DEEPLABV3+ CHUQUR O‘QITISH MODELI YORDAMIDA O‘PKA RENTGEN TASVIRLARINING SEGMENTATSIYASI

Ro‘zibayev Ortiq Baxtiyorovich[1], Saidrasulov Sherzod Norboy o‘g‘li[2], Zaripov Fazil Maxsetovich[3], Raximov Komron Asqar o‘g‘li[4]

[1]TATU "Dasturiy injiniring" fakulteti dekani, PhD
[2]TATU "Axborot texnologiyalarining dasturiy ta'minoti" kafedrasi dotsenti, PhD
[3]TATU "Dasturlash texnologiyalari" kafedrasi katta o‘qituvchisi
[4]TATU magistranti
E-mail:raximovkamron3@gmail.com

K E Y W O R D S

o‘pka segmentatsiyasi, ko‘krak rentgen tasviri, DeepLabV3+, Dice koeffitsiyenti, Jaccard indeksi, chuqur o‘qitish, tibbiy tasvirlarni qayta ishlash

A B S T R A C T

Zamonaviy texnologiyalarning rivojlanishi natijasida sog‘liqni saqlash sohasini qo‘llab-quvvatlovchi turli tibbiy diagnostika tizimlari tez sur'atlarda rivojlanmoqda. So‘nggi yillarda turli kasalliklarni erta aniqlash maqsadida chuqur o‘qitish (deep learning) algoritmlaridan foydalanishga bo‘lgan qiziqish keskin ortdi. Amaliyotda koronavirus (COVID-19) va sil kasalligi (TB) kabi kasalliklarni tashxislashda ko‘pincha o‘pka rentgen tasvirlaridan foydalaniladi. Chuqur o‘qitish modellari rentgen tasvirlaridan o‘pka hududlarini ajratib olish orqali sil kasalligini yuqori aniqlik bilan aniqlay oladi. O‘pka sohasi segmentatsiya qilinganidan so‘ng qo‘llanilgan klassifikatsiya usullari, tasvirning to‘liq kadridan foydalanilganga nisbatan kasallikni aniqlash ehtimolini sezilarli oshiradi. Ushbu maqolaning asosiy maqsadi - ko‘krak rentgen tasvirlaridan o‘pka segmentatsiyasini amalga oshirish uchun DeepLabV3+ konvolyutsion neyron tarmog‘iga asoslangan semantik segmentatsiya modelini qo‘llashdir. Ko‘plab CNN arxitekturalarida pastga o‘tish (downsampling) jarayonida takroriy konvolyutsiya va pooling amallari natijasida tasvirning fazoviy aniqligi kamayib boradi. Ushbu cheklovni bartaraf etish maqsadida DeepLabV3+ arxitekturasi backbone qismidagi pooling va striding amallarini qayta optimallashtirgan holda "Atrous Convolution" texnikasidan foydalanadi.

Eksperimental natijalarga ko‘ra, model 94% Jaccard indeksi, va 97% Dice koeffitsiyentiga erishdi. Shuningdek, DeepLabV3+ modeli boshqa mashhur segmentatsiya arxitekturalari bilan keng qamrovli taqqoslashdan o‘tkazildi. Natijalar DeepLabV3+ modelining ko‘krak rentgen tasvirlaridan o‘pka segmentatsiyasini aniq va ishonchli bajarish qobiliyatini tasdiqlaydi.

