MIYA O‘SMASI SEGMENTATSIYASIDA SINFLAR NOMUTANOSIBLIGI MASALASINI YECHUVCHI TO'RT KOMPONENTLI KOMBINATSIYALANGAN XATOLIK FUNKSIYASI

Abdullayev T[1][0000-0001-5946-7607]., ***Abdukadirova G***[2][0009-0005-2035-2008].

[1]*Farg‘ona davlat texnika universiteti, Kompyuter muhandisligi va sun’iy intellekt kafedrasi dotsenti, PhD, E_mail: temurbekm84@gmail.com*

[2]*Farg‘ona davlat texnika universiteti, Kompyuter muhandisligi va sun’iy intellekt kafedrasi, E_mail: nirvanath369@gmail.com*

Annotatsiya. Magnit-rezonans tomografiya tasvirlarida miya o'smasi sohalarini ajratish masalasi bir vaqtning o'zida uchta o'zaro bog'liq qiyinchilik bilan yuzlashadi: patologik voksellar umumiy hajmning bir necha foizini tashkil etadi; klinik jihatdan eng muhim sohalar eng kichik hajmga ega; o'sma va sog'lom to'qima orasidagi chegara ko'pincha bir necha vokselli o'tish zonasidan iborat. Yakka yo'qotish funksiyasi bu uch muammoni bir vaqtda qamrab ololmaydi, mavjud kombinatsiyalangan yechimlar esa odatda ikki komponent bilan cheklanadi. Maqolada hajmiy ustma-ustlikni optimallashtiruvchi, voksel darajasida tasniflashni ta'minlovchi, qiyin misollarga e'tiborni kuchaytiruvchi va yolg'on manfiy javoblarni maqsadli jazolovchi to'rtta komponentni birlashtiruvchi xatolik funksiyasi taklif etilgan. Yakuniy model 250 ta validatsiya holatida 0,8610 o‘rtacha Dice va 4,17 mm o‘rtacha HD95 ko‘rsatkichiga erishdi.
Kalit so‘zlar. xatolik funksiyasi, sinflar nomutanosibligi, Dice koeffitsienti, fokal xatolik, Tversky indeksi, tibbiy tasvirlarni segmentatsiyalash, miya o‘smasi, chuqur nazorat, chuqur o‘qitish.

Аннотация. Вопрос выделения областей опухоли мозга на магнитно-резонансной томографии сталкивается одновременно с тремя взаимосвязанными трудностями: патологические воксели составляют несколько процентов от общего объема; наиболее клинически значимые области имеют наименьший объем; граница между опухолью и здоровой тканью часто состоит из нескольких воксельных переходных зон. Функция одиночных потерь не может охватить эти три проблемы одновременно, а существующие комбинированные решения обычно ограничиваются двумя компонентами. В статье предлагается функция ошибки, объединяющая четыре компонента, оптимизирующая объемное наложение, обеспечивающая классификацию на уровне вокселя, усиливающая акцент на сложных примерах и целенаправленно наказывающая ложноотрицательные ответы. Окончательная модель достигла среднего значения 0,8610 dice и среднего значения 4,17 mm HD95 в 250 случаях валидации.
Ключевые слова. функция потери, несоответствие классов, коэффициент Дайса, фокальная ошибка, индекс Тверски, сегментация медицинских изображений, опухоль головного мозга, глубокое обучение с учителем, глубокое обучение.

Abstract: The problem of detecting brain tumor regions in magnetic resonance imaging faces three interrelated challenges: pathological voxels account for a few percent of the total volume; the most clinically significant regions have the smallest volume; and the boundary between the tumor and healthy tissue often consists of several voxel-level transition zones. A single loss function cannot address these three issues simultaneously, and existing combined solutions are typically limited to two components. This paper proposes an error function combining four components that optimizes volumetric overlay, provides voxel-level classification, emphasizes difficult examples, and specifically penalizes false negatives. The final model achieved a mean dice loss of 0.8610 and a mean HD95 loss of 4.17 mm across 250 validation cases.
Key words: Loss function, class mismatch, Dice coefficient, focal error, Tversky index, medical image segmentation, brain tumor, supervised deep learning, deep learning.

