



PRIMENA ALGORITAMA MAŠINSKOG UČENJA U OFTAMOLOŠKOJ ANALIZI SLIKA OKA KOD PREVREMENO ROĐENIH BEBA

MACHINE LEARNING ALGORITHMS IN OFTALMOLOGY OF PREMATURELY BORN BABIES

Jovana Jovanović, *Fakultet tehničkih nauka, Novi Sad*

Oblast – SOFTVERSKO INŽENJERSTVO I INFORMACIONE TEHNOLOGIJE

Kratak sadržaj – *Ovaj rad daje uvid u algoritme mašinskog učenja koji se mogu koristiti za detekciju Retinopatije kod prevremeno rođenih beba. Za rešavanje problema upotrebljene su konvolutivne neuronske mreže. Izvršena je analiza dobijenih rezultata upotrebom ResNet50, Xception i InceptionV3 modela. Na osnovu izvršenih analiza se došlo do zaključka da skup podataka koji je korišćen nije dobar i da treba da se popravi.*

Ključne reči: *Retinopatija kod prevremeno rođenih beba, konvolutivne neuronske mreže*

Abstract – *This paper provides insight into machine learning algorithms that can be used to detect Retinopathy of prematurity. Convolutional neural networks were used to solve the problem. The analysis of the obtained results was performed using ResNet50, Xception and InceptionV3 models. Based on the performed analyzes, it was concluded that the data set used was not good enough and needed to be corrected.*

Keywords: *Retinopathy of prematurity, Convolutional neural network*

1. UVOD

Retinopatija kod novorođenčadi (ROP) je očno oboljenje koje se javlja kod prevremeno rodene dece i u najtežem obliku može da dovede do potpunog gubitka vida. Jedna je od vodećih uzroka gubitka vida kod dece. Svake godine 50000 beba u svetu izgubi vid zbog ove bolesti [1]. Nema simptoma kada se prvi put razvije. Može se otkriti samo tokom pregleda kod oftamologa. Rano otkrivanje ove bolesti je od velikog značaja.

Rad se bavi problemom detekcije ROP-a. Izabrano je da se problem reši upotrebom veštakе inteligencije (*eng. Artificial intelligence*), koja je se sve više koristi u medicini. Međutim, iako se ove metode sve više koriste, još uvek postoji strah da su metode zasnovane na AI skljone greškama i osjetljive na greške u podacima. Generalno, nisu tako dobre kao medicinski stručnjaci [2]. Ipak, one se smatraju budućnošću kliničke dijagnostike u oblasti oftamologije i medicine uopšte [3].

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Dragan Dinu, docent.

Na osnovu prethodnih radova na ovu temu [4, 5, 6], izabran je podskup metoda mašinskog učenja koje su dale najbolje rezultate. Odabrane su konvolutivne neuronske mreže za koje se smatra da su trenutno najperspektivnije za problem detekcije. Tri neuronske mreže koje su odabrane su *ResNet50*, *Xception* i *InceptionV3* model.

Cilj ovog rada je da se primenom izabranih modela mašinskog učenja, odredi koji od njih najbolje klasificuje podatke iz skupa ulaznih oftalmoloških slika.

2. OFTAMOLOGIJA

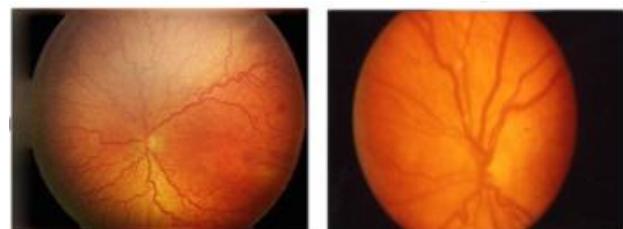
Naziv oftamologija potiče od latinskih reči *Ophthalmos*, odnosno oko i *logos*, što u prevodu znači nauka. Takođe, oftamologija je grana medicine koja se bavi proučavanjem ljudskog oka, njegovom anatomijom, funkcijom i bolestima.

Čulo vida je jedno od najbitnijih čula kod čoveka, jer nam daje informacije o spoljašnjem svetu i omogućava nam kvalitetniji život. Uzroci gubitka vida razlikuju se u odnosu na to koliko je neka država razvijena.

2.1 Retinopatija kod dece

ROP (*Slika 1*) je identifikovan kao glavni uzrok slepila kod dece. Kod prevremeno rođenih beba krvni sudovi mrežnjače se ne razvijaju u potpunosti.

