

**ODREĐIVANJE VRSTE TUMORA MOZGA NA OSNOVU MRI SNIMAKA
ENDOKRANIJUMA PRIMENOM METODA VEŠTAČKE INTELIGENCIJE****DETERMINING THE TYPE OF BRAIN TUMOR BASED ON MRI IMAGES OF THE
ENDOCRANIUM USING ARTIFICIAL INTELLIGENCE METHODS**

Aleksa Stojić, *Fakultet tehničkih nauka, Novi Sad*

Oblast – Elektrotehnika i računarstvo

Kratak sadržaj – Cilj rada je brža i pouzdanija klasifikacija vrste tumora korišćenjem metoda veštačke inteligencije. Rešavanje problema klasifikacije slika MRI snimaka na vrste tumora. Rešenje je implementirano finim podešavanjem parametara na tri pretrenirana modela, Resnet50, DenseNet121 i EfficientNet-B3. Najbolji rezultat dalo je fino podešavanje parametara na pretreniranom modelu EfficientNet-B3, sa tačnošću od 98%..

Ključne reči: Klasifikacija slika, Računarska vizija, tumor mozga, fino podešavanje parametara pretreniranog modela

Abstract – The goal of the work is a faster and more reliable classification of the type of tumor using artificial intelligence methods. Solving the problem of classifying MRI images into tumor types. The solution was implemented by fine-tuning parameters on three pre-trained models, Resnet50, DenseNet121 and EfficientNet-B3. The best result was obtained by fine-tuning the parameters on the pre-trained EfficientNet-B3 model, with an accuracy of 98%..

Keywords: Image classification, computer vision, brain tumor, fine tuning of pre-trained model

1. UVOD

Tumor mozga predstavlja značajan izazov za zdravstvene sisteme širom sveta. Prema podacima Američke asocijacije za tumor mozga, približno 700.000 ljudi u Sjedinjenim Državama trenutno živi sa primarnim tumorom mozga, dok se godišnje očekuje se oko 84.000 novih slučajeva. Svetska zdravstvena organizacija procenjuje da tumori mozga čine oko 1,6% svih kancera širom sveta. Stopa smrtnosti je podjednako zabrinjavajuća, s obzirom da su tumori mozga vodeći uzrok smrtnosti od kancera kod osoba starih od 15 do 39 godina. Stopa preživljavanja varira u zavisnosti od vrste tumora, mesta na kom se nalazi i terapije, ali prosečna petogodišnja stopa preživljavanja za maligne tumore mozga je približno 36% [1].

S medicinskog stanovišta, tumori mozga su kategorisani u različite tipove na osnovu načina nastanka i ponašanja.

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Aleksandar Kupusinac, red. prof.

Primarni tipovi između ostalih uključuju gliome, meningiome i tumore hipofize. Za ovaj rad naznačajniji su gliome, meningiome i tumori hipofize koji se nalaze na slikama u korišćenom setu podataka. Gliomi su najčešći primarni tumori mozga i potiču od glijalnih ćelija koje pružaju podršku i ishranu neuronima. Mogu biti od niskog do visokog stepena malignosti. Meningiomi su drugi po učestalosti tumori mozga. Nastaju iz meninge, zaštitnih membrana koje pokrivaju mozak i kičmenu moždinu. Uglavnom su benigni, ali u nekim slučajevima mogu postati maligni i zahtevati hirurško uklanjanje. Tumori hipofize nastaju u hipofizi, maloj žlezdi smeštenoj u osnovi mozga koja reguliše mnoge važne hormonske funkcije. Većina ovih tumora je benigna, ali čak i benigni tumori mogu izazvati značajne zdravstvene probleme zbog svog uticaja na hormonalnu ravnotežu i pritiska koji mogu vršiti na okolna tkiva mozga. Razumevanje ovih različitih tipova tumora, njihovog ponašanja, i njihovog uticaja na pacijente je ključno za efikasno dijagnostikovanje i lečenje. Rana detekcija i precizna klasifikacija mogu značajno poboljšati ishode za pacijente, omogućavajući bolju personalizaciju terapije i dugoročnu kontrolu bolesti[2][3][4].

