

**PREDLOG SISTEMA VEŠTAČKE INTELIGENCIJE ZA POMOĆ U MAMOGRAFSKOJ
DIJAGNOSTICI****A PROPOSAL OF AN ARTIFICIAL INTELLIGENCE SYSTEM FOR ASSISTANCE IN
MAMMOGRAPHY DIAGNOSTICS**

Nikola Jovišić, *Fakultet tehničkih nauka, Novi Sad*

**Oblast – ELEKTROTEHNIČKO I RAČUNARSKO
INŽENJERSTVO**

Kratak sadržaj – Mamografija kao dijagnostička metoda za otkrivanje maligniteta široko je u upotrebi i oslanja se na ekspertsko tumačenje radiologa. U ovom radu istražena je prilika da se takav sistem unapredi veštačkom inteligencijom koja bi predstavljala podršku u donošenju odluka u vezi sa tumačenjem mamografskih snimaka. Istražen je model U-net za segmentaciju tkiva, opisana njegova generalna arhitektura i arhitektura prilagođena za opisani problem, kao i njegova primena na nekim od otvorenih skupova podataka. Opisan je proces i opisani su parametri treniranja modela. Izneseni su i diskutovani rezultati primenjenog modela i sve to sumirano u zaključnom poglavlju.

Ključne reči: mamografija; neuronske mreže; U-net; segmentacija

Abstract – Mammography as a diagnostic method for detecting malignancy is widely used and relies on the expert interpretation of radiologists. In this paper, the opportunity to improve such a system with artificial intelligence, which would represent support in decision-making related to the interpretation of mammographic images, was explored. The U-net model for tissue segmentation is investigated, its general architecture and architecture adapted for the described problem are described, as well as its application to some of the open datasets. The process and the parameters of the training are described. The results of the applied model are presented and discussed and all this is summarized in the concluding chapter.

Keywords: mammography; neural networks; U-net; segmentation

1. UVOD

Kada je reč o bolestima dojke najčešći i vrlo efikasan metod dijagnostike jeste mamografija, tj. snimanje dojke rendgenskim zracima. Korisna je jer je neinvazivna (ne narušava se integritet tkiva tokom samog dijagnostičkog procesa), nije bolna i, uprkos nekim verovanjima, nije štetna.

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Srđan Vukmirović, red. prof.

Ova metoda daje uvid u unutrašnjost dojke i pomaže pri detekciji sumnjivih masa kao što su benigni i maligni tumori i kalcifikacije. Sa ovakvog snimka donosi se bitna odluka o tome da li:

- pacijenta okarakterisati kao zdravog
- pacijentu direktno dijagnostikovati problem
- pacijenta poslati na dalja ispitivanja (magnetna rezonanca (MRI), biopsija i sl.)

Ovakvi pregledi sprovode se ne samo u slučajevima kada lekar posumnja na problem, već i preventivno, pa tako snimici zdravih pacijenata čine dominantan udeo ukupnih mamografskih snimaka.

Problem nastaje jer postoji manjak visokokvalifikovanog medicinskog kadra u Srbiji (mada je problem zastupljen i u ostatku Evrope, pa i sveta) sposobnog za rešavanje ovog tipa zadataka. Velika potreba za istim ima ozbiljne reperkusije na cenu, kvalitet, dostupnost i pogodnost zdravstvenih usluga, pa čak i na morbiditet i mortalitet, a sve jer ne postoji način da se rutinski donose odluke u koje se može verovati.

