KOMPYUTER TOMOGRAFIYASI TASVIRLARI ASOSIDA O‘PKA PATOLOGIYALARINI AVTOMATIK TASHXISLASH UCHUN GIBRID CNN ARXITEKTURASI: MS-AttUNet MODELI

UDK: 004.93+616-073.75

Iskandarova S.N.

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti magistranti

sayyora5@mail.ru

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 yangi gibrid konvolyutsion neyron tarmoq arxitekturasi — MS-AttUNet (Multi-Scale Attention U-Net) taklif etiladi. Model U-Net segmentatsiya, ResNet-50 klassifikatsiya bloklari, Multi-Scale Feature Extraction (MSFE) moduli va Convolutional Block Attention Module (CBAM) attention mexanizmini birlashtiradi. Tadqiqot LIDC-IDRI, MosMedData, COVID-19 CT va mahalliy ma'lumotlar bazalaridan to‘plangan 2

398 ta bemorning 380 000 ta KT kesim tasvirida olib borildi. Test to‘plamida model 96,4% aniqlik, 94,7% sezgirlik, 97,1% maxsuslik va 0,974 AUC-ROC ko‘rsatkichlariga erishdi va mavjud zamonaviy yondashuvlardan 2,6–8,1% ga ustun keldi. Natijalar asosida 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, multi-scale feature extraction, segmentatsiya, tibbiy tasvirlarni qayta ishlash.*

Abstract. *This paper proposes a novel hybrid convolutional neural network architecture, MS-AttUNet (Multi-Scale Attention U-Net), for automatic diagnosis of lung diseases based on computed tomography (CT) images. The model integrates U-Net segmentation and ResNet-50 classification backbones with a Multi-Scale Feature Extraction (MSFE) module and the Convolutional Block Attention Module (CBAM). The study uses 2,398 patient CT examinations (~380,000 slices) from LIDC-IDRI, MosMedData, COVID-19 CT, and a local Uzbek dataset. On the held-out test set the model achieved 96.4% accuracy, 94.7% sensitivity, 97.1% specificity, and 0.974 AUC-ROC, outperforming state-of-the-art baselines by 2.6–8.1%. A web-based diagnostic tool, CT-DiagAI, was implemented on top of the proposed model.*

Keywords: *computed tomography, artificial intelligence, deep learning, convolutional neural networks, U-Net, ResNet, attention mechanism, multi-scale feature extraction, segmentation, medical image processing.*

1. KIRISH

Tibbiy tasvirlash — zamonaviy diagnostikaning eng muhim asboblaridan biri. Kompyuter tomografiyasi (KT) yuqori fazoviy ruxsat (0,3–0,5 mm), qisqa skaner vaqti (5–10 soniya) va 3D rekonstruksiya imkoniyati tufayli o‘pka, jigar, miya hamda boshqa a'zolar patologiyalarini aniqlashda asosiy vositaga aylangan

[1]. Jahon sog‘liqni saqlash tashkiloti ma'lumotlariga ko‘ra, dunyoda har yili 2 milliarddan ortiq KT tekshiruvi o‘tkaziladi va bu raqam yiliga 5–7% ga oshib bormoqda. Bunday hajmdagi tasvirlarni qo‘lda tahlil qilish radiologning 15–30 daqiqa vaqtini oladi va xato darajasi 3–5% ni tashkil qiladi [6].

Sun'iy intellekt va chuqur o‘qitish algoritmlari sohasidagi so‘nggi yutuqlar tibbiy tasvirlarni avtomatik tahlil qilish uchun yangi imkoniyatlar yaratdi [7, 8]. Ronneberger va boshqalar (2015) tomonidan taklif etilgan U-Net arxitekturasi tibbiy tasvirlarni segmentatsiyalashda standart yechim sifatida qo‘llaniladi [3]. He va boshqalar (2016) ResNet arxitekturasi orqali chuqur tarmoqlardagi gradient yo‘qolish muammosini hal etishdi [4]. Setio va boshqalar LUNA16 tanlovida 3D CNN modeli orqali o‘pka tugunlarini aniqlashda 92,5% aniqlikka erishishdi [9]. Wang va boshqalar (2021) DeepCovid modeli orqali COVID-19 ni KT da aniqlashda 90,3% aniqlik ko‘rsatkichini olishdi [5].

