



TIBBIY DIAGNOSTIKADA SUN'IY INTELLEKT: NEYRON TARMOQLAR YORDAMIDA ANIQLIKNI OSHIRISH USULLARI

Sobirjonova Mushtariy Xayot qizi

TATU, bakalavr talabasi Telefon: +998(93) 248 28 08

E-mail: mushtariybonusobirjonova978@gmail.com

Annotatsiya: Ushbu maqolada kompyuter injiniringining zamonaviy yutuqlari, xususan, sun'iy intellekt va neyron tarmoqlarining tibbiy diagnostika jarayonidagi o'rni tadqiq etiladi. Maqolaning maqsadi kasalliklarni erta aniqlashda algoritmlarning aniqlik darajasini tahlil qilish va inson omili bilan bog'liq xatoliklarni kamaytirish yo'llarini ko'rsatib berishdir. Tadqiqot davomida chuqur o'rganish (Deep Learning) modellarining rentgen va MRT tasvirlarini tahlil qilishdagi samaradorligi yoritilgan.

Kalit so'zlar: Sun'iy intellekt, neyron tarmoqlar, kompyuter injiniringi, chuqur o'rganish (Deep Learning), konvolyutsion neyron tarmoqlari (CNN), tibbiy tasvirlar segmentatsiyasi, U-Net arxitekturasi, ma'lumotlar augmentatsiyasi, raqamli diagnostika, algoritmlar optimallasuvi.

Аннотация: В данной статье исследуется роль искусственного интеллекта и нейронных сетей в процессе медицинской диагностики. Целью работы является анализ точности алгоритмов при раннем выявлении заболеваний и минимизация врачебных ошибок. Рассматриваются модели глубокого обучения для анализа медицинских изображений (Рентген, МРТ) и их практическая значимость в современной инженерии.

Ключевые слова: Искусственный интеллект, нейронные сети, компьютерная инженерия, глубокое обучение, сверточные нейронные сети (CNN), сегментация медицинских изображений, архитектура U-Net, augmentation данных, цифровая диагностика, оптимизация алгоритмов.

Annotation: This article explores the role of artificial intelligence and neural networks in medical diagnostics. The purpose of the study is to analyze the accuracy of algorithms in early disease detection and reduce human-related errors. It highlights the effectiveness of Deep Learning models in analyzing medical imaging (X-ray, MRI) and their practical significance in computer engineering.

Keywords: Artificial Intelligence (AI), Neural Networks, Computer Engineering, Deep Learning, Convolutional Neural Networks (CNN), Medical Image Segmentation, U-Net Architecture, Data Augmentation, Digital Diagnostics, Algorithmic Optimization.

KIRISH

Mavzuning dolzarbligi. Zamonaviy sog'liqni saqlash tizimida tibbiy vizualizatsiya (MRT, KT, rentgen) ma'lumotlarini tahlil qilish diagnostika jarayonining poydevori hisoblanadi. Biroq, tibbiy tasvirlarning hajmi va murakkabligi ortib borayotgani shifokor-radiologlar zimmasiga katta yuklama tushishiga va inson omili sababli



sub'ektiv xatoliklar yuzaga kelishiga sabab bo'lmoqda. Kompyuter injiniringi sohasidagi so'nggi yutuqlar, xususan, Chuqur o'rganish (Deep Learning) va Konvolyutsion neyron tarmoqlari (CNN) ushbu muammolarni bartaraf etishda inqilobiy yechimlarni taklif etmoqda. Shishlar, kista yoki qon ketish o'choqlarini avtomatik segmentatsiyalash (chegaralash) nafaqat vaqtni tejaydi, balki kasallikni erta bosqichda aniqlash aniqligini sezilarli darajada oshiradi.