Da bi se izbegao najgori scenario velikog broj lažnih negativnih izveštaja (oni koji pacijente sa oboljenjem karakterišu kao zdrave) ovakvo stanje rezultuje problemom u praksi da se opcija slanja pacijenata na dodatna ispitivanja dešava relativno često. Pacijenti se šalju u zdravstvene ustanove drugog i trećeg stepena zdravstvene zaštite, odnosno ustanove koje su namenjene za zdravstvenu zaštitu de fakto obolelih pacijenata, iako je ovde zapravo reč o pacijentima kod kojih ništa još nije dijagnostikovano. Ovo značajno preopterećuje te ustanove pacijentima sa lažnim pozitivnim izveštajima (oni koji pacijente bez oboljenja karakterišu kao sumnjive), liste čekanja u njima vrlo su velike i pacijenti često ostaju primorani da se odluče za druge vidove zdravstvene zaštite (lečenje u privatnim ustanovama, lečenje u inostranstvu i sl.) ili, u još težem slučaju, ostaju uskraćeni za bilo kakav vid zdravstvene zaštite. Zdravi pacijenti po pravilu bivaju izloženi velikom stresu dok ne dođu na red za dalja ispitivanja, da bi se stresa oslobodili tek nakon 6-12 meseci kada je on već ostavio posledice, a obolelim pacijentima, koji zbog zdravih moraju čekati isto toliko, problem može dodatno da se zakomplikuje.

Moderni razvoj veštačke inteligencije pruža nove mogućnosti za usavršavanje dijagnostike, naročito u domenu istraživanja segmentacionih mreža, na čemu je zasnovano ovde predloženo rešenje. Jedan sistem veštačke inteligencije zasnovan na obradi slike mogao bi

se razviti u svrhu automatizacije ili poluautomatizacije procesa odlučivanja u dijagnostici oboljenja dojke.

2. UPOTREBA I OBUČAVANJE U-NET MODELA U SEGMENTACIJI SUMNJIVIH MASA NA DOJCI

U-Net je arhitektura neuronske mreže koja se koristi za semantičku segmentaciju slika, odnosno za razdvajanje i klasifikaciju pojedinačnih piksela na slici. Posebno je dizajnirana za obradu medicinskih slika, kao što su snimci magnetne rezonance (MRI) ili snimci rendgenskih zraka. Glavni cilj U-Net modela je precizno razdvajanje objekata i regiona od interesa na slici kako bi se olakšala analiza i interpretacija medicinskih podataka. Ova arhitektura je nazvana U-Net zbog svog oblika koji podseća na latinično slovo "U". Sastoji se od dve glavne komponente: koder (*coder*) i dekoder (*decoder*). Koder se sastoji od nekoliko slojeva konvolucije koji postepeno smanjuju prostornu dimenziju slike i izvlače bitne karakteristike. Dekoder, s druge strane, koristi slojeve koji povećavaju prostornu dimenziju i pomažu u rekonstrukciji segmentirane slike.

Glavna inovacija koju U-Net donosi je upotreba *skip konekcija* (*skip connections*) koje omogućavaju prenos informacija iz koda direktno u dekoder. Ove veze pomažu u obnavljanju detalja i održavaju konteksta informacija koji bi se mogao izgubiti tokom postupka konvolucije. Osim toga, skip konekcije takođe pomažu u prevazilaženju problema gubitka rezolucije koji se često javlja u dubokim neuronskim mrežama. Treba napomenuti da uobičajena U-Net arhitektura koristi funkciju gubitka poznatu kao *softmax* (*softmax*) koja omogućava klasifikaciju svakog piksela na slici. Ova funkcija gubitka pomaže u optimizaciji mreže kako bi se postigla što preciznija segmentacija. U-Net se pokazao veoma uspešnim u mnogim medicinskim aplikacijama, uključujući segmentaciju tumora, identifikaciju organa i analizu histoloških snimaka. Njegova sposobnost za preciznu segmentaciju i očuvanje konteksta informacija čini ga vrlo korisnim alatom za medicinske stručnjake u procesu dijagnostike i tretmana.

Kako različiti vidovi segmentacije (semantička, panoptička i sl.) imaju slične zahteve koji se tiču same arhitekture (eventualno je potrebno promeniti broj kanala izlaza) slična arhitektura može da se koristi za različite zadatke.

Konkretno, odlučeno je da se za segmentaciju sumnjivih masa na dojci koristi VGG16 arhitektura. Za enkoder deo preuzet je VGG16 iz Keras biblioteke sa *ImageNet* težinama.