Mavjud yondashuvlarning umumiy kamchiligi — turli o‘lchamdagi patologik shakllanishlarni bir xil arxitekturada samarali aniqlay olmasligi. Mayda nodulalar (3–5 mm) va keng tarqalgan infiltratlar (5–10 sm) bir-biridan tubdan farq qiladigan vizual xususiyatlarga ega va bitta kernel o‘lchamiga moslashtirilgan tarmoqlar har ikkalasini ham yetarli aniqlikda aniqlay olmaydi. Shuningdek, mavjud yechimlarning aksariyati chet ellik aholi ma’lumotlarida o‘qitilgani sababli, mahalliy aholi xususiyatlariga moslashishda muammolar yuzaga kelishi mumkin.

O‘zbekiston Respublikasi Prezidentining 2020-yil 5-oktyabrdagi PF-6079-son «Raqamli O‘zbekiston-2030 strategiyasini tasdiqlash to‘g‘risida»gi Farmoni va 2018-yil 7-fevraldagi PF-5349-son sun'iy intellekt texnologiyalarini rivojlantirish bo‘yicha hujjatlar tibbiyot sohasiga AI texnologiyalarini joriy etishni davlat siyosatining ustuvor yo‘nalishi sifatida belgilaydi. Bu kontekstda mahalliy ma'lumotlarda o‘qitilgan, yuqori aniqlikdagi tashxis tizimini ishlab chiqish dolzarbdir.

Ushbu maqolada quyidagi asosiy hissalar taqdim etiladi: (1) Multi-Scale Feature Extraction moduli va CBAM attention mexanizmini U-Net hamda ResNet-50 bilan birlashtirgan yangi MS-AttUNet arxitekturasi; (2) Dice, Focal va BCE yo'qotishlarini birlashtirgan kompozit yo'qotish funksiyasi; (3) chet ellik va mahalliy ma’lumotlarni qamragan 2 398 bemorlik integral baza; (4) klinik amaliyotga moslashtirilgan CT-DiagAI nomli web-asoslangan dasturiy vosita.

Maqolaning keyingi qismi quyidagicha tashkil etilgan: 2-bo'limda metodologiya — ma'lumotlar bazasi, oldindan qayta ishlash, taklif etilgan model arxitekturasi va o‘qitish parametrlari tasvirlanadi; 3-bo'limda eksperimental natijalar va boshqa modellar bilan taqqoslash keltiriladi; 4-bo'limda natijalarning muhokamasi, tizimning amaliy qo‘llanilishi va cheklovlari ko‘rib chiqiladi; 5-bo'limda asosiy xulosalar shakllantiriladi.

2. METODLAR

2.1. Ma'lumotlar bazasi

Tadqiqotda to‘rtta turli manbadan to‘plangan integral baza shakllantirildi. Bazaning tarkibi 1-jadvalda keltirilgan.

1-jadval. Tadqiqot ma'lumotlar bazasining tarkibi

Ma'lumotlar bazasi	**Bemorlar**	**Kesimlar**	**Patologiyalar**	**Ulushi, %**
LIDC-IDRI	1 018	244 527	O‘pka tugunlari	42,4
MosMedData	1 110	110 000	COVID-19	46,3
COVID-19 CT Lung	20	3 520	COVID-19	0,8

Mahalliy (RIxPM)	250	21 953	Aralash	10,5
JAMI	**2 398**	**380 000**	**—**	**100,0**

