

Detekcija i klasifikacija tumora na mozgu

Korišćenjem EfficientNet V2 B0 modela i integracija sa mobilnom aplikacijom

Luka Jeremić

Univezitet Donja Gorica
Podgorica, Crna Gora

Abstract— Cilj ovog istraživačkog rada je istražiti mogućnost detekcije i klasifikacije tumora na mozgu s visokom preciznošću. U tu svrhu, u radu se koristi transfer learning metoda i fokusira se na korišćenje EfficientNet V2 B0 modela, koji je poznat po izuzetnoj efikasnosti i rezultatima u području kompjuterske vizije. Pored analize EfficientNet V2 B0 modela, ovaj rad će takođe opisati razvoj aplikacije koja omogućava korisnicima da na jednostavan način detektuju i klasifikuju tumore na mozgu. Aplikacija je implementirana u React Native okruženju, pružajući intuitivno korisničko iskustvo i brzu obradu slika.

Aplikacija je dizajnirana da korisniku omogući da jednostavno snimi sliku CT skena tumora na mozgu putem mobilnog uređaja. Nakon snimanja slike, aplikacija prosljedi sliku modelu EfficientNet V2 B0 radi procjene i klasifikacije tumora. Ovaj korak se oslanja na transfer learning, gdje prethodno obučeni EfficientNet V2 B0 model koristi svoje znanje sa velikog skupa slika kako bi izvršio preciznu klasifikaciju na novoj slici.

Kombinacija EfficientNet V2 B0 modela i razvijene aplikacije omogućava korisnicima brz pristup dijagnostičkim rezultatima i mogućnost praćenja tumora na mozgu. Ova tehnologija ima potencijal da značajno unaprijedi procese dijagnostike i donošenja odluka u medicinskim ustanovama, smanjujući vrijeme čekanja i pružajući tačnije rezultate.

Ovaj rad će detaljno istražiti rezultate i performanse EfficientNet V2 B0 modela u detekciji i klasifikaciji tumora na mozgu, kao i procijeniti praktičnu primjenjivost razvijene aplikacije u stvarnim scenarijima zdravstvene njege. Ovaj rad ima za cilj da doprinese razumijevanju mogućnosti primjene dubokog učenja u oblasti medicinske dijagnostike i pružiti korisne smjernice za dalja istraživanja i razvoj.

Keywords-*component; model; detekcija; tumor; biomedicina; Preciznost; transfer-learning; efficientNet V2 B0; medicinska slika; efikasnost; CT sken; dijagnostika;*

I. UVOD

Tumori mozga su nenormalan rast ćelija koji se dešava u mozgu ili oko maramice oko mozga[1]. Oni mogu biti značajan izazov zbog njihove prirode da izazovu komplikacije i poremećaj normalnih funkcija[1]. Rana detekcija može imati ključnu ulogu u liječenju tumora. Otkrivanje tumora mozga u ranoj fazi pruža priliku za više opcija liječenja. Omogućava medicinskim stručnjacima da istraže bolje pristupe, kao što su hirurška resekcija, terapija zračenjem, hemoterapija, ciljane terapije i imunoterapije[2]. U suštini kada možemo da

detektujemo da li postoji tumor rano mnogo je veća vjerovatnoća da ćemo i uspješno izliječiti pacijenta. Takođe je neophodno da pravilno klasifikujemo tumor da bi pacijent primio odgovarajuću terapiju. Doktori i medicinski stručnjaci mogu da procjene koji je tumor sa određenom stopom sigurnosti. U ovom slučaju bi dobro bilo da doktori imaju objektivnu pomoć vještačke inteligencije. To ne znači da treba samo na nju se osloniti već da ona služi kao pomoć odnosno još jedna perspektiva.

