

Semantička segmentacija kralježnice na temelju snimaka magnetske rezonance

Radešić, Rikardo

Undergraduate thesis / Završni rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:534844>

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

Download date / Datum preuzimanja: **2024-11-24**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Rikardo Radešić

Zagreb 2023. godina

SVEUČILIŠTE U ZAGREBU

FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentori:

Doc. dr. sc. Marko Švaco

Doc. dr. sc. Filip Šuligoj

Student:

Rikardo Radešić

Zagreb 2023. godina

IZJAVA

Izjavljujem da sam ovaj rad izradio/la samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se mentoru doc. dr. sc. Filipu Šuligoju i doc. dr. sc. Marku Švaci na zadanom zadatku, pomoći i savjetima prilikom izrade završnog rada. Također se zahvaljujem obitelji na podršci tijekom studiranja.

Rikardo Radešić



SVEUČILIŠTE U ZAGREBU

FAKULTET STROJARSTVA I BRODOGRADNJE

Središnje povjerenstvo za završne i diplomske ispite

Povjerenstvo za završne i diplomske ispite studija strojarstva za smjerove:

proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo materijala i mehatronika i robotika



| | |
|-------------------------------------|--------|
| Sveučilište u Zagrebu | |
| Fakultet strojarstva i brodogradnje | |
| Datum | Prilog |
| Klasa: 602 – 04 / 23 – 6 / 1 | |
| Ur.broj: 15 - 1703 - 23 - | |

ZAVRŠNI ZADATAK

Student: **Rikardo Radešić** JMBAG: **0035221152**

Naslov rada na hrvatskom jeziku: **Semantička segmentacija kralježnice na temelju snimaka magnetske rezonance**

Naslov rada na engleskom jeziku: **Semantic segmentation of the spine based on magnetic resonance imaging**

Opis zadatka:

U medicini se koriste različite metode za vizualizaciju i mapiranje anatomskih struktura ljudskog tijela, kao što su magnetska rezonanca (MRI), kompjutorizirana tomografija (CT) ili rendgensko snimanje. Između navedenih, za područje kralježnice, liječnici koriste MRI skeniranje kako bi smanjili izloženost pacijenata X-zrakama. Snimke MRI-a često se koriste kako bi se dobio uvid u kliničku situaciju, te donijela odluka o optimalnom postupku liječenja ili zahvatu. Tumačenje sadržaja MRI snimaka obično obavljaju stručni liječnici koji na temelju specijaliziranog znanja i razumijevanja problematike mogu uspješno identificirati interesne strukture.

Kako bi se ubrzao i olakšao postupak tumačenja sadržaja MRI snimaka, u sklopu ovog rada predlaže se provođenje semantičke segmentacije medicinskih slika primjenom algoritama strojnog vida. U sklopu semantičke segmentacije, digitalnoj slici dodjeljuje se oznaka klase po pikselu, koja pokazuje kojem dijelu od interesa pripada. Ove oznake po pikselu obično tvore regije koje odgovaraju različitim tkivima na snimkama. U okviru rada potrebno je:

- Istražiti postojeće metode koje se koriste za semantičku segmentaciju kralježaka i okolnih tkiva,
- istražiti i preuzeti javno dostupne setove označenih MRI podataka kralježnice,
- primijeniti algoritme strojnog vida i evaluirati uspješnost segmentacije,
- usporediti rezultate sa State-of-the-art rješenjima.

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:

30. 11. 2022.

Datum predaje rada:

1. rok: 20. 2. 2023.
2. rok (izvanredni): 10. 7. 2023.
3. rok: 18. 9. 2023.

Predviđeni datumi obrane:

1. rok: 27. 2. – 3. 3. 2023.
2. rok (izvanredni): 14. 7. 2023.
3. rok: 25. 9. – 29. 9. 2023.

Zadatak zadao:

Doc. dr. sc. Marko Švaco

Dr. sc. Filip Šuligoj

Predsjednik Povjerenstva:

Prof. dr. sc. Branko Bauer

SADRŽAJ

| | |
|--|----|
| 1. UVOD..... | 1 |
| 2. STROJNI VID U MEDICINI..... | 3 |
| 2.1. Tradicionalni pristup..... | 4 |
| 2.2. Duboko učenje..... | 5 |
| 2.3. Mehanizam pažnje..... | 6 |
| 2.4. DSC (Dice similarity coefficient)..... | 8 |
| 2.5. Postojeće metode za semantičku segmentaciju kralježaka i okolnih tkiva..... | 8 |
| 3. ALGORITMI U STROJNOM VIDU..... | 10 |
| 3.1. Mrežne strukture bazirane na dubokom učenju..... | 10 |
| 3.1.1. CNN (Convolutional Neural Network)..... | 10 |
| 3.1.2. FCN (Fully Convolutional Network)..... | 12 |
| 3.1.3. U-Net..... | 13 |
| 3.1.4. GAN (Generative Adversial Network)..... | 14 |
| 3.2. SVM (Support Vector Machine)..... | 15 |
| 3.3. Pristup s obradom slike..... | 16 |
| 3.3.1. Thresholding metoda..... | 16 |
| 3.3.2. Metoda segmentacije na temelju rubova..... | 17 |
| 3.3.3. Metoda segmentacije temeljena na regiji..... | 17 |
| 3.3.4. Watershed Based metoda..... | 17 |

| | |
|---|----|
| 4. RAZVOJ ALGORITAMA ZA SEGMENTACIJE KRALJEŽNICE..... | 18 |
| 4.1. Segmentacija kralježnice br.1 | 18 |
| 4.1.1. Rezultati slike br.1 | 22 |
| 4.2. Segmentacija kralježnice br.2 | 24 |
| 4.2.1. Rezultati slike br.2 | 26 |
| 4.3. Evaluacija uspješnosti segmentacije | 27 |
| 5. Zaključak..... | 30 |

POPIS SLIKA

| | |
|---|----|
| Slika 1. MRI snimka kralježnice [13] | 2 |
| Slika 2. Proces analize slike [2], a - tradicionalni pristup; b - pristup dubokim učenjem | 4 |
| Slika 3. Segmentacijske metode bazirane na obradi slike [12]..... | 9 |
| Slika 4. CNN proces [15]..... | 11 |
| Slika 5. Up-sampling primjer [8] | 12 |
| Slika 6. Rezultati up-samplinga [8] | 13 |
| Slika 7. U-Net proces [9] | 14 |
| Slika 8. GAN proces [10]..... | 15 |
| Slika 9. Thresholding metoda | 16 |
| Slika 10. Učitavanje i konverzija slike u sivu..... | 18 |
| Slika 11. Izoštavanje slike | 19 |
| Slika 12. Erozija slike | 19 |
| Slika 13. Pronalaženje kontura na slici | 20 |
| Slika 14. Kreiranje crne slike..... | 20 |
| Slika 15. Eliminacija nepotrebnih kontura..... | 21 |
| Slika 16. Dilacija kontura | 21 |
| Slika 17. Dodavanje kontura na originalnu sliku..... | 22 |
| Slika 18. Prikaz slika..... | 22 |
| Slika 19. Rezultati slika nakon procesa slike br.1 [13]..... | 23 |
| Slika 20. Učitavanje i konverzija slike u sivu..... | 24 |
| Slika 21. Erozija slike | 24 |
| Slika 22. Thresholdanje slike..... | 24 |
| Slika 23. Pronalaženje kontura na slici | 25 |
| Slika 24. Kreiranje crne slike..... | 25 |
| Slika 25. Eliminacija nepotrebnih kontura..... | 25 |
| Slika 26. Dilacija kontura | 25 |
| Slika 27. Dodavanje kontura na originalnu sliku..... | 25 |
| Slika 28. Spremanje slike..... | 26 |

| | |
|---|----|
| Slika 29. Rezultati slika nakon procesa slike br.2 [13]..... | 26 |
| Slika 30. Rezultati slika nakon procesa slike br.2 - nastavak | 27 |
| Slika 31. Rezultati segmentacije različitim metodama | 28 |
| Slika 32. Dice similarity coefficient kod | 28 |