I. KIRISH

Ko‘krak qafasi rentgen tasvirlari (CXR) tibbiyotda yurak, o‘pka va boshqa torakal anatomik tuzilmalarni ko‘rish hamda baholashda eng ko‘p qo‘llaniladigan diagnostik usullardan biridir [1]. Har yili dunyo bo‘yicha millionlab rentgen tasvirlari olinadi, ularni qo‘lda tahlil qilish esa katta vaqt, tajriba va mehnat talab etadi. Shu sababli so‘nggi yillarda ko‘plab klinik jarayonlarda kompyuter yordamida diagnostika (CAD) tizimlaridan foydalanish kengayib bormoqda [3]. CAD tizimlari radiologlarga o‘pka kasalliklarini aniqlashda yordam berish, baholash jarayonlarini tezlashtirish va diagnostika aniqligini oshirishda muhim rol o‘ynaydi. Bu kabi tizimlarda tasvirning ayrim anatomik tuzilmalarini, ayniqsa o‘pka maydonlarini yuqori aniqlikda segmentatsiya qilish alohida ahamiyatga ega. O‘pka segmentatsiyasi pnevmoniya, COVID-19, sil kasalligi, o‘pka nodullari kabi patologiyalarni aniqlash va ularning o‘lcham hamda tarqalish hududini baholash uchun zarur bosqich hisoblanadi [4]. Shu bilan birga, o‘pka hududlari to‘g‘ri ajratilganda klassifikatsiya modellarining natijalari ham sezilarli darajada yaxshilanadi [5]. Amaliyotda o‘pka, yurak, klavikula va boshqa tuzilmalar rentgen tasvirlarida bir-biriga qisman qoplanib ketadi, chegaralar

(cc) BY

ko‘pincha xiralashgan bo‘ladi [6]. Bundan tashqari, bemorning yoshi, jinsi, tana tuzilishi ham anatomik ko‘rinishning o‘zgaruvchanligiga sabab bo‘ladi. Ba'zan tasvirda tibbiy uskunalar- kateter, elektrodlari yoki pacemaker- mavjudligi segmentatsiyani yanada murakkablashtiradi [7]. An'anaviy segmentatsiya usullari bunday murakkab holatlarda barqaror natija bera olmaydi [8].

So‘nggi yillarda chuqur o‘qitish (deep learning) va konvolyutsion neyron tarmoqlar (CNN) semantik segmentatsiya sohasida katta yutuqlarga erishdi [9]. FCN, U-Net va ResNet kabi arxitekturalar tibbiy tasvirlarni segmentatsiya qilishda keng qo‘llanilmoqda [10]. Biroq U-Net kabi klassik modellarda fazoviy aniqlikning yomonlashuvi yoki murakkab kontekstlarni yetarlicha o‘rganmaslik holatlari kuzatiladi. Shunday muammolarni bartaraf etish uchun DeepLab oilasi taklif qilingan bo‘lib, DeepLabV3+ modeli Atrous Spatial Pyramid Pooling (ASPP) va encoder-decoder tuzilmasi orqali yuqori aniqlikni ta'minlaydi [12]. Atrous konvolyutsiya (dilated convolution) modelning receptive field'ini kengaytiradi, ya'ni tasvirdagi yirik va mayda strukturalarni bir vaqtning o‘zida o‘rganish imkonini beradi. ASPP esa turli miqyosdagi konvolyutsion filtrlar orqali modelning ko‘p o‘lchamli kontekstni ajrata olish qobiliyatini oshiradi.

Model samaradorligi ma'lumotlar sifati va hajmiga bevosita bog‘liq bo‘lgani sababli ushbu tadqiqotda keng tarqalgan Montgomery, Shenzhen va JSRT rentgen ma'lumotlar to‘plamlaridan foydalanildi. Ularning birlashtirilishi modelning umumlashtirish qobiliyatini yaxshilaydi va real klinik sharoitga yaqin holatlarda ham barqaror natija beradi. Shuningdek, o‘qitish jarayonida data augmentatsiya usullari qo‘llanilib, modelning yorug‘lik, shovqin, kontrast farqlari va geometrik o‘zgarishlarga moslashuvchanligi oshirildi. Ushbu tadqiqotning asosiy maqsadi - ko‘krak rentgen tasvirlaridan o‘pka sohasini yuqori aniqlikda segmentatsiya qilish uchun DeepLabV3+ CNN modeli samaradorligini baholash, uni boshqa segmentatsiya modellari bilan taqqoslash va klinik diagnostika jarayonida qo‘llash mumkinligini o‘rganishdan iborat. Olingan eksperimental natijalar DeepLabV3+ modeli o‘pka segmentatsiyasida yuqori aniqlik va barqarorlikka ega ekanini tasdiqlaydi.

