U-NET CHUQUR O‘QITISH MODELI YORDAMIDA UMURTQA POG‘ONASINING KOMPYUTER TOMOGRAFIYASI TASVIRLARINI SEGMENTATSIYA QILISH

Nishanov Axram Xasanovich[1], Zaripov Fazil Maxsetovic[1], Jo‘raqulov Nodirbek Sobirovich[1], Qambarov Baxriddin Panji o‘g‘li[4]

[1]Toshkent axborot texnologiyalari universiteti
[2]Toshkent iqtisodiyot universiteti

K E Y W O R D S

umurtqa pog‘onasi segmentatsiyasi, KT tasvirlari, **U-Net**, Dice koeffitsiyenti, Jaccard indeksi, chuqur o‘qitish (deep learning), tibbiy tasvirlarni qayta ishlash

A B S T R A C T

Ushbu maqolada umurtqa pog‘onasi tibbiy tasvirlaridan vertebra tuzilmalarini segmentatsiya qilishda **U-Net konvolyutsion neyron tarmog‘i** asosida semantik segmentatsiya modelini qo‘llash masalasi qaralgan. Kompyuter tomografiyasi (KT) tasvirlaridan umurtqa segmentlarini aniq ajratib olish kasalliklarni erta va ishonchli aniqlashda muhim ahamiyatga ega. U-Net arxitekturasi encoder–decoder tuzilmasi va skip-connection bog‘lanishlari orqali tasvir xususiyatlarini chuqur o‘rganib, yuqori aniqlikdagi segmentatsiya xaritasini hosil qiladi. Tajriba natijalariga ko‘ra, model samaradorligini baholandi va **Jaccard indeksi (IoU) metrikasi ko‘rsatkichi 90%** va **Dice koeffitsiyenti** ko‘rsatkichi 92% ni tashkil qildi. Olingan natijalar mazkur modelning boshqa segmentatsiya modellariga nisbatan umurtqa vertebra segmentlarini aniq va ishonchli ajratish imkoyatiga ega ekanligini ko‘rsatadi.

I. KIRISH

Umurtqa pog‘onasi inson organizmining asosiy tayanch-harakat tizimi tarkibiy qismi bo‘lib, u tana barqarorligini ta’minlash, mexanik yuklamalarni taqsimlash hamda orqa miyani himoya qilish kabi muhim funksiyalarni bajaradi. Umurtqa pog‘onasi bilan bog‘liq patologiyalar, xususan, disk churrasi, degenerativ disk kasalliklari, skolioz va turli deformatsiyalar global miqyosda keng tarqalgan sog‘liq muammolari sirasiga kiradi [1]. Ushbu kasalliklarni aniqlash va klinik baholash jarayonida ko‘pincha kompyuter tomografiyasi (KT) tasvirlaridan foydalaniladi. Har yili katta hajmdagi umurtqa pog‘onasi tasvirlari olinadi va ularni qo‘lda tahlil qilish radiolog mutaxassislardan yuqori darajadagi malaka, katta vaqt va e’tibor talab etadi. Shu bois so‘nggi yillarda tibbiy tasvirlarni avtomatlashtirilgan tarzda tahlil qilishga qaratilgan kompyuter yordamida diagnostika tizimlariga bo‘lgan ehtiyoj sezilarli darajada ortib bormoqda [2]. Mazkur tizimlar diagnostika jarayonini tezlashtirish, inson omili bilan bog‘liq xatoliklarni kamaytirish va tahlil natijalarining aniqligini oshirishga xizmat qiladi. Kompyuter yordamida diagnostika tizimlarining muhim bosqichlaridan biri bu tibbiy tasvirlardan muhim anatomik tuzilmalarni, xususan umurtqa pog‘onasi segmentlarini aniq ajratib olish, ya’ni segmentatsiya jarayonidir. Umurtqa segmentatsiyasi disk churrasi, degenerativ o‘zgarishlar va boshqa patologik holatlarni aniqlash, ularning lokalizatsiyasi va hajmini baholashda muhim ahamiyat kasb etadi [3].