POPIS TABLICA

POPIS OZNAKA

SAŽETAK

U sklopu ovog rada obrađena je tema računalnog vida za medicinsku svrhu. U medicini se koriste različite metode za segmentiranje dijelova tijela sa snimaka (npr. organi, kosti, razna tkiva..) i ovaj rad fokusira se na segmentaciju kralježnice snimaka magnetske rezonance pomoću algoritama strojnog vida. To znači da je program sam sposoban prepoznati svaki kralježak zasebno, te ih označiti. Ovim putem se cijeli postupak tumačenja sadržaja MRI snimaka može znatno olakšati i ubrzati. Postoje metode koje imaju tradicionalan pristup segmentacije, te one koje rade pomoću dubokih neuronskih mreža. Istraženo je više metoda u oba pristupa segmentaciji, kao što su CNN, FCN, U-Net, GAN, Edge detection, thresholding,.. Kasnije u radu segmentirane su dvije različite kralježnice otprilike istim pristupom, obje pomoću algoritama obrade slike. Dobiveni rezultati jedne od tih dviju segmentacija, uspoređene su pomoću Dice koeficijenta sličnosti sa State-of-the-art rješenjima segmentacije. Evaluirana je uspješnost segmentacije, te su doneseni zaključci. Cilj ovog rada je istražiti koliko se dobro može provesti postupak segmentacije pristupom obrade slike u usporedbi s dobro razvijenim već postojećim metodama segmentacije u medicini.

Ključne riječi: strojni vid, duboko učenje, segmentacija, umjetna inteligencija, kralježnica, obrada slike, medicina

SUMMARY

This paper focuses on the topic of computer vision for medical purposes. In medicine, various methods are employed for the segmentation of body parts from images, such as organs, bones, and various tissues. This paper specifically concentrates on segmenting the spine from magnetic resonance imaging (MRI) scans using machine vision algorithms. This means that the program is capable of autonomously recognizing and labeling each vertebra individually. This approach significantly streamlines and accelerates the process of interpreting the content of MRI scans. There are methods that follow a traditional segmentation approach, as well as those that utilize deep neural networks. Several methods have been explored in both segmentation approaches, including CNN, FCN, U-Net, GAN, edge detection, thresholding, and others. Later in the paper, two different spines were segmented using roughly the same image processing algorithms. The obtained results of one of these two segmentations were compared using the Dice coefficient of similarity with state-of-the-art segmentation solutions. The success of the segmentation was evaluated, and conclusions were drawn. The aim of this paper is to investigate how well the segmentation process can be conducted using image processing approaches compared to well-established existing methods of segmentation in medicine.

Keywords: computer vision, deep learning, segmentation, artificial intelligence, spine, image processing, medicine

1. UVOD

Pregled kralježnice magnetskom rezonancijom (MRI) često je ključna dijagnostička procedura koja omogućava detaljno ispitivanje kralježnice i okolnih struktura s visokom razlučivošću. Liječnici koriste MRI skeniranje, u odnosu na kompjutoriziranu tomografiju (CT) ili rendgensko snimanje, kako bi minimalizirali potrebu za izlaganjem pacijenata X-zrakama. MRI snimke često se primjenjuju radi dobivanja detaljnog uvida u kliničko stanje pacijenata, što omogućava donošenje odluka o najprikladnijem postupku liječenja ili zahvata.

Segmentacija se može postići i putem strojnog vida, ne samo ljudskim metodama. Segmentacija je proces analize slika u računalnom vidu koji se koristi za identifikaciju i izolaciju specifičnih dijelova ili objekata unutar slike. To je bitan proces u strojnom vidu jer omogućava računalu da razumije i odvoji te različite dijelove slika, te na taj način obavi postupak segmentacije.

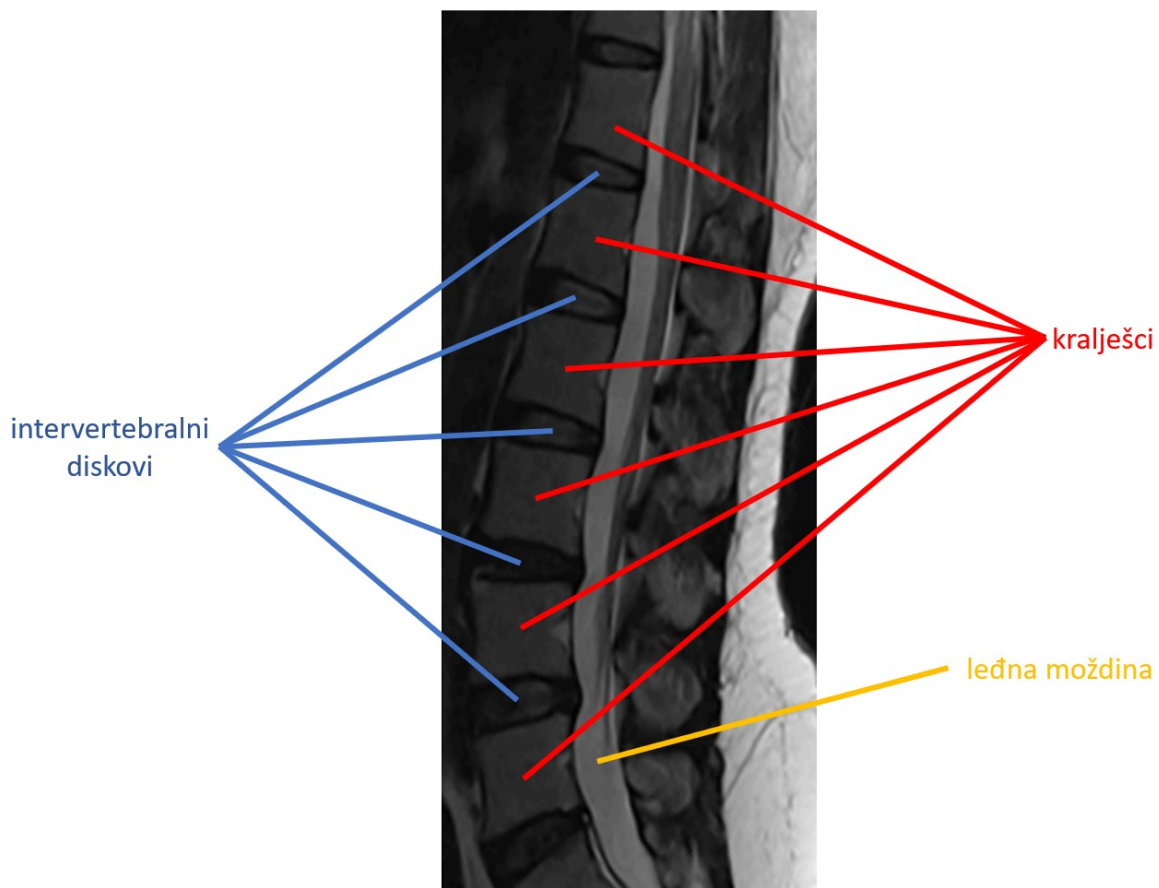
Kod segmentacije kralježnice, cilj je uspješno „odvojiti“ svaki kralježak za sebe, na temelju čega se može dijagnosticirati u čemu je problem s nekom kralježnicom. Automatska segmentacija kralježnice pomoću umjetne inteligencije i strojnog vida postoji već neko vrijeme, te se i dalje se razvija. Segmentaciju uz pomoć računala u današnje vrijeme možemo postići relativno jednostavno. Kralježnica je kritična potporna struktura u ljudskom tijelu koja se sastoji od mnogo kralježaka (33 do 34).

Da bismo ubrzali i olakšali proces tumačenja MRI snimaka, koristi se semantička segmentacija medicinskih slika putem algoritama strojnog vida. Ovaj napredni pristup omogućava identifikaciju i označavanje različitih anatomskih struktura i različitih tkiva na slikama, što može znatno olakšati i ubrzati proces analize i dijagnoze medicinskih slika, povećati točnost dijagnoza, pomoći pri operacijama, smanjiti sveukupne troškove zdravstvene skrbi, te još mnogo toga.