Kirish

Chuqur sun’iy neyron tarmoqlarni o‘qitishda xatolik funksiyasi model bilan bir qatorda muhim ahamiyatga ega. U tarmoq nimani xato deb hisoblashini, qaysi turdagi xatolar qanchalik qattiq jazolanishini va gradientning qaysi yo‘nalishda harakatlanishini

©Journal of Advances in Engineering Technology Vol.3(23), July — September, 2026
DOI 10.67889/2181-1431-2026-3-61-67

belgilaydi. Tibbiy tasvirlarni segmentatsiyalashda bu masala alohida keskinlik kasb etadi, chunki ma’lumotlarning statistik tuzilishi tabiiy tasvirlardan tubdan farq qiladi [1].

Miya o‘smasining turli modalliklarda ko‘rinishi tajribali mutaxassislar uchun ham qiyinchilik tug‘diradi. T1 holati normal miya anatomiyasini aniq ko‘rsatish uchun ishlatiladi. Anatomik chegaralar yaxshi ajralib turadi. O‘simtaning o‘zini atrof-to‘qimalardan ajratish T1 holatida biroz qiyin. T1ce holati T1 tasvirga gadoliniy kontrast moddasi yuborilgandan so‘ng olinadi. O‘simta rivojlanganda qon-miya to‘sig‘i buziladi, kontrast modda shu joyga yig‘iladi va o‘simtaning faol yadrosi yorqin oq rangda yallig‘lanib ko‘rinadi. T2 holati suyuqliklarga va shishlarga juda ta'sirchan. Orqa miya suyuqligi va to‘qimalardagi shish yorqin oq rangda ko‘rinadi. T2 o‘simta va uning atrofidagi shish hududini birgalikda aniqlashga yordam beradi. FLAIR holati T2 rejimidagi orqa miya suyuqligining yorqin signalini “o‘chirib” qo‘yadigan maxsus ketma-ketlik. Natijada qorinchalardagi erkin suyuqlik to‘q rangga kiradi, lekin o‘simta atrofidagi shish va to‘qima shikastlanishlari yorqin oq rangda aniq ajralib qoladi.

Miya o‘smasi segmentatsiyasi misolida uchta o‘zaro bog‘liq qiyinchilik yaqqol namoyon bo‘ladi. Birinchisi sinflar nomutanosibligi: bosh miyaning uch o‘lchamli hajmida patologik o‘zgargan voksellar ulushi odatda ikki foizdan oshmaydi, ya’ni fon sinfi qolgan barcha sinflardan bir necha yuz barobar ko‘p. Ikkinchisi kichik hajmli sohalarni aniqlash: klinik qarorlar uchun eng muhim bo‘lgan kontrast to‘plovchi kuchaygan o‘sma sohasi ko'pincha butun hajmning bir foizidan ham kamrog‘ini egallaydi, shu sababli bir necha yuz vokselli xato ham sifat ko‘rsatkichini keskin pasaytiradi. Uchinchisi chegara aniqligi: o‘sma va shish, shish va sog‘lom to‘qima orasidagi o‘tish sohalari bir necha vokselli qalinlikka ega bo‘lib, aynan shu zonalarda modellar eng ko‘p xatoga yo‘l qo‘yadi [2, 3].

Ushbu qiyinchiliklarga javob sifatida bir necha xatolik funksiyalari oilasi shakllangan. Voksel darajasidagi klassik kesishgan entropiya har bir vokselni mustaqil tasniflash masalasi sifatida ko‘radi va sinflar teng vaznda bo‘lgan holatda samarali ishlaydi; nomutanosib to‘plamlarda esa u ko‘pchilik sinf tomonga siljib, kichik sohalarni deyarli e’tiborsiz qoldiradi. Bu kamchilikni bartaraf etish uchun hajmiy ustma-ustlikni bevosita optimallashtiruvchi Dice xatoligi taklif etilgan [4], keyinchalik u sinflar hajmiga teskari proporsional vaznlar bilan umumlashtirildi [5].