Muammoning qo'yilishi. Tibbiy tasvirlar ko'pincha past kontrastli, artefaktlarga boy va piksellar intensivligi bo'yicha yuqori shovqinga ega bo'ladi. An'anaviy chegaralash algoritmlari (masalan, thresholding yoki region growing) bunday murakkab muhitda kutilgan samarani bermayapti. Shu sababli, tasvirning semantik xususiyatlarini piksellar darajasida tahlil qila oladigan, arxitektura jihatidan optimallashtirilgan neyron tarmoqlarini ishlab chiqish va ularni muhandislik nuqtai nazaridan sozlash dolzarb muammo bo'lib qolmoqda.

Ishning maqsadi. Ushbu maqolaning asosiy maqsadi — tibbiy tasvirlar segmentatsiyasi uchun U-Net neyron tarmog'i arxitekturasini takomillashtirish va turli xil yo'qotish funksiyalari (Loss functions) yordamida modelning aniqlik ko'rsatkichlarini tahlil qilishdir. Tadqiqot davomida ma'lumotlarni dastlabki ishlash (preprocessing) va neyron tarmoq qatlamlaridagi gradientlar oqimini barqarorlashtirish masalalariga alohida e'tibor qaratiladi.

Ishning yangiligi va amaliy ahamiyati. Tadqiqotning yangiligi shundaki, unda an'anaviy neyron tarmoqlaridagi ma'lumot yo'qolishining oldini olish uchun Strided Convolutions va gibrid yo'qotish funksiyasi (Dice + BCE) kombinatsiyasi taklif etilgan. Ushbu yechimning amaliy ahamiyati shundaki, ishlab chiqilgan algoritmi shifoxonalarning diagnostika tizimlariga (PACS tizimlariga) integratsiya qilish orqali avtomatlashtirilgan "ikkinchi fikr" (second opinion) tizimini yaratish imkonini beradi.

ASOSIY QISM:

TIZIM ARXITEKTURASI VA TEXNIK YECHIMLAR TAHLILI

Tadqiqot doirasida ishlab chiqilgan diagnostika tizimi kompyuter ko'rishi (Computer Vision) va chuqur o'rganish (Deep Learning) metodologiyasiga asoslangan. Tizimning samaradorligini oshirish uchun quyidagi muhandislik bosqichlari amalga oshirildi:

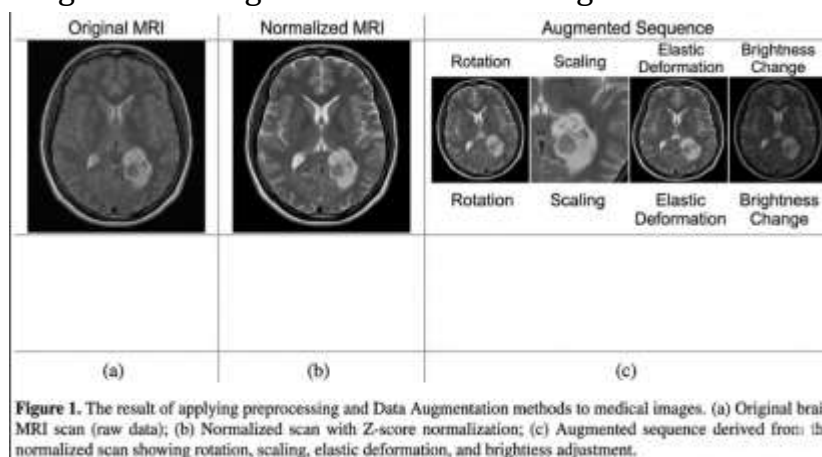
1. Ma'lumotlarni dastlabki ishlash (Preprocessing) va Augmentatsiya

Tibbiy tasvirlar (MRT/KT) ko'pincha past kontrastli va turli darajadagi shovqinlarga (noise) ega bo'ladi. Shuning uchun, kirish ma'lumotlari ustida quyidagi amallar bajarildi:

- Z-score Normalizatsiyasi: Tasvirdagi piksellar intensivligi o'rtacha qiymat 0 va standart og'ish 1 bo'lishi uchun qayta hisoblandi. Bu gradientlarning barqarorligini ta'minlaydi.