Mahalliy ma’lumotlar bazasi Respublika ixtisoslashtirilgan pulmonologiya ilmiy-amaliy tibbiyot markazi (RIxPM) bilan hamkorlikda to‘plandi. Barcha ma'lumotlar HIPAA va O‘zbekiston Respublikasining «Shaxsiy ma'lumotlar to‘g‘risida»gi qonuni talablariga muvofiq anonimlashtirildi. Ma’lumotlar tasodifiy tarzda 70/15/15 nisbatda o‘qitish (1 679 bemor), validatsiya (360 bemor) va test (359 bemor) to‘plamlariga bo‘lindi. Bunda bir bemorning kesimlari faqat bitta to‘plamga tushishi ta'minlandi (patient-level split), ya'ni data leakage muammosi oldi olindi.

2.2. Oldindan qayta ishlash

Oldindan qayta ishlash bosqichida quyidagi amallar bajarildi:

1) DICOM fayllarni o'qish va Hounsfield birliklariga (HU) o‘tkazish: $HU = pixel_value \times RescaleSlope + RescaleIntercept;$

2) HU clipping: qiymatlar [−1000; +400] diapazonida qirqildi (o‘pka to'qimasi va atrofidagi havo va yumshoq to'qimalar uchun ma'noli diapazon);

3) Min-max normalizatsiya: $x_{_norm} = (x - x_{_min}) / (x_{_max} - x_{_min});$

4) Tasvir o‘lchamini standartlashtirish: 256×256 piksel (asl 512×512 dan kamaytirib, hisoblash narxini ikki barobardan ko‘proq kamaytirish);

5) Lung windowing: W=1500, L=−600 — o‘pka to'qimasi uchun tibbiy standart sozlama;

6) O‘pka maskasini ajratish: Otsu thresholding va morfologik amallar (closing, opening) yordamida o‘pka sohasi qolgan to'qimalardan ajratildi;

7) Ma'lumotlar augmentatsiyasi: tasodifiy aylantirish (±15°), gorizontal flip (50% ehtimol), masshtablash (0,9–1,1), elastik deformatsiya (α=34, σ=4), qo‘shimcha gauss shovqini (σ=0,01).

2.3. Taklif etilgan MS-AttUNet arxitekturasi

Taklif etilgan model to‘rt asosiy komponentdan iborat:

Encoder bloki (E). ResNet-50 [4] arxitekturasi asos qilib olindi. ImageNet bazasida oldindan o‘qitilgan og'irliklardan transfer learning yondashuvi orqali foydalanildi. Encoder kirish tasvirini bosqichma-bosqich kichraytirib, beshta darajadagi xususiyat xaritalari hosil qiladi: 256×256 → 128×128 → 64×64 → 32×32 → 16×16. Har bir darajada xususiyat kanallari soni 64, 256, 512, 1024, 2048 ga teng.

Multi-Scale Feature Extraction moduli (MSFE). Bu modul turli o‘lchamdagi patologik shakllanishlarni bir vaqtda aniqlash uchun mo‘ljallangan. Modulda parallel ravishda 1×1, 3×3, 5×5, 7×7 kernel o‘lchamli konvolyutsiyalar va dilation rates 1, 2, 4, 8 ga teng atrous (dilated) konvolyutsiyalar qo‘llaniladi. Atrous konvolyutsiya parametrlar sonini oshirmasdan qabul qilish maydonini (receptive field) kengaytirish imkonini beradi. Sakkizta tarmoqning chiqishlari concatenation orqali birlashtiriladi va 1×1 konvolyutsiya bilan kanal soni mosligi ta’minlanadi.

CBAM attention moduli. Woo va boshqalar [11] tomonidan taklif etilgan Convolutional Block Attention Module ikki ketma-ket attention bosqichidan iborat: Channel Attention (qaysi xususiyat kanallari muhim) va Spatial Attention (tasvirning qaysi sohalari muhim). Channel Attention max-pooling va average-pooling natijalarini MLP orqali o‘tkazadi. Spatial Attention 7×7 konvolyutsiya orqali fazoviy attention xaritasini hosil qiladi.