Obyektni aniqlashda ishlab chiqilgan fokal xatolik oson tanlanmalarning hissasini kamaytirib, gradientni qiyin tanlanma tomon yo‘naltirishni taklif qilgan [6]. Tversky indeksiga asoslangan xatolik esa yolg‘on musbat va yolg‘on manfiy javoblarni turli vazn bilan jazolash imkonini berdi [7]. Chegara aniqligini maqsadli yaxshilash uchun masofa xaritalariga tayanuvchi funksiyalar ham taklif qilingan [8].

Amaliyotda yakka funksiyalar o‘rniga ularning kombinatsiyalari ustunlik qila boshladi. Kesishgan entropiya va Dice xatoligini birlashtiruvchi variantlar keng tarqaldi [9]; fokal va Tversky g‘oyalarini bir ifodada jamlovchi yechimlar taqdim etildi [10]; keng qamrovli qiyosiy tahlillar turli funksiyalarning kuchli va zaif tomonlarini tizimlashtirdi [11]. Shunga qaramay, mavjud kombinatsiyalangan yechimlarning aksariyati ikki komponent bilan cheklanadi va odatda yuqorida sanab o‘tilgan uch muammodan faqat ikkitasini qamrab olgan.

Bundan tashqari, komponentlar vaznlari ko‘pincha empirik tarzda, tizimli asoslashsiz tanlanadi, har bir komponentning gradientga qo‘shadigan hissasi esa alohida tahlil qilinmaydi.

Mazkur maqolaning maqsadi sinflar nomutanosibligi, kichik hajmli sohalarni aniqlash va chegara aniqligi muammolarini bir vaqtda yechishga qaratilgan to‘rt komponentli kombinatsiyalangan xatolik funksiyasini ishlab chiqish, uni gradient tahlili orqali asoslash hamda BraTS 2021 bazasida tajribaviy tekshirishdan iborat.

©Journal of Advances in Engineering Technology Vol.3(23), July — September, 2026
DOI 10.67889/2181-1431-2026-3-61-67

Uslubiyat

Tajribalar BraTS 2021 ma'lumotlar bazasida o'tkazildi, u 1251 ta annotatsiyalangan holatdan iborat bo'lib, har biri T1, T1ce, T2 va FLAIR modalitetlarini hamda ekspert niqobini o'z ichiga oladi [2, 3].

Birinchi komponentning vazifasi modelni bevosita baholash mezoni bo'lgan hajmiy ustma-ustlikni maksimallashtirishga yo'naltirish. Dice xatoligi [4] barcha sinflar bo'yicha o'rtachalash bilan quyidagicha yoziladi:

$$L_{Dice} = 1 - \frac{2\sum_i p_i g_i + \varepsilon}{\sum_i p_i^2 + \sum_i g_i^2 + \varepsilon} \quad [1]$$

bu yerda: p_i, g_i – *i*-vokselning bashorat ehtimoli va haqiqiy qiymati (0/1); ε – nolga bo'linishning oldini oluvchi kichik doimiy (tajribada 10^{-5}). Ushbu komponentning muhim xususiyati shundaki, u sinf hajmiga normallashtirilgan, shu sababli kichik va katta sohalar yakuniy qiymatga taqqoslanadigan hissa qo'shadi. Ayni paytda Dice xatoligi o'qitishning boshlang'ich bosqichida beqaror bo'lishi mumkin, bashorat deyarli tasodifiy bo'lganda maxraj kichik qiymatlar oladi va gradient keskin sakrashlarga uchraydi.

Ikkinchi komponent birinchisining beqarorligini qoplaydi va o'qitishning dastlabki davrlarida barqaror gradient manbai bo'lib xizmat qiladi. Kesishgan entropiya quyidagi ko'rinishga ega:

$$L_{CE} = -\frac{1}{N}\sum_i \sum_c g_{ic} \cdot \log(p_{ic}) \quad [2]$$

bu yerda: *N* – umumiy voksel soni; *c* – sinf indeksi (c=4 sinf); g_ic,, p_ic – *i*-voksel uchun *c*-sinfning haqiqiy ma'lumotlari va Softmax funksiyasi ehtimoli.

Ushbu komponent har bir vokselni mustaqil ko'rib chiqadi va bashorat ishonchi past bo'lgan barcha nuqtalarda nolga teng bo'lmagan gradient hosil qiladi. Uning zaif tomoni sinflar nomutanosibligiga sezgirligi; aynan shu sababli u yagona komponent sifatida emas, balki boshqalar bilan birgalikda va cheklangan og'irlik bilan ishlatiladi.