II. MATERIALS AND METHODS

A. Dataset

Dataset je preuzet online sa već postojećim slikama koje su anotirane. On se sastoji više kategorija tumora. U svakoj kategoriji postoji više desetina i stotina slika. Skup podataka je organizovan u različite kategorije tumora, od kojih svaka predstavlja specifičan tip tumora na mozgu. Ove kategorije mogu uključivati uobičajene tipove tumora kao što su astroцитom, ependimom, gangliogliom, meduloblastom, meningiom, neuroцитom, papiloma, švanom i drugi. Pored toga, skup podataka može uključivati kategoriju za normalne slike mozga koja služi kao referenca za poređenje. Izabrao sam ovaj dataset jer ima raznih slika tumora na mozgu, koji obuhvataju različite kategorije tumora i obuhvataju varijacije u veličini tumora, lokaciji i modalitetima snimanja.

III. ARHITEKTURA I INEGRACIJA MOBILNE APLIKACIJE I MODELA

Nakon što se identifikuje problem i dataset koji će se koristiti za problem neophodno je da se opišu koraci za pravljenje modela. Na početku dataset je podijeljen u train, test i validacione podatke. U datasetu za trening je 800 podataka, u validacionom 187 i u testnom 281. Sledeći korak je augmentacija slike. Povećanje podataka o slici je tehnika koja se obično koristi u zadacima mašinskog učenja i kompjuterskog vida, uključujući klasifikaciju slika, kako bi se poboljšale performanse i sposobnost generalizacije modela[3]. To uključuje primjenu različitih transformacija ili modifikacija na postojeće slike za obuku da bi se kreirale nove, proširene verzije podataka[3]. Neke od prednosti su: povećana robusnost, poboljšana generalizacija modela. ublažavanje neravnoteže klasa, smanjenje preopterećenja... Sada je neophodno definišemo arhitekturu mreže i koje model da izaberemo. Kao što sam već naveo izabrao sam EfficientNet V2 model i samim tim se radi transfer learning.

A. *Transfer Learning:*

Transfer learning je tehnika u mašinskom učenju i dubokom učenju koja koristi znanje stečeno iz unaprijed obučanih modela za rešavanje novih zadataka ili domena[4]. To uključuje korišćenje unaprijed obučanog modela, koji je obučan na velikom skupu podataka za drugačiji, ali povezan zadatak, kao polaznu tačku za obuku novog modela na ciljnom zadatku ili skupu podataka[4]. U kontekstu kompjuterskog vizije, transfer learning je promijenio ovu oblast tako što je omogućilo razvoj tačnih i efikasnih modela čak i sa ograničenim označenim podacima. Umjesto da obučavamo duboku neuronsku mrežu od nule, što može biti računarski skupo i dugotrajno, učenje transfer learning nam omogućava da iskoristimo prednosti naučenih reprezentacija i znanja ugrađenih u unaprijed obučene modele. Ovdje postoje dva glavna koraka: Pre-training – ovdje se mreža trenira na velikom datasetu tako što koristi anotirane podatke. Fine tuning – ovdje adaptiramo mrežu prema datasetu i umjesto da treniramo model od nule, selektivno izaberemo određene slojeve i nakon toga ih treniramo na našem datasetu[4].

B. *EfficientNet V2 B0*

EfficientNetV2 je konvoluciona neuronska mreža koja ima bržu brzinu treninga i bolju efikasnost parametara od prethodnih modela EfficientNetV1[5]. Da bi razvili ove modele, autori koriste kombinaciju pretraživanja i skaliranja neuronske arhitekture koja je svjesna treninga, kako bi zajednički optimizovali brzinu treninga. Modeli su pretraživani iz prostora za pretragu obogaćenog novim operacijama kao što je Fused-MBConv[5]. Efikasnost skaliranja modela takođe se u velikoj mjeri oslanja na osnovnu mrežu. Da bi dodatno poboljšali performanse, autori su razvili novu osnovnu mrežu izvedeći pretragu neuronske arhitekture koristeći AutoML MNAS okvir, koji optimizuje i tačnost i efikasnost (FLOPS)[6]. Rezultirajuća arhitektura koristi mobilnu invertovanu konvoluciju uskog grla (MBConv), slično kao MobileNetV2 i MnasNet, ali je nešto veća zbog povećanog FLOP budžeta[6]. Zatim se povećava osnovna mreža da bi dobili porodicu modela, nazvanu EfficientNets. Jedna od glavnih prednosti korišćenja EfficientNet V2 B0 modela je njegova efikasnost. Ovaj model je pažljivo optimizovan kako bi postigao visoku tačnost klasifikacije uz minimalne resurse za obuku i evaluaciju[7]. To ga čini idealnim izborom za primjene u kojima je brzina i efikasnost bitna, poput detekcije tumora na mozgu. Ovo je posebno važno u kontekstu detekcije tumora na mozgu, gde je ključno prepoznati i klasifikovati različite vrste tumora sa visokom preciznošću.

