient* i *Jaccard indeks*.

Nakon treniranja i evaluacije modela utvrđeno je da *Jaccard index* iznosi 0.7123, *Dice coefficient* iznosi 0.7956, a iznos gubitka je 0.2151. Rezultati su na granici između prihvatljivih i dobrih rezultata. Model bi se mogao koristiti kao pomoć radiolozima prilikom segmentiranja tumora, ali ne bi mogao u potpunosti zamijeniti ručnu segmentaciju. Povećanjem računalne snage mogli bih se poboljšati i krajnji rezultati jer bi se slika mogla održati u originalnom formatu te bi se za ulaz

u model mogle kombinirati sve četiri sekvence magnetske rezonance. Bolje rezultate moguće je dobiti i dodatnom predobradom podataka te boljim izborom funkcije gubitka.

LITERATURA

- [1] „Hrvatski zavod za javno zdrvstvo“. <https://www.hzjz.hr/> (pristupljeno 27. lipanj 2023.).
- [2] K. Kamnitsas i ostali, „DeepMedic for Brain Tumor Segmentation“, u *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, A. Crimi, B. Menze, O. Maier, M. Reyes, S. Winzeck, i H. Handels, Ur., u *Lecture Notes in Computer Science*, vol. 10154. Cham: Springer International Publishing, 2016, str. 138–149. doi: 10.1007/978-3-319-55524-9_14.
- [3] X.-X. Yin, L. Sun, Y. Fu, R. Lu, i Y. Zhang, „U-Net-Based Medical Image Segmentation“, *J. Healthc. Eng.*, sv. 2022, str. 4189781, 2022, doi: 10.1155/2022/4189781.
- [4] „DeepMedic“. <https://deepmedic.org/> (pristupljeno 28. travanj 2023.).
- [5] X. Liu, L. Song, S. Liu, i Y. Zhang, „A Review of Deep-Learning-Based Medical Image Segmentation Methods“, *Sustainability*, sv. 13, izd. 3, str. 1224, sij. 2021, doi: 10.3390/su13031224.
- [6] „Cancer.Net | Oncologist-approved cancer information from the American Society of Clinical Oncology“. <https://www.cancer.net/> (pristupljeno 03. lipanj 2023.).
- [7] „HeMED - Hrvatska elektronička medicinska edukacija“. <https://www.hemed.hr/> (pristupljeno 14. travanj 2023.).
- [8] N. E. Millard i K. C. De Braganca, „Medulloblastoma“, *J. Child Neurol.*, sv. 31, izd. 12, str. 1341–1353, lis. 2016, doi: 10.1177/0883073815600866.
- [9] L. M. DeAngelis, „Brain tumors“, *N. Engl. J. Med.*, sv. 344, izd. 2, str. 114–123, sij. 2001, doi: 10.1056/NEJM200101113440207.
- [10] A. Perkins i G. Liu, „Primary Brain Tumors in Adults: Diagnosis and Treatment“, *Prim. Brain Tumors*, sv. 93, izd. 3, 2016.
- [11] A. O. Rodriguez, „Principles of magnetic resonance imaging“, *Princ. Magn. Reson. IMAGING*, 2004.
- [12] J. S. Klein, W. E. Brant, C. A. Helms, i E. N. Vinson, Ur., *Brant and Helm's fundamentals of diagnostic radiology*, Fifth edition. u radiology. Philadelphia Baltimore New York London Buenos Aires Hong Kong Sydney Tokyo: Wolters Kluwer, 2019.
- [13] „A Study of MRI Segmentation Methods in Automatic Brain Tumor Detection“, *Int. J. Eng. Technol.*, sv. 8, izd. 2, 2016.
- [14] A. R. K.-C. Hebrang, *Radiologija*. Zagreb: Medicinska naklada, 2007.
- [15] E.-W. Radü i M. A. Sahraian, *MRI Atlas of MS Lesions*. Berlin, Heidelberg: Springer-Verlag Springer e-books, 2008.