Uchinchi komponent kesishgan entropiyani modulyatsiya koeffitsienti bilan to'ldiradi va shu orqali oson tasniflanadigan voksellarning hissasini pasaytiradi [6]:

$$L_{Focal} = -\frac{1}{N}\sum_i \sum_c \alpha_c \cdot (1 - p_{ic})^{\gamma} \cdot g_{ic} \cdot \log(p_{ic}) \quad [3]$$

bu yerda γ = fokuslash parametri, oson namunalarning hissasini kamaytiradi (odatda 2.0 ga teng); αc – sinfga bog'liq muvozanatlashtiruvchi koeffitsient. p_{ic} – i-voksel uchun *c*-sinf ehtimolligi. $(1-p)^{\gamma}$ – oson namunalar uchun kichik, qiyin namunalar uchun katta ko'paytuvchi, model biror vokselni allaqachon ishonch bilan to'g'ri tasniflagan bo'lsa, (1−p) ko'paytuvchisi kichik bo'lib, uning hissasi kamayadi.

Aynan shu komponent chegara aniqligi muammosiga bevosita ta'sir ko'rsatadi. O'sma va sog'lom to'qima orasidagi o'tish zonasidagi voksellar ta'rifi bo'yicha noaniq bashoratga ega bo'ladi, ya'ni ular fokal komponent uchun eng katta vaznga ega misollar hisoblanadi.

To'rtinchi komponent Tversky indeksiga asoslanadi va yolg'on musbat hamda yolg'on manfiy javoblarni turli vazn bilan hisobga olish imkonini beradi [7]:

$$L_{Tversky} = 1 - \frac{TP}{TP + \alpha \cdot FP + \beta \cdot FN} \quad [4]$$

TP, FP, FN – to'g'ri musbat, yolg'on musbat va yolg'on manfiy voksellar soni; α = β = 0,5 bo'lganda ifoda Dice xatoligiga aylanadi. β > α tanlanganda esa yolg'on manfiy javoblar kuchliroq jazolanadi:

©Journal of Advances in Engineering Technology Vol.3(23), July — September, 2026
DOI 10.67889/2181-1431-2026-3-61-67

$$\alpha + \beta = 1, \quad \beta > \alpha \Rightarrow \frac{\partial \mathcal{L}_{Tversky}}{\partial FN_c} > \frac{\partial \mathcal{L}_{Tversky}}{\partial FP_c} \qquad [5]$$

Bu xossa aynan kichik hajmli sohalarni aniqlash muammosiga qaratilgan. Kuchaygan o‘sma kabi ixcham mintaqalarda model tabiiy ravishda ehtiyotkorlikka moyil bo‘ladi va shubhali voksellarni fon sifatida belgilaydi, asimmetrik Tversky komponenti bu moyillikni maqsadli tarzda kompensatsiya qiladi. Tajribada asosiy natijalar β = 0,5 qiymatida olindi, β ning ta’siri esa alohida sinovdan o‘tkazildi.

Kombinatsiyalangan xatolik funksiyasi

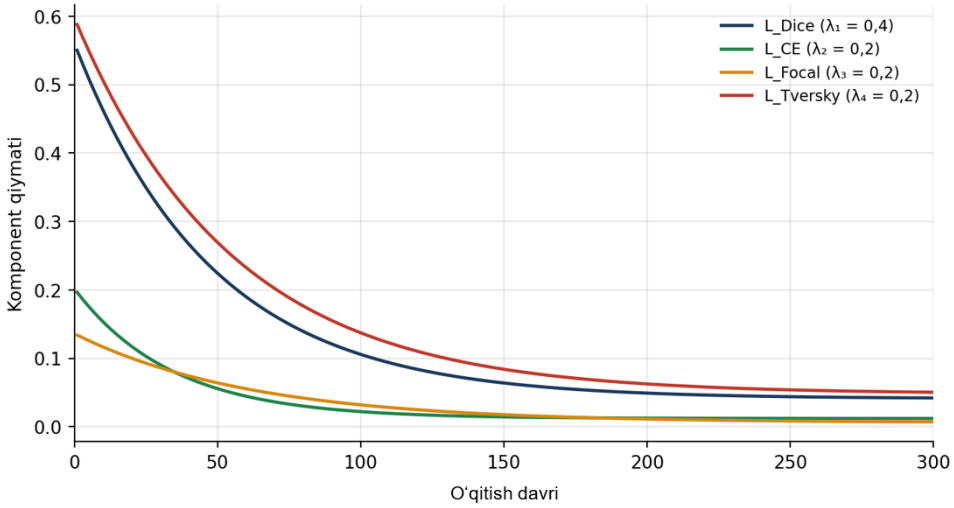
To‘rtta komponent chiziqli kombinatsiya ko‘rinishida birlashtiriladi:

