

Segmentacija srčanih komora iz 2D MRI slika pomoću U-Net konvolucijske neuronske mreže

Grubeša, Marko

Master's thesis / Diplomski rad

2021

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:200:053630>

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

Download date / Datum preuzimanja: **2025-02-19**

Repository / Repozitorij:

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



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

Sveučilišni studij

**SEGMENTACIJA SRČANIH KOMORA IZ 2D MRI
SLIKA POMOĆU U-NET KONVOLUCIJSKE
NEURONSKE MREŽE**

Diplomski rad

Marko Grubeša

Osijek, 2021.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac D1: Obrazac za imenovanje Povjerenstva za diplomski ispit

Osijek, 15.07.2021.

Odboru za završne i diplomske ispite**Imenovanje Povjerenstva za diplomski ispit**

Ime i prezime studenta:	Marko Grubeša
Studij, smjer:	Diplomski sveučilišni studij Računarstvo
Mat. br. studenta, godina upisa:	D-1055R, 06.10.2019.
OIB studenta:	96464662643
Mentor:	Izv. prof. dr. sc. Irena Galić
Sumentor:	Marija Habijan
Sumentor iz tvrtke:	
Predsjednik Povjerenstva:	Izv. prof. dr. sc. Krešimir Nenadić
Član Povjerenstva 1:	Izv. prof. dr. sc. Irena Galić
Član Povjerenstva 2:	Dr. sc. Hrvoje Leventić
Naslov diplomskog rada:	Segmentacija srčanih komora iz 2D MRI slika pomoću U-Net konvolucijske neuronske mreže
Znanstvena grana rada:	Umjetna inteligencija (zn. polje računarstvo)
Zadatak diplomskog rada:	Istražiti i opisati način dobivanja MRI slika i njihove karakteristike. Istražiti i opisati kliničku pozadinu (prikaz srca na MRI slikama, dijelove srca, klinička potreba) te dati kratak pregled područja. Objasniti teorijske osnove načina rada konvolucijskih neuronskih mreža. Razviti sustav za predobradu MRI slika. Razviti sustav za segmentaciju cijelog srca pomoću U-Net konvolucijske neuronske mreže. Usporediti dobivene rezultate segmentacije sa i bez pretprocesiranja podataka. Prikazati i objasniti rezultate te odrediti preciznost izvođenja razvijenog sustava. Tehnologije: Python, biblioteke Pytorch, Keras ili Tensorflow Tema rezervirana za: Marko Grubeša Sumentor: Marija Habijan. Za sve informacije u vezi rada javiti se na marija.habijan@ferit.hr.
Prijedlog ocjene pismenog dijela ispita (diplomskog rada):	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 3 bod/boda Jasnoća pismenog izražavanja: 3 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene mentora:	15.07.2021.
Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis:
	Datum:

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**IZJAVA O ORIGINALNOSTI RADA**

Osijek, 20.07.2021.

Ime i prezime studenta:

Marko Grubeša

Studij:

Diplomski sveučilišni studij Računarstvo

Mat. br. studenta, godina upisa:

D-1055R, 06.10.2019.

Turnitin podudaranje [%]:

18

Ovom izjavom izjavljujem da je rad pod nazivom: **Segmentacija srčanih komora iz 2D MRI slika pomoću U-Net konvolucijske neuronske mreže**

izrađen pod vodstvom mentora Izv. prof. dr. sc. Irena Galić

i sumentora Marija Habijan

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.

Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

SADRŽAJ

1. UVOD.....	1
1.1. Zadatak diplomskog rada.....	1
1.2. Organizacija rada.....	2
2. TRENUTNE METODE SEGMANTACIJE	3
3. MEDICINSKA I TEHNOLOŠKA POZADINA	7
3.1. Struktura ljudskog srca	7
3.2. Dobivanje slika pomoću magnetske rezonance	9
3.2.1. Pozadinska fizika magnetske rezonance	10
3.3. Formati zapisa medicinskih slika.....	11
3.4. Konvolucijske neuronske mreže	14
3.4.1. Slojevi konvolucijskih neuronskih mreža	14
3.5. Semantička segmentacija medicinskih slika pomoću konvolucijskih neuronskih mreža	19
4. RAZVIJENI SUSTAV ZA SEGMANTACIJU	22
4.1. Skup podataka	22
4.2. Predobrada podataka	23
4.2.1. Bayesova metoda uklanjanja šuma	24
4.3. U-Net arhitektura neuronske mreže.....	25
5. DOBIVENI REZULTATI.....	27
5.1. Rezultati predobrade podataka	27
5.2. Usporedba rezultata segmentacije sa i bez predobrade podataka	29
5.3. Evaluacija rezultata segmentacije	30
6. ZAKLJUČAK.....	35
ZAHVALE	36
LITERATURA.....	37

<i>SAŽETAK</i>	41
<i>ABSTRACT</i>	42
<i>PRILOG</i>	43
PRILOG A - MODEL U-NET KONVOLUCIJSKE NEURONSKE MREŽE	43
PRILOG B - BAYESOVA METODA UKLANJANJA ŠUMA	44

1. UVOD

Segmentacija je jedan od ključnih problema u polju računalnog vida i obrade slike. Cilj segmentacije je grupiranje piksela u istaknuta područja slike, tj. područja koja odgovaraju pojedinačnim dijelovima slike ili predmeta [1,2]. Takva tehnika daje nam detaljnije razumijevanje predmeta na slici. Segmentacija ima široku primjenu u raznim područjima. Neka od tih područja su autonomna vozila, virtualna stvarnost, interakcija čovjeka i računala te ima i veliku primjenu u medicinskoj obradi slike. Medicinska obrada slike koristi se za dobivanje slika dijelova tijela za medicinsku uporabu radi identificiranja ili proučavanja bolesti [3]. Područje medicinske obrade slika izrazito brzo se razvija, ponajviše zbog razvoja tehnika obrade slika, što uključuje analizu, prepoznavanje, poboljšavanje te segmentaciju slike. Medicinska obrada slike obuhvaća upotrebu i istraživanje trodimenzionalnih nizova podataka koji se najčešće dobivaju pomoću računalne tomografije (CT, engl. *Computed Tomography*) ili magnetske rezonancije (MRI, engl. *Magnetic Resonance Imaging*) [4]. Magnetska rezonanca je tehnika medicinskog snimanja koja se koristi u radiologiji za oblikovanje slika anatomije i fizioloških procesa u tijelu [5]. Pomoću te tehnike dobivaju se slike srčanih komora na kojima se može obavljati medicinska obrada slike. Na tim slikama provode se razne metode radi uklanjanja šuma i poboljšanja kvalitete slike te se sve češće upotrebljavaju i metode dubokog učenja.

Duboko učenje je grana strojnog učenja, koji je, zauzvrat grana područja umjetne inteligencije. Duboko učenje pruža skup algoritama i metoda koje se mogu koristiti za rješavanje problema koje ljudi izvode intuitivno i gotovo automatski, ali su inače vrlo izazovne za računalo [6]. U-Net konvolucijska neuronska mreža, bazirana na dubokom učenju, pokazala je izuzetne rezultate u području segmentacije medicinskih slika i zbog toga se često upotrebljava i za različite zadatke obrade kardiovaskularnih slika.

1.1. Zadatak diplomskog rada

Zadatak ovog diplomskog rada je istražiti i opisati način dobivanja MRI (engl. *Magnetic Resonance Imaging*) slika i njihove karakteristike. Potom, opisati kliničku pozadinu (prikaz srca na MRI slikama, dijelove srca, klinička potreba) te dati kratak pregled područja prethodno razvijenih metoda za segmentaciju srca iz MRI slika. Potrebno je objasniti teorijske osnove načina rada konvolucijskih neuronskih mreža te razviti metodu za predobradu MRI slika. Potrebno je razviti sustav za segmentaciju cijelog srca pomoću U-net konvolucijske neuronske mreže te

usporediti dobivene rezultate segmentacije s i bez pretprocesiranja podataka i prikazati preciznost izvođenja razvijenog sustava.

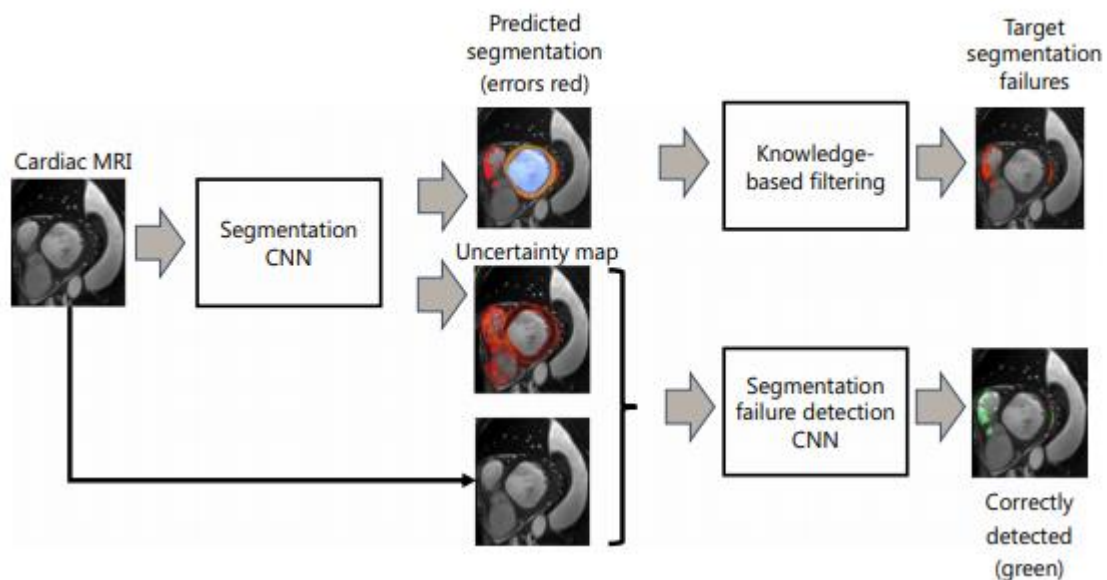
1.2. Organizacija rada

Ovaj se rad sastoji od šest poglavlja. U prvom poglavlju dan je uvod i opis zadatka. U drugom poglavlju dan je pregled područja gdje se opisuju trenutne metode segmentacije. Treće poglavlje opisuje medicinsku i tehnološku pozadinu. U četvrtom poglavlju opisan je razvijeni sustav za segmentaciju. Peto poglavlje opisuje dobivene rezultate te daje usporedbu rezultata sa i bez predobrade podataka. U šestom poglavlju dan je sažetak rada i zaključak.