Amaliyotda umurtqa pog‘onasi tasvirlarida anatomik tuzilmalar o‘zaro yaqin joylashgan bo‘lib, ularning chegaralari ko‘pincha aniq ajralib turmaydi. Bundan tashqari, tasvir sifati, shovqin darajasi, kontrast farqlari hamda bemorlarning individual anatomik xususiyatlari segmentatsiya jarayonini murakkablashtiradi [4]. An’anaviy tasvirni qayta ishlash usullari bunday murakkab sharoitlarda har doim ham yuqori aniqlik va barqarorlikni ta’minlay olmaydi. So‘nggi yillarda

© A.X. Nishanov, F.M. Zaripov, N.S. Jo‘raqulov, B.P. Qambarov

chuqur o‘qitish (deep learning) metodlari, xususan, konvolyutsion neyron tarmoqlar (CNN) tibbiy tasvirlarni tahlil qilish va segmentatsiya qilish sohasida sezilarli natijalarga erishishga imkon berdi [5]. Ayniqsa, U-Net arxitekturasi tibbiy tasvirlar segmentatsiyasi uchun maxsus ishlab chiqilgan bo‘lib, uning encoder-decoder tuzilmasi hamda skip-connection mexanizmlari tasvirdagi fazoviy ma’lumotlarni samarali saqlash va tiklash imkonini beradi [6]. Ushbu model kichik va murakkab anatomik tuzilmalarni yuqori aniqlikda ajratib olish qobiliyati tufayli keng qo‘llanilmoqda [13]. Model samaradorligi bevosita o‘quv ma’lumotlarining sifati va hajmiga bog‘liq bo‘lganligi sababli, tibbiy tasvirlarni oldindan qayta ishlash hamda data augmentatsiya usullaridan foydalanish muhim ahamiyatga ega [14]. Ushbu yondashuvlar modelning turli yorug‘lik sharoitlari, shovqin darajalari, kontrast o‘zgarishlari va geometrik transformatsiyalarga nisbatan barqarorligini oshiradi [7].

Mazkur tadqiqotning asosiy maqsadi U-Net arxitekturasiga asoslangan chuqur o‘qitish modeli yordamida umurtqa pog‘onasi tibbiy tasvirlaridan vertebra segmentlarini avtomatik tarzda ajratib olish va modelning segmentatsiya samaradorligini baholashdan iborat. Olingan natijalar U-Net modelining umurtqa pog‘onasi tasvirlarini segmentatsiya qilishda yuqori aniqlik va barqarorlikni ta’minlashini ko‘rsatadi hamda uning klinik diagnostika jarayonlarida qo‘llash imkoniyatlari mavjudligini tasdiqlaydi