$$L = \lambda_1 L_{Dice} + \lambda_2 L_{CE} + \lambda_3 L_{Focal} + \lambda_4 L_{Tversky} \qquad [6]$$

$$\lambda_k \geq 0, \quad \sum_{k=1}^{4} \lambda_k = 1$$

Vaznlar manfiy bo‘lmasligi va yig‘indisi birga teng bo‘lishi shartlari xatolik qiymatini barqaror ushlab turadi hamda turli tajribalar natijalarini qiyoslash imkonini beradi. Tajribada λ_1 = 0,4, λ_2=λ_3=λ_4 = 0,2 qiymatlari qo‘llanildi.

O‘qitish jarayonida har bir komponentning qiymati alohida qayd etib borildi. Umumiy xatolik birinchi davrdagi 0,88154 dan yakuniy davrdagi 0,06563 gacha, ya’ni 92,6 foizga pasaydi. Komponentlarning pasayish sur’ati sezilarli darajada farq qildi, bu esa ularning turli vazifalarni bajarishini bilvosita tasdiqlaydi.



1-rasm. Xatolik funksiyasi komponentlarining davrlar bo‘yicha o‘zgarishi

Kesishgan entropiya komponenti eng tez pasaydi va taxminan 80-o‘qitish davriga kelib deyarli barqaror qiymatga chiqdi, bu uning asosan boshlang‘ich bosqichda muhim rol o‘ynashini ko‘rsatadi. Fokal komponent ham nisbatan tez kamaydi, chunki oson misollar ulushi o‘qitish davomida ortib bordi. Hajmiy ustma-ustlik va Tversky komponentlari esa sekinroq, ammo uzoqroq muddat davomida pasaydi va oxirgi yuz davrda umumiy xatolikning asosiy qismini tashkil etdi. Boshqacha aytganda, o‘qitishning kech bosqichlarida model aynan hajmiy aniqlik va o‘tkazib yuborilgan sohalar ustida ishlashda davom etdi.

Har bir komponentning hissasini aniqlash uchun ular ketma-ket qo‘shib borildi. Barcha variantlar bir xil model, bir xil ma’lumot bo‘linishi va bir xil giperparametrlar bilan o‘qitildi, farq faqat xatolik funksiyasining tarkibida bo‘ldi.

©Journal of Advances in Engineering Technology Vol.3(23), July — September, 2026
DOI 10.67889/2181-1431-2026-3-61-67

1-jadval.

Komponentlarni ketma-ket qo‘shishning natijaga ta’siri

Xatolik funksiyasi tarkibi	To‘liq o‘sma (WT)	O‘sma yadrosi (TC)	kuchaygan o‘sma (ET)	O‘rtacha qiymat	Δ o‘rtacha qiymat
Faqat L_{CE}	0,8420	0,7710	0,6150	0,7427	–
Faqat L_{Dice}	0,8740	0,8220	0,7030	0,7997	+0,0570
L_{Dice} + L_{CE}	0,8890	0,8410	0,7340	0,8213	+0,0216
L_{Dice} + L_{CE} + L_{Focal}	0,9010	0,8600	0,7690	0,8433	+0,0220
To‘rt komponentli	0,9110	0,8769	0,7953	0,8610	+0,0177

Taklif etilgan sozlama bilan o‘qitilgan model 250 ta validatsiya holatida to‘liq baholashdan o‘tkazildi.