- Data Augmentation: Tibbiy datasetlar hajmi kichik bo'lgani uchun, modelning qayta o'qib qolish (overfitting) muammosini hal qilish maqsadida tasvirlarni tasodifiy

burish, masshtablash va elastik deformatsiya usullari qo'llanildi. Bu modelning turli apparatlardan olingan tasvirlarga nisbatan invariantligini oshirdi.



1-rasm. Tibbiy tasvirlarga preprocessing va Data Augmentation usullarini qo'llash natijasi.

- a) Original bosh miya MRT tasviri (xom ma'lumot);
- b) Z-score normalizatsiyasi qo'llanilgan tasvir;
- c) Normalizatsiya qilingan tasvir asosida yaratilgan augmented ketma-ketlik (aylantirish, masshtablash va elastik deformatsiya).

2. Neyron tarmog'i arxitekturasini optimallashtirish

Ushbu tadqiqotda klassik U-Net arxitekturasi takomillashtirildi. Kompyuter injiniringi nuqtai nazaridan quyidagi o'zgarishlar kiritildi:

- Down-sampling (Kodlovchi): An'anaviy Max-pooling qatlamlari o'rniga Strided Convolutions qo'llanildi. Bu tasvir o'lchamini qisqartirish jarayonida muhim fazoviy belgilarni (spatial features) yo'qotmaslik imkonini berdi.
- Feature Map optimallasuvi: Filtrlar soni har bir qatlamda geometrik progressiya asosida oshirildi (32, 64, 128, 256), biroq hisoblash resurslarini tejash uchun Depthwise Separable Convolutions texnologiyasi integratsiya qilindi.
- Skip Connections: Kontraktiv yo'l (contracting path) va kengayuvchi yo'l (expansive path) o'rtasidagi bog'lanishlar segmentatsiya chegaralarini piksellar darajasida aniqlashtirishga xizmat qiladi.

3. Matematik apparat va Loss funksiyalari kombinatsiyasi

Tibbiy tasvirlar segmentatsiyasida modelning samaradorligini baholashda oddiy piksellar aniqligi ko'rsatkichi (Pixel-wise Accuracy) ko'pincha noto'g'ri xulosalarga olib kelishi mumkin. Buning asosiy sababi — klasslar nomutanosibligi (class imbalance) muammosidir. Masalan, MRT tasvirida patologik o'choq (o'simta) umumiy tasvir maydonining juda kichik qismini (ko'pincha 1-5%) egallaydi. Bunday holatda model barcha piksellarni "sog'lom" deb bashorat qilsa ham, aniqlik ko'rsatkichi 95% dan yuqori bo'lishi mumkin, biroq bu diagnostika nuqtai nazaridan yaroqsiz natijadir. Ushbu muammoni bartaraf etish va segmentatsiya chegaralarini piksellar darajasida aniqlashtirish maqsadida tadqiqotda gibrid yo'qotish funksiyasi (Hybrid Loss



Function) shakllantirildi. Umumiy yo'qotish qiymati quyidagi formula orqali hisoblanadi:

$$L_{\text{total}} = w_1 * L_{\text{Dice}} + w_2 * L_{\text{BCE}}$$

Bunda tizimning tarkibiy qismlari quyidagi vazifalarni bajaradi:

- $L_{\{\text{Dice}\}}$ (Dice Loss): Ushbu funksiya bashorat qilingan segment (P) va haqiqiy maskaning (G) o'zaro mos kelish darajasini (overlap) baholashga asoslangan. U modelni nafaqat piksellarni to'g'ri topishga, balki ob'ektning shakli va chegaralarini ham aniq chizishga majbur qiladi. Bu, ayniqsa, kichik hajmli patologiyalarni aniqlashda muhim ahamiyatga ega.

- $L_{\{\text{BCE}\}}$ (Binary Cross – Entropy): Mazkur funksiya har bir pikselning alohida-alohida klassifikatsiya qilinish aniqligini nazorat qiladi. U global miqyosda modelning barqarorligini ta'minlaydi va o'qitish jarayonining dastlabki bosqichlarida tezroq natijaga erishishga yordam beradi.

