KOMPYUTER TOMOGRAFIYASI TASVIRLARI ASOSIDA TASHXISLASH ALGORITMLARINI ISHLAB CHIQISH

Iskandarova F.N.

Toshkent xalqaro moliyaviy menejment va texnologiyalar universiteti

feruza621988@gmail.com

Sobirova M

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti magistranti

Nuritdinov Jahongir To‘lqin o‘g‘li

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti magistranti

nuriddinovjahongir250@gmail.com

Madina Shaymanova

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti magistranti

Annotatsiya. Maqolada kompyuter tomografiyasi (KT) tasvirlari asosida o‘pka kasalliklarini avtomatik tashxislash uchun ishlab chiqilgan gibrid konvolyutsion neyron tarmoq modeli — MS-AttUNet keltirilgan. Model U-Net segmentatsiya bloki, ResNet-50 klassifikatsiya bloki, Multi-Scale Feature Extraction (MSFE) moduli va CBAM attention mexanizmini birlashtiradi. 2398 ta bemorning 380 000 ta KT kesim tasvirida sinovdan o‘tkazilgan model 96,4% aniqlik, 94,7% sezgirlik va 0,974 AUC-ROC ko‘rsatkichlariga erishdi. CT-DiagAI nomli web-asoslangan dasturiy vosita ishlab chiqildi.

Kalit so‘zlar: *kompyuter tomografiyasi, sun'iy intellekt, chuqur o‘qitish, konvolyutsion neyron tarmoqlar, U-Net, ResNet, attention mexanizmi, tibbiy tasvirlarni segmentatsiyalash.*

1. KIRISH

Tibbiy tasvirlash sohasida kompyuter tomografiyasi (KT) eng samarali tashxislash usullaridan biri hisoblanadi. Jahon sog‘liqni saqlash tashkiloti (JSST) ma'lumotlariga ko‘ra, har yili dunyoda 2 milliarddan ortiq KT tekshiruvi o‘tkaziladi va bu raqam yiliga 5–7% ga oshib bormoqda. Biroq, KT tasvirlarini qo‘lda tahlil qilish 15–30 daqiqa vaqt talab etadi, radiolog xatolari esa 3–5% ni tashkil qiladi.

O‘zbekiston Respublikasi Prezidentining 2020-yil 5-oktyabrdagi PF-6079-son Farmoni asosida raqamli tibbiyot va sun'iy intellekt texnologiyalarini joriy etish davlat siyosatining ustuvor yo‘nalishlaridan biriga aylandi. Ushbu kontekstda KT tasvirlarini avtomatik tashxislash tizimini yaratish nafaqat ilmiy, balki ijtimoiy ahamiyatga ham ega.

Mavjud yondashuvlar (U-Net, ResNet, DenseNet, EfficientNet) turli o‘lchamdagi patologik o‘zgarishlarni bir vaqtning o‘zida aniqlashda yetarli aniqlikni ta'minlay olmaydi. Mayda nodular shakllanishlar (3–5 mm) va keng tarqalgan infiltratlar (5–10 sm) bir xil arxitekturada samarali aniqlanmaydi. Shu sababli multi-scale yondashuv va attention mexanizmini birlashtirgan yangi gibrid model ishlab chiqish dolzarbdir.

Tadqiqot maqsadi — KT tasvirlari asosida o‘pka patologiyalarini yuqori aniqlikda (≥95%) avtomatik aniqlash uchun gibrid CNN arxitekturasini ishlab chiqish va undan amalda foydalanish imkonini beruvchi web-asoslangan dasturiy vositani yaratish.

Ilmiy yangiligi. Multi-Scale Feature Extraction moduli va CBAM attention mexanizmini U-Net hamda ResNet-50 arxitekturalari bilan birlashtirgan yangi MS-

AttUNet modeli taklif etildi. Mahalliy aholiga moslashtirilgan KT tasvirlari bazasi shakllantirildi.

2. METODLAR

2.1. Ma’lumotlar bazasi va oldindan qayta ishlash

Tadqiqotda to‘rtta turli manbadan jami 2 398 ta bemorning KT tekshiruvi (taxminan 380 000 ta kesim) to‘plandi: LIDC-IDRI (1 018 bemor — o‘pka tugunlari), MosMedData (1 110 bemor — COVID-19), COVID-19 CT Lung and Infection Segmentation Dataset (20 bemor) va Respublika ixtisoslashtirilgan pulmonologiya ilmiy-amaliy tibbiyot markazi bilan hamkorlikda to‘plangan mahalliy ma'lumotlar (250 bemor). Ma’lumotlar 70/15/15 nisbatda o‘qitish, validatsiya va test to‘plamlariga bo‘lindi.