Za prilagođavanje ovom modelu je bilo potrebno postojeće *grayscale* slike pretvoriti u trokanalne, a što je ostvareno konkateniranjem istog kanala kroz sva tri. Dimenzije ulazne (a, po prirodi arhitekture U-Net, dakle, i izlazne) slike su 224x224. Kako su dimenzije slika u skupu podataka raznovrsne i značajno veće od toga (neke prelaze i dimenzionalnost od 5000) sve su umanjene na ovu veličinu.

Dekoder je ručno kreiran, sa skip-konekcijama. Podeljen je u pet blokova koji koriste 2D konvolucione slojeve sa veličinom kernela 3x3.

Odgovarajućim preprocesiranjem svi snimci i sve korespondentne maske dovedene su u stanje pogodno za konzumiranje od strane modela.


- podaci su podeljeni u 1124 para slika-maski za trening i 343 para slika-maski za testiranje
- primenjene su tehnike uvećavanja-augmentacije skupa (*data augmentation*) - vertikalno i horizontalno obrtanje (*flip*) i promena osvetljenosti (*brightness*), dok su neke druge augmentacije kao što su izduživanje slike izostavljene jer nisu verna simulacija promene u odnosu na originalni skup podataka na koju bi model mogao da naiđe u realnoj upotrebi
- kao metrika za evaluaciju modela primarno je korišćen količnik preseka i unije predviđene i istinite maske (*IoU – intersection over union*) koja je uobičajena metrika u segmentacionim zadacima
- trening je ograničen na 50 epoha
- koristeći *Keras early stop* mehanizam, uz parametar strpljivosti 5 trening je zaustavljen i pre dostizanja ograničenja od 50 epoha, tj. kada 5 epoha za redom u odabranoj metrici više nije bilo napretka
- funkcija cilja (*loss function*) koja je optimizovana u procesu treniranja je binarna unakrsna entropija (*binary cross-entropy*) koja je uobičajena kod binarnih klasifikacionih problema, a što upravo semantička segmentacija na dve klase („jeste“ i „nije“ sumnjiva masa) i jeste – klasifikacija piksela na dve klase
- trening je sproveden na *Huawei Ascend NPU (neural processing unit)* jedinicama
- veličina grupe (*batch size*) za trening je 10
- parametar verovatnoće za ispuštanje (*dropout*) je postavljen na 0.5
- optimizator za optimizaciju parametara U-net mreže koji je iskorišten je ADAM
- tempo obučavanja (*learning rate*) je postavljen na 0.0001
- u treningu, po završetku svake epohe, sačuvan je onaj model koji se pokazao bolje od prethodnog najboljeg po odabranoj metrici i kao konačni proglašen je poslednji – najbolji model

3. REZULTATI I DISKUSIJA

Na slikama prikazani su primeri izlaza iz U-net modela. Levo se nalazi preprocesiran snimak dojke koji je upotrebljen kao ulaz u model, u sredini anotaciona maska za dati primer iz test skupa i desno izlaz iz U-net modela u vidu meke maske (*soft mask*).

Primećuje se da model prilično dobro pronalazi sumnjive mase i da je učestalost lažnih negativnih regiona veoma mala što je veoma bitno. Model dodatno pronalazi neke mase koje u anotaciji nisu naznačene. Manuelnom inspekcijom od strane radiologa, zaključeno je da su tu u pitanju neke benigne mase, kalcifikati, fibrozno tkivo i sl. što u anotaciji nije naznačeno.

Ova pojava lažnih pozitivnih u ovoj fazi nije mnogo problematična jer, u upotrebi modela kao asistencije pri anotaciji vrlo je jednostavno odbaciti objekte (maske, poligone) za koje lekar smatra da nisu potrebni. U produkcionoj fazi, sa druge strane, svakako bi bio razvijan dodatni model za klasifikaciju svake od pronađenih instanci i instance koje nisu od interesa bivale bi odbacivane tada.