II. NAZARIY QISM

DeepLabV3+ modeli. Ko‘krak qafasi rentgen tasvirlaridagi o‘pka chegaralarining xiraligi, anatomik tuzilmalarning qisman bir-birini yopib turishi va patologik hududlarning kontrasti past bo‘lishi sababli segmentatsiya jarayoni an'anaviy CNN modellarida ko‘plab cheklovlarga duch keladi. Ushbu muammolarni bartaraf etish maqsadida ushbu tadqiqotda DeepLabV3+ arxitekturasi qo‘llanildi [12]. Model atrous konvolyutsiya, Atrous Spatial Pyramid Pooling (ASPP) va kengaytirilgan encoder–decoder mexanizmlari orqali yuqori aniqlikdagi semantik segmentatsiyani ta'minlaydi.

1. Atrous (Dilated) Convolution. Atrous konvolyutsiya filtr elementlari orasiga “bo‘sh kataklar” qo‘shish orqali receptive field'ni kengaytiradi. Bu modelga fazoviy rezolyutsiyani yo‘qotmasdan global xususiyatlarni o‘rganish imkonini beradi.

Atrous konvolyutsiya quyidagicha aniqlanadi:

$$y[i] = \sum_{k=1}^{K} x[i + r \cdot k]\ w[k]$$

Bu yerda:

- x- *kiruvchi tasvir,*
- w- *filtr og‘irliklari,*
- r- *dilation rate,*
- K- *filtr o‘lchami.*

Agar $r = 1$ bo‘lsa - bu oddiy convolution. Agar $r > 1$ bo‘lsa - receptive field dilation rate ga mutanosib ravishda kengayadi.

2. Atrous Spatial Pyramid Pooling (ASPP). ASPP moduli tasvirni bir vaqtning o‘zida bir nechta miqyoslarda tahlil qilishga imkon beradi. Bu turli o‘lchamdagi obyektlar mavjud bo‘lgan tibbiy tasvirlar uchun ayniqsa muhim.

ASPP quyidagilarni o‘z ichiga oladi:

(cc) BY

- *1 × 1* convolution
- Dilated convolution (dilation rate: 6, 12, 18)
- Global average pooling branch
- Barcha natijalarni concatenation qilish

ASPP matematik ko'rinishi:

Har bir branch quyidagi operatsiyani bajaradi:

$$F_r = f(x; r) = \sum_k x[k] \cdot w_r[k]$$

Bu yerda:

- x- *kiruvchi feature map (encoder chiqishi)*
- w_r- *dilation rate* r *bilan mos keluvchi konvolyutsiya filtr og'irliklari*
- k- *filtr kernelining indekslari*
- r- *dilation darajasi (ASPP'da odatda 6, 12 yoki 18)*
- F_r- *shu dilation darajasida olingan xususiyat xaritasi*
- $f(x; r)$- *atrous convolution operatori*

Yakundagi ASPP chiqishi:

$$F_{ASPP} = Concat\left(F_{r_1}, F_{r_2}, F_{r_3}, F_{avg}\right)$$

Bu yerda:

- $F_{r_1}, F_{r_2}, F_{r_3}$- *turli dilation darajalarida olingan xususiyat xaritalari*
- F_{avg} - *global average pooling yo'li orqali olingan global kontekst xususiyatlari*
- $Concat(\cdot)$ - *kanallar bo'yicha birlashtirish operatori*
- F_{ASPP} - *ASPP modulining yakuniy birlashtirilgan chiqishi*

3.Encoder-ResNet101 Backbone. Modelning encoder qismi ResNet101 arxitekturasiga asoslanadi. ResNetning asosiy g'oyasi - identity skip-connection orqali

chuqur tarmoqda gradient yo'qolishini oldini olish.