C. *Treniranje i evaluacija modela*

Sledeći korak je da učitamo model. Prvo definišemo model. To se radi tako što se preuzme već postojeći sa githuba. Nakon toga se generiše model i spremimaju se podaci za testiranje. Prvi korak je biranje dataseta za trening. Proces treniranja modela dubokog učenja je ključan za optimizaciju njegovog učinka na određenom zadatku.

Da bi obučili TensorFlow model, u radu se koristi široko prihvaćena tehnika nadgledanog učenja. Ovo uključuje iterativno prilagođavanje parametara i težina modela na osnovu označenih podataka o obuci, sa ciljem da se minimizira neslaganje između predviđenih i stvarnih vrijednosti. Takav pristup obuci koristi mogućnosti TensorFlow okvira za efikasno obučavanje dubokih neuronskih mreža. Funkcija `train_model` igra centralnu ulogu u procesu obuke. Ona obuhvata neophodne korake za obuku TensorFlow modela i obezbeđuje pojednostavljen interfejs za određivanje ključnih parametara obuke. Funkcija uzima nekoliko ulaza, uključujući sam model, broj epoha za obuku, listu povratnih poziva za praćenje i kontrolu procesa obuke i skup podataka za obuku predstavljen kao objekat `tf.data.Dataset`.

Tokom obuke, funkcija koristi metod uklapanja koji obezbeđuje TensorFlow Keras API. Ova metoda izvodi osnovnu petlju za obuku, gdje se model iterativno obučava na serijama podataka. Metoda uklapanja ažurira težine modela minimiziranjem unaprijed definisane funkcije gubitka i izračunava metriku od interesa. Određivanjem broja epoha, funkcija određuje broj kompletnih prolaza kroz koje će podaci obuke proći tokom obuke. Da bi se poboljšala efikasnost treninga, funkcija omogućava miješanje podataka u treningu. Miješanje podataka osigurava da model naiđe na različite uzorke u svakoj epohi, olakšavajući bolju generalizaciju i sprečavajući ga da zapamti redosled primjera obuke. Koristeći funkciju `train_model`, može se efikasno trenirati naš TensorFlow model uz zadržavanje fleksibilnosti i kontrole nad različitim aspektima obuke. Ovo nam dozvoljava mogućnost istraživanja različite konfiguracije treninga, eksperimentisanja sa hiperparametrima i korišćenje naprednih tehnika kao što su rano zaustavljanje ili zakazivanje brzine učenja. Na kraju, ova funkcija doprinosi uspjehu sistema za otkrivanje i klasifikaciju tumora mozga tako što obezbeđuje optimalne performanse modela kroz efikasnu obuku. Model je prošao kroz 22 epohe. Nakon toga imao je preciznost od 98%.