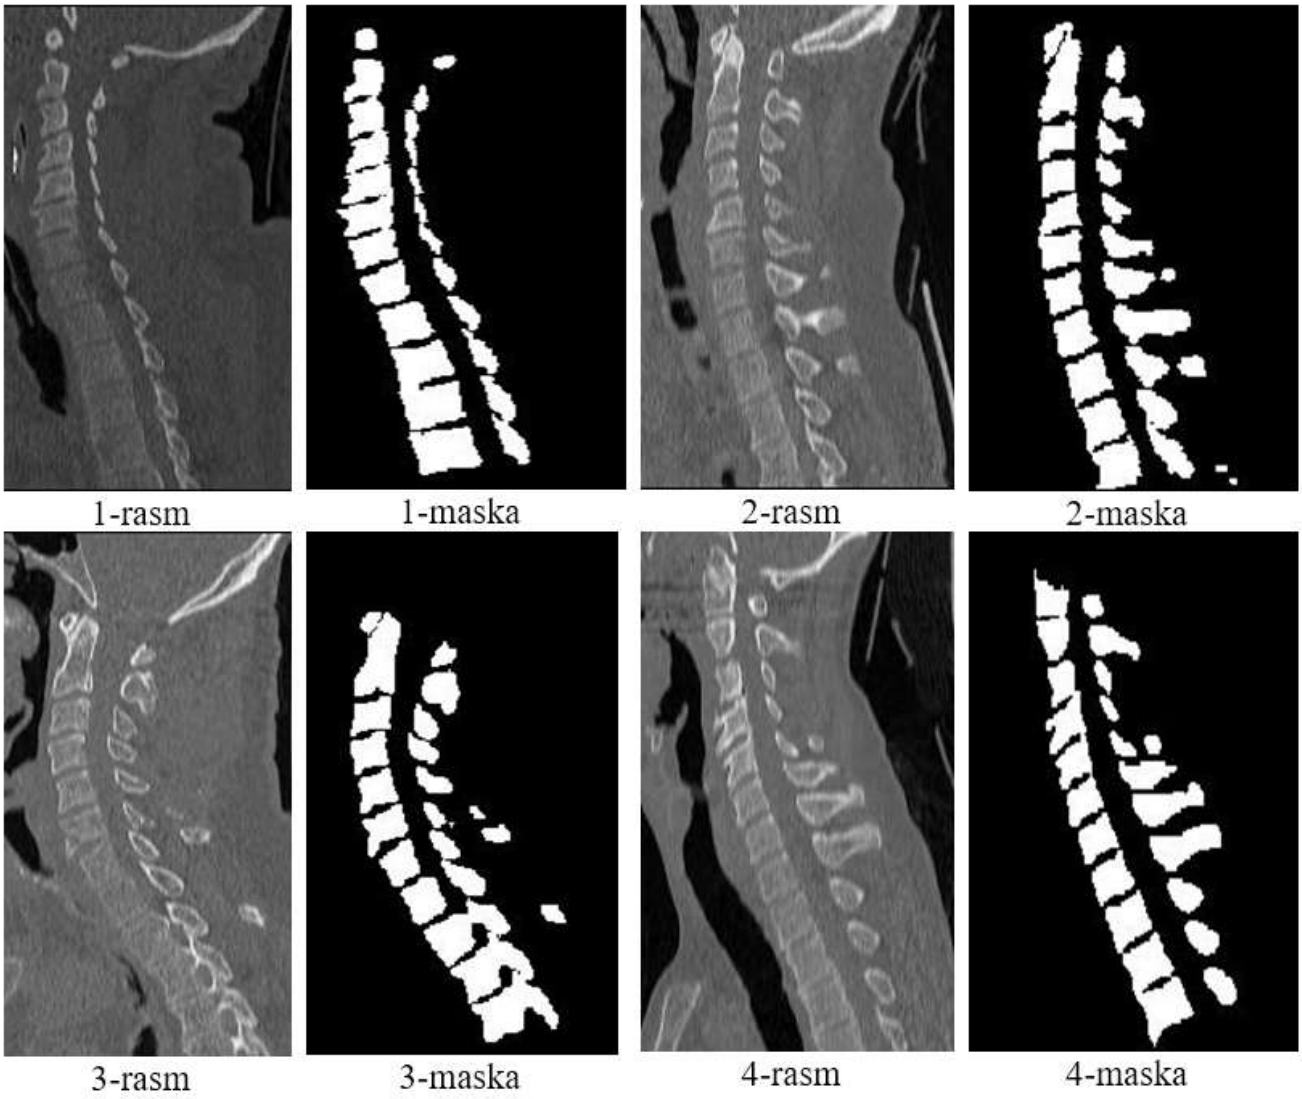
II. MATERIAL VA METODOLOGIYA

Dataset. Mazkur tadqiqotda umurtqa pog‘onasi tasvirlarini segmentatsiya qilish vazifasini bajarish uchun VerSe19 va VerSe20 (Vertebrae Segmentation Challenge 2019 va 2020) [21, 22] ochiq tibbiy tasvirlar datasetlaridan foydalanildi. Ushbu datasetlar umurtqa pog‘onasi vertebralarini avtomatik segmentatsiya qilish bo‘yicha tadqiqotlar uchun keng qo‘llaniladigan va ilmiy hamjamiyat tomonidan e’tirof etilgan ma’lumotlar to‘plamlaridan hisoblanadi. VerSe19 va VerSe20 datasetlari turli yosh, jins va klinik holatlarga ega bo‘lgan bemorlardan olingan kompyuter tomografiyasi (KT) tasvirlarini o‘z ichiga oladi. Ushbu tasvirlar yuqori aniqlikda bo‘lib, ularda umurtqa pog‘onasining barcha asosiy vertebralari (servikal, torakal va lumbal segmentlar) qamrab olingan. Har bir tasvir uchun vertebralar bo‘yicha aniq segmentatsiya maskalari mavjud bo‘lib, ular tajribali radiolog mutaxassislar tomonidan qo‘lda annotatsiya qilingan.