ResNet blokidagi asosiy formula:

$$y = F(x, W) + x$$

Bu yerda:

- $F(x, W)$- *convolution → batch norm → ReLU*
- x- *skip-connection orqali uzatilgan signal*

Bunday tuzilma modelni chuqurlashtirish imkonini beradi va segmentatsiyada murakkab strukturalar o'rganilishini osonlashtiradi.

4. Decoder qismi. DeepLabV3+ ning eng muhim yaxshilanishlaridan biri - lightweight decoder ning joriy etilishi. U yuqori darajada abstrakt bo'lgan encoder natijalarini kichik rezolyutsiyadagi erta qatlamlar bilan birlashtiradi.

Decoder jarayoni:

1. ASPP chiqishi 4× upsampling qilinadi.
2. Encoderning erta qatlamidan olingan pastki darajadagi xususiyatlar bilan concatenation qilinadi.
3. Bir nechta 3×3 convolution orqali aniqlik yaxshilanadi.
4. Yakuniy maska hosil qilish uchun 8× upsampling amalga oshiriladi.

Decoder matematik modeli:

$$F_{dec} = g(Concat(Ups(F_{ASPP}), F_{low}))$$

Bu yerda:

- F_{low}- *pastki qatlamdan olingan xususiyatlar*
- $g(\cdot)$- *convolution + ReLU*
- $Ups(\cdot)$- *bilinear upsampling*

5. Yakuniy bosqich. DeepLabV3+ arxitekturasining yakuniy bosqichi - segmentation head, u pastki fazoviy rezolyutsiyaga ega feature map'larni original tasvir o'lchamiga qaytarib, har bir piksel uchun o'pka / o'pka emas ehtimolini hisoblaydi.

Yakuniy chiqish formulasi:

$$\hat{Y} = \sigma(W * F_{dec})$$

(cc) BY

Bu yerda:

- F_{dec}*- dekoder bosqichidan olingan yuqori aniqlikdagi xususiyat xaritasi*
- W*- yakuniy* 1×1 *convolution filtr og'irliklari*
- $*$*- konvolyutsiya operatori*
- $\sigma(\cdot)$*- sigmoid aktivatsiya funksiyasi*
- $\hat{Y}$*- model tomonidan bashorat qilingan piksel darajasidagi segmentatsiya maskasi (0–1 ehtimollik xaritasi)*

Sigmoid funksiyasi:

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

Bu funksiya decoder natijalarini [0,1] oralig'ida ehtimollik sifatida ifodalaydi.

Segmentatsiya jarayonida:

- $\hat{Y} \approx 1 \rightarrow$ *piksel o'pka hududiga tegishli*
- $\hat{Y} \approx 0 \rightarrow$ *piksel o'pka emas*

DeepLabV3+ modelining yakuniy chiqishi $\hat{Y}$ tibbiy segmentatsiya uchun zarur bo'lgan continuous probability mask hisoblanadi. Keyinchalik maska:

$$Y = \begin{cases} 1, & agar\ \hat{Y} > 0.5 \\ 0, & aks\ holda \end{cases}$$

threshold orqali *binary maskaga* aylantiriladi.

Bu bosqich o'pka chegaralarini aniqroq ajratish va Dice / IoU metrikalarini hisoblashda zarur.