Po završetku procesa evaluacije, metoda vraća rezime rezultata evaluacije. Model je postigao vrijednost gubitka od 0,2545 i tačnost od 0,9746. Vrijednost gubitka predstavlja neslaganje između predviđenih i stvarnih vrijednosti, pri čemu niže vrednosti ukazuju na bolje performanse. Pokazatelj tačnosti odražava udio tačno predviđenih instanci u odnosu na ukupan broj instanci u skupu podataka testa. Veća tačnosti ukazuje na bolje ukupne performanse. Rezultati evaluacije pružaju vredan uvid u performanse modela na nevidljivim podacima. Oni omogućavaju da procijenimo sposobnost modela da generalizuje izvan podataka o obuci i napravi tačna predviđanja na primjerima iz stvarnog svijeta. Ocjenjivanjem modela možemo procijeniti njegovu efikasnost u otkrivanju i klasifikaciji tumora mozga, što je primarni cilj modela.

Ovi rezultati evaluacije pokazuju da je EfficientNet-V2 model postigao relativno nisku vrijednost gubitka i visok rezultat tačnosti. Ovi rezultati pokazuju da je model naučio smislene reprezentacije iz podataka o obuci i da može efikasno da

generalizuje na slikama tumora na mozgu. Takve performanse obećavaju i sugerišu da model ima potencijal za precizno otkrivanje i klasifikaciju tumora mozga u scenarijima iz stvarnog svijeta.

IV. INTEGRACIJA MOBILNE APLIKACIJE I MODELA

Integracija je imala za cilj da iskoristi mogućnosti mašinskog učenja i kompjuterske vizije kako bi pružila jednostavan i efikasan alat za medicinske profesionalce u otkrivanju i klasifikaciji tumora na mozgu.

Mobilna aplikacija, razvijena koristeći React Native, služila je kao korisnički interfejs za snimanje slika mozga i pokretanje procesa detekcije. Korisnici mogu jednostavno pokrenuti aplikaciju na svojim mobilnim uređajima i pristupiti funkciji kamere unutar aplikacije. Nakon što je snimila sliku mozga pacijenta, aplikacija je pokrenula sledeće korake za otkrivanje i klasifikaciju tumora.

Kada je slika snimljena, aplikacija je neprimjetno komunicirala sa serverom kako bi obradila sliku i dobila rezultate predviđanja. Snimljena slika je poslata kao POST zahtjev serveru, koji je primio API baziran na Flask-u. API je primio podatke o slici i pokrenuo neophodne korake za analizu tumora.

Na strani servera, prvi ključni korak je bio učitavanje obučenog modela mašinskog učenja. Model, zasnovan na EfficientNet-V2 arhitekturi kao što sam spomenuo. Učitavanje modela omogućilo je efikasno predviđanje i klasifikaciju tumora mozga na osnovu snimljene slike. Po prijemu slike, server je koristio učitani model za obradu podataka slike. Slika je prošla korake prethodne obrade, kao što su promjena veličine i normalizacija, kako bi se obezbjedila kompatibilnost sa ulaznim zahtjevima modela. Prethodno obrađena slika je zatim prošla kroz model, koji je iskoristio svoje naučene karakteristike da bi predvidio prisustvo i klasifikaciju tumora mozga. Nakon što je model napravio svoje predviđanje, server je generisao odgovarajući rezultat na osnovu predviđenog tipa tumora i povezanog nivoa pouzdanosti. Ovaj rezultat je zatim vraćen u mobilnu aplikaciju, koja je prikazala rezultat korisniku. Aplikacija je obezbjedila korisnički interfejs koji je predstavio predviđeni tip tumora i nivo pouzdanosti u procentima. Korisnik može lako da protumači rezultat i nastavi sa daljom medicinskom procenom i donošenjem odluka.

Neke od prednosti ovakve aplikacije su:

Poboljšana pristupačnost:

Integracijom modela za otkrivanje i klasifikaciju tumora na mozgu u mobilnu aplikaciju, tehnologija postaje lako dostupna široj publici. Mobilne aplikacije imaju širok domet, omogućavajući korisnicima da pristupe funkcionalnostima i mogućnostima modela sa svojih pametnih telefona ili tableta.

Ova pristupačnost promovise rano otkrivanje, osnažuje pacijente i olakšava blagovremene medicinske intervencije. Integracija mobilne aplikacije pruža dostupnost otkrivanja i klasifikacije tumora mozga bilo kada i bilo gdje. Korisnici mogu da slikaju ili skenove mozga direktno sa svojih mobilnih uređaja, eliminišući potrebu za specijalizovanim opremom ili posjetama medicinskim ustanovama.