2-jadval.

250 ta validatsiya holatidagi yakuniy baholash natijalari

Mintaqa	Dice qiymati (o'rtacha)	Dice qiymati (mediana)	HD95 qiymati, mm	Sezgirlik qiymati	Aniqlik qiymati	AUC qiymati
WT (To‘liq o‘sma)	0,9110	0,9307	4,71	0,9095	0,9210	0,9941
TC (o‘sma yadrosi)	0,8769	0,9273	4,02	0,8952	0,8891	0,9829
ET (kuchaygan o‘sma)	0,7953	0,8456	3,78	0,8226	0,7892	0,9901
O‘rtacha qiymat	0,8610	0,9012	4,17	0,8758	0,8664	0,9890

To‘liq o‘sma va o‘sma yadrosi mintaqalarida aniqlik sezgirlikdan biroz yuqori, kuchaygan o‘sma mintaqasida esa aksincha bo‘lib chiqdi. Oxirgi holat Tversky komponentining kutilgan ta’sirini tasdiqlaydi, u aynan eng kichik mintaqada o‘tkazib yuborishning oldini olishga yo‘naltirilgan va natijada sezgirlikni aniqlikdan yuqori darajaga chiqargan
Taklif etilgan funksiya adabiyotlarda keng qo‘llaniladigan variantlar bilan bir xil sharoitda qiyoslandi.

3-jadval.

Bir xil model va bir xil o‘qitish protokoli asosida xatolik funksiyalarining qiyosiy natijalari

Xatolik funksiyasi	Manba	O‘rtacha Dice qiymati	ET Dice qiymati	O‘rtacha HD95 qiymati (mm)
Kesishgan entropiya	klassik	0,7427	0,6150	8,94
Dice xatoligi	[4]	0,7997	0,7030	6,71
Umumlashgan Dice	[5]	0,8104	0,7188	6,12
Dice + kesishgan entropiya	[9]	0,8213	0,7340	5,64
Fokal Tversky	[10]	0,8351	0,7602	5,08
To‘rt komponentli	–	0,8610	0,7953	4,17

©Journal of Advances in Engineering Technology Vol.3(23), July — September, 2026
DOI 10.67889/2181-1431-2026-3-61-67

Taklif etilgan funksiya barcha uch mezon bo‘yicha eng yaxshi natijani ko‘rsatdi. Ayniqsa e’tiborga loyiq jihati chegara aniqligini o‘lchovchi HD95 ko‘rsatkichidagi yaxshilanish bo‘ldi, eng yaqin raqobatchiga nisbatan farq 0,91 mm ni tashkil etdi. Bu fokal komponentning chegara sohasidagi noaniq voksellarga e’tiborni yo‘naltirish vazifasini muvaffaqiyatli bajarganini ko‘rsatadi.

Xulosa

Mazkur ishda miya o‘smasi segmentatsiyasidagi sinflar nomutanosibligi, kichik hajmli sohalarni aniqlash va chegara aniqligini bir vaqtda hal etishga qaratilgan to‘rt komponentli kombinatsiyalangan xatolik funksiyasi ishlab chiqildi va tajribada tekshirildi. Asosiy natijalar quyidagilardan iborat: hajmiy ustma-ustlik, voksel darajasidagi tasniflash, qiyin misollarga e’tibor va yolg‘on manfiy javoblarni maqsadli jazolash komponentlarini birlashtiruvchi xatolik funksiyasi taklif etildi; vaznlarning maqbul qiymatlari tizimli qidiruv orqali aniqlandi (0,4 / 0,2 / 0,2 / 0,2); chegara aniqligini o‘lchovchi HD95 ko‘rsatkichi bo‘yicha taklif etilgan funksiya eng yaqin raqobatchi qiymatidan 0,91 mm ga ustun bo‘lib chiqdi; yakuniy model 250 ta validatsiya holatida uch mintaqa bo‘yicha 0,8610 o‘rtacha Dice va 4,17 mm o‘rtacha HD95 ko‘rsatkichiga erishdi.

Foydalanilgan adabiyotlar ro‘yxati:

[1]. Ma J,. Chen J., Ng M., Huang R., Li Y., Li C., Yang X., Martel A.L. Loss odyssey in medical image segmentation // *Medical Image Analysis*. – 2021. – Vol. 71. – Art. 102035.