III. MATERIAL VA METODOLOGIYA

Dataset. Ushbu tadqiqotda o'pka segmentatsiyasi uchun uchta keng qo'llaniladigan ochiq rentgen datasetlaridan - Montgomery, Shenzhen va JSRT datasetlaridan foydalanildi [13]. Montgomery dataseti138 ta yuqori aniqlikdagi ko'krak qafasi tasvirlari va ularga mos ravishda ajratilgan chap va o'ng o'pka segmentatsiya maskalarini o'z ichiga oladi. Shenzhen datasetida turli yoshdagi bemorlarning 562 ta CXR tasviri mavjud bo'lib, undagi anatomik farqlilik va patologiya xilma-xilligi modelning umumlashtirish qobiliyatini oshiradi. JSRT dataseti esa 247 ta standartlashtirilgan rentgen tasviri va radiologlar tomonidan tayyorlangan aniq annotatsiyalangan o'pka segmentatsiya maskalaridan iborat. Ushbu uchta dataseti birlashtirilishi tasvir sifati, anatomik ko'rinish va patologik holatlar bo'yicha keng spektrni qamrab oladi. Shuningdek, tasvirlarning turli rezolyutsiya va kontrast darajaga ega bo'lishi modelni real klinik sharoitlarga moslashgan holda o'qitish imkonini beradi. Shu orqali DeepLabV3+ arxitekturasining barqarorligi va aniqligi yuqori darajada namoyon bo'lishi ta'minlandi.

Ma'lumotlarga dastlabki ishlov berish. Modelni o'qitishdan oldin barcha tasvirlar bir xil formatga keltirildi va ularning sifatini barqarorlashtirish bo'yicha bir nechta ma'lumotlarga dastlabki ishlov berish bosqichlari bajarildi. Avvalo, Montgomery, Shenzhen va JSRT datasetlaridagi barcha rentgen tasvirlari 512×512 piksel o'lchamga o'zgartirildi va grayscale formatga standartlashtirildi. O'pka segmentatsiya maskalari ham xuddi shu o'lchamga moslashtirilib, piksel qiymatlari 0-1 oralig'iga normallashtirildi. Tasvirlarda keskinlik va yorug'likning turlicha bo'lishi model o'qitilishiga salbiy ta'sir qilmasligi uchun barcha rasm va o'pka segmentatsiya maskalari float32 formatga o'tkazildi. Datasetida uchraydigan ortiqcha bo'sh joylar, keraksiz chekkalar yoki nomuvofiq maskalar tekshirilib, kerakli hollarda tozalandi. Barcha tasvir va maskalar modelga mos ravishda (H, W, 1) shaklga keltirildi. Ma'lumotlarni oldindan qayta ishlash jarayonining standartlashtirilishi ma'lumotlar sifati va modelning barqaror o'qitilishi uchun asos yaratdi, shu bilan birga segmentatsiya aniqligining oshishiga xizmat qildi. Modelning umumlashtirish qobiliyatini oshirish va turli klinik sharoitdagi tasvirlarga moslashuvchanligini ta'minlash maqsadida ma'lumotlarga augmentatsiya usullari qo'llandi. Bular qatoriga tasvirni gorizontal aylantirish, yorug'lik va kontrastni o'zgartirish, tasodifiy shovqin qo'shish, zoom-in/zoom-out va kichik geometrik o'zgarishlar kiradi. Ushbu jarayonlar tasvirlarning rang intensivligi, yoritilishi va shakliy farqliliklar bo'yicha modellarni barqaror o'qitishga yordam berdi.

(cc) BY

Barcha datasetlar birlashtirilgach, ma'lumotlar train, validation va test to‘plamlariga ajratildi. Umumiy ma'lumotlarning asosiy qismi - 70% modelni o‘qitish (train) uchun, 20% validatsiya jarayoni uchun va qolgan 10% test to‘plami sifatida ajratildi. Validatsiya to‘plami modelning o‘qitilish jarayonida ortiqcha moslashuv (overfitting) holatini kuzatish uchun ishlatildi, test to‘plami esa yakuniy baholash bosqichida modelning real tasvirlardagi samaradorligini aniqlash uchun qo‘llanildi. Augmentatsiya qilingan namunalar faqat train to‘plamiga qo‘shildi, validatsiya va test tasvirlari asl ko‘rinishda qoldirildi. Bu yondashuv modelning haqiqiy klinik tasvirlarda ham barqaror va aniqlik bilan ishlashini ta'minladi.