Slika 1. Primeri izlaza U-net modela

Tačnost ovog modela iznosi 99%, ali značajnije od ove metrike, kako je na izlazu uvek velik broj piksela pozadine i naivnom predikcijom čitave slike kao pozadine dobijala bi se visoka tačnost, metrika količnika preseka i unije (*IoU – intersection over union*) iznosi 0.25 na test skupu.

Iako nije u pitanju velika vrednost, ova vrednost metrike je zadovoljavajuća uzimajući u obzir da su u pitanju meke

maske i da model pronalazi dodatne mase koje, kao što je rečeno, nisu problematične.

4. LITERATURA

[1] Ciritsis A, Rossi C, Vittoria De Martini I, Eberhard M, Marcon M, Becker AS, Berger N, Boss A. Determination of mammographic breast density using a deep convolutional neural network. *Br J Radiol.* 2019 Jan;92(1093):20180691. doi: 10.1259/bjr.20180691. Epub 2018 Oct 1. PMID: 30209957; PMCID: PMC6435091.

[2] <https://www.kaggle.com/competitions/rsna-breast-cancer-detection/>

[3] R.N.J. Graham, R.W. Perriss, A.F. Scarsbrook, DICOM demystified: A review of digital file formats and their use in radiological practice, *Clinical Radiology*, Volume 60, Issue 11, 2005, Pages 1133-1140, ISSN 0009-9260

[4] <https://www.kaggle.com/code/theoviel/breast-density-classification-using-monai>

[5] Vikash Gupta, Mutlu Demirer, Robert W. Maxwell, Richard D. White, Barbaros Selnur Erdal: "A multi-reconstruction study of breast density estimation using Deep Learning", 2022; [<http://arxiv.org/abs/2202.08238> arXiv:2202.08238]

[6] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich: "Going Deeper with Convolutions", 2014; [<http://arxiv.org/abs/1409.4842> arXiv:1409.4842]

[7] Pablo Fonseca, Julio Mendoza, Jacques Wainer, Jose Ferrer, Joseph Pinto, Jorge Guerrero, Benjamin Castaneda, "Automatic breast density classification using a convolutional neural network architecture search procedure," *Proc. SPIE 9414, Medical Imaging 2015: Computer-Aided Diagnosis*, 941428 (20 March 2015); doi: 10.1117/12.2081576

[8] Ciritsis A, Rossi C, Vittoria De Martini I, Eberhard M, Marcon M, Becker AS, et al. Determination of mammographic breast density using a deep convolutional neural network. *Br J Radiol* 2019; 92: 20180691.

[9] Shen, L., Margolies, L.R., Rothstein, J.H. et al. Deep Learning to Improve Breast Cancer Detection on Screening Mammography. *Sci Rep* 9, 12495 (2019). <https://doi.org/10.1038/s41598-019-48995-4>

[10] Alexander Kirillov, Eric Mintun, Nikhila Ravi, Hanzi Mao, Chloe Rolland, Laura Gustafson, Tete Xiao, Spencer Whitehead, Alexander C. Berg, Wan-Yen Lo, Piotr Dollár, Ross Girshick: "Segment Anything", 2023; [<http://arxiv.org/abs/2304.02643> arXiv:2304.02643]

[11] Jun Ma, Bo Wang: "Segment Anything in Medical Images", 2023; [<http://arxiv.org/abs/2304.12306> arXiv:2304.12306]

[12] Olaf Ronneberger, Philipp Fischer, Thomas Brox: "U-Net: Convolutional Networks for Biomedical Image Segmentation", 2015; [<http://arxiv.org/abs/1505.04597> arXiv:1505.04597]

[13] <https://towardsdatascience.com/active-learning-overview-strategies-and-uncertainty-measures-521565e0b0b>

Kratka biografija:



Nikola Jovišić rođen je 14.03.2000. u Beogradu. Završio je Srednju medicinsku školu „Dr Ružica Rip“ u Somboru i osnovne akademske studije na Fakultetu Tehničkih nauka u Novom Sadu, smer Računarstvo i automatika. Ispunio je sve obaveze i položio je sve ispite predviđene studijskim programom.