2. TRENUTNE METODE SEGMENTACIJE

U-Net se smatra jednom od standardnih CNN (engl. *Convolutional Neural Network*) arhitektura za zadatke klasifikacije slika, kada trebamo ne samo definirati cijelu sliku prema njezinoj klasi već i segmentirati područja slike po klasi, tj. proizvesti masku koja će odvojiti sliku u nekoliko klasa [7]. Najčešće se koristi u biomedicini za segmentaciju srca, mozga i ostalih dijelova tijela.

Sander i ostali [8] opisali su automatsku segmentaciju s detekcijom lokalnih greški u MRI slikama srca. Ova tehnika koristi 3 konvolucijske neuronske mreže. Svaka mreža kao ulaz prima CMR (engl. *Cardiac Magnetic Resonance*) sliku te svaka od njih ima četiri izlazna kanala koji prikazuju vjerojatnosti za tri srčane strukture i pozadinu. Nakon toga, za otkrivanje i ispravljanje grešaka lokalne segmentacije korišten je pomoćni CNN koji analizira ulaznu sliku. Nakon analize, kreira se mapa koja prikazuje područja neuspješne segmentacije. Slika 2.1 prikazuje korake opisane metode automatske segmentacije s detekcijom lokalnih greški.




Slika 2.1 Koraci automatske segmentacije s detekcijom lokalnih greški [8]

Shewaye [9] je predstavio metodu segmentacije tehnikom rasta regije. Ideja je da se prvo odabere početni piksel te se onda svi susjedni pikseli spoje s tim pikselom ako ispunjavaju

unaprijed određene kriterije jednolikosti. Svaki puta kada se regiji doda piksel srednja vrijednost regije se mijenja uzimajući u obzir novo dodani piksel. Algoritam rasta regije prati sljedeće korake: odabir početnog piksela, računanje mjere sličnosti svakog susjednog piksela s početnim pikselom, ako je kriterij sličnosti zadovoljen dodati piksel regiji, označiti dodani piksel određenom bojom za tu regiju te izmijeniti vrijednost regije. Kada rast za tu regiju prestane, odabirati novi piksel te ponoviti navedene korake.

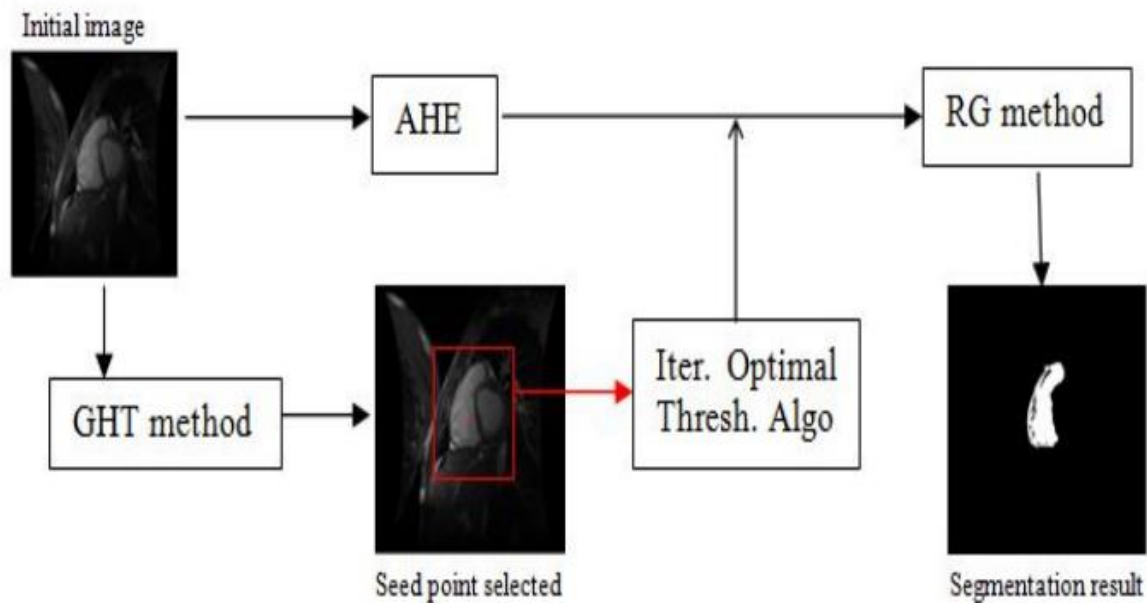
Payer i ostali [10] opisali su kako bi bilo poželjno pronaći koordinate svih srčanih podstrukture kako bi se moglo fokusirati samo na lokaliziranu regiju. Ideja je da se koriste dvije odvojene konvolucijske neuronske mreže. Prva mreža pronalazi koordinate cijelog srca, dok se druga mreža fokusira na pozicije iz skupa podataka s fokusom na anatomske pogodne položaje te pruža željenu segmentaciju. Wang i ostali [11] opisuju metodu koja koristi U-net arhitekturu. Ova metoda može istovremeno naučiti otkrivati područje interesa srca i klasificirati piksele u različite podstrukture bez gubitka rezolucije. U-net daje grubo predviđanje piksela te nakon uspješne predikcije dolazi se do rekonstrukciju u originalnu dimenziju. Druga arhitektura koja je bazirana na SRCNN (engl. *Super Resolution Convolutional Neural Network*) uzima originalne podatke i dobivene rezultate iz prve mreže kao ulaz te tako omogućuje izravnu predikciju na slikama s originalnom rezolucijom.

Wai i ostali [12] opisali su segmentaciju aorte. Segmentacija lumena aorte s MRI slika bitna je za preciznu mehaničku karakterizaciju aorte. Jedan od izazova za ovaj zadatak je rijetkost anotacija aorte, označeno je samo nekoliko okvira. Kako bi se riješio taj problem primijenjena je *non-rigid* registracija slike za propagaciju anotiranih slika koji imaju oznake na susjedne u srčanom ciklusu koji nemaju oznaku. Korištenjem te tehnike učinkovito se generiraju pseudo anotirane slike koji se onda mogu koristiti za treniranje. Ova metoda djelomično nadziranog učenja postiže *dice score* 0.96 za uzlaznu aortu i 0.95 za silaznu aortu. Test je proveden na 100 uzoraka. Ovaj pristup također je baziran na FCN (engl. *Fully Convolutional Network*) i RNN (engl. *Recurrent Neural Network*) te se s njima segmentacija može izvesti direktno bez potrebe za procjenom područja interesa. Slika 2.2 prikazuje detekciju aorte. Slike 2.2 a) i 2.2 b) prikazuju uzlaznu aortu, a slike 2.2 c) i 2.2 d) silaznu aortu.



Slika 2.2 Segmentacija aorte [15]

Daoudi i ostali [16] koriste metodu tehnike rasta regije sličnu kao Shewaje [9] uz dodatna pojašnjenja načina odabira početnog piksela, kao i korištenje dodatnih metoda obrade slike. Proces segmentiranja započinjem poboljšanjem kontrasta slike pomoću adaptivnog izjednačavanja histograma (AHE, engl. *Adaptive Histogram Equalization*). Pomoću te metode mijenjanja kontrasta, histogram se može prilagoditi tako da proširi rubove područja s lošom distribucijom. Također se koristi generalizirana Houghova transformacija (GHT) koja će služiti za izbor početnog piksela. Najbitniji parametar ove metode je odabir granične vrijednosti. Provodi se iterativni algoritam koji će pronaći idealnu graničnu vrijednost te se potom obavlja proces segmentacije. Slika 2.3 prikazuje opisani proces metode iz te se vidi konačni rezultat segmentacije srca.



Slika 2.3 Prikaz metode iz rada [16]


S obzirom da je istraživanje segmentacije srca izrazito često promatrano područje, razvijene su i brojne druge metode čiji se detaljni opisi mogu pronaći u preglednim radovima [13,14].

3. MEDICINSKA I TEHNOLOŠKA POZADINA

Područje obrade slike i dubokog učenja često su potrebni za rješavanje različitih zadataka poput segmentacije ili klasifikacije. Metode dubokog učenja često se primjenjuju i u medicinskoj obradi slike gdje je poželjno poznavati strukturu organa ili pojedinih dijelova tijela. Ovo poglavlje opisuje strukturu ljudskog srca te dodatno pojašnjava kako magnetska rezonanca funkcionira i u kojem formatu medicinske slike budu zapisane. Također, opisuje konvolucijske neuronske mreže te proces semantičke segmentacije medicinskih slika pomoću konvolucijskih neuronskih mreži.

3.1. Struktura ljudskog srca

Srce je mišićni organ koji djeluje poput pumpe za kontinuirano slanje krvi u cijelom tijelu. Srce je samo središte krvožilnog sustava. Ovaj sustav se sastoji od mreže krvnih žila, poput arterija, vena i kapilara. Arterije, vene i kapilare prenose krv do svih dijelova ljudskoga tijela. Električni sustav regulira srce i koristi električne signale za kontrakciju srca. Pri kontrakciji srca, krv se pumpa u krvožilni sustav. Sustav ulaznih i izlaznih ventila u srčanim komorama rade kako bi osigurali protok krvi udesno (Slika 3.1). Bez pumpanja srca, krv ne može cirkulirati unutar tijela [17].



Slika 3.1 Struktura srca [18]

Srce se sastoji od lijeve i desne polovice i podijeljeno je u četiri komore. Srčana septuma proteže se u duljini između dvije polovice srca kao što je prikazano na slici 3.2. Septum razdvaja četiri klijetke u lijevi i desni atrij te u lijevu i desnu komoru. Lijeva klijetka je dio cirkulacije i povezana je s lijevim atrijem. Odgovorna je za opskrbu tijela kroz cirkulaciju aorte krvlju koja dolazi iz pluća. Desna klijetka dio je plućne cirkulacije i povezana je s desnim atrijem [19].

Slika 3.1 prikazuje protok krvi kroz srce. Krv se preuzima iz srca pomoću najveće arterije u tijelu aorte koja ima grane za glavu i vrat, srce, jetru, crijeva, bubrege i donje ekstremitete. Vene prikupljaju krv bogatu ugljikovim dioksidom i raspadnutim produktima metabolizma iz svih dijelova tijela i nosi je preko gornje i donje šuplje vene u desno srce gdje preko plućne arterije ta krv odlazi u pluća. U plućima se krv obogaćuje kisikom, odnosi u lijevu polovicu srca do ostalih dijelova tijela [20].