ROP je oboljenje koje se odlikuje abnormalnim rastom krvnih sudovi, koji mogu da izrastu iz mrežnjače i prouzrokuju stvaranje ožiljnog tkiva, što dovodi do odvajanje mrežnjače. Ukoliko se ne nadgleda i ne leči u tačno vreme, može prouzrokovati gubitak vida [7].



Slika 1. ROP

3. METODOLOGIJA

U ovom poglavlju je dat kratak opis osnovnih teorijskih pojmove neophodnih za razumevanje korišćenih tehnika.

3.2 Neuronske mreže

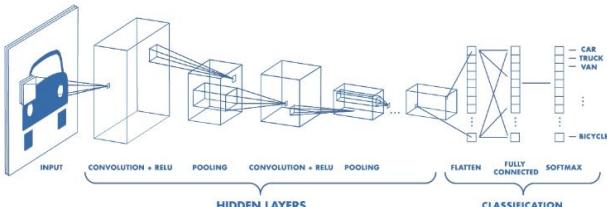
Neuronske mreže su skup algoritama inspirisanih funkcionalnim biološkim neuronskim mrežama mozga, pa se zbog toga nazivaju i veštačkim neuronskim mrežama (*Artificial Neural Network*) [8]. Ova vrsta mreža se sastoji od slojeva u kojima se nalaze neuroni, odnosno čvorovi [9]. Neuroni jednog sloja su povezani sa neuronima iz drugog sloja. Svaki sloj čvorova trenira se na različitom skupu karakteristika, na osnovu rezultata dobijenih u prethodnom sloju. Što se više napreduje sa istraživanjem u oblasti neuronskih mreža, to čvorovi mogu da prepoznaju sve složenije karakteristike, jer objedinjuju i rekombinuju karakteristike iz prethodnog sloja.

3.1 Konvolutivne neuronske mreže

Konvolutivne neuronske mreže su vrsta neuronskih mreža, koje se najčešće primenjuju za analizu vizuelnih slika. Koriste se za detekciju objekata, prepoznavanje lica, klasifikaciju slika i mnoge druge stvari [10].

Konvolutivne neuronske mreže imaju mogućnost hvatanja prostornih i vremenskih zavisnosti na slici primenom filtera i upotrebo operacije konvolucije. Filter je matrica brojeva, koja se prevlači po slici od gornjeg levog ugla ka donjem desnom uglu. Za svaku tačku na slici, izračunava se vrednost na osnovu filtera pomoću operacije konvolucije.

Upotreba filtera i operacije konvolucije smanjuje broj parametara koje neuronske mreža treba da nauči, a omogućava i da se lokacija karakteristika koje se izdvajaju sa slike promeni.



Slika 2. Arhitektura konvolutivne neuronske mreže

Konvolutivne neuronske mreže se sastoje iz dve glavne komponente (Slika 2):

1. Komponenta za učenje karakteristika - u ovom delu mreže se izdvajaju bitne karakteristike slike, kao što su ivice, oblici, linije.
2. Klasifikacija - sastoji se od potpuno povezanih slojeva. Služi za dodeljivanje verovatnoća onoga što algoritam predviđa.

4. IMPLEMENTACIJA

U ovom poglavljiju dat je osvrt na rešenje postavljenog zadatka, odnosno primena algoritama nad određenim skupom podataka. Kada se rešavaju problemi mašinskog učenja potrebno je odrediti sledeće stvari:

1. Prikupiti ili pronaći skup podataka za problem koji se rešava.
2. Odlučiti se koje algoritme mašinskog učenja koristiti za rešavanje problema.
3. Evaluirati dobijene rezultate.

4.1 Skup podataka

Da bi metode mašinskog učenja bolje „naučile“ željene modele i/ili ponašanje, potrebno je posedovati što veću količinu podataka. Prvi bitan korak koji je potrebno preduzeti jeste formirati skup podataka koji će se koristiti za obučavanje algoritama. Skup podataka se sastoji od parova ulaznih i izlaznih vrednosti, gde će ulazne vrednosti da budu slike, a izlazne klase kojoj slika pripada. Postoje dve klase, a to su detektovan je ROP i nema ROP-a.