Interaktivan interfejs prilagođen korisniku:

Integracija sa mobilnom aplikacijom otvara mogućnosti za dizajniranje intuitivnog i korisničkog interfejsa. Funkcije kao što su analiza u realnom vremenu i vizualizacije mogu biti ugrađene, omogućavajući korisnicima da komuniciraju sa modelom bez napora. Aplikacija može da pruži uputstva korak po korak, što korisnicima olakšava navigaciju kroz proces otkrivanja i klasifikacije. On bi u budućnosti bio različit za doktora i pacijenta. Nakon toga klikom na prvo dugme 'Skeniraj biomedicinsku sliku' otvara se kamera i korisnik se pita da li dozvoljava aplikaciji pristup kameri. Kada korisnik prihvati imamo opciju da slikamo neki CT sken. Nakon toga klikom na dugme 'Napravi predikciju' uspešno slikamo sken i pošaljemo ga modelu na obradu. Kada model prihvati sliku, on napravi predikciju i vrati rezultat te predikcije. Posle par sekundi dobijamo nazad rezultat(Slika 2).



Slika 1: Otvaramo kameru da bi slikali CT sken



Slika 2: Model vraća rezultat predikcije

Ovdje je (slika 3) model napravio predikciju gdje je siguran 95% da se na slici nalazi tumor koji se kategoriše kao Astrocitoma T1. Napravio je tačnu predikciju.

Integracija mobilne aplikacije i servera za otkrivanje tumora mozga pokazala je potencijal korišćenja mašinskog učenja i kompjuterske vizije u domenu medicine. Ova integracija predstavlja značajan napredak u oblasti mašinskog učenja i biomedicinskih slika jer omogućava korisniku lak i pristup tehnologiji.

V. ZAKLJUČAK

U ovom radu je predstavljena sveobuhvatna studija o otkrivanju i klasifikaciji tumora na mozgu koristeći mobilnu aplikaciju i implementaciju zasnovanu na modelu koji stoji na serveru. Rad može da imati doprinos u oblasti medicinske dijagnostike i da ima potencijal da poboljša ishode pacijenata.

Tokom ovog istraživanja istaknute su važnost ranog otkrivanja tumora na mozgu i izazove u vezi sa tradicionalnim dijagnostičkim metodama. Da bi se odgovorilo na ove izazove, razvijena je mobilna aplikacija koja omogućava korisnicima da snimaju slike mozga i započnu proces otkrivanja tumora.

Tokom procesa implementacije, vršeni su eksperimenti sa različitim tehnikama povećanja podataka o slici kako bih poboljšali performanse i robusnost modela. Takođe je korišten transfer learning, prilagođavajući unaprijed obučeni model našem specifičnom zadatku otkrivanja tumora na mozgu. Ove tehnike su se pokazale efikasnim u postizanju tačnih i pouzdanih rezultata.

Rezultati dobijeni iz implementacije pokazali su efikasnost mobilne aplikacije i pristupa zasnovanog na serveru u otkrivanju tumora na mozgu. Kombinovanjem mobilnih uređaja i računarske snage servera, stvorilo se jednostavno i precizno rešenje za rano otkrivanje tumora. Rad može imati pozitivan uticaj na medicinske stručnjake i pacijente, osnažujući ih vrijednim uvidima i poboljšavajući rezultate liječenja.

Ovaj rad pokazuje uspješnu primjenu mobilne aplikacije i sistema zasnovanog na serveru za otkrivanje i klasifikaciju tumora na mozgu. Ovo rešenje nudi praktičnost i efikasnost medicinskim radnicima, omogućavajući im da rano otkriju tumore na mozgu i donesu informisane odluke u vezi sa brigom o pacijentima. Predviđam proširenje mogućnosti ovog sistema, optimizaciju performansi modela i integraciju dodatnih funkcija kako bi se dodatno poboljšala upotrebljivost i klinički uticaj. Spajanjem najsavremenije tehnologije i zdravstvene zaštite, cilj je da se doprinese tekućim naporima u korišćenju vještačke inteligencije za poboljšanje zdravlja ljudi.