Slika 3.2 Detaljniji prikaz srčanih komora [21]

3.2. Dobivanje slika pomoću magnetske rezonance


Magnetska rezonancija (MRI) je tehnika medicinskog snimanja koja se koristi u radiologiji za oblikovanje slika anatomije i fizioloških procesa u tijelu. Magnetska rezonancija stvara trodimenzionalne anatomske slike koje se koriste za otkrivanje bolesti, dijagnozu i praćenje liječenja. Temelji se na tehnologiji koja pobuđuje i otkriva promjenu smjera rotacijske osi protona koji se nalaze u vodi koja čini živa tkiva [22]. MRI (engl. *Magnetic Resonance Imaging*) ne uključuje rendgenske zrake ili upotrebu ionizirajućeg zračenja, što ga razlikuje od CT (engl. *Computed Tomography*) i PET (engl. *Positron Emission Tomography*) skeniranja. MRI se široko koristi u bolnicama i klinikama za medicinsku dijagnostiku i postavljanje i praćenje bolesti bez izlaganja tijela zračenju. MRI pretrage traju dugo i glasne su. Kao što je prikazano na slici 3.3 većina MR (engl. *Magnetic Resonance*) uređaja ima kućište u obliku tunela u čiji se središnji dio pomoću automatiziranog stola za pregled postavlja dio tijela kojeg treba analizirati [23]. Osim toga, ljudi s nekim medicinskim implantatima ili drugim metalom koji se ne može ukloniti u tijelu možda neće biti u mogućnosti potpuno sigurno proći MRI pregled.



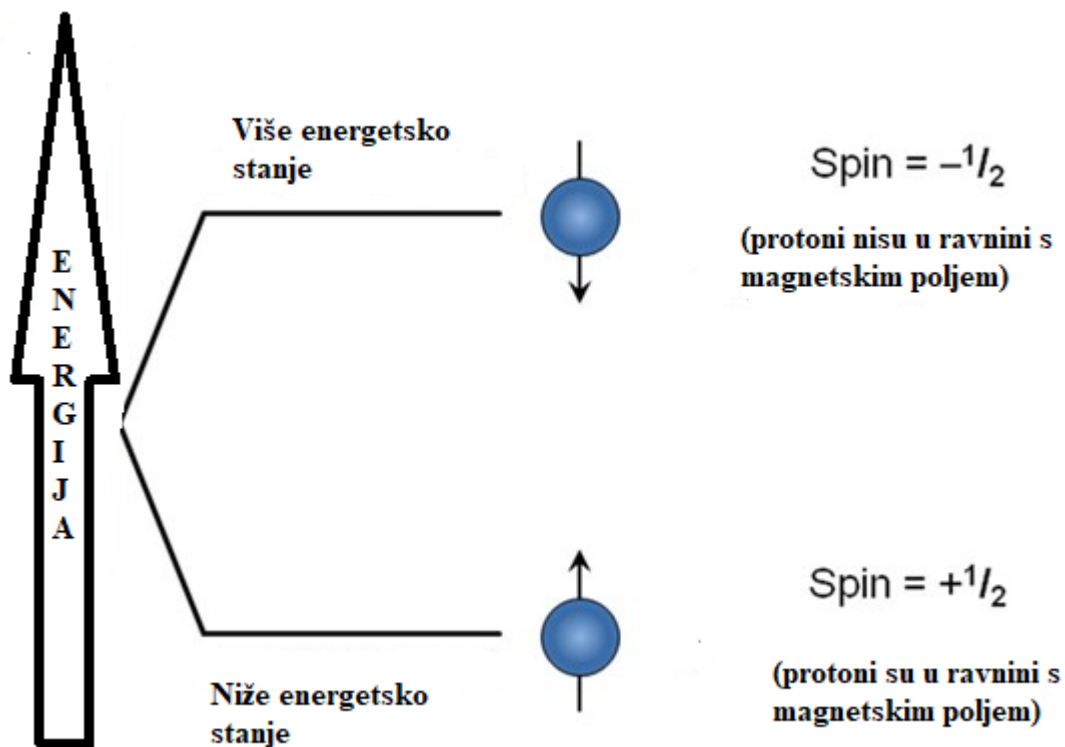
Slika 3.3 Uređaj za snimanje MRI slika [24]

3.2.1. Pozadinska fizika magnetske rezonance

Atomi se sastoje od tri osnovne čestice: protona koji posjeduju a pozitivni naboj, neutroni, koji nemaju naboj i elektroni, koji imaju negativan naboj. Protoni i neutroni nalaze se u jezgri ili jezgri atoma, dok su elektroni smješteni u ljuskama koji okružuju jezgru. Karakteristične kemijske reakcije elemenata ovise o određenom broju svake od tih čestica. Svojstva koja se najčešće koriste za kategorizaciju elemenata su atomski broj i atomska težina. Treće svojstvo jezgre je spin. Može se smatrati da se jezgra neprestano okreće oko svoje osi konstantnom brzinom te je ta rotacija oko svoje osi okomita na smjer rotacije (Slika 3.4 prikazuje rotaciju) [25]. MRI uređaji koriste snažne magnete koji proizvode snažno magnetsko polje koje prisiljava protone u tijelu da se poravnaju s tim poljem. Na slici 3.5 vidljivo je kada radijska frekvencija pulsira kroz pacijenta, protoni se stimuliraju i izbacuju se iz ravnoteže te se naslanjaju na povlačenje magnetskog polja. Kad je radijsko frekvencijsko polje isključeno, MRI senzori mogu detektirati energiju koja se oslobađa kad se protoni poravnaju s magnetskim poljem. Vrijeme potrebno da se protoni usklade s magnetskim poljem, kao i količina oslobođene energije, mijenja se ovisno o okruženju i kemijskoj prirodi molekula. Liječnici su u stanju utvrditi razliku između različitih vrsta tkiva na temelju tih magnetskih svojstava [22].



Slika 3.4 Spin jezgre atoma [25]



Slika 3.5 Poravnanje protona [26]

3.3. Formati zapisa medicinskih slika

Glavni formati korišteni za zapis medicinskih slika su: Analyze, Nifti (engl. *Neuroimaging Informatics Technology Initiative*), Minc (engl. *Medical Image NetCDF*) i Dicom (engl. *Digital Imaging and Communications in Medicine*). Medicinska slika predstavlja prikaz unutarnje strukture ili funkcije anatomske regije u obliku niza elemenata slike koji se nazivaju pikseli ili vokseli. Ono što izražava numerička vrijednost piksela ovisi o modalitetu slike, protokolu akvizicije, rekonstrukciji i na kraju, naknadnoj obradi [27].

Dubina piksela je broj bitova koji se koristi za kodiranje podataka svakog piksela. Svaka slika pohranjuje se u datoteku i čuva u memoriji računala kao skupina bajtova. Bajtovi su skupina od 8 bitova i predstavljaju najmanju količinu koja se može pohraniti u memoriju računala [27].

Fotometrijska interpretacija određuje kako se podaci piksela trebaju tumačiti za ispravan prikaz slike kao jednobojna ili slika u boji. Jednobojne slike imaju jedan uzorak po pikselu i na

njemu nisu pohranjeni podatci o boji. Za prikaz slika koriste se nijanse sive boje. Broj nijansi sive ovisi o broju bitova korištenih za pohranu uzorka koji se podudara s dubinom piksela. Kliničke radiološke slike, poput magnetske rezonancije i računalne tomografije imaju fotometrijsku interpretaciju sive skale. Boja se koristi za kodiranje smjera krvotoka u Doppler ultrazvuku, kako bi se pokazale dodatne informacije na anatomskoj slici [27].

Metapodatci su informacije koje opisuju sliku. Metapodatci su spremljeni na početku datoteke kao zaglavlje i sadrže barem dimenzije matrice slike, prostornu razlučivost, dubinu piksela i fotometrijsku interpretaciju. Slike koje dolaze iz dijagnostičkih modaliteta imaju informacije o načinu stvaranja slike. Na primjer, slika nastala magnetskom rezonancijom imaće parametre koji se odnose na upotrijebljeni impulsni slijed, informacije o vremenu, broj akvizicija itd. Tablica 3.1 prikazuje opis svakog formata korišten pri zapisu medicinskih slika [27].

Tablica 3.1 Opis formata medicinskih slika [27]

Format	Zaglavlje	Ekstenzija	Tip podataka
Analyze	Fiksne duljine: 348 bajtova binarnog formata	.img, .hdr	Integer, float, kompleksni broj
Nifti	Fiksne duljine: 352 bajtova binarnog formate (348 bajtova u slučaju spremanja podataka kao .img ili .hdr)	.nii	Integer, float, kompleksan broj
Minc	Proširivi binarni format	.mnc	Integer, float, kompleksan broj
Dicom	Binarni format promjenjive duljine	.dcm	Integer

Ovisno o vrsti podataka, numeričke vrijednosti piksela pohranjuju se kao cijeli brojevi ili brojevi s pomičnim zarezom koristeći minimalni broj bajtova potreban za predstavljanje vrijednosti.

Formati medicinskih slika mogu se podijeliti u dvije kategorije. Prvi su formati namijenjeni su za standardizaciju slika generiranih dijagnostičkim modalitetima kao što je Dicom. Druga kategorija je napravljena s ciljem olakšanja analize nakon obrade, kao što su Nifti, Minc i Analyze. Datoteke medicinskih slika obično se pohranjuju pomoću jedne od sljedeće dvije moguće konfiguracije. Onaj u kojem jedna datoteka sadrži i metapodatke i podatke o slici, s metapodacima pohranjenim na početku datoteke. Ovu paradigmu koriste formati datoteka Dicom, Minc i Nifti. Druga konfiguracija pohranjuje metapodatke u jednu datoteku, a slikovne podatke u drugu. Format datoteke Analyze koristi paradigmu s dvije datoteke [27].

Analyze format prije je bio standard za naknadnu obradu medicinskih slika. Dizajniran je za višedimenzionalne podatke. Moguće je u jednu datoteku pohraniti trodimenzionalne ili četverodimenzionalne podatke (četvrta dimenzija predstavlja vremenske podatke). Sastoji se od dvije binarne datoteke: slikovne datoteke s „*.img*“ nastavkom, a one sadrže voksel podatke te zaglavlje s „*.hdr*“ nastavkom koji sadrži metapodatke kao što su broj piksela u x, y i z smjeru, veličinu vokselu i tip podataka. Zaglavlje je fiksne duljine 348 bajtova i opisan je kao struktura u C programskom jeziku. Ovaj format se danas smatra zastarjelim, ali se još uvijek koristi [28].