Decoder bloki (D). U-Net [3] decoder qismiga o‘xshash tarzda qurilgan. Skip connections encoder ning mos qatlamlaridan xususiyatlarni decoder ga uzatadi va shu orqali yuqori darajadagi semantik ma'lumot va past darajadagi tafsilotlar birlashtiriladi. Transposed konvolyutsiya orqali tasvir o‘lchami asta-sekin tiklanadi. Chiqishda ikkita boshlik mavjud: (1) segmentatsiya boshligi (sigmoid aktivatsiya bilan piksel bo‘yicha bashorat), (2) klassifikatsiya boshligi (softmax bilan patologiya turini aniqlash).

Modelning umumiy formulatsiyasi:

$$Y = D(MSFE(CBAM(E(X))))$$

bu yerda X — kirish KT tasviri (256×256), Y — segmentatsiya maskasi va klassifikatsiya bashorati. Model jami 31,4 mln parametrdan iborat, hisoblash murakkabligi — 47,2 GFLOPs (FP32 da).

2.4. Yo'qotish funksiyasi va o‘qitish

Modelni o‘qitish uchun uchta yo'qotish funksiyasini birlashtirgan kompozit funksiya qo‘llanildi:

$$L_total = \alpha \cdot L_dice + \beta \cdot L_focal + \gamma \cdot L_BCE, \quad \alpha=0,5; \ \beta=0,3; \ \gamma=0,2$$

Dice yo'qotishi sinflar nomutanosibligi sharoitida segmentatsiya sifatini yaxshilaydi: $L_dice = 1 - 2\cdot|A \cap B| / (|A| + |B|)$. Focal loss [12] kam uchraydigan sinflarga e'tiborni qaratadi: $L_focal = -\alpha(1 - p_t)^{\gamma} \cdot log(p_t)$, γ=2. BCE loss esa standart binar kross-entropiya sifatida ishlatilgan.

O‘qitish parametrlari: optimizator — Adam (β_1=0,9; β_2=0,999; ε=1e-8); boshlang‘ich o‘qish darajasi — 1e-4 ReduceLROnPlateau (patience=5, factor=0,5) bilan; batch size — 16; epoxalar soni — 100, EarlyStopping (patience=15, monitor=val_loss); regularizatsiya — L2 weight decay 1e-5 va Dropout 0,3. Hardware: NVIDIA RTX 4090 (24 GB VRAM), Intel Core i9-12900K, 64 GB DDR5 RAM. O‘qitish vaqti — 28 soat 17 daqiqa.

2.5. Baholash metrikalari

Modelni baholash uchun standart metrikalar to'plami qo‘llanildi: Accuracy = (TP+TN)/(TP+TN+FP+FN); Precision = TP/(TP+FP); Recall (Sensitivity) = TP/(TP+FN); Specificity = TN/(TN+FP); F1-score = 2·Precision·Recall / (Precision+Recall); AUC-ROC; segmentatsiya uchun — Dice koeffitsienti va IoU (Intersection over Union) = |A ∩ B| / |A ∪ B|. Modellar orasidagi statistik ahamiyatlilikni tekshirish uchun McNemar testi qo‘llanildi.

3. NATIJALAR

3.1. Modelning umumiy ko‘rsatkichlari

MS-AttUNet modelining o‘qitish, validatsiya va test to‘plamlaridagi ko‘rsatkichlari 2-jadvalda keltirilgan.

2-jadval. MS-AttUNet modelining baholash natijalari

Metrika	**O‘qitish**	**Validatsiya**	**Test**
Accuracy	98,2%	96,8%	**96,4%**
Precision	97,5%	95,2%	94,9%
Recall (Sensitivity)	96,8%	94,9%	**94,7%**
Specificity	98,7%	97,4%	**97,1%**
F1-score	97,1%	95,0%	94,8%
AUC-ROC	0,991	0,978	**0,974**

Dice coefficient	0,943	0,918	0,912
IoU	0,892	0,851	0,843

O‘qitish va test natijalari orasidagi farq atigi 1,8% ni tashkil qiladi (Accuracy: 98,2% vs 96,4%), bu modelning overfitting muammosidan xolicligini ko‘rsatadi. Validatsiya va test natijalari orasidagi farq esa 0,4% — bu validatsiya to‘plamining test taqsimotiga yaxshi mos kelishini bildiradi.