Mazkur datasetlarning muhim afzalliklaridan biri ularning yuqori darajadagi anatomik va patologik xilma-xilligidir. Unda sog‘lom hamda turli kasalliklarga chalingan bemorlarning tasvirlari mavjud bo‘lib, bu esa ishlab chiqilgan modelning umumlashtirish qobiliyatini oshirishga xizmat qiladi. Shuningdek, tasvirlarning rezolyutsiyasi, kontrast darajasi va tasvirga olish sharoitlarining farqlanishi modelni turli real klinik sharoitlarga moslashuvchanligini ta’minlaydi. VerSe19 va VerSe20 datasetlarining birgalikda qo‘llanilishi o‘quv ma’lumotlari hajmini oshirish bilan birga, modelning barqarorligi va aniqligini sezilarli darajada yaxshilash imkonini beradi. Natijada, ushbu datasetlar asosida o‘qitilgan model umurtqa pog‘onasi tasvirlaridan vertebralarni aniq segmentatsiya qilishda yuqori samaradorlik ko‘rsatkichlariga erishadi.

Mazkur tadqiqotda Kaggle platformasida taqdim etilgan VerSe19 va VerSe20 datasetlarining birlashtirilgan varianti qo‘llanildi. Ushbu ma’lumotlar to‘plami jami 754 ta kompyuter tomografiyasi (KT) tasvirlari hamda ularga mos keluvchi 754 ta segmentatsiya maskalaridan iborat bo‘lib, 1-rasmda mazkur datasetdan olingan namunaviy tasvirlarning to‘rtta namunasi keltirilgan bo‘lib, unda asl KT tasvirlari hamda ularga mos segmentatsiya maskalari vizual tarzda namoyish etilgan.