U ovom radu su korišćena dva skupa podataka, nazvaćemo ih skup A i skup B. Skup B predstavlja modifikovani skup A. Sve slike su dobijene pomoću širokokutnog uređaja za snimanje, poznatog kao RetCam. Slike su prikupljene u bolnicama u Srbiji. Rezolucija slika je 640x480 piksela. Skup A se sastoji od 6021 slike, od toga 4448 slika koje pripadaju klase da ima ROP-a i 1573 slike iz suprotne klase. Skup podataka B, kako je već rečeno je malo promenjen i ima 7231 sliku, od toga 4601 sliku sa ROP-om i 2630 slika na kojima nije dijagnostikovana bolest.

Da bi se uspešno obučio i evaluirao model, skupovi podataka su podeljeni na 2 celine, a to su trening skup i test skup, u razmeri 80:20. Trening skup je dalje podeljen i na validacioni u razmeri 25% validacioni skup i 75% trening skup. Za podelu trening skupa korišćena je tehnika stratifikacije, da bi na ravnomeran način u oba skupa bio srazmeran broj instanci obe klase.

Zbog ograničenih resursa u pogledu memorije, podaci su učitavani u paketima (batch-evima) od po 64 slike. Takođe, sve slike su smanjene na veličinu od 240x320 piksela i normalizovane su, vrednosti boja na slici su svedene u raspon od 0 do 1.

4.1 Konvolutivne neuronske mreže

Modeli konvolutivnih neuronskih mreža koje su korišćene u ovom radu su izabrani na osnovu prethodnih radova koji su napisani na ovu temu.

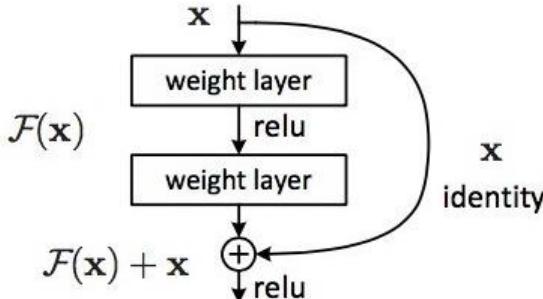
4.1.1 Rezidualne neuronske mreže

Rezidualne neuronske mreže ili skraćeno ResNet su specifična vrsta neuronskih mreža. Predstavljaju veoma duboke neuronske mreže, koje koriste rezidualne konekcije [11].

Rezidualna mreža ima arhitekturu konvolutivne neuronske mreže, koja može da podrži stotine ili više konvolutivnih blokova i blokova identiteta.

Rešavaju problem gradijenta koji nestaje. Neuronske mreže se treniraju putem povratnog širenja, koje se oslanja na gradijentni spust da bi se pronašle optimalne težine koje minimiziraju funkciju gubitka. Kada se doda više slojeva, ponovljeno množenje njihovih derivata na kraju čini gradijent beskrajno malim, što znači da dodatni slojevi neće poboljšati performanse ili ih čak smanjiti.

Svi blokovi u mreži, konvolutivni ili blokovi identiteta su rezidualni blokovi, a primer jednog rezidualnog bloka može se videti na slici Slika 3.



Slika 3. Prikaz jednog rezidualnog bloka

Rezidualni blokovi sadrže vezu koja preskače slojeve između, koja je poznata kao veza preskakanja i ona čini jezgro preostalih blokova [11]. Zbog ove veze izlaz iz sloja nije isti.

U radu je korišćen ResNet50 model ovih mreža. On sadrži 50 slojeva.

4.1.2 Xception

Xception je duboka konvolutivna neuronska mreža, koja uključuje dubinski razdvojene konvolucije (eng. Depthwise Separable Convolutions). Razvijena je od strane Google istraživača.

Mreža se sastoji iz tri toka, ulazni, srednji i izlazni. Podaci prvo prolaze kroz ulazni tok, zatim ulaze kroz srednji tok i kroz njega teku osam puta, na kraju prolaze kroz izlazni tok. Svaki sloj konvolucije i odvojene kovolucije (eng. SeparableConvolution layers) praćen je sa normalizacijom [12].

4.1.3 InceptionV3

InceptionV3 je treća verzija konvolutivnih neuronskih mreža razvijenih od strane Google-a. Sastoji se od 11 početnih modula, gde se svaki modul sastoji od slojeva grupisanja i konvolutivnih filtera sa ispravljenim linearnim jedinicama kao funkcijom aktivacije [13].