Dijagnostika tumora mozga uključuje i invazivne i neinvazivne metode. Neinvazivne tehnike kao što su magnetna rezonanca (MRI) i kompjuterska tomografija (CT) često se koriste za početnu detekciju i praćenje. Međutim, konačna dijagnoza često zahteva invazivne postupke kao što je biopsija, tokom koje se uzimaju uzorci tkiva za ispitivanje kancerogenih ćelija. Proces može biti vremenski zahtevan i složen, što često dovodi do odlaganja u početku tretmana. Pored tog problema, postoji značajan nedostatak medicinskih stručnjaka u nekim regijama. Na primer, u Srbiji, odnos broja neurologa na broj stanovnika je relativno nizak u poređenju sa evropskim standardima, što doprinosi odlaganjima u dijagnozi. U Sjedinjenim Američkim Državama, iako je pristup specijalistima generalno lakši, i dalje postoje razlike između različitih država i ruralnih područja [5][6].

Iz prethodno navedenih razloga, cilj ovog rada je istraživanje i procena različitih pristupa u klasifikaciji tumora mozga korišćenjem metoda mašinskog učenja. Koristeći napredne tehnike u mašinskom učenju i analizi slika, ovo istraživanje ima za cilj da pruži uvid u poboljšanje tačnosti i efikasnosti dijagnoze. Predložene metodologije će biti upoređene radi utvrđivanja njihove efikasnosti u identifikovanju različitih tipova tumora,

potencijalno nudeći nove puteve za ranu detekciju i bolje ishode za pacijente [7].

2. PODACI

Skup podataka koji je upotrebljen za potrebe ovog rada sastoji se od slika MRI snimaka endokranijuma čoveka koji je podeljen u dva direktorijuma, trening i test. U okviru tih direktorijuma nalaze se još 4 dodatna direktorijuma koji predstavljaju 4 klase koje se nalaze u setu. Ukupno sadrže 3264 fotografije. Nazivi klasa su glioma (926 fotografija), meningioma (937 fotografija), bez tumora (500 fotografija) i tumor hipofize (901 fotografija).

Informacija o nazivu direktorijuma korišćena je kao klasa (labela) u procesu klasifikacije. Iako je skup bio podeljen na trening i test skup, tokom učitavanja sve slike su uz informaciju kojoj klasi pripadaju učitane u jednu kolekciju. Slike su skalirane na jednake dimenzije 224 x 224. Takav skup koji sadrži sve fotografije zatim je podeljen na trening skup i test skup u odnosu 80:20. Dalje transformacije vršene su nad trening skupom. Od tog skupa stvoren je još jedan skup koji je uz originalne fotografije sadržao i augmentovane fotografije. Od svake fotografije nasumično je stvorena jedna augmentovana primenom jednog od odabranih metoda koje su činili nasumično rotiranje fotografije za 90 stepeni, obrtanje po horizontalnoj i vertikalnoj osi. U slučaju da je u tom procesu došlo do nastanka novih piksela za metod popunjavanja izabran je najbliži. Takva dva trening seta su zatim podeljena na trening i validacioni skup u odnosima 50:50, 70:30 i 90:10. Ovim načinom pretprocesiranja i podele trening skupa svaki model je treniran na 6 različitih pristupa i testiran istim skupom podataka. Prilikom ovih podela vođeno je računa da raspodela klasa u svim skupovima ostane ista kao i u originalnom skupu. Opisani skup podataka preuzet je sa izvora [8].