3.2. Patologiyalar bo‘yicha tahlil

Test to‘plamida turli patologiya turlari bo‘yicha alohida natijalar 3-jadvalda keltirilgan.

3-jadval. Patologiyalar bo‘yicha aniqlash natijalari

Patologiya	Soni	Sensitivity	Specificity	F1	AUC
O‘pka tugunlari	142	95,8%	97,6%	0,961	0,982
COVID-19	89	96,6%	98,2%	**0,971**	0,987
Pnevmoniya	67	94,0%	96,3%	0,945	0,971
Sil	34	91,2%	95,8%	0,928	0,957
Emfizema	28	89,3%	94,5%	0,911	0,943
O‘rtacha	**360**	**94,7%**	**97,1%**	**0,948**	**0,974**

Eng yuqori aniqlik COVID-19 ni aniqlashda erishildi (F1=0,971; AUC=0,987). Bu MosMedData bazasidagi katta hajmdagi sifatli ma'lumotlar va COVID-19 ga xos «matli oyna» (ground-glass opacity) shaklidagi xarakterli vizual belgilar bilan izohlanadi. Eng past natija emfizemada qayd etildi (F1=0,911) — ushbu kasallikning vizual belgilari (parenxima zichligining diffuz kamayishi) boshqa patologiyalar bilan o‘xshash bo‘lishi va test to‘plamida emfizema namunalari kamligi (28 ta) sabab bo‘ldi.

3.3. Mavjud yondashuvlar bilan taqqoslash

Adolatli taqqoslash uchun barcha modellar bir xil test to‘plamida (360 bemor) sinab ko‘rildi. Natijalar 4-jadvalda keltirilgan.

4-jadval. MS-AttUNet ning mavjud yondashuvlar bilan taqqoslanishi

Model	Accuracy	Sensitivity	Parametrlar	Vaqt, s
U-Net (asl)	88,3%	85,7%	31,0M	0,03
ResNet-50	91,5%	89,2%	25,6M	0,02
DenseNet-121	92,7%	90,4%	8,0M	0,05
EfficientNet-B3	93,2%	90,1%	12,0M	0,04
DeepCovid (Wang)	90,3%	87,5%	18,5M	0,06
Attention U-Net	93,8%	91,6%	34,9M	0,04
MS-AttUNet (taklif)	**96,4%**	**94,7%**	**31,4M**	**0,04**

MS-AttUNet barcha taqqoslangan modellardan accuracy bo‘yicha ustun keldi. Eng yaqin raqib — Attention U-Net (93,8%) bilan farq 2,6%, eng past natijali asl U-Net (88,3%) bilan farq 8,1% ni tashkil qildi. Sezgirlik (Sensitivity) bo‘yicha ustunlik 3,1–9,0% diapazonida. Parametrlar soni (31,4 mln) Attention U-Net dan kichikroq (34,9 mln) bo‘lsa-da, ko‘rsatkichlar sezilarli darajada yaxshi — bu MSFE moduli va CBAM attention birikmasining samaradorligini ko‘rsatadi. Bashorat vaqti (0,04 s/kesim) klinik amaliyot uchun to‘liq yetarli.

Statistik ahamiyatlilikni tekshirish uchun MS-AttUNet va eng yaxshi raqib (Attention U-Net) orasida McNemar testi o‘tkazildi: $\chi^2 = 24,7$; $p < 0,001$. Bu farqning haqiqiy va ahamiyatli ekanligini tasdiqlaydi.