Modelni o‘qitish. Ushbu tadqiqotda DeepLabV3+ modeli o‘pka segmentatsiyasi vazifasi uchun Kaggle platformasida mavjud bo‘lgan Tesla P100 16GB GPU yordamida o‘qitildi. Modelni samarali optimallashtirish uchun chuqur o‘rganishdagi keng tarqalgan texnikalar — *learning rate scheduling, early stopping va model checkpoint* callback mexanizmlari qo‘llanildi. Model o‘qitilishidan oldin barcha tasvirlar (512×512) o‘lchamga keltirildi, piksel qiymatlari esa 0–1 oralig‘ida normallashtirildi. Tasvirlarning cheklangan soni sababli modelning umumlashtirish qobiliyatini yaxshilash uchun turli geometrik va fotometrik data augmentatsiya usullari qo‘llandi. Bu yondashuv modelni yorug‘lik farqi, kontrast, shovqin va tasvirdagi kichik siljishlarga nisbatan barqaror bo‘lishini ta'minladi. Model *Adam* optimizatori yordamida o‘qitildi, uning ustunligi gradientlarning moslashuvchan yangilanishi orqali tarmoqqa tez va barqaror yaqinlashish imkonini berishidir. Adam parametrlari quyidagicha tanlandi:

- boshlang‘ich learning rate: 1×10^{-4}
- $\beta_1 = 0.9$
- $\beta_2 = 0.999$
- weight decay qo‘llanilmadi

O‘pka segmentatsiyasi piksel darajasidagi noaniqliklarni o‘z ichiga olgani sababli ikkita komponentdan iborat bo‘lgan *BCE–Dice Loss* qo‘llanildi.

Soft Dice koeffitsiyenti formulasi:

$$Dice(Y,\hat{Y}) = \frac{2\sum_i Y_i\hat{Y}_i + \epsilon}{\sum_i Y_i + \sum_i \hat{Y}_i + \epsilon}$$

Binary Cross Entropy (BCE) Loss formulasi:

$$\mathcal{L}_{BCE} = -\frac{1}{N}\sum_{i=1}^{N}\left[Y_i\, log\left(\hat{Y}_i\right) + (1-Y_i)\, log\left(1-\hat{Y}_i\right)\right]$$

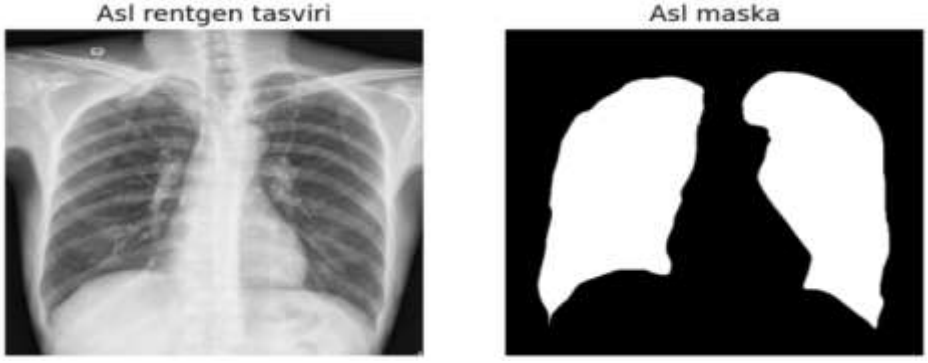
BCE–Dice kombinatsiyalangan loss:

$$\mathcal{L}_{total} = \alpha\cdot\mathcal{L}_{BCE} + (1-\alpha)\cdot\left(1 - Dice\left(Y,\hat{Y}\right)\right)$$

Bu yerda:

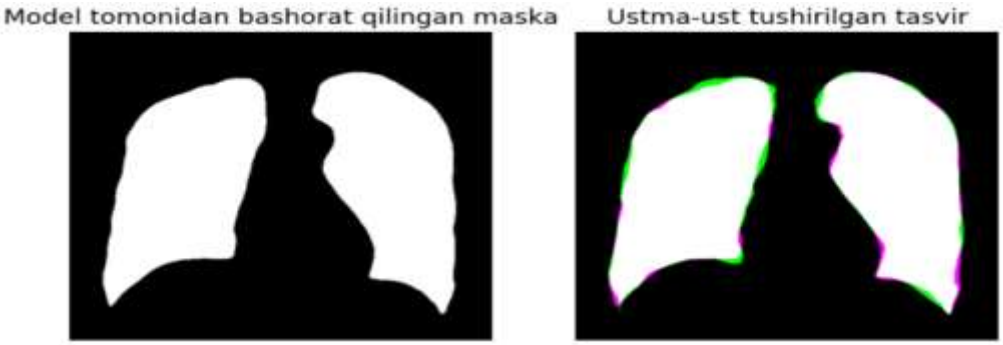
- Y_i— asl (ground truth) mask piksel qiymati
- $\hat{Y}_i$— model bashorati
- N— piksel soni
- ϵ— nolga bo‘linishni oldini olish uchun kichik konstant
- α— BCE va Dice hissasini boshqaruvchi koeffitsient

NATIJALAR.



1-rasm. Asl rentgen va maska tasvirlari.

(cc) BY



2-rasm. Bashorat qilingan maska va uni asl maska bilan solishtirilgani.

Segmentatsiya maskalarining vizual tekshiruvi ham modelning yuqori samaradorligini tasdiqladi. Asl va bashorat qilingan maska o‘rtasidagi ustma–ust tushirilgan tasvirlar (overlay) fon va o‘pka hududlarining aniq ajratilganini ko‘rsatdi. Qora va oq piksel zonalari mos ravishda fon va o‘pka hududlarining to‘g‘ri segmentatsiyasini bildiradi. Yashil piksel o‘pka bo‘lishiga qaramay noto‘g‘ri fon sifatida, binafsha piksel esa aksincha fon bo‘lishiga qaramasdan o‘pkaga tenglashtirilgan pikselni bildiradi.

1-jadval

Modelning eksperimental natijalari

Metrika	Qiymat
Dice	0.97
IoU	0.94
Global Accuracy	0.98

2-jadval

Boshqa modellarga nisbatan taqqoslash

Muallif	Model	Dataset	GA	IoU	Dice
Hashem & Kamil [2]	U-Net	Shenzhen	91.47%	74.94%	-
Pranata va boshqalar [4]	U-Net	MC+ Shenzhen	91.68%	-	-
Chavan va boshqalar [6]	ResUNet++	MC	-	94.27%	96.26%
Lyu & Tian [8]	MWG-UNet	JSRT	-	81.36%	85.18%
Sulaiman va boshqalar [11]	CNN	MC	97%	93%	96%
Ushbu tadqiqot (DeepLabV3+)	**DeepLabV3+**	**MC+JSRT+ Shenzhen**	**98.31%**	**94%**	**97%**

Olingan natijalar DeepLabV3+ arxitekturasining boshqa segmentatsiya modellariga nisbatan ustunligini ko‘rsatdi. Buning asosiy sabablari quyidagilar bilan bog‘liq: model tasvirdagi umumiy va lokal kontekstni bir vaqtning o‘zida o‘rgana oladigan ASPP modulidan foydalanadi, dilated konvolyutsiyalar orqali receptive field kengaytiriladi va encoder–decoder tuzilmasi past qatlamlardagi fazoviy ma’lumotni tiklashga yordam beradi. Shu omillar birgalikda

(cc) BY

o‘pka konturlarini aniq ajratishga xizmat qilib, modelning yakuniy ko‘rsatkichlarining yuqori chiqishiga sabab bo‘lgan.

XULOSA.