Oldindan qayta ishlash bosqichida DICOM fayllar Hounsfield birliklariga (HU) o‘tkazildi, qiymatlar [−1000; +400] diapazonida qirqildi (clipping), min-max normalizatsiya qo‘llanildi, tasvirlar 256×256 o‘lchamga keltirildi. Lung windowing (W=1500, L=−600), Otsu thresholding va morfologik amallar yordamida o‘pka maskasi ajratildi. Ma'lumotlar augmentatsiyasi: aylantirish (±15°), gorizontal flip, masshtablash (0,9–1,1), elastik deformatsiya.

2.2. Taklif etilgan model arxitekturasi

MS-AttUNet modeli to‘rt asosiy modulni birlashtiradi: (1) ResNet-50 asosidagi encoder bloki (ImageNet og'irliklari bilan transfer learning), (2) parallel 1×1, 3×3, 5×5, 7×7 konvolyutsiyalar va dilation rates 1, 2, 4, 8 bilan atrous konvolyutsiyalardan iborat MSFE moduli, (3) CBAM attention moduli (Channel + Spatial Attention) va (4) skip connections bilan U-Net decoder bloki. Model formulasi: $Y = D(MSFE(CBAM(E(X))))$. Modelning umumiy parametrlar soni — 31,4 mln, hisoblash murakkabligi — 47,2 GFLOPs.

Birlashtirilgan yo'qotish funksiyasi qo‘llanildi: $L_{total} = \alpha \cdot L_{dice} + \beta \cdot L_{focal} + \gamma \cdot L_{BCE}$, bu yerda $\alpha=0,5$; $\beta=0,3$; $\gamma=0,2$. Modelni o‘qitish uchun

Adam optimizator (lr=1e-4, ReduceLROnPlateau), batch size 16, 100 epoxa (EarlyStopping patience=15), Dropout 0,3 va L2 regularizatsiya (1e-5) parametrlari ishlatildi. O‘qitish NVIDIA RTX 4090 (24 GB VRAM) GPU da 28 soat 17 daqiqa davom etdi.

2.3. Baholash metrikalari va dasturiy vosita

Modelni baholash uchun Accuracy, Precision, Recall (Sensitivity), Specificity, F1-score, AUC-ROC, Dice coefficient va IoU metrikalari hisoblandi. Statistik ahamiyatlilikni tekshirish uchun McNemar testi qo‘llanildi. CT-DiagAI dasturiy vositasi React.js (frontend), Flask (backend), TensorFlow Serving (model), PostgreSQL (DB), MinIO (fayl saqlash) va Docker/Kubernetes (orkestratsiya) texnologiyalarida amalga oshirildi.

3. NATIJALAR

Test to‘plamida MS-AttUNet quyidagi ko‘rsatkichlarga erishdi: aniqlik (Accuracy) — 96,4%; sezgirlik (Sensitivity) — 94,7%; maxsuslik (Specificity) — 97,1%; F1-score — 94,8%; AUC-ROC — 0,974; Dice koeffitsienti — 0,912; IoU — 0,843. Patologiyalar bo‘yicha eng yuqori natija COVID-19 ni aniqlashda qayd etildi (F1=0,971; AUC=0,987), eng past — emfizemada (F1=0,911), bu ushbu kasallikning vizual o‘xshashligi va kichik test to‘plami bilan izohlanadi.

Mavjud zamonaviy modellar bilan taqqoslashda MS-AttUNet barcha boshqa yondashuvlardan ustun keldi: U-Net (88,3%) ga nisbatan +8,1%, ResNet-50 (91,5%) ga nisbatan +4,9%, DenseNet-121 (92,7%) ga nisbatan +3,7%, EfficientNet-B3 (93,2%) ga nisbatan +3,2%, Attention U-Net (93,8%) ga nisbatan +2,6% yuqori aniqlik ko‘rsatdi. Sezgirlik bo‘yicha farq 3,1–9,0% ni tashkil qildi. McNemar testi natijalari farqlarning statistik ahamiyatliligini tasdiqladi ($p < 0,001$).