U trenutku pisanja rada integracija mašinskog učenja, kompjuterske vizije i mobilnih tehnologija ima potencijal da promijeni medicinsku dijagnostiku i transformiše praksu zdravstvene zaštite.

REFERENCE

- [1] Smith, S. (2012). *Brain tumor: Causes, symptoms, signs, diagnosis, treatments, stages of brain tumor*. U.S. Dept. of Health and Human Services, National Institutes of Health.
- [2] Biomedicine. (2017). Larsen & Keller Educ.
- [3] Rosenblum, M. L., & Wilson, C. B. (1984). *Brain tumor therapy*. Karger.
- [4] Alez, G. (2011). Brain Tumor: Everything you need to know about the disease including signs and symptoms. Webster'S Digital Service.
- [5] *Computer vision*. (2015). Springer.
- [6] Yang, Q. (2020). *Transfer learning*. Cambridge University Press.
- [7] Efficient NetV2: <https://arxiv.org/pdf/2104.00298v2.pdf>
- [8] EfficientNet: Improving Accuracy and Efficiency through AutoML and Model Scaling: <https://ai.googleblog.com/2019/05/efficientnet-improving-accuracy-and.html>
- [9] https://tfhub.dev/google/imagenet/efficientnet_v2_imagenet21k_b0/feature_vector/2
- [10] Dataset: <https://www.kaggle.com/datasets/navoneel/brain-mri-images-for-braintumor-detection>
- [11] Brain Tumor Detection and Classification Using Deep Learning and Sine-Cosine Fitness Grey Wolf Optimization
- [12] Brain tumor detection from MRI images using deep learning techniques P Gokila Brindha1, M Kavinraj, P Manivasakam and P Prasanth
- [13] BRAIN TUMOR: Analysis, Classification, and Detection Using Machine Learning and Deep Learning with Python GUI by Vivian Siahaan (Author), Rismon Hasiholan Sianipar (Author)
- [14] "Machine Learning and Medical Imaging" by Guorong Wu,
- [15] "Medical Image Analysis with Deep Learning" by Gustavo Carneiro, Andrew P. Bradley, and Jacinto C. Nascimento
- [16] "Deep Learning for Medical Image Analysis" by S. Kevin Zhou, Hayit Greenspan, and Dinggang Shen
- [17] A Deep Analysis of Brain Tumor Detection from MR Images Using Deep Learning Networks - by Md Ishtyaq Mahmud 1, Muntasir Mamun
- [18] Brain Tumor Detection and Segmentation in Medical Imaging Using Neural Networks and Deep Learning" by S. S. Gajre and S. S. Rathour
- [19] "Assistive Diagnostic Tool for Brain Tumor Detection using Computer Vision" by Sahithi Ankireddy

- [20] A. B. M. Ashikur Rahman, M. Sohel Rahman, and M. Ashrafal Amin. "Brain tumor detection and classification using machine learning: a comprehensive survey." *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, no. 1, pp. 1037-1060, 2021.
- [21] Y. Zhang, Y. Wang, and Y. Zhang. "A Robust and Novel Approach for Brain Tumor Classification Using Convolutional Neural Network." *Journal of Healthcare Engineering*, vol. 2021, pp. 1-9, 2021.
- [22] S. K. Singh and S. K. Singh. "Performance analysis of machine learning algorithm of detection and classification of brain tumor using computer vision." *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, no. 1, pp. 1061-1072, 2021.
- [23] S. S. Kumar, S. K. Singh, and S. K. Singh. "A novel deep learning-based brain tumor detection using the Bagging ensemble with K-nearest neighbor." *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, no. 1, pp. 1073-1085, 2021.