3. EKSPERIMENT

U ovom poglavlju je predstavljen opis implementacije sistema za određivanje vrste tumora mozga na osnovu slika MRI snimaka endokranijuma. U osnovu sistema je klasifikacija slika na jednu od četiri moguće klase: slika bez tumora, tumor hipofize, glioma i meningioma. Ulaz u sistem je slika MRI snimka endokranijuma pacijenta, a izlaz je dijagnoza predviđena od strane modela. Implementacija sistema biće opisana na visokom nivou apstrakcije.

Nad pretreniranim modelima primenjene su tehnike učenja sa prenosom znanja i finog podešavanja parametara. Svi modeli su trenirani na dva skupa podataka. Prvi skup podataka čine slike iz izvornog skupa podataka na kojima je primenjeno pretprocesiranje u vidu skaliranja slike na 224 x 224 piksela, dok je na drugom skupu podataka na delu slika namenjenom za trening primenjena augmentacija, opisana u prethodnom poglavlju.

Pretrenirani modeli su prilagođeni za rešavanje problema klasifikacije MRI snimaka endokranijuma tako što je poslednji sloj modifikovan tako da kao izlaz ima 4 klase koje su prisutne u ulaznom setu podataka. Takođe su

korišćene tehnike treniranja sa prenosom znanja i finog podešavanja parametara tako što je isprobano da se određen broj poslednjih slojeva prilagodi ulaznom setu podataka. Broj odmrznutih poslednjih slojeva je iznosio od 0 do 5.

Tokom treniranja kao kriterijum za gubitak je korišćena CrossEntropyLoss funkcija. Ona se koristi za klasifikacione probleme u kojima se predviđaju klase i čini tipičan izbor za zadatke višeklasne klasifikacije. Za optimizator je korišćen Adam koji je jedan od najčešće korišćenih algoritama za optimizaciju u dubokom učenju. On se koristi za računanje težina modela na osnovu grešaka izračunatih tokom treniranja. U svakoj iteraciji model se proverava validacionim skupom podataka. Izlaz iz te operacije se koristi za računanje gubitaka. Tokom treniranja implementirano je rano zaustavljanje. Svaki model koji na validacionom skupu podataka ima manji gubitak od najboljeg do tog trenutka čuva se kao najbolji model. Ukoliko se gubitak ne poboljša u 5 uzastopnih epoha, trening se zaustavlja kako bi se izbeglo preterano treniranje.

3.1. Model ResNet50

U ovom pristupu za rešavanje problema klasifikacije medicinskih slika oprobano je model razvijen od strane Microsoft-a. Model je objavljen u 2015. godini i broj 50 u modelu predstavlja broj slojeva u mreži. Arhitektura modela podeljena je u 4 dela koje čine konvolucionni slojevi, identitet blok, konvolucionni blok i konvolucionni blok koji je zadružen za procesiranje i transformaciju odlika. Na kraju se nalazi potpuno povezani sloj koji vrši krajnju klasifikaciju. Model je treniran na ImageNet setu podataka koji sadrži više od 14 miliona fotografija i 1000 klasa. Iz tog razloga predstavlja moćan model koji može da se koristi za više klasifikacionih problema poput detekcije objekata, prepoznavanja lica i analize medicinskih slika. Takođe ima primenu i u ekstrakciji odlika za druge zadatke, kao što je detekcija objekata i semantička segmentacija. Kao ulaz koristi fotografije dimenzija 224 x 224 koje sadrže 3 kanala.

3.2. Model DenseNet121

U ovom pristupu za rešavanje problema klasifikacije medicinskih slika oprobano je model razvijen od strane grupe naučnika. Model je objavljen u 2016. godini i broj 121 u modelu predstavlja broj slojeva u mreži.