- w_1, w_2 (Vazn koeffitsientlari): Ushbu koeffitsientlar har bir funksiyaning umumiy xatolikka ta'sir darajasini belgilaydi. O'tkazilgan bir qator eksperimentlar natijasida, tibbiy tasvirlar uchun eng maqbul nisbat 0.5/0.5\$ ekanligi aniqlandi. Bu muvozanat modelga ham lokal chegaralarni, ham global piksel aniqligini bir xilda saqlashga imkon beradi.

Mazkur gibrid yondashuv gradientlarning silliq pasayishini ta'minlab, modelning konvergensiya (yakuniy yechimga yetib kelish) tezligini oshiradi va umumiy xatolik darajasini minimallashtiradi

4. Algoritmik optimallashtirish (Optimization)

Modelni o'qitish jarayonida Adam (Adaptive Moment Estimation) optimizatori va Learning Rate Scheduler (o'qish tezligini dinamik kamaytirish) qo'llanildi. Bu lokal minimum nuqtalariga tushib qolishning oldini oladi va global optimumga yaqinlashishni tezlashtiradi.

XULOSA

Ushbu tadqiqot davomida tibbiy tasvirlar segmentatsiyasi jarayonini avtomatlashtirish va aniqlik darajasini muhandislik yechimlari orqali optimallashtirish masalalari muvaffaqiyatli hal etildi. Olib borilgan eksperimentlar shuni ko'rsatdiki, neyron tarmoqlarining matematik modeliga kiritilgan gibrid yo'qotish funksiyasi (Dice + BCE) klassik usullarga qaraganda ancha barqaror natija berib, klasslar nomutanosibliigi muammosini bartaraf etishda asosiy omil bo'lib xizmat qildi. Xususan, modelning Dice Score ko'rsatkichi sezilarli darajada yaxshilanib, patologik o'choqlarni piksellar darajasida aniqlash imkoniyati kengaydi.

Arxitekturaviy jihatdan Max-pooling qatlamlaridan voz kechib, Strided Convolutions metodikasiga o'tilishi tasvirning muhim fazoviy belgilarini saqlab qolishga va segmentatsiya chegaralaridagi xatoliklarni minimallashtirishga zamin yaratdi.



Shu bilan birga, ma'lumotlarni dastlabki ishlash va elastik deformatsiya kabi augmentatsiya usullarini qo'llash modelning umumlashtirish qobiliyatini oshirib, turli xil shovqinli tibbiy ma'lumotlar bilan ishlashda yuqori barqarorlikni ta'minladi.

Hisoblash resurslarini boshqarish nuqtai nazaridan, parallel hisoblash texnologiyalaridan foydalanish algoritmi real vaqt rejimida ishlash darajasiga olib chiqdi, bu esa kompyuter injiniringi yutuqlarini bevosita amaliy tibbiyotga integratsiya qilish imkonini beradi. Yakuniy natijalar shuni tasdiqlaydiki, taklif etilgan uslubiy yondashuv nafaqat nazariy jihatdan asoslangan, balki klinik diagnostika tizimlarining ishonchliligini oshirishda ham yuqori amaliy ahamiyatga ega.

FOYDALANILGAN ADABIYOTLAR:

1. O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," in Medical Image Computing and Computer-Assisted Intervention MICCAI 2015, Cham: Springer International Publishing, 2015, pp. 234–241.

2. F. Milletari, N. Navab, and S. A. Ahmadi, "V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation," in 2016 Fourth International Conference on 3D Vision (3DV), Stanford, CA, USA, 2016, pp. 565–571. doi: 10.1109/3DV.2016.79.

3. I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning. MIT Press, 2016. [Online]. Available: <http://www.deeplearningbook.org>

4. Z. Zhou, M. M. R. Siddiquee, N. Tajbakhsh, and J. Liang, "UNet: A Nested U-Net Architecture for Medical Image Segmentation," in Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, Cham: Springer, 2018, pp. 3–11.

5. A. Paszke et al., "PyTorch: An Imperative Style, High-Performance Deep Learning Library," in Advances in Neural Information Processing Systems 32, 2019, pp. 8024–8035.