3.4. Tizimning ish vaqti

CT-DiagAI tizimi 250 ta kesimdan iborat o‘rtacha bemor tekshiruvini GPU yordamida 16,6 soniyada qayta ishlaydi: DICOM o‘qish — 0,8 s, oldindan qayta ishlash — 1,2 s, model bashorati — 12,5 s, hisobot yaratish — 2,1 s. CPU rejimida bu vaqt 219,4 soniyaga teng. An'anaviy qo‘lda tahlilga (15–30 daqiqa) nisbatan tizim 50–100 marta tezroq ishlaydi, bu klinik amaliyotda real vaqt rejimida ishlatish imkonini beradi.

3.5. Dasturiy vositaning tavsifi

CT-DiagAI tizimi uch qatlamli mikroservis arxitekturasi asosida qurilgan. Frontend qism React.js (v18.2) va Tailwind CSS yordamida amalga oshirilgan; DICOM ko‘rgich Cornerstone.js kutubxonasiga asoslangan bo‘lib, axial/sagittal/coronal proyeksiyalar, 3D rekonstruksiya, MIP rejimi va Grad-CAM heatmap vizualizatsiyasini qo‘llab-quvvatlaydi. Backend Flask (v3.0) freymvorkida REST API sifatida implementatsiya qilingan. AI model TensorFlow Serving orqali alohida konteynerda ishlaydi va bu uni mustaqil yangilash imkonini beradi. Ma'lumotlar PostgreSQL (v15) da saqlanadi, DICOM fayllar — MinIO

obyekt-saqlash serverida, Redis esa sessiyalarni keshlash uchun ishlatiladi. Tizim Docker konteynerlarida ishlaydi va Kubernetes orqali boshqariladi, bu yuqori mavjudlik (high availability) va horizontal masshtablashga imkon beradi.

4. MUHOKAMA

Tadqiqot natijalari bir necha muhim xulosalarni shakllantirish imkonini beradi. Birinchidan, MSFE moduli va attention mexanizmini birlashtirish samaradorligi empirik tasdiqlandi: parallel turli kernel o‘lchamlari (1×1 dan 7×7 gacha) va dilation rate lari yordamida ham mayda nodulalar (3–5 mm), ham keng infiltratlar (5–10 sm) yagona arxitekturada samarali aniqlanadi. CBAM attention model qaroriga eng muhim sohalarni belgilab, foydasiz signal-shovqin aralashmalaridan diqqatni chalg'itadi. Ushbu ikki yondashuvning birikmasi alohida-alohida ishlatilgan holatlarga nisbatan qo‘shimcha samara berdi.

Ikkinchidan, kompozit yo'qotish funksiyasi (Dice + Focal + BCE) kichik patologiya sinflari (sil — 34 ta, emfizema — 28 ta) uchun ham ma'qul natijalarni ta'minladi. An'anaviy BCE loss bilan o‘qitilgan modellarda kichik sinflar uchun sezgirlik 70–80% atrofida bo‘lsa, taklif etilgan yondashuvda bu ko‘rsatkich sil uchun 91,2% va emfizema uchun 89,3% ga ko‘tarildi. Focal loss ning gamma=2 parametri va Dice loss ning sinflar nomutanosibligiga kamroq sezgirligi bu natijaga olib keldi.

Uchinchidan, mahalliy ma'lumotlar bazasini (RIxPM bilan hamkorlikda 250 bemor) integratsiya qilish modelni O‘zbekiston aholisi xususiyatlariga moslashtirish imkonini berdi. Faqat chet ellik bazalarda o‘qitilgan modellar mahalliy ma’lumotlarda 2–4% past aniqlik ko‘rsatadi (predvaritel sinovlar natijalariga ko‘ra) — bu populyatsion farqlar va skaner sozlamalaridagi farqlar bilan izohlanadi. Mahalliy ma'lumotlarni qo‘shish bu farqni bartaraf etdi.