Tizimning ish vaqti GPU yordamida bir bemor uchun 16,6 soniyani tashkil qildi (DICOM o‘qish — 0,8 s, oldindan qayta ishlash — 1,2 s, 250 ta kesim uchun

model bashorati — 12,5 s, hisobot yaratish — 2,1 s). CPU rejimida bu vaqt 219,4 soniya. An'anaviy qo‘lda tahlilga (15–30 daqiqa) nisbatan tizim 50–100 marta tezroq ishlaydi.

4. MUHOKAMA VA XULOSA

Tadqiqot natijalari Multi-Scale Feature Extraction moduli va attention mexanizmini birlashtirish tibbiy tasvirlarni tahlil qilishda samaradorlikni sezilarli oshirishini ko‘rsatdi. MSFE moduli turli kernel o‘lchamlari va dilation ratelar orqali ham mayda nodulalar (3–5 mm), ham keng infiltratlarni bir vaqtda aniqlashga imkon beradi. CBAM attention esa modelga muhim sohalarga e'tibor qaratish imkonini berib, foydasiz xususiyatlardan diqqatni chalg'itadi.

Modelning o‘qitish va validatsiya orasidagi farq atigi 1,4% ni tashkil qildi — bu overfitting muammosi yetarli darajada hal etilganligini bildiradi. Qo‘llanilgan birlashtirilgan yo'qotish funksiyasi (Dice + Focal + BCE) sinflar nomutanosibligi muammosini yumshatadi, bu esa kam uchraydigan patologiyalar (sil, emfizema) uchun ham qabul qilinadigan natijalarni ta'minlaydi.

Amaliy ahamiyat. CT-DiagAI tizimi O‘zbekiston tibbiyot muassasalarida joriy etilishi mumkin. Bu shifokorlarning ish samaradorligini oshiradi, tashxis vaqtini 15 daqiqadan 30 soniyagacha qisqartiradi va ayniqsa qishloq joylarida malakali radiolog tanqisligi muammosini yumshatishga yordam beradi. Tizim Grad-CAM heatmap orqali model qaroriga asos bo‘lgan sohalarni vizualizatsiya qiladi, bu klinik amaliyot uchun muhim shaffoflik elementidir.

Cheklovlar va kelgusi ishlar. Hozirgi model 2D kesimlar bilan ishlaydi; 3D fazoviy munosabatlardan to'liq foydalanish uchun 3D CNN arxitekturasini ishlab chiqish rejalashtirilgan. Shuningdek, federated learning yondashuvi orqali bemor maxfiyligini saqlagan holda turli klinikalar ma'lumotlaridan birgalikda foydalanish imkoniyatlari o‘rganiladi. Modelni jigar, miya va qorin a'zolari patologiyalariga kengaytirish istiqboldagi ishlardan biridir.

Xulosa qilib aytganda, taklif etilgan MS-AttUNet modeli va CT-DiagAI dasturiy vositasi KT tasvirlarini avtomatik tashxislashda yuqori aniqlik (96,4%) va tezlikni (16,6 s) namoyish etdi, mavjud yechimlardan 2,6–8,1% ga ustun natijalarga erishdi. Bu raqamli tibbiyot va sun'iy intellekt texnologiyalarini O‘zbekiston sog‘liqni saqlash tizimiga joriy etishda muhim qadam hisoblanadi.

FOYDALANILGAN ADABIYOTLAR

1. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation // MICCAI. — 2015. — Vol. 9351. — P. 234–241.
2. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // CVPR. — 2016. — P. 770–778.
3. Woo S., Park J., Lee J.Y., Kweon I.S. CBAM: Convolutional Block Attention Module // ECCV. — 2018. — P. 3–19.
4. Setio A.A.A., Traverso A., de Bel T., et al. Validation, comparison, and combination of algorithms for automatic detection of pulmonary nodules in CT images: The LUNA16 challenge // Medical Image Analysis. — 2017. — Vol. 42. — P. 1–13.
5. Wang S., Kang B., Ma J., et al. A deep learning algorithm using CT images to screen for COVID-19 // European Radiology. — 2021. — Vol. 31. — P. 6096–6104.
6. Litjens G., Kooi T., Bejnordi B.E., et al. A survey on deep learning in medical image analysis // Medical Image Analysis. — 2017. — Vol. 42. — P. 60–88.
7. Esteva A., Robicquet A., Ramsundar B., et al. A guide to deep learning in healthcare // Nature Medicine. — 2019. — Vol. 25, No. 1. — P. 24–29.