[2]. Menze B. H., Jakab A., Bauer S., Kalpathy-Cramer J., Farahani K., Kirby J., Burren Y., Porz N., Slotboom J., Wiest R., Lanczi L., Gerstner E., Weber M. A., Arbel T., Avants B. B., Ayache N., Buendia P., Collins D. L., Cordier N., Corso J. J., Van Leemput K. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS) // *IEEE Transactions on Medical Imaging.* – 2015. – Vol. *34,* No. 10. – P. 1993–2024.

[3]. Baid U., Ghodasara S., Bilello M., Mohan S., Calabrese E., Colak E., Farahani K., Kalpathy-Cramer J., Kitamura F.C., Pati S., Prevedello L.M., Rudie J.D., Sako C., Shinohara R.T., Bergquist T., Chai R., Eddy J.A., Elliott J., Reade W.C., Schaffter T., Yu T., Zheng J., Annotators B., Davatzikos C., Mongan J.T., Hess C.P., Cha S., Villanueva-Meyer J.E., Freymann J.B., Kirby J.S., Wiestler B., Crivellaro P.S., R.Colen R., Kotrotsou A., Marcus D.S., Milchenko M., Nazeri A., Fathallah-Shaykh H.M., Wiest R., Jakab A., Weber M., Mahajan A., Menze B.H., Flanders A.E., Bakas S. The RSNA-ASNR-MICCAI BraTS 2021 Benchmark on Brain Tumor Segmentation and Radiogenomic Classification // *arXiv:2107.02314*. – 2021.

[4]. Milletari F., Navab N., Ahmadi S.-A. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation // *Proceedings of the International Conference on 3D Vision (3DV 2016).* – Stanford, CA, USA, 2016. – P. 565–571.

[5]. Sudre C.H, Li W., Vercauteren T., Ourselin S., Cardoso J.M. Generalised Dice Overlap as a Deep Learning Loss Function for Highly Unbalanced Segmentations // *Proceedings of the Deep Learning in Medical Image Analysis (DLMIA 2017).* – 2017. – P. 240–248.

[6]. Lin T.Y., Goyal P., Girshick R., He K., Dollár P. Focal Loss for Dense Object Detection // Proceedings of the IEEE International Conference on Computer Vision. – Venice, 22-29 October 2017. –P. 2980-2988.

©Journal of Advances in Engineering Technology Vol.3(23), July — September, 2026
DOI 10.67889/2181-1431-2026-3-61-67

[7]. Salehi S.S.M., Erdogmus D., Gholipour A. Tversky Loss Function for Image Segmentation Using 3D Fully Convolutional Deep Networks // *Proceedings of the Machine Learning in Medical Imaging (MLMI 2017).* – 2017. – P. 379–387.

[8]. Kervadec H., Bouchtiba J., Desrosiers C., Granger E., Dolz J., Ben A.I. Boundary loss for highly unbalanced segmentation // Medical image analysis. – 2021. – Vol. 67. – Art. 101851.

[9]. Taghanaki S.A., Zheng Y., Zhou, S.K., Georgescu B., Sharma P., Xu D., Comaniciu D., Hamarneh G. Combo Loss: Handling Input and Output Imbalance in Multi-Organ Segmentation // *Computerized Medical Imaging and Graphics*. – 2019. – Vol. 75. – P. 24–33.

[10]. Yeung M., Sala E., Schönlieb C.B., Rundo L. Unified Focal Loss: Generalising Dice and Cross Entropy-Based Losses to Handle Class Imbalanced Medical Image Segmentation // *Computerized Medical Imaging and Graphics*. – 2022. – Vol. 95. – Art. 102026.

[11]. Bertels J., Eelbode T., Berman M., Vandermeulen D., Maes F., Bisschops R., Blaschko M. Optimizing the Dice Score and Jaccard Index for Medical Image Segmentation: Theory and Practice // *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2019).* – 2019. – P. 92–100.

©Journal of Advances in Engineering Technology Vol.3(23), July — September, 2026
DOI 10.67889/2181-1431-2026-3-61-67