To‘rtinchidan, tizimning ish vaqti (16,6 s) klinik amaliyot talablariga to‘liq javob beradi. Radiolog odatda bemor uchun 15–30 daqiqa sarflaganda, ushbu tizim

dastlabki tashxis loyihasini 30 soniyadan kam vaqtda taqdim etadi. Bu ayniqsa qishloq tibbiyot punktlarida muhim, chunki O‘zbekistonda 1 mln aholiga to‘g‘ri keladigan radiologlar soni shahar va qishloq joylar o‘rtasida sezilarli farq qiladi. Dasturiy vosita ikkinchi mutaxassis (second reader) sifatida ishlatilishi mumkin va shifokorga e'tibor qaratish kerak bo‘lgan sohalarni belgilab beradi.

Tadqiqotning amaliy chiqaruvchanligi (translatability) bir necha jihatlarda tasdiqlandi: (1) tizim DICOM standartiga to‘liq muvofiqligi tufayli mavjud PACS (Picture Archiving and Communication System) infrastrukturalariga oson integratsiya qilinadi; (2) Grad-CAM vizualizatsiyasi shifokorga model qaroriga asos bo‘lgan sohalarni ko‘rsatib beradi — bu klinik amaliyotda muhim shaffoflik elementi; (3) avtomatik PDF hisobot generatori standart radiologik hisobot formatiga mos keladi va shifokor vaqtini tejaydi.

Tadqiqotning cheklovlari. Birinchidan, hozirgi MS-AttUNet 2D kesimlar bilan ishlaydi va kesimlar orasidagi 3D fazoviy munosabatlardan to‘liq foydalanmaydi. Ikkinchidan, model faqat o‘pka patologiyalariga moslashtirilgan; jigar, miya yoki qorin a'zolari uchun qo‘shimcha o‘qitish va validatsiya talab qilinadi. Uchinchidan, mahalliy ma'lumotlar bazasi nisbatan kichik (250 bemor) — uni kengaytirish modelning generalizatsiyasini yaxshilashi mumkin. To‘rtinchidan, tadqiqot prospective klinik sinovlarda hali sinab ko‘rilmagan; haqiqiy klinik sharoitda ishlash sifati alohida ko‘p markazli sinovlarda baholanishi kerak.

Kelgusi tadqiqot yo'nalishlari. (1) 3D CNN arxitekturasini ishlab chiqish va volumetrik konteksdan to‘liq foydalanish; (2) Vision Transformer va Swin Transformer kabi yangi arxitekturalar bilan taqqoslash hamda gibridlashtirish; (3) Federated learning yondashuvi orqali bemor maxfiyligini saqlagan holda turli klinikalar ma'lumotlaridan birgalikda foydalanish; (4) Self-supervised pre-training texnikalari (MAE, SimCLR) bilan kichik ma'lumotlardagi samaradorlikni oshirish; (5) Kelajakda model qaroriga isbot beradigan kontrfaktual tushuntirishlar (counterfactual explanations) qo‘shish.

5. XULOSA

Ushbu maqolada KT tasvirlari asosida o‘pka patologiyalarini avtomatik tashxislash uchun yangi gibrid arxitektura — MS-AttUNet taklif etildi va keng masshtabli eksperimental tadqiqot orqali samaradorligi tasdiqlandi. Asosiy natijalar quyidagicha: model test to‘plamida 96,4% aniqlik, 94,7% sezgirlik, 97,1% maxsuslik va 0,974 AUC-ROC ga erishdi. Mavjud zamonaviy yondashuvlardan (U-Net, ResNet-50, DenseNet-121, EfficientNet-B3, DeepCovid, Attention U-Net) accuracy bo‘yicha 2,6–8,1% ga ustun keldi va bu farq statistik jihatdan ahamiyatli ($p < 0,001$).