Umjetna inteligencija (artificial intelligence – AI) krenula se spominjati oko 1950-ih godina. Njezin razvitak je trenutno u eksponencijalnom rastu i tako će se vjerojatno i nastaviti. To je područje računalne znanosti koje, ako je „program“ dobro napravljen, sposobno izvoditi zadatke koji inače zahtijevaju ljudsku inteligenciju. To znači da je računalo sposobno naučiti,

razumjeti, rješavati probleme, zaključivati i prepoznati stvari, u svrzi za koju je napravljen, bez ikakve ljudske pomoći. Dakle, otuda i naziv, jer možemo reći da je računalo s umjetnom inteligencijom stvarno inteligentno. Računalo je brže i ponekada efikasnije od ljudskog rada, ali isto kao što čovjek može pogriješiti, postoje i greške kod računala.

U ovom radu će se razmatrati područje strojnog vida (machine vision). U nekim metodama segmentacije implementirana je i umjetna inteligencija. Strojni vid bavi se razvojem sustava i tehnologija tako da se računalu omogući da „vidi“ i interpretira vizualne informacije, isto kao što bi to napravilo ljudsko oko i mozak. Primjeri toga su prepoznavanje lica, autonomna vozila, sigurnosni nadzor, industrijska automatizacija, poljoprivreda, robotika, itd.



Slika 1. MRI snimka kralježnice [13]


2. STROJNI VID U MEDICINI

Segmentacija u medicinskom strojnom vidu igra ključnu ulogu u analizi medicinskih snimaka. Ovaj proces omogućava točno identificiranje i izolaciju konkretnih anatomskih elemenata ili zona unutar tih slika, što ima ključnu ulogu u postavljanju dijagnoza, razvoju terapija i praćenju tijeka bolesti.

Metode strojnog vida, ili computer vision (CV), široko su istraživane u posljednje vrijeme. Nedavni napredak u dubokom učenju pruža napredne alate za analizu slika s visokom preciznošću i kvalitetom. Strojni vid možemo podijeliti na tradicionalni strojni vid i duboko učenje.

Duboko učenje rasprostranjeno je u području obrade digitalnih slika kako bi riješilo zahtjevne probleme, kao što su segmentacija slika, klasifikacija slika i detekcija objekata. Metode dubokog učenja, kao što su konvolucijske neuronske mreže (CNN), su posebno uspješne jer koriste velike količine podataka i moćne računalne resurse, što je omogućilo postizanje izvanrednih rezultata koji su premašili tradicionalne metode. Duboko učenje također ima potencijal poboljšati identifikaciju tumora, organa ili patoloških promjena na medicinskim slikama, što pomaže i ubrzava proces prepoznavanja problema od strane medicinskih stručnjaka i potiče donošenje ključnih kliničkih odluka.

Iako duboko učenje ima izvanredne sposobnosti u računalnom vidu, važno je napomenuti da ne može riješiti sve izazove u tom području. Postoje problemi za koje su tradicionalne metode bolje rješenje. Pojava dubokog učenja otvara nova vrata za primjenu tradicionalnih tehnika kako bi se prevladali mnogi izazovi koje duboko učenje može postaviti, kao što su visoki zahtjevi za računalnom snagom, vrijeme obuke, potrebna preciznost, karakteristike, te mnogi drugi faktori. Tradicionalne metode segmentacije još uvijek se koriste u medicini tamo gdje je potrebna visoka preciznost i interpretacija slika uz minimalan rizik od grešaka, a kombinacija tradicionalne metode i metode dubokog često pružaju najbolje rezultate u analizi medicinskih snimaka.



Slika 2. Proces analize slike [2], (a) - tradicionalni pristup; (b) - pristup dubokim učenjem

U ovom radu će se segmentacija obaviti tradicionalnim pristupom, ili pristupom obrade slike, te će se ti rezultati uspoređivati s rezultatom koji je dobiven metodama koje se temelje na dubokim neuronskim mrežama (metodama dubokog učenja i mehanizma pažnje).

2.1. Tradicionalni pristup

Ponekad duboko učenje može biti suvišno i tradicionalne tehnike računalnog vida mogu biti učinkovitije i zahtijevati manje koda od dubokog učenja. Na primjeru klasifikacije proizvoda na pokretnoj traci za montažu, gdje se proizvodi razlikuju samo po boji (npr. crvena i plava), duboka neuronska mreža može biti korisna ako postoji dovoljno podataka za obuku. Međutim, isti cilj može se postići i primjenom tehnika poput „thresholdinga“.

Tradicionalna računalna vizija (CV) pruža potpunu transparentnost, omogućujući procjenu kako će rješenje funkcionirati izvan faze treninga. Inženjer za računalnu viziju može steći dublje uvide u probleme, koji se mogu direktno prenijeti na algoritam. Ako se pojavi problem, parametri se mogu prilagoditi kako bi se osiguralo bolje funkcioniranje na raznolikom skupu slika. Danas se tradicionalne tehnike koriste kada se problem može pojednostaviti, kako bi se mogle implementirati na jeftinim mikrokontrolerima ili kako bi se ograničio problem za duboke tehnike učenja.

Tradicionalni pristup koristi dobro uspostavljene tehnike računalne vizije. Mogu se koristiti različiti algoritmi računalne vizije, kao što su detekcija rubova i detekcija kutova. Slike se analiziraju kako bi se izdvojilo što više relevantnih karakteristika, a te karakteristike zajedno čine definiciju za svaku klasu objekata.

Jedan od izazova s ovim tradicionalnim pristupom jest potreba za ručnim odabirom značajki koje su bitne za svaku konkretnu sliku. Kako broj klasa koje treba klasificirati raste, proces izdvajanja značajki postaje sve zahtjevniji. Od inženjera za računalnu viziju se očekuje da donosi odluke o tome koje značajke najbolje opisuju različite klase objekata, a to često uključuje dugotrajan proces ispitivanja i ispravaka.

2.2. Duboko učenje

Duboko učenje ili Deep Learning (DL) je područje strojnog učenja koje se temelji uglavnom na umjetnim neuronskim mrežama, koje su inspirirane načinom funkcioniranja ljudskog mozga. Baš kao što ljudski mozak ima mnogo pojedinačnih stanica ili neurona, svaki obavlja jednostavne operacije i komunicira s drugima kako bi donio zaključke, a duboko učenje se bazira na sličnom principu. Usredotočuje se na sposobnost sustava da nauči i "dodijeli zasluge" putem više slojeva neuronske mreže na precizan, efikasan način. Duboko učenje često koristi koncepte samoorganizacije i međusobne interakcije između malih jedinica („neurona“), što se pokazalo učinkovitim.

Napredak u dubokom učenju i tehnološkim uređajima, kao što su računalna snaga i optičke komponente, znatno su poboljšali izvedbu vizualnih aplikacija. U usporedbi s tradicionalnim tehnikama računalnog vida, duboko učenje omogućava inženjerima računalnog vida postizanje više preciznosti u zadacima kao što su klasifikacija slika, semantička segmentacija, detekcija objekata, itd. Budući da se neuronske mreže u DL-u treniraju umjesto da se programiraju ručno, aplikacije koje koriste ovaj pristup često zahtijevaju manje stručnih analiza i preciznih podešavanja, tako da iskorištavaju ogromnu količinu podataka.

U duboko učenje uveo se koncept učenja "end-to-end", gdje stroju pružamo skup slika koje su označene informacijama o tome koje se kategorije objekata nalaze na svakoj slici. Model se uči na dostupnim podacima, pri čemu neuronske mreže pomoću mehanizma pažnje identificiraju osnovne uzorke u klasifikaciji slika i automatski prepoznaju najvažnije i najreprezentativnije karakteristike povezane s određenom klasom objekata za svaki pojedinačni objekt.

Razvoj konvolucijskih neuronskih mreža (CNN) imao je ogroman utjecaj u području računalnog vida u posljednjih nekoliko godina i odgovoran je za veliki napredak u sposobnosti prepoznavanja objekata. Ovaj skok u napretku omogućen je povećanjem računalne snage, kao i povećanjem količine dostupnih podataka za obuku neuronskih mreža.

2.3. Mehanizam pažnje

Prepoznavanje slika je zadatak koji ljudi obavljaju od djetinjstva. Primjerice, djeca se uče prepoznavati voće i povrće kao što su jabuke, banane i lubenice. Je li moguće naučiti računala da obave sličan zadatak? Može li čovjek izgraditi stroj koji može vidjeti i razumjeti sliku na način sličan ljudima?