Nifti format je nastao s namjerom iskoristi prednosti Analyze formata, ali i da riješi njegove mane. Iako format također omogućuje pohranu podataka zaglavlja i piksela u zasebne datoteke, slike se obično spremaju kao jedna „*.nii*“ datoteka, u njoj se spajaju podatci zaglavlja i piksela. Zaglavlje je duljine 348 bajtova ako se sprema „*.img*“ i „*.hdr*“ datoteka te 352 bajtova ako se pohrani kao jedna „*.nii*“ datoteka. Nifti format omogućuje način zapisa na dva načina. Prvi način, sadrži rotaciju i translaciju, koja se koristi za mapiranje koordinata vokselu. Drugi način, koristi se za spremanje 12 parametara linearne transformacije koja definira poravnanje volumena slike prema koordinatnom sustavu. Nifti format brzo je zamijenio Analyze format u medicinskoj obradi slike te je to danas najčešće korišteni format u tom području [27].

Dicom nije samo format datoteke, nego i mrežni komunikacijski protokol. Dicom standard opisuje kako formatirati i razmijeniti medicinske slike i povezane podatke unutar bolnice i izvan nje. Dicom kao format datoteke omogućio je da se podatci piksela ne mogu odvojiti od opisa medicinskog postupka koje je doveo do stvaranja same slike te to znači da se metapodatci ne

odvajaju od slike. Metapodatci i pikseli su spojeni u jednu datoteku, a zaglavlje Dicom, pored podataka o matrici slike, sadrži najcjelovitiji opis cjelokupnog postupka korištenog za generiranje slike. Zaglavlje također sadrži podatke o pacijentu kao što su ime, spol, dob, težina i visina [27, 29].

Minc sustav uključuje tri komponente: specifikaciju i format datoteke, programsku biblioteku te veliki broj alata. Minc ima proširiv dizajn te je idealan za upotrebu u većim ustanovama te za baze podataka. Zaglavlje može imati puno informacija, jedinstvene identifikatore i eksplicitnu povijest obrade. Novije verzije ovog formata podržavaju 64 bitne datoteke [30].

3.4. Konvolucijske neuronske mreže


Konvolucijske neuronske mreže slične su uobičajenim neuronskim mrežama. Sastoje se od neurona koji imaju težine i pristranost. Svaki neuron prima neke ulaze, izvodi točkasti produkt i po želji ga slijedi s nelinearnošću. Cijela mreža izražava jednu diferencijalnu funkciju ocjenjivanja i ima funkciju gubitka. Konvolucijske neuronske mreže iskorištavaju činjenicu da se ulaz sastoji od slike te su slojevi konvolucijske neuronske mreže raspoređene u tri dimenzije: širina, visina i dubina [31]. Svaki sloj u CNN-u (engl. *Convolutinal Neural Network*) primjenjuje drugačiji skup filtara, obično stotine ili tisuće njih te kombinira rezultate. Zadnji sloj CNN-a koristi ove značajke više razine za predviđanje sadržaja slike. CNN nam daje dvije ključne prednosti: lokalnu invarijantnost i kompoziciju. Koncept lokalne invarijantnosti omogućuje nam da klasificiramo sliku koja sadrži određeni objekt bez obzira gdje se taj objekt nalazi na slici. Svaki filter sastavlja lokalnu zakrpu značajki niže razine u prikaz više razine, slično onome kako možemo sastaviti skup matematičkih funkcija koji se nadovezuju na rezultat prethodnih funkcija: $f(g(x(h(x))))$. Kompozicija omogućuje mreži da nauči što više iz danih značajki [6].

Postoji mnogo vrsta slojeva koji se koriste za izgradnju konvolucijskih neuronskih mreža, ali najčešće se koristi: Konvolucijski sloj (CONV), aktivacijski sloj (ACT ili RELU), sloj sažimanja (POOL), potpuno povezani sloj (FC), sloj standardizacije vrijednosti na izlazu skrivenih slojeva (BN), sloj slučajnog izostavljanja neurona (DO). Slaganje niza ovih slojeva na specifičan način dobiva se CNN. CONV, RELU, POOL i FC su najbitniji pri definiranju arhitekture mreže [6].


3.4.1. Slojevi konvolucijskih neuronskih mreža

CONV sloj je najbitniji sloj konvolucijske neuronske mreže. CONV sloj sastoji se od skupa K filtara, gdje svaki filter ima visinu i širinu te su gotovo uvijek kvadratne. Ti filtri su mali, ali se

protežu kroz cijelu dubinu volumena. Za volumene dublje u mreži, dubina će biti broj filtera primijenjenih u prethodnom sloju. Svaki K filter možemo zamisliti kako „klizi“ po ulaznom području, izračunava množenje po elementima, zbrajanje te potom pohranjuje izlazne vrijednosti u dvodimenzionalni izlaz koji se naziva aktivacijska mapa (Slika 3.6) [6]. Nakon primjene K filtera na ulazni volumen nastale su K dvodimenzionalne aktivacijske mape. Aktivacijske mape se slažu duž dimenzije dubine tog niza kako bi se dobio konačni izlazni volumen (slika 3.7) [6,31].



Slika 3.6 Primjena K filtra na slici [6]



Slika 3.7 Slaganje K mapa u konačni izlaz [6]

Pri radu sa slikama, često je nepraktično povezati slike neurone u trenutni volumen s ostalim prijašnjim volumenima. Jednostavno postoji previše veza i previše težina, što onemogućava treniranje dubokih mreža na slikama velikih dimenzija. Umjesto toga, kada se koristi CNN, svaki neuron se poveže samo s lokalnim područjem ulaza volumena. Veličina takve regije naziva se


receptivno polje neurona. Postoje tri parametra koja kontroliraju veličinu izlaznog volumena: dubina, korak i popunjavanje nulama [6].

Dubina izlaznog volumena kontrolira broj neurona (filtra) u CONV sloju koji se spajaju na lokalno područje ulaznog volumena. Svaki filter stvara aktivacijsku mapu [6].

Na slici 3.6 prikazana je konvolucijska matrica manjom matricom kako „klizi“ kroz veliku matricu. Pri tome zaustavi se na svakoj koordinati, izvodi račun te sprema izlaz. Tako se može odabrati proizvoljan broj koraka kada će se primijeniti konvolucija na ulaznom volumenu. Najčešći broj koraka je jedan ili dva [6].

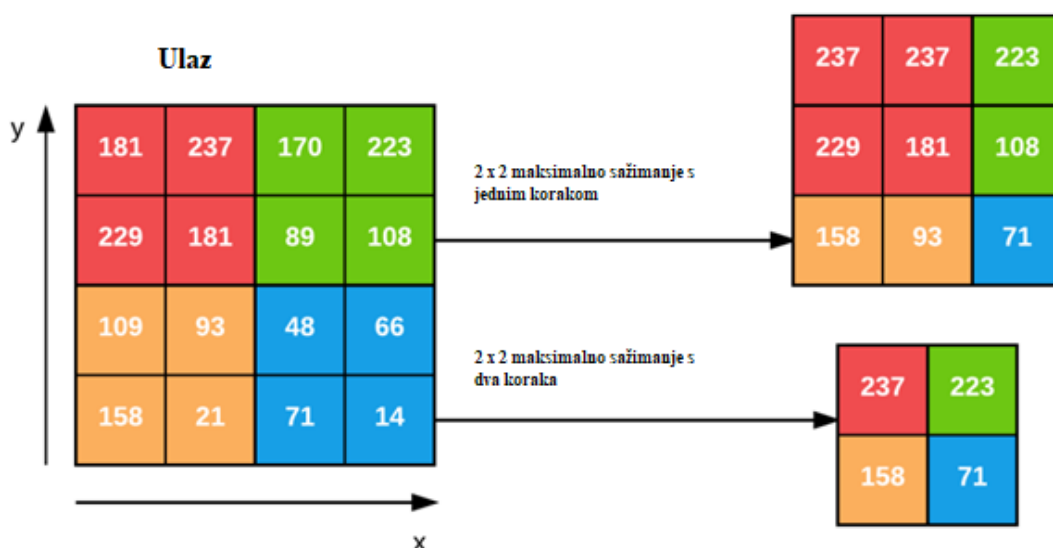
Metodom popunjavanjem ulaza s nulama duž granice slike daje mogućnost izjednačavanja dimenzije ulaza i izlaza. Ova metoda postaje bitna kada se krenu slagati više CONV slojeva jedna na drugu [6].

Nakon svakog CONV sloja, primjenjuje se nelinearna aktivacijska funkcija: ispravljena linearna jedinica (engl. *Rectified Linear Activation Function*, ReLU) i eksponencijalna linearna jedinica (engl. *Exponential Linear Unit*, ELU) ili neke druge varijante tih dviju. Aktivacijske funkcije se koriste za određivanje izlaza iz prethodnog sloja. Najčešće se koristi ReLU aktivacijska funkcija [32]. Kao što je prikazano na slici 3.8 a), kada je y manji od nule, onda je $f(y)$ jednak nuli, a kada je y jednak nuli ili veći od nule, $f(y)$ je jednak y . Problem kod ovakve ReLU funkcije je to što sve negativne vrijednosti odmah postaju nula, što smanjuje sposobnost modela da se pravilno prilagodi skupu podataka. Zbog tog razloga sve češće se koristi takozvani *Leaky ReLU* (Slika 3.8 b)) koji omogućava korištenje negativnih vrijednosti. Aktivacijski sloj prima ulazni volumen dimenzija W (širina) \times H (visina) \times D (dubina) i primjenjuje aktivacijsku funkciju. Izlaz iz aktivacijskog sloja je iste dimenzije kao ulaz [6, 31].



Slika 3.8 ReLU i Leaky ReLU [31]

Sloj sažimanja (engl. *Pooling layer*, POOL) često se uvodi između konvolucijskih slojeva. Primarna funkcija POOL sloja je postupno smanjenje dimenzija ulaznog volumena. To omogućuje smanjenje količine parametara i računanja u mreži, također pomaže pri kontroli prekomjerne prilagodbe mreže. POOL slojevi koriste maksimalnu ili prosječnu funkciju. Maksimalno sažimanje obično se provode usred CNN arhitekture kako bi se smanjila prostorna veličina, dok se prosječno sažimanje koristi kao završni sloj mreže. Najčešće se koristi maksimalno sažimanje te je veličina sažimanja većinom dimenzija 2 x 2, ali pri većim slikama koristi se i 3 x 3 [6]. Slika 3.9 prikazuje korištenje maksimalnog sažimanja. Gornja matrica ima korak veličine 1, a donja korak veličine 2.