Multi-Scale Feature Extraction moduli va CBAM attention birikmasi turli o‘lchamdagi patologik shakllanishlarni yagona arxitekturada samarali aniqlash imkonini berdi. Kompozit yo'qotish funksiyasi (Dice + Focal + BCE) sinflar nomutanosibligi muammosini yumshatdi va kichik sinflar uchun ham qabul qilinadigan natijalarni ta'minladi. Mahalliy ma'lumotlarni integratsiyalash modelni O‘zbekiston aholisi xususiyatlariga moslashtirish imkonini berdi.

CT-DiagAI nomli web-asoslangan dasturiy vosita ishlab chiqildi va bemor uchun to‘liq tashxislash 16,6 soniyada bajariladi — bu an'anaviy qo‘lda tahlilga nisbatan 50–100 marta tezroq. Tizim DICOM standartiga to‘liq muvofiq, Grad-CAM vizualizatsiya orqali shaffoflik ta'minlaydi va avtomatik hisobot generatori klinik amaliyot talablariga javob beradi. Tadqiqot natijalari O‘zbekiston tibbiyot muassasalarida amaliy joriy etish uchun istiqbolli zamin yaratadi.

ADABIYOTLAR RO‘YXATI

1. Hsieh J. Computed Tomography: Principles, Design, Artifacts, and Recent Advances. — 3rd ed. — Bellingham: SPIE Press, 2015. — 666 p.
2. Goldman L.W. Principles of CT and CT technology // Journal of Nuclear Medicine Technology. — 2007. — Vol. 35, No. 3. — P. 115–128.

3. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation // Medical Image Computing and Computer-Assisted Intervention (MICCAI). — 2015. — Vol. 9351. — P. 234–241.

4. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2016. — P. 770–778.

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. Brady A.P. Error and discrepancy in radiology: inevitable or avoidable? // Insights into Imaging. — 2017. — Vol. 8, No. 1. — P. 171–182.

7. 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.

8. 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.

9. 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.

10. Krizhevsky A., Sutskever I., Hinton G. ImageNet classification with deep convolutional neural networks // NeurIPS. — 2012. — Vol. 25. — P. 1097–1105.

11. Woo S., Park J., Lee J.Y., Kweon I.S. CBAM: Convolutional Block Attention Module // European Conference on Computer Vision (ECCV). — 2018. — P. 3–19.

12. Lin T.Y., Goyal P., Girshick R., He K., Dollár P. Focal loss for dense object detection // IEEE International Conference on Computer Vision (ICCV). — 2017. — P. 2980–2988.

13. Huang G., Liu Z., Van Der Maaten L., Weinberger K.Q. Densely connected convolutional networks // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2017. — P. 4700–4708.

14. Tan M., Le Q. EfficientNet: Rethinking model scaling for convolutional neural networks // International Conference on Machine Learning (ICML). — 2019. — P. 6105–6114.

15. Milletari F., Navab N., Ahmadi S.A. V-Net: Fully convolutional neural networks for volumetric medical image segmentation // International Conference on 3D Vision (3DV). — 2016. — P. 565–571.

16. Selvaraju R.R., Cogswell M., Das A., et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization // IEEE International Conference on Computer Vision (ICCV). — 2017. — P. 618–626.

17. O‘zbekiston Respublikasi Prezidentining 2020-yil 5-oktyabrdagi PF-6079-son «Raqamli O‘zbekiston-2030 strategiyasini tasdiqlash to‘g‘risida»gi Farmoni. — Toshkent, 2020.

18. Morozov S.P., Andreychenko A.E., Pavlov N.A., et al. MosMedData: Chest CT Scans with COVID-19 Related Findings Dataset // arXiv preprint. — 2020. — arXiv:2005.06465.

19. Armato S.G., McLennan G., Bidaut L., et al. The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A completed reference database of lung nodules on CT scans // Medical Physics. — 2011. — Vol. 38, No. 2. — P. 915–931.

20. Dosovitskiy A., Beyer L., Kolesnikov A., et al. An image is worth 16×16 words: Transformers for image recognition at scale // International Conference on Learning Representations (ICLR). — 2021.