Sastoji se od serije gustih blokova od kojih svaki sadrži više konvolucionih slojeva. Svaki blok kao ulaz prima izlaz prethodnog bloka ali i sve izlaze prethodnih blokova. To zajedno čini gusto povezanu konvolucionu mrežu između svih slojeva u modelu što omogućava informacijama da efikasnije putuju kroz mrežu, po čemu je model i dobio ime. Model se široko koristi za rešavanje problema klasifikacije što mu je omogućilo treniranje na više setova podataka od kojih su neki ImageNet, CIFAR-10, and CIFAR-100. Ograničenje ovog modela jeste da ulazne fotografije moraju biti dimenzija 224 x 224 i imati tačno 3 kanala, što znači da sadrže boju. Postoje varijacije ovog modela koje podržavaju drugačije dimenzije, nalazi primenu u klasifikaciji fotografija, detekciji objekata, analizi medicinskih slika i procesiranju jezika.

3.3. Model EfficientNet-B3

U ovom pristupu za rešavanje problema klasifikacije medicinskih slika korišćen je model EfficientNet-B3, koji je razvijen kao deo serije EfficientNet modela predstavljenih 2019. godine. EfficientNet predstavlja arhitekturu neuronskih mreža i metod skaliranja koji uniformno skalira sve dimenzije dubine, širine/rezolucije koristeći složeni koeficijent. Arhitektura EfficientNet-a se sastoji od naslaganih konvolucionih slojeva obično organizovanih hijerarhijski. Svaki konvolucionni sloj je praćen aktivacionom funkcijom i slojevima za normalizaciju. Konvolucije razdvajive po dubini su široko primenjene u ovoj mreži, što omogućava visoku tačnost uz značajno manje parametara u poređenju sa tradicionalnim arhitekturama. Model je dizajniran tako da izvlači maksimalne performanse dok smanjuje broj računanja i memorije potrebne za treniranje, čineći ga posebno pogodnim za primenu na medicinskim slikama gde je preciznost ključna. EfficientNet-B3 se trenira na različitim skupovima podataka, uključujući ImageNet, i pokazao je izvanredne rezultate u zadacima klasifikacije slika, kao i detekciji objekata. Model nalazi primenu u analizi medicinskih slika, kao i u drugim oblastima poput klasifikacije fotografija i procesiranja jezika.

5. REZULTATI

Na osnovu sprovedenih eksperimenata zaključak je da su najlošije rezultate beležili modeli čija je osnova bio pretrenirani model ResNet50. Eksperiment sa ovim modelom proizveo je najmanje modela koji su imali tačnost veću od 90% i najbolji model ove klase (tačnost 94.79%) je slabiji od najboljih modela iz preostala dva eksperimenta. Modeli proistekli iz eksperimenta čija je osnova bio pretrenirani model DenseNet121 su pokazali bolje rezultate u proseku i iz ovog eksperimenta proističe drugi najbolji model (tačnost 96.32%). Eksperiment u kom je korišćen pretrenirani model EfficientNet-B3 je proizveo u proseku najbolje modele i pojedinačno model sa najboljim preformansama nakon evaluacije (tačnost 98.01%). U nastavku poglavlja date su tabele u kojima se porede najrelevantnije mere performansi najjačeg modela iz svakog eksperimenta. Za klasu snimaka bez tumora to je mera preciznosti (tabela 1).

Tabela 1. Vrednosti mere preciznosti za klasu no_tumor za najbolje modele iz sva tri eksperimenta

Model	Bez tumora
ResNet50	0.97
DenseNet121	0.97
EfficientNet-B3	0.97

Za tumor klase mera odziva (tabela 2).

Tabela 2. Vrednosti mere odziva za tumor klase za najbolje modele iz sva tri eksperimenta

	Glioma	Meningioma	Tumor hipofize
ResNet50	0.96	0.89	1
DenseNet121	0.95	0.93	1
EfficientNet-B3	0.98	0.96	1

Takođe je data tabela sa marko f-merama svih eksperimenata (tabela 3).

Tabela 3. Vrednosti makro f-mere za najbolje modele iz sva tri eksperimenta

Model	Makro f-mera
ResNet50	0.9485
DenseNet121	0.9647
EfficientNet-B3	0.9802

Po svakom od ovih kriterijuma, model dobijen finim podešavanjem parametara od pretreniranog modela EfficientNet-B3 beleži najbolje rezultate.