Slika 3.9 Prikaz izlaza nakon POOL sloja [6]

Neuroni u potpuno povezanim slojevima (engl. *Fully-Connected*, FC) povezani su sa svim aktivacijama u prethodnom sloju. FC slojevi su uvijek postavljeni na kraju mreže. Uobičajeno je koristiti jedan ili dva FC sloja prije primjene klasifikatora [6].

Normalizacija serije (engl. *Batch Normalization*, BN) sloj koristi se za normalizaciju aktivacija ulaznog volumena prije nego što se preda idućem sloju u mreži. Pokazalo se da je BN izuzetno učinkovita u smanjenju broja epoha potrebno za treniranje neuronske mreže. Normalizacije serije


također ima dodatnu prednost pri pomaganju „stabiliziranja“ treninga. Omogućuje korištenje većeg raspona stope učenja [6].

Sloj slučajnog izostavljanja neurona (engl. *Dropout*, DO) će za svaku mini seriju u skupu treninga nasumično raskinuti veze ulaza s prethodnog na sljedeći sloj u mreži. Slika 3.10 prikazuje kako izgleda mreža nakon korištenja DO sloja kad se nasumično raskinu veze s vjerojatnošću od 50 posto. DO sloj se koristi radi sprječavanja prekomjerne prilagodbe mreže [6].



Slika 3.10 DO sloj s vjerojatnošću od 50 posto [6]

Slika 3.11 prikazuje kako bi izgledala arhitektura konvolucijske neuronske mreže nakon povezivanja najbitnijih slojeva.




Slika 3.11 Arhitektura konvolucijske neuronske mreže [33]

3.5. Semantička segmentacija medicinskih slika pomoću konvolucijskih neuronskih mreža

Semantička segmentacija je poprilično nova biomedicinska tehnologija obrade slike, ali je već dala veliki doprinos održivoj medicinskoj skrbi. S brzim razvojem dubokog učenja, medicinska obrada slike temeljena na konvolucijskim neuronskim mrežama postala je žarište istraživanja. Unatoč velikim dostignućima segmentacije u području obrade medicinskih slika temeljenu na dubokom učenju, još uvijek postoje poteškoće pri istraživanju. Na primjer, točnost segmentacije nije prevelika, broj medicinskih slika u skupu podataka je mali, a razlučivost niska. Netočni rezultati segmentacije nisu u stanju ispuniti stvarne kliničke zahtjeve. Zbog toga se pokušavaju unaprijediti trenutna rješenja segmentacije pomoću konvolucijskih neuronskih mreža [34].

Prilikom izvođenja operacija segmentacije slike, konvolucijske neuronske mreže imaju izvrsne mogućnosti izdvajanja značajki i dobre mogućnosti izražavanja značajki. Ne zahtijevaju ručno izdvajanje značajki slike ili pretjeranu obradu slika. Stoga se CNN koristi u medicinskoj segmentaciji slika. Trenutno popularni algoritmi za semantičku segmentaciju medicinskih slika osim U-neta su : SegNet, PSPNet, DeepLab [34,35].

Za opću klasifikaciju CNN mreža, poput VGG i ResNet, na kraj mreže dodaju se potpuno povezani slojevi. Informacije o vjerojatnosti kategorije mogu se dobiti nakon *softmax* sloja, ali ove su informacije o vjerojatnosti jednodimenzionalne. Odnosno, može se identificirati samo kategorija cijele slike, a ne kategorija svakog piksela. Dakle, ova potpuno povezana metoda nije prikladna za segmentaciju slike. Za rješenje tog problema koristi se FCN. U uobičajenoj CNN strukturi, prvih pet slojeva su konvolucijski slojevi. Šesti i sedmi sloj su potpuno povezani slojevi duljine 4096 (jednodimenzionalni vektor). Osmi sloj je potpuno povezani sloj duljine 1000, koji odgovara vjerojatnosti od 1000 kategorija. FCN mijenja zadnja tri sloja u konvolucijske slojeve čiji su filtri konvolucije dimenzija 7×7 , 1×1 i 1×1 . Tako će se dobiti dvodimenzionalna mapa značajki svakog piksela. Zatim slijedi *softmax* sloj za dobivanje klasifikacijskih informacija svakog piksela. Ovakvim načinom riješen je problem segmentacije. Potpuno konvolucionalna mreža može prihvatiti ulazne slike bilo koje veličine. FCN koristi dekonvolucijski sloj za vraćanje slike na istu veličinu kakva je bila na ulazu. Dakle, predviđanje se može generirati za svaki piksel, zadržavajući originalnu dimenziju slike. Na kraju se vrši klasifikacija po pikselima na uzorkovanoj mapi značajki za dovršetak konačne segmentacije slike [34]. Slika 3.12 prikazuje strukturu FCN-a.




Slika 3.12 FCN [32]

DeepLab v1 se temelji na VGG-16 mreži, uklanjajući posljednji potpuno povezani sloj VGG mreže i umjesto toga koristi potpunu konvoluciju, jer će upotreba previše slojeva za sažimanje rezultirati premalom veličinom sloja značajki. Sadržane značajke su previše rijetke, što nije pogodno za semantičku segmentaciju. DeepLab v1 koristi atroznu konvoluciju. U usporedbi s tradicionalnom konvolucijom, receptivno polje može se proširiti bez povećanja količine izračuna i gustoća značajki može se povećati. Konačno, DeepLab v1 koristi uvjetno slučajno polje da poboljša točnost granica segmentacije. DeepLab v2 je poboljšanje temeljeno na DeepLab v1. DeepLab v2 riješio je problem segmentacije uzrokovane razlikom iste skale objekta u istoj slici. DeepLab v3 koristi ResNet-101 arhitekturu. Cilj mu je da riješi problem multiskalne segmentacije te je zato dizajniran kaskadni ili paralelni atrozni konvolucijski modul. DeepLab v3+ proširuje se na DeepLab v3. Dodan je jednostavan modul dekodera za pročišćavanje rezultata segmentacije, pogotovo za segmentacije na rubovima objekta [34].

SegNet ima simetričnu strukturu koder-dekoder na temelju semantičke segmentacije FCN-a za postizanje segmentacije slike na razini piksela. Mreža se uglavnom sastoji od koder i dekodera. Koder je mrežni model koji koristi VGG-16, većinom za analizu podataka o objektu. Dekoder pretvara parsiranu informaciju u konačni oblik slike, odnosno svaki piksel je predstavljen bojom ili oznakom koja odgovara informaciji objekta. Dekoder koristi veliki indeks sažimanja koji se prenosi koderu da nelinearno uzima uzorke svojih unosa, tako za uzimanje uzoraka nije potrebno

učenje. Zatim se koristi konvolucijski filter koji se može trenirati te on stvara gustu mapu značajki. Kad se mapa značajki vrati u izvorni oblik, one se šalju *softmax* klasifikatoru za klasifikaciju piksela [34].

PSPNet je semantički model segmentacije koji koristi ResNet-101 kao sloj za ekstrakciju značajki i uvodi modul piramidalnog sažimanja kako bi identificirao prethodne informaciju o slici [35]. Slika 3.13 prikazuje arhitekturu PSPNet-a. Arhitektura koristi piramidu od 4 razine, svaka razina koristi konvoluciju te one pokrivaju cijelu, polovicu i manje dijelove slike. Te konvolucije su povezane te će se one na kraju spojiti s početnom mapom značajki.




Slika 3.13 PSPNet arhitektura [36]

4. RAZVIJENI SUSTAV ZA SEGMENTACIJU

Kao što je opisano u prijašnjem poglavlju, za segmentaciju medicinskih slika koriste se konvolucijske neuronske mreže. U-Net konvolucijska neuronska mreža pokazala je izuzetne rezultate u ovom području te se ona najčešće koristi. Često se nad podacima prije treniranja provodi predobrada. Predobrada podataka može uključivati razne metode obrade slike, filtriranje podataka, kategoriziranje podataka i još mnogo drugih. Ovo poglavlje opisuje kakva se predobrada izvela nad podacima te opisuje U-net konvolucijsku neuronsku mrežu.

4.1. Skup podataka

Skup podataka korišten u ovom diplomskom radu predstavlja slike magnetske rezonancije srčanih komora. Skup podataka sadrži 20 slika srčanih komora u Nifti formatu te isto toliko oznaka koji su također u Nifti formatu. Oznake su maske za svaku sliku te su one zapravo anotirane slike koje označavaju točnu poziciju srčanih komora s slika magnetske rezonance. Na slici 4.1 prikazana je slika magnetske rezonancije pomoću ITK-SNAP alata [37, 38]. ITK-SNAP omogućuje rad s slikama magnetske rezonancije. Slika 4.1 prikazuje pomoću oznake točnu poziciju srca.




Slika 4.1 Slika magnetske rezonancije pomoću ITK-SNAP alata [37, 38]

4.2. Predobrada podataka

Kako bi se omogućilo treniranje 2D CNN-a, slike su iz Nifti formata pretvorene u poznatije formate s ".png" ili ".jpeg" ekstenzijom.. Nifti format sprema slike magnetske rezonancije u tri prostorne dimenzije x , y i z i četvrtu dimenziju t koja predstavljanja vrijeme (Slika 4.1). Prilikom konverzije slike u drugi format, slike će prolaziti kroz svaku od tih prostornih dimenzija i spremi sve slike koje se čine x , y i z dimenziju. Isti taj postupak rađen je i nad oznakama. Tako su sada slike spremljene u formatu koji je prikladniji za treniranje.

Naravno, spremljeno je puno slika i postoje slike koje nemaju nikakvu anotaciju, tj. postoje slike magnetske rezonancije iz x , y i z dimenzije gdje srce nije uopće vidljivo. Takve slike se potom izbacuju te one nisu potrebne pri treniranju mreže.

Nakon toga slike se dijele na validacijski skup i trening skup. 75 posto slika spada u trening skup dok 25 posto slika je odvojeno za validaciju mreže. Slike u x i y dimenziji se treniraju zajedno, zasebno od z dimenzije koji se trenira posebno jer je razlika u dimenziji slika između x , y i z dimenzije pre značajan i nije moguće odrediti zadovoljavajuću rezoluciju koja odgovara za svaku prostornu dimenziju, tako će se pri usporedbi rezultata uspoređivati mreže nastale treniranjem slika iz x i y dimenzije te mreže nastala treniranjem slika iz z dimenzije. Slika 4.2 prikazuje kako izgledaju slike magnetske rezonancije iz svake prostorne dimenzije zajedno s njihovom oznakom.