4.2 Obučavanje

Obučavanje se radi nad instancama trening skupa. Jedna obrada svih instanci se naziva epoha. Obučavanje se sastoji od 4 koraka, a to su:

1. Kreiranje inicijalnog stanja modela neuronske mreže
2. Izračunavanje izlaza za instancu ulaznih podataka
3. Ocenjivanje dobijenih izlaza
4. U ovom koraku sve zavisi od dobijenog izlaza. Ukoliko je izlaz dovoljno tačan, onda je kraj, u suprotnom se prelazi na narednu instancu podataka i ponavlja se korak 2.

Modeli su kreirani upotrebom Keras biblioteke. Ukinut je poslednji sloj i dodati su novi slojevi. Dodat je jedan sloj za grupisanje da bi se smanjio broj parametara, ravan sloj (Flatten layer), da bi podaci bili pogodniji za klasifikaciju. Zatim su stavljena dva potpuno povezana sloja sa ReLu kao funkcijom aktivacije i još jedan sa softmax funkcijom i oni predstavljaju deo za klasifikaciju. Nakon što se postavi inicijalno stanje modela i dobije rezultat za jednu instancu iz skupa podataka, potrebno je oceniti koliko je rezultat zadovoljavajući. Ova ocena se naziva funkcija gubitka (eng. loss function) i direktno utiče na sposobnost modela da "nauči", bez obzira na to koji algoritam za ažuriranje stanja se koristi. Zato je bitno adekvatno obrazovati funkciju gubitka. Pošto je problem klasifikacione prirode iskorišćena je Cross entropy funkcija. Nakon odabira funkcije gubitka, potrebno je odabrati odgovarajući algoritam za učenje.

Ovaj deo se zove i optimizacija modela i ima za cilj pronašetak ekstrema funkcije gubitka. Za funkciju optimizacije upotrebljena je funkcija RMSProp, zato što bira različit korak učenja za svaki parametar. Takođe, pored funkcije optimizacije potrebno je odrediti i korak učenja, koji predstavlja konstantu koja određuje brzinu učenja same mreže. Promena koraka učenja rađena je po principu povratnog poziva (eng. Callback), upotrebom metode ReduceLROnPlateau, koja menja brzinu učenja kada se detektuje da nema promena za dati broj epoha u obučavanju.

5. REZULTATI

U ovom poglavlju predstavljeni su rezultati dobijeni primenom izabranih modela konvolutivnih neuronskih mreža nad A i B skupom podataka. U tabeli *Tabela 1* su prikazani rezultati za svaki model pojedinačno. Za merenje performansi modela iskorišćeni su tačnost, F1 mikro mera i funkcija gubitka. Tačnost predstavlja delić predviđanja koje je model uspešno klasifikovao. F1 mikro mera predstavlja koji procenat pozitivnih predviđanja je tačan.

Na osnovu prikazanih podataka može se zaključiti da modeli daju bolje performanse za skup podatka A, što znači da povećanjem instanci podataka u skupu B, modeli nisu uspeli da povećaju svoju efikasnost, kao što je bilo očekivano.

Nad skupom podataka A, ResNet50 model ima najbolju tačnost i F1 meru, ali i najveću funkciju gubitka, pa je zbog toga model sa najboljim performansama za skup A, InceptionV3 model.

Nad skupom B najbolje se pokazao Xception model. Kada se obuhvate rezultati za oba skupa, model sa najboljim performansama je Xception,

Tabela 1. Prikaz dobijenih rezultata (vrednosti su izražene u %)

	Skup A			Skup B		
	ResNet50	Xception	InceptionV3	ResNet50	Xception	InceptionV3
Tačnost	76	74.9	75	69	72	70
F1 mikro mera	76	74.9	75	69	72	70
Funkcija gubitka	54	53.7	53.6	60	57	59

6. ZAKLJUČAK

U ovom radu koriste se metode mašinskog učenja za detekciju ROP bolesti nad dva skupa podataka. Za rešavanje problema, upotrebljena su tri modela kovolutivnih neuronskih mreža, ResNet50, Xception i InceptionV3.

Tabela 2. Klasifikacioni izveštaj dobijen primenom Xception modela nad skupom A (vrednosti izražene u %)

	Preciznost	Odziv	F1 mera	Broj instanci u skupu
0	0.53	0.42	0.47	314
1	0.81	0.87	0.84	889
Tačnost			0.75	1203

Dobijeni rezultati nastali evaluacijom modela nad testnim skupovima prikazani su u delu o rezultatima. Xception model se najbolje pokazao od svih modela, ali kada se detaljno pregleda izveštaj klasifikacije prikazan u tabelama *Tabela 2* i *Tabela 3*, na osnovu odziva može se zaključiti da jako loše klasificuje slike koje nemaju ROP.