Ushbu tadqiqotda ko‘krak qafasi rentgen tasvirlaridan o‘pka hududlarini aniqlik bilan segmentatsiya qilish uchun DeepLabV3+ arxitekturasi qo‘llanildi. Modelni o‘qitish jarayonida Montgomery, Shenzhen va JSRT ma’lumotlar to‘plamlarining birlashtirilishi umumlashtirish qobiliyatini yaxshiladi va real klinik holatlarga yaqin sharoitlarda barqaror natija berdi. Tajribaviy natijalar Dice koeffitsientining 97% dan yuqori qayd etilganini ko‘rsatib, modelning segmentatsiya aniqligi yuqori ekanini tasdiqladi. ASPP modulining ko‘p miqyosli kontekstni tahlil qilish xususiyati va dilated konvolyutsiyalar orqali receptive field’ning kengayishi modelning murakkab konturli anatomik tuzilmalarni ham samarali ajratishiga imkon berdi. Qo‘llangan augmentatsiya usullari modelning turli yorug‘lik, shovqin va geometrik o‘zgarishlarga nisbatan barqarorligini oshirdi. Natijalar DeepLabV3+ modelini ko‘krak rentgen tasvirlarida o‘pka segmentatsiyasi uchun ishonchli vosita sifatida ko‘rib chiqish mumkinligini ko‘rsatadi. Kelgusida modelni yanada kengroq datasetlar bilan o‘qitish, shuningdek segmentatsiyadan keyingi klassifikatsiya modullari bilan integratsiya qilish uning klinik qo‘llanilish imkoniyatlarini yanada kengaytirishi mumkin.

FOYDALANILGAN ADABIYOTLAR.

1. Liu W., Chen J., & Zhang Y. (2021). Improved U-Net with EfficientNet encoder for lung segmentation from chest X-ray images. *Computers in Biology and Medicine*, 134, 104462.
2. Hashem S. A., & Kamil M. Y. (2020). Lung segmentation from chest X-ray images using U-Net architecture. *International Journal of Engineering Research and Technology*, 13(10), 2826–2832.
3. Gite S., Mahajan A., & Pise N. (2021). Comparative analysis of deep learning models for lung segmentation on chest X-ray images. *Biomedical Signal Processing and Control*, 68, 102677.
4. Pranata T., Wang K. C., & Hsu C. H. (2020). Lung segmentation using U-Net with CLAHE preprocessing for chest X-ray images. *Journal of Healthcare Engineering*, 2020, Article ID 3020146.
5. Bassi P. R., & Attux R. (2021). Impact of lung segmentation on COVID-19 classification in chest X-ray images. *IEEE Latin America Transactions*, 19(9), 1542–1549.
6. Chavan M., Jadhav S., & Patil P. (2021). ResUNet++: An advanced architecture for lung segmentation in chest X-ray images. *Expert Systems with Applications*, 185, 115636.
7. Said Y., Barr M., & Al-Madi N. (2022). UNETR-based segmentation and classification framework for lung cancer detection. *Computers in Biology and Medicine*, 143, 105299.
8. Lyu Y., & Tian X. (2019). MWG-UNet: Multi-weight generative adversarial network for lung and heart segmentation from chest X-rays. *Neurocomputing*, 350, 30–45.
9. Ullah A., Khan S. U., & Kim J. (2020). Multi-organ segmentation of chest X-ray images using two-stage encoder–decoder networks. *IEEE Access*, 8, 146589–146602.
10. Hasan D., & Jader U. (2021). Lung segmentation from chest X-ray images using SegNet. *International Journal of Computer Assisted Radiology and Surgery*, 16(3), 401–412.
11. Sulaiman A., Mohamed A., & Ali H. (2021). A CNN-based concatenation block architecture for accurate lung segmentation. *Multimedia Tools and Applications*, 80, 23853–23869.
12. Chen L.-C., Zhu Y., Papandreou G., Schroff F., & Adam H. (2018). Encoder–decoder with atrous separable convolution for semantic image segmentation. *Proceedings of the European Conference on Computer Vision (ECCV)*, 801–818.
13. Jaeger S., Candemir S., Antani S., Wang, Y-X., Lu P.-X., & Thoma G. (2014). Two public chest X-ray datasets for computer-aided screening of pulmonary diseases. *Quantitative Imaging in Medicine and Surgery*, 4(6), 475–484.

(cc) BY