Slika 4.2 MRI slike s pripadajućom oznakom

Prije treniranja slike se još postave na određenu rezoluciju jer sve slike moraju biti istih dimenzija prilikom treniranja te se slike pretvore u jednobojne slike. Metoda za predobradu koja se koristi u ovom radu prije treniranja slika je Bayesova metoda za uklanjanje šuma..

4.2.1. Bayesova metoda uklanjanja šuma

Bayesova metoda za uklanjanje šuma bazirana na temelju Bayesovog klasifikatora. Naivni Bayesov klasifikator je probalistički model koji se koristi za klasificiranje podataka. Bayesov klasifikator je baziran na Bayesovom teoremu koji je dan formulom 4-1:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (4-1)$$

Formula 4-1 predstavlja Bayesov teorem. Teorem prikazuje kako se pronalazi vjerojatnost događaja A, s obzirom na događaj B. Ovdje je B dokaz, a A hipoteza [39].

Pojava šuma čest je problem pri snimanju slika magnetske rezonance. Fahmy [40] je opisao vjerojatnosni model za signale krvi i tkiva te za to koristi Bayesov klasifikator. Klasifikator se koristi za prepoznavanje i filtriranje pozadinskog signala te s time se može ukloniti pozadinski šum s slike.

$$d(\bar{v}) = \log(f_{S_1, S_2}(S_1, S_2 | tkivo)) - \log(f_{S_1, S_2}(S_1, S_2 | pozadina)) \quad (4-2)$$

Formula 4-2 [40] prikazuje korišteni vjerojatnosni model dobiven na temelju Bayesovog klasifikatora. S_1 i S_2 predstavljaju dobivene slike u obliku vektora, a njih možemo klasificirati u dvije klase: pozadina ili tkivo. Probabilistički model funkcionira na takav način da će za svaki piksel izračunati vjerojatnost događaja je li taj piksel pozadina ili tkivo te će se tako smanjiti šum na slici jer će se šum klasificiranjem kao pozadina ukloniti s slike [40]. Daljnjim raspisivanjem formule 4-2 dobiva se formula 4-3 [40]:

$$d(\bar{v}) = \log\left(I_o\left(\frac{\hat{p}(x,y)\text{sinc}(\partial\hat{\omega})S_1}{\sigma^2}\right)\right) + \log\left(I_o\left(\frac{\hat{p}(x,y)\text{sinc}(1-\partial\hat{\omega})S_2}{\sigma^2}\right)\right) - \quad (4-3)$$

$$\hat{p}(x,y) \frac{\text{sinc}(\partial\hat{\omega})^2 + \text{sinc}(1-\partial\hat{\omega})^2}{2\sigma^2}$$

Jednadžba 4-3 dat će konačni vjerojatnosni iznos za pojedini piksel. Ako je vrijednost $d(\bar{v})$ veća od nule piksel se klasificira kao tkivo, ako je manja od nule klasificira se kao pozadina. I_o

predstavlja nultu vrijednost modificirane Besselove funkcije prvog reda, $\hat{p}(x, y)$ je trenutno promatrani piksel, $\partial\hat{w}$ predstavlja deformaciju na tkivu, σ predstavlja standardnu devijaciju šuma [40].

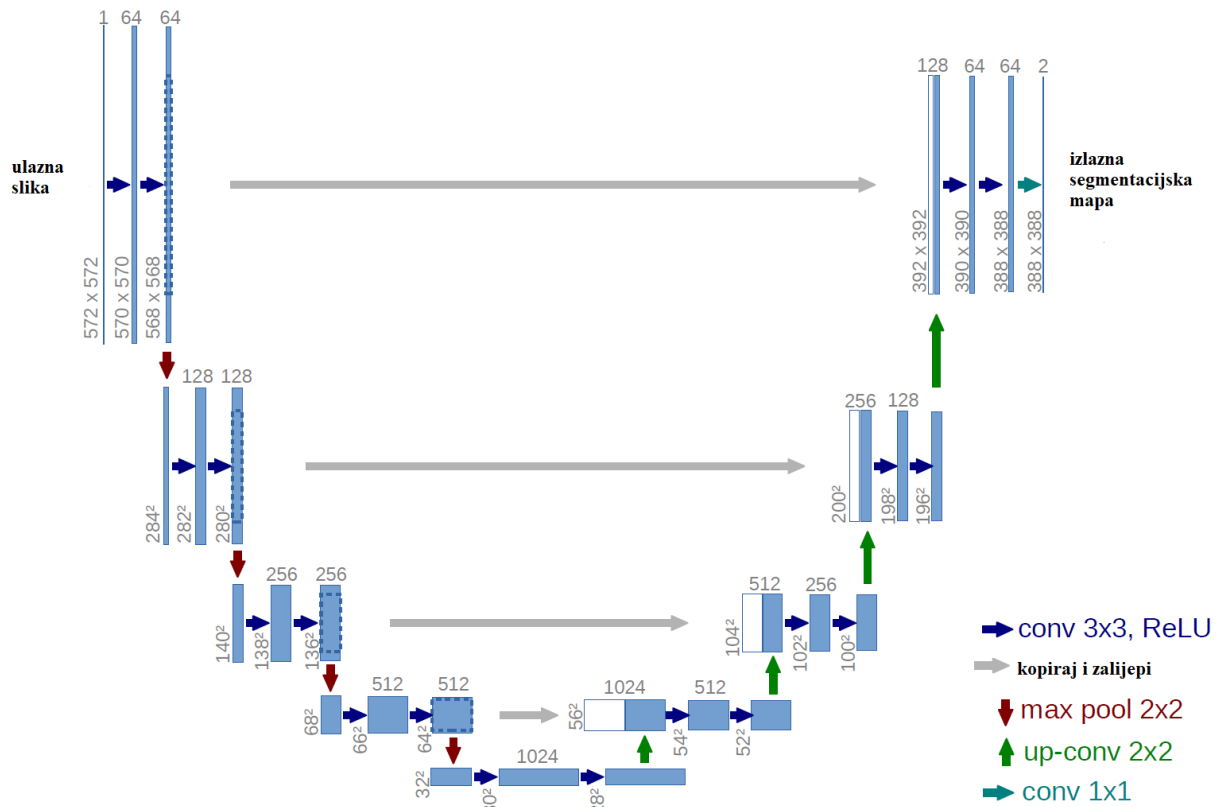
4.3. U-Net arhitektura neuronske mreže

U-net je izvorno izumljen i prvi put korišten za biomedicinsku segmentaciju slike. Arhitektura U-net mreže prikazana je na slici 4.3. Na prvi pogled ima oblik slova „U“. Arhitektura je simetrična i sastoji se od dva glavna dijela: lijevi dio, naziva se kontrakcijskim putem, koji provodi konvolucijski proces te od desnog dijela (ekspanzivni put), kojeg čine transponirani dvodimenzionalni konvolucijski slojevi [41].

Kontracijski put stalno ponavlja dvostruku konvoluciju dimenzije 3×3 koja će stalno povećavati dubinu slike. Potom se provodi sloj maksimalnog sažimanja dimenzije 2×2 te će on prepoloviti dimenziju slike. Taj se proces ponavlja 3 puta dok se ne dođe do dna gdje se provode 2 konvolucijska sloja, ali bez sloja sažimanja [42].


Ekspanzivni put će sliku vratiti nazad u originalnu dimenziju. To se postiže pomoću transponirane konvolucije. Transponirana konvolucija tehnika je povećanja uzorka koja proširuje veličinu slika. Transponirani konvolucijski slojevi su dimenzije 2×2 . Nakon transponirane konvolucije, slika se spaja s odgovarajućom slikom iz kontrakcijskog puta te se to radi za postizanje preciznije segmentacije. Ovaj proces se također ponavlja 3 puta [42].

Na samom vrhu provodi se konvolucijski sloj s veličinom filtra 1×1 te se mijenja dimenzija slike da zadovolji zahtjeve predviđanja.



Slika 4.3 Arhitektura U-net mreže [41]

Slika 4.4 prikazuje blok dijagram provođenja cijelog procesa predobrade i treniranja.




Slika 4.4 Blok dijagram predobrade podataka i treniranje mreže

5. DOBIVENI REZULTATI


Tijekom treniranja mreže koriste se određene mjere pomoću kojih se zaključuje je li model ima dobre ili loše performanse. Cilj ovoga poglavlja je prikazati rezultate predobrade podataka, usporediti rezultate segmentacije sa i bez predobrade podataka te evaluacija rezultata segmentacije.

5.1. Rezultati predobrade podataka

U prethodnom poglavlju opisana je Bayesova metoda uklanjanja šuma. Pomoću te metode radi se predobrada podataka prije treniranja konvolucijske neuronske mreže. Slika 5.1 i slika 5.2 prikazuje rezultate nakon predobrade iz svake prostorne dimenzije. Srce je na slikama 5.1 i 5.2 izraženije nakon predobrade te se šum smanjio. Šum nije u potpunosti uklonjen jer bi sa prejakom predobradom oblik srca također uklonio.



Slika 5.1 a) MRI slike b) Rezultati predobrade MRI slike c) Originalne maske




Slika 5.2 a) MRI slike b) Rezultati predobrade MRI slike c) Originalne maske

5.2. Usporedba rezultata segmentacije sa i bez preobrade podataka

U-net konvolucijska neuronska mreže trenirana je i na podacima bez korištenja Bayesove metode uklanjanja šuma. Slika 5.3 i slika 5.4 prikazuju rezultate segmentacije sa i bez preobradbe.



Slika 5.3 a) Segmentacija bez preobrade podataka b) Segmentacija sa preobradom podataka c) Originalne maske



Slika 5.4 a) Segmentacija bez predobrade podataka b) Segmentacija sa predobradom podataka c) Originalne maske

Sa slika je vidljivo da je predobrada podataka imala utjecaj na konačni rezultat segmentacije. Slike dobivene predobradom imaju oblik sličan originalnoj maski. Iako rezultati dobiveni bez predobrade ne daju loše rezultate, vidljivo je da pronalazak piksela manje precizan.


5.3. Evaluacija rezultata segmentacije

Tijekom treniranja i nakon treniranja mreže koriste se razne mjere za evaluaciju rezultata. Za modele koji koriste semantičku segmentaciju rezultati se vrednuju pomoću mjerenja: IoU(engl. *Intersection over Union*), preciznosti piksela ili dice koeficijent (engl. *dice score*) [43].

Preciznost piksela predstavlja postotak točno klasificiranih piksela. Ova mjera zna biti zavarujuća kada je zastupljenost klasa na slici mala, jer će mjera biti pristrana uglavnom o tome koliko dobro prepoznaje slučajeva gdje klasa nije prisutna [43].