Razvoj mehanizma pažnje nadahnut je biološkim sustavom čovjeka i njegovim mehanizmom obrade informacija. Čovjek obično ne tretira sve informacije s jednakom važnošću prilikom obrade veće količine vanjskih informacija. Na temelju prijašnjih iskustava iz života, čovjek je sposoban procijeniti važnost pojedine informacije, a što više stari i skuplja iskustva, povećava mu se učinkovitost i točnost obrade informacija. Ljudski mozak daje prednost informacijama za koje smatra da su važnije, te takvim informacijama pridaje mnogo veću pažnju i više resursa za razmišljanje, dok se manje važne informacije potencijalno zanemaruju. Ljudsko oko je dio biološkog kognitivnog sustava, a slika visoke razlučivosti je samo taj mali dio koji se u tom trenutku gleda, dok su svi periferni dijelovi slike niske razlučivosti.

Zamislite da vam netko pokaže sliku na kojoj je jabuka i kaže vam da proučite jabuku. U tom trenutku, dodjeljujete najveću važnost jabuci za koju iz prijašnjih iskustava znate kako izgleda ili kako bi barem otprilike trebala izgledati. Nakon kratkog promatranja slike, oduzeta vam je i postavljeno vam je pitanje vezano za neku drugu stvar koja se od mnogo njih nalazila na slici. Vjerojatno nećete znati odgovoriti na pitanje vezano za tu drugu stvar, nego samo za jabuku. Na taj način nama mozak dodjeljuje važnost i fokusira se na to što tražimo; u ovom slučaju tako da nam je rečeno što trebamo promatrati. Ovaj proces dodjeljivanja važnosti može se naučiti.

Sljedeći korak kod analize slika je odrediti kako omogućiti računalima da nauče karakteristike podataka. Velika sposobnost računala i njegova grafička snaga dobiva puno pažnje u posljednje vrijeme.

Mehanizam pažnje u dubokom učenju je tehnika kojom se poboljšavaju performanse neuronske mreže omogućavajući modelu da se fokusira na najvažnije ulazne podatke. Ovo se postiže tako da model daje važnost nekim ulaznim podacima više nego drugima, te se bavi njima. Proširen je s obrade prirodnog jezika na strojno gledanje; konstruira značajke slike u specifične vektore i računa povezanosti. Ta povezanost predstavlja odnos između globalnih piksela slike te im dodjeljuje važnost. Ovaj pristup široko je upotrebljiv i može se implementirati u različite zadatke slika, kao što su segmentacija slika, detekcija objekata, praćenje u videozapisima, klasifikacija slika, itd.

U usporedbi s tradicionalnim algoritmima strojnog učenja, kombinacija mehanizma pažnje i dubokih algoritama za učenje ima prednosti. Značajke u dubokom učenju ostvaruju se učenjem i optimizacijom, dok se mnogi tradicionalni algoritmi za strojno učenje i dalje oslanjaju na ručno izrađivanje značajki.

U medicini to može biti prepoznavanje različitih tkiva ili dijelova tijela, a u ovom primjeru je to prepoznavanje različitih kralježaka.

2.4. DSC (Dice similarity coefficient)

Dice koeficijent sličnosti, također zvan „Sorensen-Dice coefficient“, je statistički alat koji uspoređuje sličnost između dvije skupine podataka [4]. Dice koeficijent često se koristi za evaluaciju medicinskih slika s nejednako velikim segmentacijama.

Dice koeficijent je preferirani izbor za zadatke segmentacije slika jer bolje reagira na preklapanje između predviđenih i stvarnih maski. Ova osjetljivost postiže se tako da se segmentacijske maske (npr. dvije segmentacije različitim metodama) tretiraju kao skupovi piksela. I predviđena i stvarna segmentacija prikazuju se kao binarne maske, gdje svaki piksel pripada segmentiranom objektu ili ne.

Koeficijent varira od 0 do 1, pri čemu 1 označava da su dva skupa identična, a 0 označava da dva skupa nemaju preklapanja.

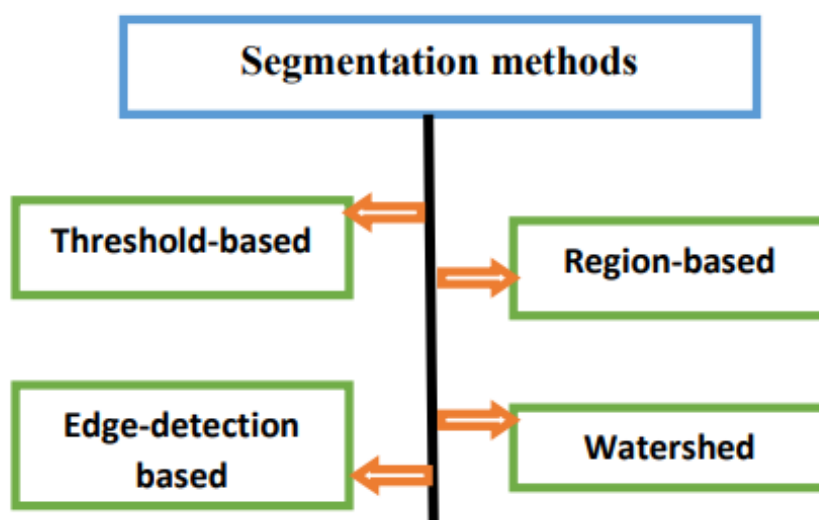
2.5. Postojeće metode za semantičku segmentaciju kralježaka i okolnih tkiva

U posljednjim godinama, metode medicinske analize slika temeljene na mehanizmu pažnje u kombinaciji s dubokim učenjem privukle su veliku pozornost. Ove metode postigle su najnaprednije rezultate u višestrukim zadacima dubokog učenja na medicinskim slikama. Mehanizam pažnje obično se koristi kao modul u metodama dubokog učenja [3]. Pod to spadaju algoritmi bazirani na dubokom učenju i mehanizmu pažnje, kao što su CNN, FCN, GAN, U-Net.

Konvolucijska neuronska mreža (CNN) jedna je od najpopularnijih mreža u analizi slika kralježnice [5]. U usporedbi s konvolucijskim neuronskim mrežama (CNN), U-Net ostvaruje cjelovite informacije o kralježnicama spajanjem značajki s up samplingom. U-Net je tipična konvolucijska neuronska mreža za segmentaciju slika [5][14]. GAN (Generative Adversarial Network) povećava globalnu preciznost i sprječava prenaučenosť u segmentaciji slika kralježnice [5]. U radu [5] istraživale su se metode segmentacije kralježnice (CNN, U-Net, GAN) bazirane na segmentaciji dubokim neuronskim mrežama. Segmentacija objekata je ključni korak u dijagnostici kralježnice i obuhvaća većinu dubokih metoda u analizi slika.

Visoka preciznost analize usporediva je s onom koju postižu liječnici ručno. Tehnika dubokog učenja (DL) predstavlja moćan alat za analizu kralježnice putem slika. Uvjereni smo da će uz suradnju istraživača i kliničara, inteligentne, lako interpretirane i pouzdane metode analize kralježnice pomoću dubokog učenja imati široku primjenu u budućoj kliničkoj praksi [5]. Istraživanje je pokazalo da su metode segmentacije bazirane na dubokom učenju učinkovite i poprilično točne. Metoda duboke mreže s potpunom konvolucijom (FCN) je istovremeno segmentirala i označavala lumbalnu kralježnicu koristeći lokalno okruženje lumbalne kralježnice [14]. U ovom radu segmentirala se kralježnica raznim segmentacijskim metodama na bazi dubokog učenja. FCN pokazao se kao dobar pristup segmentaciji kralježnice, ali su ostale metode (U-Net, CNN) imale bolje rezultate.

Segmentacija slika ima nekoliko tehnika za podjelu slika na segmente, te svaka tehnika ima svoje karakteristike. Segmentacijske tehnike bazirane na obradi slike mogu se podijeliti na thresholding metodu, segmentacija na temelju rubova, segmentacija temeljena na regiji i watershed baziranu metodu [12]. Iako su tehnike temeljene na intenzitetu brze i efikasne segmentacije, mogu se pojaviti greške, što može zahtijevati intervenciju korisnika ili primjenu regulacijskih metoda, što je prikazano i kasnije u radu.