Pokušano je da se problem reši dodavanjem novih slika koje nemaju ROP u skup podataka B, ali kako je prikazano u tabeli *Tabela 3* problem nije rešen. Pa se na osnovu toga zaključuje da je potrebno ispraviti skup podataka.

Takođe, skupovi podataka su labelirani od strane jednog oftamologa, što nije dobro, jer postoji samo jedno mišljenje. Za buduće radove sa prikazanim skupovima podataka, potrebno je prvo srediti podatke.

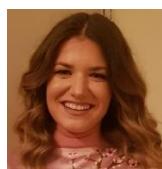
Tabela 3. Klasifikacioni izveštaj dobijen primenom Xception modela nad skupom B (vrednosti izražene u %)

	Preciznost	Odziv	F1 mera	Broj instanci u skupu
0	0.78	0.34	0.47	526
1	0.71	0.95	0.81	920
Tačnost			0.71	1446

7. LITERATURA

- [1] O. D. Saugstad, „Oxygen and retinopathy of prematurity,“ *Journal of Perinatology* , pp. S46-S50, 2006.
- [2] M. A. Zarbin, „Artificial Intelligence: Quo Vadis?“ *Translational Vision Science & Technology*, t. 9, pp. 1-1, 2020.
- [3] J. A. H. a. D. T. Azar, „The AI Revolution and How to Prepare for It,“ *Translational Vision Science & Technology*, t. 9, pp. 16-16, 2020.
- [4] R. J. Y. C. L. Z. J. H. Y. W. W. D. J. Z. Z. Y. Jianyong Wang, „Automated retinopathy of prematurity screening using deep neural networks,“ *EBioMedicine*, 2018.
- [5] Y. C. J. Z. R. J. Z. Y. F. I. Junjie Hu, „Automated Analysis for Retinopathy of Prematurity by Deep Neural Networks,“ *Translations on Medical Imaging*, 2019.
- [6] W. L. Q.-q. D. C. C. a. Y. S. Yan Tong, „Automated identification of retinopathy of prematurity by image-based deep learning,“ *Eye and Vision*, 2020.
- [7] N. S. A. O. D. S. A. S. J. K. Sanja Knežević, „Analysis of Risk Factors in the Development of Retinopathy of Prematurity,“ 2011.
- [8] L. Hardesty, „Neural Networks,“ 4 April 2017. [Na mreži]. Available: <https://news.mit.edu/2017/explained-neural-networks-deep-learning-0414>. [Poslednji pristup 10 September 2020].
- [9] C. Nicholson, „A Beginner's Guide to Neural Networks and Deep Learning,“ Pathmand, [Na mreži]. Available: <https://wiki.pathmind.com/neural-network#element>. [Poslednji pristup 10 September 2020].
- [10] M. Stewart, „Simple Introduction to Convolutional Neural Networks,“ Towrds Data Science, 17 Feb 2019. [Na mreži]. Available: <https://towardsdatascience.com/simple-introduction-to-convolutional-neural-networks-cdf8d3077bac>. [Poslednji pristup 10 September 2020].
- [11] H. Mujtaba, „Introduction to Resnet or Residual Network,“ 9 Sep 2020. [Na mreži]. Available: <https://www.mygreatlearning.com/blog/resnet/>. [Poslednji pristup 16 September 2020].
- [12] F. Chollet, „Xception: Deep Learning with Depthwise Separable Convolutions,“ *Computer Vision and Pattern Recognition*, 2016.
- [13] S.-H. Tsang, „Review: Inception-v3 — 1st Runner Up (Image Classification) in ILSVRC 2015,“ 10 Sep 2018. [Na mreži]. Available: <https://medium.com/@sh.tsang/review-inception-v3-1st-runner-up-image-classification-in-ilsvrc-2015-17915421f77c>. [Poslednji pristup 16 September 2020].

Kratka biografija:



Jovana Jovanović rođena je u Zvorniku 1996. god. Master rad na Fakultetu tehničkih nauka iz oblasti Softversko inženjerstvo i informacione tehnologije, odbranila je 2020. godine.
kontakt: jovana.jovanovic@uns.ac.rs