IoU, također poznat i kao Jaccardov indeks, jedna je od najčešće korištenih metrika u semantičkoj segmentaciji. IoU metrika je vrlo izravna i izuzetno učinkovita. IoU predstavlja omjer područja preklapanja između predviđene segmentacije i referentnog podatka s područjem unije

između predviđene segmentacije i referentnog podatka (slika 5.5). Vrijednosti se kreću od nula do jedan (0% - 100%), pri čemu nula znači da nema preklapanja i 1 koja označava savršeno preklapajuću segmentaciju [43].



Slika 5.5 Vizualizacija računa IoU [44]


Dice koeficijent je 2 x područje preklapanja podijeljeno s ukupnim brojem piksela na obje slike (slika 5.6) [43].



Slika 5.6 Vizualizacija računa dice koeficijenta [43]

Još jedna bitna mjera pri treniranju mreže predstavlja funkcija gubitaka. Funkcija gubitaka kvantificira koliko se dobro referentne oznake slažu s predviđenom oznakom klase. Što je razina slaganja veća, gubitak je sve manji te je to i pokazatelj da je veća točnost klasifikacije [6].

Za evaluaciju rezultata korišten je dice koeficijent i funkcija gubitaka. Evaluacija je rađena na 4 modela. Mreže su bile trenirane na slikama iz x,y prostorne dimenzije sa i bez predobrade te na slikama iz z prostorne dimenzije sa i bez predobrade podataka. Slika 5.7 prikazuje grafove funkcije gubitaka. Slika 5.7 a) prikazuje funkcije gubitaka prije predobrade podataka, gornji graf je iz x,y prostornih dimenzija, donji graf je iz z prostorne dimenzije. Grafovi iz slike 5.7 b) koristili su predobradu podataka. Vidljivo je sa slike da nema prevelike razlike u funkciji gubitaka između modela dobiveni slikama iz x, y prostornih dimenzija, ali je vidljivo da se gubitak postepeno smanjuje te je to pokazatelj da mreža treba imati visoku točnost klasifikacije. Kod slika iz z prostorne dimenzije, slike s predobradom imaju manji gubitak nego slike bez predobrade. Stopa učenja pri treniranju iznosi 0.0001. Stopa učenja kontrolira koliko se brzo model prilagođava skupu podataka.




Slika 5.7 a) Funkcija gubitaka za modele bez predobrade podataka b) Funkcija gubitaka za modele sa predobradom podataka

Funkcije gubitaka pokazuju zadovoljavajuće rezultate za slučajeve sa i bez predobrade podataka. Najveća razlika vidljiva je na vrijednosti dice koeficijenta. Dice koeficijent za slike iz x,y prostornih dimenzija bez predobrade iznosi 87.14 posto, dok kod podataka sa predobradom, dice koeficijent iznosi 88.89 posto. Slike iz z prostorne dimenzije bez predobrade imaju dice koeficijent od 86.59 posto, a sa predobradom ona iznosi 88.74 posto.

Iako se naizgled ta razlika u postotcima ne čini prevelika, veći dice koeficijent u takvim razlikama daje do znanja da je segmentacija preciznija. Ti rezultati su i vidljivi na slikama u prethodnom poglavlju (slika 5.3 i slika 5.4). Uklanjanjem nepotrebnog šuma i pozadine stvaraju se slike gdje je vidljiviji oblik srca te je to utjecalo na konačne rezultate dice koeficijenta.

U globalu predobrada podataka je pomogla i segmentacija je većinom preciznija, ali postoje i slučajevi kada predobrada nije dala učinkovite rezultate. Primjer je dan na slici 5.8, gdje je vidljivo da zbog pre jake predobrade, model nije uspješno segmentirao sliku. Standardna devijacija šuma σ utječe na jačinu predobrade podataka. Pošto se ista vrijednost standardne devijacije primjenjuje na sve slike u skupu podataka, postojat će slučajevi gdje će ta vrijednost biti prevelika te će se zbog toga izgubiti oblik srca na slici.



Slika 5.8 a) Segmentacija bez predobrade podataka b) Segmentacija sa predobradom podataka c) Originalna maska

Bayesova metoda uklanjanja šuma prikazala se kao uspješna metoda obrade slike. Postoji mogućnost da zbog prejake ili premale standardne devijacije šuma neće uvijek uspješno dati zadovoljavajuće rezultate. Rezultati su pokazali da se s Bayesovom metodom uklanjanja šuma dobiva veći dice koeficijent te je funkcija gubitka manja. Moguće je da bi se metoda unaprijedila

pronalaženjem idealne vrijednosti standardne devijacije šuma te bi onda i model mreže davao preciznije segmentacije. Na rezultate bi utjecao i veći skup podataka s još anotiranih slika. Daljnje unaprjeđenje rezultata dobilo bi se i korištenjem varijacija U-net konvolucijske neuronske mreže.

6. ZAKLJUČAK

Metode dubokog učenja sve su prisutnije u raznim područjima znanosti. Tako je segmentacija jedna od tih metoda koja se krenula razvijati pa tako i u području medicinske obrade slike. Medicinska obrada slike brzo napreduje te primjenjuje specifične konvolucijske neuronske mreže nad slikama magnetske rezonancije (engl. *Magnetic Resonance Image*, MRI) i nad slikama računalne tomografije (engl. *Computed Tomography*, CT). PSPNet, SegNet i DeppLab koriste za segmentaciju MRI slika, ali izuzetne rezultate postigla je U-net konvolucijska neuronska mreža. Uz korištenje konvolucijskih neuronskih mreža, koriste se i razne metode obrade slike. Kroz ovaj rad korištena je Bayesova metoda za uklanjanje šuma i vidljivo je iz dobivenih rezultata da odvaja najbitnije dijelove slike od pozadine. Vjerojatnosni Model je napravljen da razaznaje tkivo od pozadinskog signala. Ovakva predobrada podataka donijela je zadovoljavajuće rezultate, ali treba uzeti u obzir da zbog jednolike standardne devijacije šuma rezultati nisu uvijek zadovoljavajući te segmentacija ponekad ne pronađe točno svaki piksel. U konačnici, sa Bayesovom metodom uklanjanja šuma dobile su se slike na kojima se trenirala U-net konvolucijska neuronska mreža te su se tako postigle niske vrijednosti funkcije gubitaka i visok dice koeficijent što pokazuje da je točnost segmentacije visoka.

ZAHVALE

Ovaj je rad sufinancirala Hrvatska zaklada za znanost projektom UIP-2017-05-4968.

LITERATURA

- [1] How to do Semantic Segmentation using Deep learning, [How to do Semantic Segmentation using Deep learning \(nanonets.com\)](#), Datum pristupa linku 7.6.2021
- [2] Image Segmentation, [segmentation.dvi \(toronto.edu\)](#), Datum pristupa linku 7.6.2021.
- [3] [Research in Medical Imaging Using Image Processing Techniques | IntechOpen](#), Datum pristupa linku 7.6.2021.
- [4] Medical Image Processing, [What is Medical Image Processing | Synopsys](#), Datum pristupa linku 7.6.2021.
- [5] MRI scan, [MRI scan - NHS \(www.nhs.uk\)](#), Datum pristupa linku 7.6.2021.
- [6] Deep Learning for Computer Vision with Python, Dr. Adrian Rosebrock, 2017, PyImageSearch.com
- [7] U-net, [U-Net: Image Segmentation Network \(neurohive.io\)](#), Datum pristupa linku 8.6.2021.
- [8] A fully automatic cardiac segmentation method using region growing technique, Jörg Sander, Bob D. deVos, Ivana Išgum
- [9] Cardiac MR Image Segmentation Techniques: an overview, Tizita Nesibu Shewaye
- [10] Payer, C., D. Štern, H. Bischof, and M. Urschler. Multilabel whole heart segmentation using cnns and anatomical label configurations. In: Statistical Atlases and Computational Models of the Heart. ACDC and MMWHS Challenges, edited by M. Pop, M. Sermesant, P. M. Jodoin, A. Lalande, X. Zhuang, G. Yang, A. Young, and O. Bernard. Cham: Springer, 2018, pp. 190–198
- [11] Wang, C., and O. Smedby. Automatic whole heart segmentation using deep learning and shape context. In: Statistical Atlases and Computational Models of the Heart. ACDC and MMWHS Challenges, edited by M. Pop, M. Sermesant, P. M. Jodoin, A. Lalande, X. Zhuang, G. Yang, A. Young, and O. Bernard. Cham: Springer, 2018, pp. 242–249
- [12] Bai W, Suzuki H, Qin C, Tarroni G, Oktay O, Matthews PM, et al. Recurrent neural networks for aortic image sequence segmentation with sparse annotations. In: Frangi AF, Schnabel JA, Davatzikos C, Alberola-López C, Fichtinger G, editors. 21st International Conference on Medical

Image Computing and Computer Assisted Intervention—MICCAI, 2018. Granada: Springer International Publishing (2018). p. 586–94.

[13] Deep Learning for Cardiac Image Segmentation: A Review, Chen Chen, Chen Qin, Huaqi Qui, Giacomo Tarroni, Jinming Duan, Wenjia Bai, Daniel Rueckert

[14] Overview of the Whole Heart and Heart Chamber Segmentation Methods, Marija Habijan, Danilo Babin, Irena Galić, Hrvoje Leventić, Krešimir Romić, Lazar Velicki, Aleksandra Pižurica

[15] Segmentacija aorte, [Automatic aorta segmentation on a few example volumes. \(a\) Good... | Download Scientific Diagram \(researchgate.net\)](#), Datum pristupa linku: 8.6.2021.

[16] A fully automatic cardiac segmentation method using region growing technique, Abdelaziz Daoudi, Said Mahmoudi

[17] Canterbury District Health Board, Cardiology, Self learning package. Module 1: Anatomy and Physiology of the Heart

[18] Prikaz protoka krvi kroz srce, [Heart labelled large prevedeno.PNG \(530×526\) \(wikimedia.org\)](#), Datum pristupa linku: 9.6.2021.

[19] Opis komora srca, [KOMORA SRCA - STRUKTURA, FUNKCIJA I BOLESTI - ANATOMIJA \(healthandmedicineinfo.com\)](#), Datum pristupa linku: 9.6.2021.

[20] Cirkulatorni sistem srca, [Anatomija i fiziologija srca – Kardiologija](#), Datum pristupa linku: 9.6.2021.

[21] Srčana komora, [CG Heart - Srčana komora - Wikipedia](#), Datum pristupa linku: 9.6.2021.