Slika 3. Segmentacijske metode bazirane na obradi slike [12]

Sve navedene metode mogu se koristiti i koriste se kod medicinske segmentacije, bila to neka tkiva, kosti, itd. Metode navedene u ovom potpoglavlju opisane su u nastavku.

3. ALGORITMI U STROJNOM VIDU

3.1. Mrežne strukture bazirane na dubokom učenju

3.1.1. CNN (Convolutional Neural Network)

CNN (konvolucijska neuronska mreža) jedna je od najznačajnijih mreža u području dubokog učenja i inspirirana je vizualnom percepcijom. Budući da je CNN postigla impresivne rezultate u mnogim područjima, privukla je veliku pažnju u posljednjih nekoliko godina. Računalni vid temeljen na konvolucijskim neuronskim mrežama omogućio je ljudima da ostvare ono što se smatralo nemogućim tijekom proteklih nekoliko stoljeća. Uvođenje velikih količina podataka i dostupnost hardverske opreme otvorilo je nove mogućnosti za proučavanje konvolucijskih neuronskih mreža [6][7].


U usporedbi s drugim metodama, konvolucijske neuronske mreže zahtijevaju manje preprocesiranja podataka. Njegova sposobnost da efikasno uči i razumije strukturu slika čini ga ključnim alatom u mnogim aplikacijama, uključujući medicinsku dijagnostiku, autonomnu vožnju, prepoznavanje lica, pretragu slika i još mnogo toga. Ta sposobnost da obradi slikovne podatke bez potrebe za detaljnim ručnim pripremama čini ga vrlo moćnim alatom u području računalnog vida. Microsoft, Google i Facebook su neke od tvrtka koje sudjeluju u razvoju i napredovanju arhitekture konvolucijskih neuronskih mreža jer nastoje poboljšati različite aspekte računalnog vida.

U prošlosti često se primjenjivao pristup dodavanja slika u bazu podataka, a zatim su se razvijali programi za usporedbu tih ciljanih slika sa sadržajem u bazi podataka, kako bi se utvrdila prisutnost određene slike. Međutim, glavna ograničenost tog pristupa je da slika koja već nije bila u bazi podataka, nije mogla biti prepoznata. Stoga je postojala velika potreba za razvojem sustava koji bi automatski prepoznao i identificirao karakteristike slika.

Algoritmu se mora demonstrirati mnogo slika prije nego što računalo može prepoznavati ulaz i davati predviđanja za slike koje nikada prije nije vidio. Ljudi vide sliku, ali računalo je to samo numerički podatak.

Način rada CNN-a:

Konvolucijske neuronske mreže koriste jezgre (kernele) kako bi detektirale značajke (npr. rubove) u cijeloj slici. Kernel je matrica vrijednosti koja je naučena da detektira specifične značajke.



Slika 4. CNN proces [15]


- Računalu pokažemo neku sliku, na primjer sliku psa. Računalo ne zna odmah što je na slici i treba je proučiti.
- Računalo ne gleda cijelu sliku odjednom, nego djelić po djelić, kao mali prozorčić (kernel) koji prolazi postepeno po cijeloj slici (proces zvan convolution).
- Kada pronade nešto što mu je poznato, na primjer uho od psa, taj dio zapamti.
- Kada na slici pronade još neke uzorke, recimo nos i rep od psa, grupira sve podatke što je pronašao i zaključi da je to slika psa.

Da bi računalo počelo dobro prepoznavati što je na slikama koje nikada do tada nije vidio, mora mu se pokazati jako puno slika s tom stvari koju prepoznaje i mora obaviti taj proces mnogo puta.

3.1.2. FCN (Fully Convolutional Network)

Potpuno konvolucijska mreža (FCN) je vrsta konvolucijske neuronske mreže (CNN-a) koja se koristi za semantičku segmentaciju slika [8]. Ova vrsta mreže značajno doprinosi analizi slika jer omogućuje precizno označavanje svakog piksela na slici prema njegovoj pripadnosti u određenoj klasi ili regiji. Sastoji se od konvolucijskih slojeva, isto kao i CNN, ali ima i up-sampling (povećanje razlučivosti) tih konvolucijskih slojeva kako bi izlazna slika bila iste razlučivosti kao i ulazna slika. Up-sampling slojevi omogućuju FCN-u da "pamti" gdje se nalaze rubovi i detalji objekata. Svaki piksel na izlaznoj slici ima svoju vlastitu kvalifikaciju, što omogućuje segmentaciju slike na razini piksela. To je posebno korisno za precizno označavanje objekata i regija na slici.

Za razliku od tradicionalnih CNN-ova koji zahtijevaju fiksnu veličinu ulazne slike, FCN može obraditi slike različitih veličina. Ovo je izuzetno korisno jer slike iz stvarnog svijeta često dolaze u različitim rezolucijama.




Slika 5. Up-sampling primjer [8]

FCN-32s - nakon sedam konvolucijskih slojeva, kada je slika već na jako maloj razlučivosti, poveća se na originalnu veličinu

FCN-16s - kombinacija posljednje slike i slike na četvrtom sloju konvolucije

FCN-8s – kombinacija posljednje slike i slike na trećem sloju konvolucije




Slika 6. Rezultati up-samplinga [8]

Kao što se može vidjeti iz primjera, kombinacija sa što ranijom fazom slike i njezinim up-samplingom dobivamo završnu sliku veće kvalitete koja je bolje segmentirana.

3.1.3. U-Net

U-Net je potpuno konvolucijska mreža. Razlika između U-Net-a i FCN-a je ta da U-Net koristi up-sampling sa svakog konvolucijskog sloja, što rezultira vrlo detaljnom završnom slikom.

U-Net arhitektura, koja je posebno prilagođena za semantičku segmentaciju i precizno označavanje objekata na slikama, često se koristi u medicinskim i biomedicinskim primjenama [9]. U-Net je postao vrlo važan alat u medicinskom sektoru jer se ističe po svojoj sposobnosti za preciznu i visokokvalitetnu segmentaciju na medicinskim slikama.




Slika 7. U-Net proces [9]

3.1.4. GAN (Generative Adversarial Network)

Generativna suparnička mreža (GAN) predstavlja model u kojem generator nastoji naučiti podatke, kako bi mogao stvarati nove, do tada neviđene podatke [10]. To je neuronska mreža koja se sastoji od dvije kompetitivne komponente, generatora i diskriminatora, i temelji se na ideji suparničkog treniranja. Radi tako da se generator „bori“ s diskriminatorom.

Generator prima ulazne podatke i transformira ih u lažne s ciljem stvaranja također realističnih slika. Diskriminator prima i lažne i stvarne (autentične) slike, te ih se „trudi“

razlikovati. Oba se treniraju istovremeno i natječu se jedan s drugim. Ovaj mehanizam može ispraviti pogreške u predviđanjima i nadvladati ograničenja malih skupova podataka.



Slika 8. GAN proces [10]

3.2. SVM (Support Vector Machine)

Stroj s potpornim vektorima (SVM) je računalni algoritam koji uči na primjerima kako bi pridijelio oznake objektima [11]. Ukratko, cilj klasifikacije potpornim vektorima je učinkovito pronaći "dobru" razdvajajuću plohu u visoko dimenzionalnom prostoru značajki. Optimalna ploha se definira kao ona koja ima maksimalnu marginu razdvajanja između dvije klase.

3.3. Pristup s obradom slike

U tradicionalnom pristupu koriste se razni algoritmi kako bi se postigla željena segmentacija. To su široko primjenjivi postupci koji omogućavaju rješavanje problema klasifikacije i segmentacije [12].

3.3.1. Thresholding metoda

Najpopularnija i često korištena metoda za segmentaciju slika je thresholding metoda. Ova tehnika se često primjenjuje kako bi se izdvojili objekti na prednjem planu slike od pozadine. U ovoj metodi, pikseli slike se dijele uz pomoć intenziteta slike. Postupak uključuje odabir određenog praga vrijednosti (threshold) koji se primjenjuje na svaki piksel slike. Pikseli tamniji od praga postaju potpuno crni (vrijednost inteziteta 0), a svi ostali potpuno bijeli (vrijednost 255). Odabir odgovarajućeg praga i pristupa thresholdingu može biti izazovan zadatak te zahtijeva razumijevanje karakteristika slike i ciljeva segmentacije.