- [16] N. Nundkumar, M. Guthikonda, i S. Mittal, „Peritumoral edema following Gamma Knife radiosurgery as the primary treatment for intraventricular meningiomas“, *J. Clin. Neurosci. Off. J. Neurosurg. Soc. Australas.*, sv. 20, izd. 4, str. 616–618, tra. 2013, doi: 10.1016/j.jocn.2012.03.041.
- [17] „“Dead Zone” Within Tumors Helps Cancers Spread“, *Cancer Research from Technology Networks*. <http://www.technologynetworks.com/cancer-research/news/dead-zone-within-tumors-helps-cancers-spread-370646> (pristupljeno 25. lipanj 2023.).
- [18] W. Rawat i Z. Wang, „Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review“, *Neural Comput.*, sv. 29, izd. 9, str. 2352–2449, ruj. 2017, doi: 10.1162/neco_a_00990.
- [19] N. Aloysius i M. Geetha, „A review on deep convolutional neural networks“, u *2017 International Conference on Communication and Signal Processing (ICCSP)*, Chennai: IEEE, tra. 2017, str. 0588–0592. doi: 10.1109/ICCSP.2017.8286426.
- [20] J. Zhang, „UNet - Line by Line Explanation“, 10 2019. <https://towardsdatascience.com/unet-line-by-line-explanation-9b191c76baf5>
- [21] N. Tomar, „What is UNET?“, *Analytics Vidhya*, 25. siječanj 2021. <https://medium.com/analytics-vidhya/what-is-unet-157314c87634> (pristupljeno 09. kolovoz 2023.).
- [22] M. Bowles, *Machine Learning in Python: essential techniques for predictive analysis*. Indianapolis, IN: John Wiley & Sons, Inc, 2015.
- [23] „PyTorch“. <https://www.pytorch.org> (pristupljeno 05. kolovoz 2023.).
- [24] „Keras: Deep Learning for humans“. <https://keras.io/> (pristupljeno 11. kolovoz 2023.).
- [25] „colab.google“, *colab.google*. <http://0.0.0.0:8080/> (pristupljeno 12. kolovoz 2023.).
- [26] P. A. Yushkevich, null Yang Gao, i G. Gerig, „ITK-SNAP: An interactive tool for semi-automatic segmentation of multi-modality biomedical images“, *Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. IEEE Eng. Med. Biol. Soc. Annu. Int. Conf.*, sv. 2016, str. 3342–3345, kol. 2016, doi: 10.1109/EMBC.2016.7591443.
- [27] „The NIFTI file format | Brainder.“ <https://brainder.org/2012/09/23/the-nifti-file-format/> (pristupljeno 27. kolovoz 2023.).

SAŽETAK

Tumori mozga, kao i svi ostali tumori nastaju nekontroliranom diobom stanica. Kako bih se ispravno planirala radioterapija, pratila progresija tumora te izabrala metoda liječenja, važno je ispravno ocrtavanje tumora. U ovom radu napravljen je model za automatsku segmentaciju GD pojačavajućeg tumora, peritumoralnog edema i nekrotične jezgre tumora bez povećanja. Za rješavanje ovog problema korištene su konvolucijske neuronske mreže, točnije U-Net arhitektura. Kod konvolucijskih neuronskih mreža protok informacija odvija se u samo jednom smjeru. U-Net arhitektura sastoji se od kodera, dekodera te mosta. Za izradu modela korišteni su Python, Keras, Google Colaboratory i ITK-snap. Za treniranje se koristio BraTS2020 skup podataka. Nakon predobrade i treniranja podataka dobiveni su sljedeći rezultati: *Jaccard index* iznosi 0.7123, *Dice coefficient* iznosi 0.7956, a iznos gubitka je 0.2151. Rezultati su relativno dobri, model se ne može koristiti kao zamjena za ručnu segmentaciju, ali se mogu koristiti za pomoć pri istoj.

Ključne riječi: Konvolucijske neuronske mreže, MRI, Tumor mozga, U-Net arhitektura

ABSTRACT

Deep learning for brain tumor segmentation from MRI images

Brain tumors, like all other tumors, arise from uncontrolled cell division. In order to properly plan radiotherapy, monitor tumor progression and choose a treatment method, it is important to correctly label the tumor. In this paper, a model for automatic segmentation of GD-enhancing tumor, peritumoral edema and necrotic non-enhancing tumor core. To solve this problem, convolutional neural networks, more precisely the U-Net architecture, were used. In convolutional neural networks, information flows in only one direction. The U-Net architecture consists of an encoder, a decoder and a bridge. Python, Keras, Google Collaboratory and ITK-snap were used to create the model. The BraTS2020 dataset was used for training. After data preprocessing and training, the following results were obtained: Jaccard index is 0.7123, Dice coefficient is 0.7956, and the amount of loss is 0.2151. The results are relatively good, the model cannot be used instead of manual segmentation, but it can be used to help with it.

Keywords: Convolutional neural networks, MRI, Brain tumor, U-Net architecture

ŽIVOTOPIS

Maroje Raguž rođen je 30. srpnja 1999. u Osijeku. Pohađao je Osnovnu školu Frana Krste Frankopana u Osijeku. Nakon završene osnovne škole, 2014. godine upisuje III. Gimnazija Osijek. Tijekom školovanja sudjelovao je na natjecanjima iz matematike i informatike, kao i na sportskim natjecanjima u rukometu i atletici. Nakon završene srednje škole upisuje preddiplomski sveučilišni studij računarstva na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija u Osijeku koji uspješno završava 2021. godine. Iste godine upisuje diplomski sveučilišni studij Računarstva. na istom fakultetu. Od početka 2022. godine radi preko studentskog ugovora kao java developer u Samurai Digitalu.