[22] MRI, [Magnetic Resonance Imaging \(MRI\) \(nih.gov\)](#), Datum pristupa linku: 9.6.2021.

[23] MRI, [Što je magnetska rezonancija? - Specijalna bolnica Akromion](#), Datum pristupa linku: 9.6.2021.

[24] MRI uređaj, [Cardiac MRI Becoming More Widely Available Thanks to AI and Reduced Exam Times | DAIC \(dicardiology.com\)](#), Datum pristupa linku: 9.6.2021.

- [25] MRI BASIC PRINCIPLES AND APPLICATIONS THIRD EDITION, Mark A. Brown, Richard C. Semelka,
- [26] Fizika magnetske rezonance [Kako funkcionira MRI \(uređaji za magnetsku rezonanciju\)? - Znanost Blog](#), Datum pristupa linku: 9.6.2021.
- [27] Medical Image File Formats, Michele Larobina, Loredana Murino
- [28] Robb RA, Hanson DP, Karwoski RA, Larson AG, Workman EL, Stacy MC. Analyze: a comprehensive, operator-interactive software package for multidimensional medical image display and analysis. *Comput Med Imaging Graph.* 1989;13(6):433–54. doi: 10.1016/0895-6111(89)90285-1.
- [29] Bidgood WD, Jr, Horii SC, Prior FW, Van Syckle DE. Understanding and using DICOM, the data interchange standard for biomedical imaging. *J Am Med Inform Assoc.* 1997;4(3):199–212. doi: 10.1136/jamia.1997.0040199
- [30] MINC 2.0: A Flexible Format for Multi-Modal Images, Robert D. Vincent, Peter Neelin, Najmeh Khalili-Mahani, Andrew L. Janke, Vladimir S. Fonov, Steven M. Robbins, Leila Baghdadi, Jason Lerch, John G. Sled, 4,5 Reza Adalat, David MacDonald, Alex P. Zijdenbos, D. Louis Collins. Alan C. Evans
- [31] Convolutional Neural Networks, [CS231n Convolutional Neural Networks for Visual Recognition](#), Datum pristupa linku: 13.6.2021.
- [32] ReLU, [Activation Functions in Neural Networks | by SAGAR SHARMA | Towards Data Science](#), Datum pristupa linku: 14.6.2021.
- [33] Arhitektura CNN-a [An example of CNN architecture. | Download Scientific Diagram \(researchgate.net\)](#), Datum pristupa linku: 14.6.2021.
- [34] A Review of Deep-Learning-Based Medical Image Segmentation Methods, Xiangbin Liu, Liping Song, Shuai Liu and Yudong Zhang
- [35] Artificial Convolutional Neural Network in Object Detection and Semantic Segmentation for Medical Imaging Analysis, Ruixin Yang, Yingyan Yu
- [36] [How PSPNet works? | ArcGIS for Developers](#), Datum pristupa linku: 14.6.2021.

[37] Paul A. Yushkevich, Joseph Piven, Heather Cody Hazlett, Rachel Gimpel Smith, Sean Ho, James C. Gee, and Guido Gerig. User-guided 3D active contour segmentation of anatomical structures: Significantly improved efficiency and reliability. *Neuroimage* 2006 Jul 1;31(3):1116-28

[38] <http://www.itksnap.org/>, Datum pristupa linku: 16.6.2021

[39] Bayes Classifier, [Naive Bayes Classifier. What is a classifier? | by Rohith Gandhi | Towards Data Science](#), Datum pristupa linku: 20.6.2021.

[40] Background Noise Removal in Cardiac Magnetic Resonance Images Using Bayes Classifier, Ahmed S. Fahmy

[41] U-Net: Convolutional Networks for Biomedical Image Segmentation, Olaf Ronneberger, Philipp Fischer, and Thomas Brox

[42] Arhitektura U-net mreže, [UNet — Line by Line Explanation. Example UNet Implementation | by Jeremy Zhang | Towards Data Science](#), Datum pristupa linku: 20.6.2021.

[43] Metrike za vrednovanje semantičkih modela, [Metrics to Evaluate your Semantic Segmentation Model | by Ekin Tiu | Towards Data Science](#), Datum pristupa linku: 24.6.2021.

[44] IoU prikaz, [Intersection over Union - visual equation - Jaccard index - Wikipedia](#), Datum pristupa linku: 24.6.2021.

SAŽETAK

U ovom diplomskom radu, predstavljen je sustav za segmentaciju 2D MRI (engl. *Magnetic Resonance Image*) slika srčanih komora. Za segmentaciju korištena je U-net konvolucijska neuronska mreža. Kroz rad dana je klinička pozadina o strukturi srca i fizikalna pozadina rada uređaja magnetske rezonancije. Opisani su formati zapisa slika magnetske rezonancije i način rada konvolucijskih neuronskih mreža. Sustav primjenjuje posebnu metodu obrade slike temeljena na Bayesovom teoremu. Evaluacija rezultata uspoređuje rezultate segmentacije sa i bez predobrade podataka. Provedena evaluacija postiže bolje rezultate sa predobradom podataka, ali postoje slučajevi kada zbog prejake predobrade podataka, rezultati nisu uvijek zadovoljavajući.

Ključne riječi: Segmentacija, MRI, U-net, Bayesov teorem, Srce

ABSTRACT

Title: Segmentation of heart chambers from 2D MRI images using U-net convolutional neural network

In this thesis, a system for segmentation of 2D MRI images of heart chambers is presented. The U-net convolutional neural network was used for the segmentation process. The clinical background on the structure of the heart and the physical background of the operation of MRI device were given throughout the work. Magnetic resonance image recording formats and convolutional neural networks are described. The system applies a special image processing method based on Bayes' theorem. Results evaluation compares segmentation results with and without data preprocessing. The conducted evaluation achieves better results with data preprocessing, but there are cases when due to too strong data pre-processing, the results are not always satisfactory.

Keywords: Segmentation, MRI, U-net, Bayes' theorem, Heart

PRILOG

PRILOG A - MODEL U-NET KONVOLUCIJSKE NEURONSKE MREŽE

Linija	Kôd
1:	<code>import torch</code>
2:	<code>import torch.nn as nn</code>
3:	<code>import torchvision.transforms.functional as TF</code>
4:	
5:	
6:	<code>class DoubleConv(nn.Module):</code>
7:	<code> def __init__(self, in_channels, out_channels):</code>
8:	<code> super(DoubleConv, self).__init__()</code>
9:	<code> self.conv = nn.Sequential(</code>
10:	<code> nn.Conv2d(in_channels, out_channels, 3, 1, 1, bias=False),</code>
11:	<code> nn.BatchNorm2d(out_channels),</code>
12:	<code> nn.ReLU(inplace=True),</code>
13:	<code> nn.Conv2d(out_channels, out_channels, 3, 1, 1, bias=False),</code>
14:	<code> nn.BatchNorm2d(out_channels),</code>
15:	<code> nn.ReLU(inplace=True),</code>
16:	
17:	<code>)</code>
18:	
19:	<code> def forward(self, x):</code>
20:	<code> return self.conv(x)</code>
21:	
22:	
23:	<code>class UNET(nn.Module):</code>
24:	<code> def __init__(self, in_channels=3, out_channels=2, features=[64, 128, 256,</code>
25:	<code>512]):</code>
26:	<code> super(UNET, self).__init__()</code>
27:	<code> self.downs = nn.ModuleList()</code>
28:	<code> self.ups = nn.ModuleList()</code>
29:	<code> self.pool = nn.MaxPool2d(kernel_size=2, stride=2)</code>
30:	
31:	<code> # Down part</code>
32:	<code> for feature in features:</code>
33:	<code> self.downs.append(DoubleConv(in_channels, feature))</code>
34:	<code> in_channels = feature</code>
35:	
36:	<code> # Up part</code>
37:	<code> for feature in reversed(features):</code>
38:	<code> self.ups.append(nn.ConvTranspose2d(feature * 2, feature,</code>
39:	<code>kernel_size=2,</code>
40:	<code> stride=2))</code>
41:	<code> self.ups.append(DoubleConv(feature * 2, feature))</code>
42:	<code> # Lowest part</code>
43:	<code> self.bottleneck = DoubleConv(features[-1], features[-1] * 2)</code>
44:	<code> self.final_conv = nn.Conv2d(features[0], out_channels, kernel_size=1)</code>
45:	
46:	<code> def forward(self, x):</code>
47:	<code> skip_connections = []</code>
48:	<code> for down in self.downs:</code>
49:	<code> x = down(x)</code>
50:	<code> skip_connections.append(x)</code>
51:	<code> x = self.pool(x)</code>
52:	
53:	<code> x = self.bottleneck(x)</code>
54:	<code> skip_connections = skip_connections[::-1]</code>

```

55:
56:     #check if input is divisible by 2
57:     for idx in range(0, len(self.ups), 2):
58:         x = self.ups[idx](x)
59:         skip_connection = skip_connections[idx // 2]
60:         if x.shape != skip_connection.shape:
61:             x = TF.resize(x, size=skip_connection.shape[2:])
62:
63:         concat_skip = torch.cat((skip_connection, x), dim=1)
64:         x = self.ups[idx + 1](concat_skip)
65:
66:     return self.final_conv(x)

```

PRILOG B - BAYESOVA METODA UKLANJANJA ŠUMA

Linija	Kód
1:	<code>import numpy as np</code>
2:	
3:	
4:	<code>class BayesPreprocessor:</code>
5:	
6:	<code>@staticmethod</code>
7:	<code>def bayes_noise_removal(image, o):</code>
8:	
9:	<code># implement image processing</code>
10:	<code>S1 = image</code>
11:	<code>S2 = 255 - S1</code>
12:	<code>S3 = S1 + S2</code>
13:	<code>try:</code>
14:	<code>w = S2 / S3</code>
15:	<code>except ZeroDivisionError:</code>
16:	<code>w = 0</code>
17:	<code>w = np.divide(S2, S3)</code>
18:	<code>p = np.divide(S3, w)</code>
19:	<code>try:</code>
20:	<code>p = S3 / w</code>
21:	<code>except ZeroDivisionError:</code>
22:	<code>p = 0</code>
23:	
24:	<code>dv = np.log(np.i0((p * np.sinc(w) * S1) / o ** 2)) + np.log(np.i0((p *</code>
25:	<code>np.sinc(1 - w) * S2) / o ** 2)) - p * (</code>
26:	<code>((np.sinc(w)) ** 2 + (np.sinc(1 - w)) ** 2) / (2 * o ** 2))</code>
27:	
28:	<code>dv[dv < 0] = 0</code>
29:	
30:	<code>return dv</code>