Slika 9. Thresholding metoda

Lijevo je originalna slika [13], dok je desna obrađena thresholding metodom.

3.3.2. Metoda segmentacije na temelju rubova

Edge based segmentation method je metoda koja prepoznaje rubove. Povezani piksel koji se nalazi na granici prostora nazivaju se rubom, dakle, ti pikseli poznati su kao rubne točke. Neki rubovi su vrlo jednostavni za pronalaženje, dok drugi nisu. Ova metoda se često koristi kako bi se izdvojili obrisi i konture objekata na slici, što može biti korisno u različitim zadacima računalnog vida, prepoznavanju oblika, medicinskoj slikovnoj obradi i drugim područjima. Edge based segmentacija često radi dobro za slike koje sadrže oštre kontraste između objekata i pozadine.

3.3.3. Metoda segmentacije temeljena na regiji

Region based segmentacija temelji se na segmentiranju slike na temelju sličnih karakteristika piksela, kao što su intenziteti boje, tekstura ili svjetlina. Način pristupa je taj da se jasno razdvoje različiti entiteti prisutni na slici u kojem se nastoji konstruirati površine spajanjem susjednih piksela prema kriteriju homogenosti. Ova metoda često daje dobre rezultate za slike s jasno definiranim regijama i objektima, ali zahtijeva pažljiv odabir parametara i algoritama kako bi se postigla najbolja segmentacija za određeni problem.

3.3.4. Watershed Based metoda

Tehnika koja se temelji na konceptu geografskog prikaza kao topografske površine, gdje je svjetlina ili boja piksela interpretirana kao visina terena. To predstavlja „bazene“, pa kada voda dosegne rub bazena, susjedni bazeni se spajaju zajedno. Koristi se za automatsko razdvajanje objekata na slici na temelju lokalnih karakteristika i struktura. Ova metoda segmentacije često se koristi u analizi medicinskih slika, geoinformatičkoj analizi, analizi tekstura i drugim područjima gdje je potrebno precizno i automatsko izdvajanje objekata iz slika.

4. RAZVOJ ALGORITAMA ZA SEGMENTACIJE KRALJEŽNICE

Segmentacija kralježnice odrađena je tradicionalnim pristupom, ili pristupom obrade slike. Sve je napravljeno u programskom jeziku Python pomoću OpenCV (Open Source Computer Vision Library) biblioteke koja služi za obradu slike i zadatke računalne vizije.

Prilikom segmentacije isprobani su razni algoritmi za obradu slike. Nakon višestrukih pokušaja, razvijen je način pristupa segmentaciji koji daje zadovoljavajuće rezultate. Za dva primjera segmentirane kralježnice, prezentirani su rezultati dobiveni sličnim pristupom obrade slike. Rezultat segmentacije uspoređen je s već postojećim segmentacijama iste kralježnice. Originalne MRI slike kralježnice preuzete su iz javno dostupnih znanstvenih članaka vezanih za segmentaciju u medicini [13][14].

4.1. Segmentacija kralježnice br.1

Originalna slika koja se koristi u ovoj segmentaciji je slika iz znanstvenog rada [13].

Učitavanje slike i konverzija u sivu sliku:

```
slika = cv2.imread("kraljeznica.jpg")  
siva_slika = cv2.cvtColor(slika, cv2.COLOR_BGR2GRAY)
```

Slika 10. Učitavanje i konverzija slike u sivu

U ovom koraku originalnu konverziram u sivu sliku, što znači da ćemo imati sliku samo sa sivim nijansama. To znači da svaki piksel ima jednu vrijednost svjetline, od potpuno crne (vrijednost 0) do potpuno bijele (vrijednost 255). Niža vrijednost označava tamniju nijansu, a viša svjetliju. Sliku se sprema pod nazivom „siva_slika“.

- „cv2.imread()“ je funkcija za učitavanje slike koju tada spremamo u program pod imenom „slika“

- „cv2.cvtColor()“ je funkcija koja u našem slučaju konvergira originalnu sliku u sliku sa sivim nijansama

Definiranje jezgre (kernela) za oštrinu i izoštravanje slike:

```
kernel_za_izostravanje = np.array([[ -1,  -1,  -1],  
                                   [-1,  8.5,  -1],  
                                   [-1,  -1,  -1]])  
  
izostrena_slika = cv2.filter2D(siva_slika, -1, kernel_za_izostravanje)
```

Slika 11. Izoštravanje slike

U ovom koraku izoštravamo sivu sliku, a to radimo tako da prvo definiramo jezgru za oštrinu slike. Nakon toga, korištenjem te jezgre preko druge funkcije izoštravamo sliku. Slika se sprema pod nazivom „izostrena_slika“.

- „np.array()“ je funkcija koja stvara niz, tj. skup podataka istog tipa, u ovom slučaju niz brojeva koji čine matricu
- „cv2.filter2D()“ je funkcija koja primjenjuje linearni filter na matricu piksela. To može biti za uklanjanje šuma, otkrivanje rubova, poboljšanje oštine, itd.

Definiranje jezgre za eroziju i primjena erozije na sliku:

```
jezgra_za_eroziju = np.ones(shape=(12, 13), np.uint8)  
  
erodirana_slika = cv2.erode(izostrena_slika, jezgra_za_eroziju)
```

Slika 12. Erozija slike

Prvo se definira matrica za eroziju (minimum filter) koja ima sve elemente postavljene na vrijednost 1, nakon čijeg definiranja njezinim korištenjem erodiramo sliku. To radi tako da

matrica konvoluirana (prolazi) po slici. Samo ako su svi elementi matrice koji se preklapaju s matricom jednaki 1, tada će se vrijednost tog piksela postaviti na 1; u suprotnom se vrijednost tog piksela postavlja na 0. Slika se sprema pod „erodirana_slika“.

- „np.ones()“ je funkcija za stvaranje matrice s elementima postavljenim na vrijednost 1
- „cv2.erode()“ je funkcija za izvođenje operacije erozije na slici

Pronalaženje svih kontura na slici:

```
konture, _ = cv2.findContours(erodirana_slika, cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)
```

Slika 13. Pronalaženje kontura na slici

U ovom koraku pronalazimo sve konture na erodiranoj slici, te ih pohranjujemo u varijablu „konture“.

- cv2.findContours() je funkcija za pronalaženje kontura na slici
 - „cv2.RETR_EXTERNAL“ definira način pronalaženja kontura (pronalaži samo vanjske konture)
 - „cv2.CHAIN_APPROX_SIMPLE“ je parametar koji utječe na način kako se konture aproksimiraju

Kreiranje crne slike:

```
crna_slika = np.zeros_like(slika)
```

Slika 14. Kreiranje crne slike

Kreira se crna slika koja ima iste dimenzije i oblik kao originalna slika, što znači da je vrijednost svih piksela na toj slici jednaka nuli (crna boja). Sliku spremamo pod nazivom „crna_slika“.

- „np.zeros_like()“ je funkcija koja stvara matricu koja će bit istih dimenzija kao i „slika“ te postavlja vrijednost piksela u njoj na nula

Eliminacija nepotrebnih kontura:

```
for contour in konture:
    površina = cv2.contourArea(contour)
    if 5000 < površina < 10000:
        cv2.drawContours(crna_slika, contours: [contour], -1, color: (0, 0, 255), thickness=cv2.FILLED)
```

Slika 15. Eliminacija nepotrebnih kontura

Prolaskom kroz „for“ petlju i uvjetom „if“ eliminiramo sve nepotrebne konture. Za ovu sliku, područje koje je bilo potrebno za eliminaciju je ($5000 < površina < 10000$); eliminirane su sve konture koje imaju manje od 5000 i više od 10000 piksela površine unutar njih. Površina se gleda kao broj piksela.