6. ZAKLJUČAK

Iz rezultata prikazanih u poglavlju 5., može se primetiti da sistem koristeći pretrenirani model EfficientNet-B3 daje rezultat od 98% tačnosti, što je veoma dobar rezultat. Glavna prednost korišćenja ovog sistema u odnosu na čoveka je ta što je sposoban da uoči šablone i odnose između piksela koje golom oku možda i nisu značajni. Iako sistem poseduje dobre performanse zbog osetljivosti problema kojim se bavi ne bi trebalo da se koristi nezavisno od lekara, već samo kao alat koji bi pomogao sugerišući na potencijalan tumor. Sistem beleži mali broj lažnih negativnih slučajeva za klasu bez tumora što je značajno jer može skrenuti pažnju lekara da je potrebno obaviti dodatnu analizu za nekog pacijenta. Ukoliko bi sistem klasifikovao snimak kao da poseduje tumor sprovela bi se dodatna analiza od strane lekara i na osnovu dijagnoze započela konkretna terapija.

Jedno od mogućih proširenja ovog sistema je integracija sa aparatom za snimanje MRI snimaka. Na taj način bi se dijagnoza obavljala odmah nakon snimaka i lekar bi imao uvid u predikciju čim pristupi snimcima. Drugi način jeste korišćenje složenijih i zahtevnijih pretreniranih modela od modela korišćenih u ovom radu. Još jedan od načina jeste proširenje skupa podataka čime bi se postigla bolja generalizacija sistema i rezultati na nepoznatim setovima. Uz to bi bilo moguće uključiti dodatne vrste tumora u

klasifikaciju. Uz same snimke u proces klasifikacije mogli bi se uključiti i drugi podaci o pacijentu koji se mogu koristiti pri dijagnostici tumora na mozgu. Ovim postupcima bi dijagnoza bila još tačnija i sistem bi potencijalno mogao da se koristi i u realnim uslovima kao dodatni alat pri dijagnostici za medicinsko osoblje.

7. LITERATURA

- [1] <https://www.abta.org/about-brain-tumors/brain-tumor-education/> (pristupljeno u avgustu 2024.)
- [2] D. N. Louis, A. Perry, G. Reifenberger, A. von Deimling, D. Figarella-Branger, W. K. Cavenee, and D. W. Ellison, "The 2016 World Health Organization classification of tumors of the central nervous system: a summary," *Acta Neuropathologica*, vol. 131, no. 6, pp. 803-820, Jun. 2016.
- [3] Q. T. Ostrom, G. Cioffi, H. Gittleman, N. Patil, K. Waite, C. Kruchko, and J. S. Barnholtz-Sloan, "CBTRUS statistical report: Primary brain and other central nervous system tumors diagnosed in the United States in 2012–2016," *Neuro-oncology*, vol. 21, no. Suppl 5, pp. v1-v100, 2019.
- [4] J. Hardy and J. Rees, "Pituitary tumours: diagnosis and management," *Postgraduate Medical Journal*, vol. 84, no. 991, pp. 172-178, 2008.

- [5] World Health Organization, "Global health workforce statistics," 2022.
- [6] J. Smith and A. Lee, *Advances in brain tumor classification and detection*, New York: Springer, 2023.
- [7] <https://www.atlasofms.org/chart/serbia/epidemiology/number-of-people-with-ms> (pristupljeno u avgustu 2024.)
- [8] <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri?resource=download> (pristupljeno u avgustu 2024.)

Kratka biografija:



Aleksa Stojić rođen je u Novom Sadu 1999. god. Diplomski rad na Fakultetu tehničkih nauka iz oblasti Elektrotehnike i računarstva odbranio je 2022.god. kontakt: aleksa.stojic19@uns.ac.rs