- „cv2.drawContours()“ je funkcija za crtanje kontura
 - crtamo konture na crnoj slici i to se „pamti“ u računalu
 - crvene boje - (0, 0, 255)
 - „thickness=cv2.FILLED“ popunjuje cijelu konturu bojom

Dilacija preostalih kontura:

```
dilacijska_jezgra = np.ones((6, 6))
dilacija_rezultat = cv2.dilate(crna_slika, dilacijska_jezgra, iterations=1)
```

Slika 16. Dilacija kontura

Definira se matrica za dilaciju koja ima sve elemente postavljene na vrijednost 1, nakon čega se primjenjuje dilacija na crnoj slici s konturama. Dilacija je operacija koja služi za proširenje područja na slici, u ovom slučaju kontura. Ovo se provodi zato jer se kod erozije područje za crtanje kontura smanjilo, pa ovim procesom malo proširujemo te sužene konture.

- „np.ones()“ je funkcija za stvaranje matrice s jedinicama u njoj
- „cv2.dilate()“ je funkcija za dilaciju; na crnoj slici s konturama, s dilacijskom jezgrom, jednom se provodi proces dilacije

Dodavanje popunjenih kontura na originalnu sliku:

```
segmentirana_slika = cv2.add(slika, dilacija_rezultat)
```

Slika 17. Dodavanje kontura na originalnu sliku

Na kraju nakon cijelog procesa, popunjene konture koje smo dobili lijepimo na originalnu sliku i dobivamo novu sliku „segmentirana_slika“ koja nam prikazuje segmentiranu kralježnicu.

- „cv2.add()“ dodaje popunjene konture na originalnu sliku

Prikaz slika nakon svakog procesa:


```
cv2.imshow( winname: "Originalna slika", slika)
cv2.imshow( winname: "Siva slika", siva_slika)
cv2.imshow( winname: "Izoštrena slika", izostrena_slika)
cv2.imshow( winname: "Erodirana slika", erodirana_slika)
cv2.imshow( winname: "Dilacija", dilacija_rezultat)
cv2.imshow( winname: "Originalna slika s popunjenim konturama", segmentirana_slika)
```

Slika 18. Prikaz slika

- „cv2.imshow()“ prikazuje slike pod imenom koje se definira

4.1.1. Rezultati slike br.1

U nastavku su prikazani rezultati slika nakon obavljenih procesa u kodu. Originalna slika je preuzeta, a sve ostale slike su rezultat obrade te slike.



Slika 19. Rezultati slika nakon procesa slike br.1 [13]

4.2. Segmentacija kralježnice br.2

Originalna slika koja se koristi u ovoj segmentaciji je slika iz znanstvenog rada [14].

Učitavanje slike i konverzija u sivu sliku:

```
slika = cv2.imread("kraljeznica.jpg")
siva_slika = cv2.cvtColor(slika, cv2.COLOR_BGR2GRAY)
```

Slika 20. Učitavanje i konverzija slike u sivu

Definiranje jezgre za eroziju i primjena erozije na sliku:

```
jezgra_za_eroziju = np.ones(shape=(5, 5), np.uint8)
erodirana_slika = cv2.erode(siva_slika, jezgra_za_eroziju)
```

Slika 21. Erozija slike

Thresholdanje slike:

```
_, thresholdana_slika = cv2.threshold(erodirana_slika, thresh: 97, maxval: 255, cv2.THRESH_BINARY)
```

Slika 22. Thresholdanje slike

U ovom procesu thresholda se erodirana slika. Svi pikseli koji na slici imaju vrijednost svjetline piksela ispod 97 postaju potpuno crni (0), a ostali postaju potpuno bijeli (255).

- „cv2.threshold()“ je funkcija za thresholdanje slike
 - „cv2.THRESH_BINARY“ postavlja piksele ispod praga u crno, a iznad praga u bijelo

Pronalaženje svih kontura na slici:

```
contours, _ = cv2.findContours(thresholdana_slika, cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_SIMPLE)
```

Slika 23. Pronalaženje kontura na slici

Kreiranje crne slike:

```
crna_slika = np.zeros_like(slika)
```

Slika 24. Kreiranje crne slike

Eliminacija nepotrebnih kontura:

```
for contour in konture:  
    površina = cv2.contourArea(contour)  
    if 2200 < površina < 3700:  
        cv2.drawContours(crna_slika, contours: [contour], -1, color: (0, 255, 0), thickness=cv2.FILLED)
```

Slika 25. Eliminacija nepotrebnih kontura

Dilacija preostalih kontura:

```
dilacijska_jezgra = np.ones(shape: (4, 4), np.uint8)  
dilacija_rezultat = cv2.dilate(crna_slika, dilacijska_jezgra, iterations=1)
```

Slika 26. Dilacija kontura

Dodavanje popunjenih kontura na originalnu sliku:

```
segmentirana_slika = cv2.add(slika, dilacija_rezultat)
```

Slika 27. Dodavanje kontura na originalnu sliku

Spremanje slike nakon dilacije:

```
cv2.imwrite( filename: "segmentirano.jpg", dilacija_rezultat)
```

Slika 28. Spremanje slike

Spremamo crnu sliku na kojoj su zelene konture pod imenom „segmentirano.jpg“.

- „cv2.imwrite()“ sprema sliku pod dodijeljenim imenom

4.2.1. Rezultati slike br.2

Originalna slika je preuzeta, a sve ostale slike su rezultat obrade te slike. Slika je već bila grayscale, tako da su originalna i siva slika jednake.

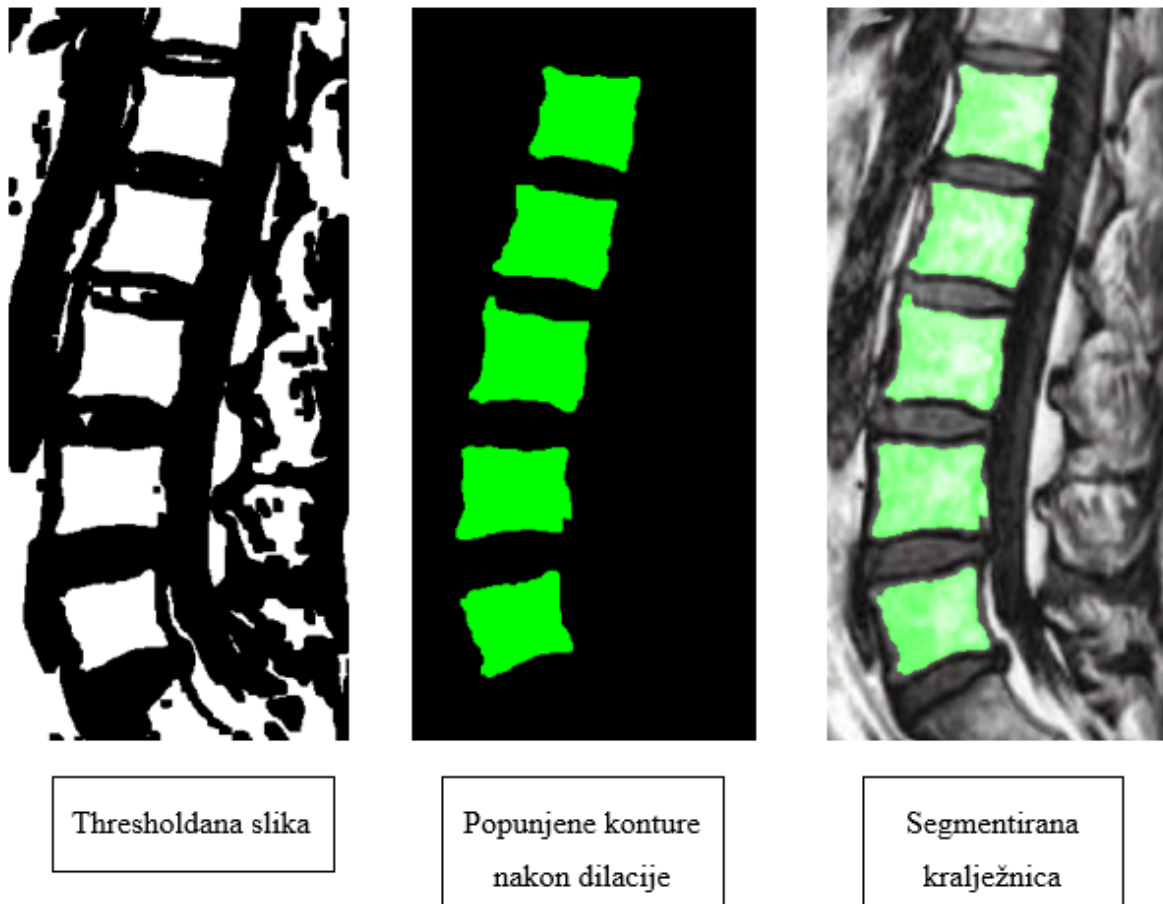


Siva slika



Erodirana slika

Slika 29. Rezultati slika nakon procesa slike br.2 [13]




Slika 30. Rezultati slika nakon procesa slike br.2 - nastavak

4.3. Evaluacija uspješnosti segmentacije

Za provjeru uspješnosti segmentacije koristit će se Dice koeficijent sličnosti. On nam daje sličnost dva modela u postotcima. Rezultat segmentacije slike br.2 biti će uspoređivan.

Segmentacija slike br.2 koja je dobivena ovdje, uz rezultate CNN-a i U-Net-a [14] za tu istu sliku, uspoređeni su sa ground truth rješenjem do kojeg se dolazi tako da liječnik sam to segmentira. Na ovaj način ćemo vidjeti koliko se ustvari dobro može segmentirati korištenjem samo tradicionalnog pristupa (algoritmima obrade slike) u odnosu na State-of-the-art rješenja.



Slika 31. Rezultati segmentacije različitim metodama

Slika „Segmentacija obradom slike“ je segmentacija provedena u poglavlju 4.2.

```
import cv2
import numpy as np

slika1 = cv2.imread(filename: "ground_truth.jpg", cv2.IMREAD_GRAYSCALE)
slika2 = cv2.imread(filename: "u-net.jpg", cv2.IMREAD_GRAYSCALE)

threshold1 = cv2.threshold(slika1, thresh: 127, maxval: 255, cv2.THRESH_BINARY)[1]
threshold2 = cv2.threshold(slika2, thresh: 127, maxval: 255, cv2.THRESH_BINARY)[1]

dice = 2 * np.sum(threshold1 & threshold2) / (np.sum(threshold1) + np.sum(threshold2))

print("Dice similarity coefficient:", dice)
```

Slika 32. Dice similarity coefficient kod

Usporedba metoda sa ground truth:

U-Net: `Dice similarity coefficient: 0.9322` (93.22%)

CNN: `Dice similarity coefficient: 0.8999` (89.99%)

Obrada slike: `Dice similarity coefficient: 0.8642` (86.42%)

Usporedbom Dice koeficijenata vidi se da su već razvijene duboke mreže bolje za segmentaciju. Iako razlika nije velika u odnosu na metodu obrade slike, za tu metodu trebalo je mnogo puta izmijeniti kod i probati ponovno, dok su U-Net i CNN samo učitali slike i segmentirali ih.

Kod segmentacije metodom obrade slika, svaka slika može se tretirati kao jedinstven slučaj budući da nosi svoje specifične karakteristike i izazove. Algoritmi temeljeni na obradi slika često se suočavaju s izazovima, kao što su promjene intenziteta ili raznolikost struktura na medicinskim slikama, što može dovesti do varijacija u rezultatima i ponekad netočnim segmentacijama.

Međutim, važno je napomenuti da to ne bi trebao biti konačan zaključak protiv metode obrade slika. Svaka metoda ima svoje prednosti i mane, i ono što se može smatrati ograničenjima u jednoj slici može se nadoknaditi pravilnim pristupom, poboljšanjima u algoritmima ili kombinacijom s drugim tehnikama.

Napredak u dubokom učenju (deep learning) zasigurno je promijenio pristup segmentacije medicinskih slika. Duboko učenje donosi izvanredne rezultate i postaje standard za mnoge aplikacije u medicinskoj slikovnoj analizi. Međutim, razumijevanje i razmatranje različitih pristupa, uključujući i metode obrade slika, može biti korisno kako bismo bolje razumjeli i iskoristili različite mogućnosti u analizi medicinskih slika.

5. Zaključak

U ovom radu detaljno je razmatrano područje računalnog vida u medicinske svrhe, s posebnim naglaskom na segmentaciju kralježnice na slikama magnetske rezonance primjenom algoritama strojnog vida. Istraživane su različite metode segmentacije, uključujući tradicionalne pristupe obradi slika i duboke neuronske mreže kao moderniju alternativu. Istražen je niz različitih metoda u oba pristupa segmentaciji, uključujući konvolucijske neuronske mreže (CNN), potpuno konvolucijske neuronske mreže (FCN), U-Net, generativne suparničke mreže (GAN), detekciju rubova (Edge detection), i pristup baziran na pragovima (thresholding). Istraživanje je uključivalo segmentaciju dviju različitih kralježnica pomoću različitih metoda obrade slike, a dobiveni rezultati uspoređeni su s postojećim naprednim rješenjima segmentacije. Ova usporedba je izvršena pomoću Dice koeficijenta sličnosti, što je relevantna mjera uspješnosti segmentacije.

Rezultati su pokazali da je tradicionalnim pristupom moguće segmentirati kralježnicu, ali su također potvrdili dominaciju dubokih neuronskih mreža u medicinskom računalnom vidu. Duboke neuronske mreže su se pokazale kao učinkovit alat za obradu MRI snimaka kralježnice, pružajući zadovoljavajuće rezultate i otvarajući perspektivu za daljnja istraživanja u ovom području.

Ovaj rad naglašava važnost istraživanja novih tehnika segmentacije u medicinskom računalnom vidu te istraživanje dubokih neuronskih mreža kao moćnog alata za poboljšanje dijagnostike i tretmana. Iako tradicionalni pristupi i dalje imaju svoje mjesto u obradi slika, duboke neuronske mreže donose inovaciju i mogućnost automatizacije procesa segmentacije. Ovaj rad pruža vrijedne uvide u usporedbu tih metoda i ukazuje na potrebu za daljnjim istraživanjima i primjenama dubokog učenja u medicinskom računalnom vidu.

LITERATURA

- [1] Wang J., Fu P., Gao R. X.: Machine vision intelligence for product defect inspection based on deep learning and Hough transform
- [2] Mahony N., Campbell S., Carvalho A., Harapanahalli S., Hernandez G., Krpalkova L., Riordan D., Walsh J.: Deep Learning vs. Traditional Computer Vision
- [3] Li X., Li M., Yan P., Li G., Jiang Y., Luo H., Yin S.: Deep Learning Attention Mechanism in Medical Image Analysis: Basics and Beyonds
- [4] Garg S., Bhagyashree S. R.: Spinal Cord MRI Segmentation Techniques and Algorithms: A Survey
- [5] Qu B., Cao J. Qian C., Wu J., Lin J., Wang L., Ou-Yang L., Chen Y., Yan L., Hong Q., Zheng G., Qu X.: Current development and prospects of deep learning in spine image analysis: a literature review
- [6] Bhatt D., Patel C., Talsania H., Patel J., Vaghela R., Pandya S., Modi K., Ghayvat H.: CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope
- [7] Li Z., Yang W., Peng S., Liu F.: A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects
- [8] Long J., Shelhamer E., Darrell T.: Fully Convolutional Networks for Semantic Segmentation
- [9] Yin X., Sun L., Fu Y., Lu R., Zhang Y.: U-Net-Based Medical Image Segmentation
- [10] Dumoulin V., Arulkumaran K., Sengupta B., Bharath A.: Generative Adversarial Networks: An Overview
- [11] Mammone A., Turchi M., Cristianini N.: Support vector machines
- [12] Shaik H. A., Rajesh V.: Image Processing based Segmentation Techniques for Spinal Cord in MRI

[13] Wang D., Sun Y., Tang X., Liu C., Liu R.: Deep learning-based magnetic resonance imaging of the spine in the diagnosis and physiological evaluation of spinal metastases

[14] Wang S., Jiang Z., Yang H., Li X., Yang Z.: Automatic Segmentation of Lumbar Spine MRI Images Based on Improved Attention U-Net

[15] <https://nafizshahriar.medium.com/what-is-convolutional-neural-network-cnn-deep-learning-b3921bdd82d5>