© A.X. Nishanov, F.M. Zaripov, N.S. Jo‘raqulov, B.P. Qambarov



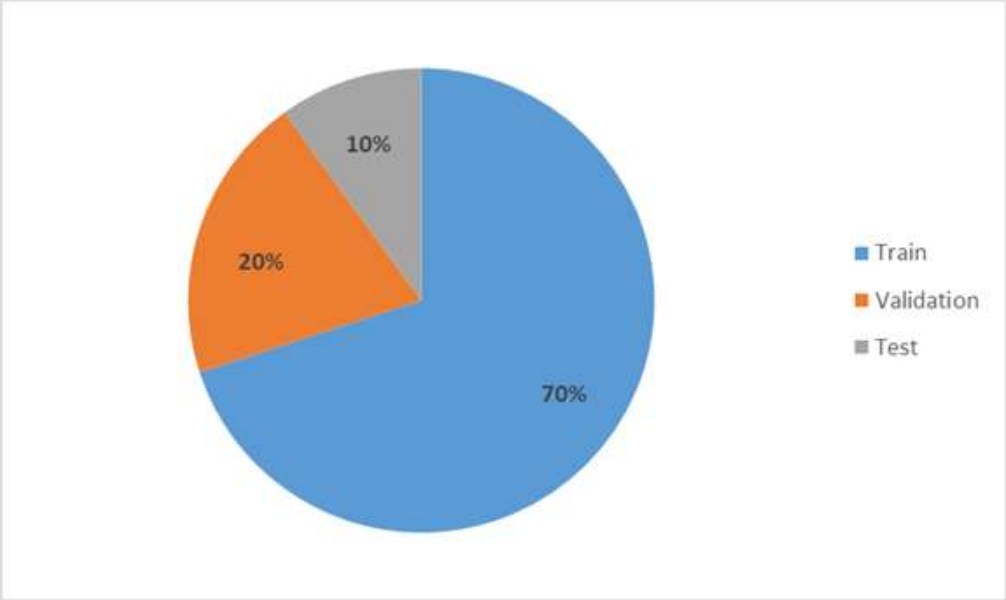
1-rasm. VerSe19 + VerSe20 datasetdagi rasm va uning maskasi

Ma’lumotlarga dastlabki ishlov berish. Modelni o‘qitishdan oldin barcha tasvirlar yagona standartga keltirildi hamda ularning sifatini barqarorlashtirish maqsadida bir qator dastlabki ishlov berish bosqichlari amalga oshirildi. Tadqiqotda foydalanilgan VerSe19 va VerSe20 datasetlaridagi barcha kompyuter tomografiyasi (KT) tasvirlari 512×512 piksel o‘lchamga keltirildi va yagona formatda qayta ishlash uchun grayscale ko‘rinishga standartlashtirildi. Umurtqa pog‘onasi vertebralariga tegishli segmentatsiya maskalari ham mos ravishda bir xil o‘lchamga o‘zgartirilib, ularning piksel qiymatlari [0, 1] oralig‘iga normallashtirildi [19]. Tasvirlardagi yorug‘lik va kontrast darajasining farqlari model o‘qitilishiga salbiy ta’sir ko‘rsatmasligi uchun barcha tasvir va maskalar float32 formatga o‘tkazildi. Shuningdek, dataset tarkibidagi ortiqcha bo‘sh hududlar, keraksiz chekka qismlar va nomuvofiq yoki noto‘g‘ri annotatsiyalangan maskalar tekshirilib, zarur hollarda tozalash ishlari amalga oshirildi. Barcha tasvirlar va ularga mos maskalar model arxitekturasiga mos ravishda (H, W, 1) o‘lchamli tensorga keltirildi. Ma’lumotlarga dastlabki ishlov berish jarayonining standartlashtirilishi modelni barqaror o‘qitish uchun muhim omil bo‘lib xizmat qildi hamda segmentatsiya aniqligining oshishiga ijobiy ta’sir ko‘rsatdi [20].

Modelning umumlashtirish qobiliyatini oshirish va turli klinik sharoitlarda olingan

© A.X. Nishanov, F.M. Zaripov, N.S. Jo‘raqulov, B.P. Qambarov

tasvirlarga moslashuvchanligini ta'minlash maqsadida ma'lumotlarga augmentatsiya usullari qo'llanildi. Jumladan, tasvirlarni gorizontal akslantirish (flipping), aylantirish (rotation), yorug'lik va kontrastni o'zgartirish, tasodifiy shovqin qo'shish, masshtablash (zoom-in/zoom-out) va kichik geometrik transformatsiyalar bajarildi. Ushbu yondashuvlar modelning turli yoritilish sharoitlari, shovqin darajalari va shakliy farqlarga nisbatan barqaror ishlashini ta'minladi [18]. Barcha ma'lumotlar birlashtirilib, keyinchalik o'quv (train), tekshiruv (validation) va sinov (test) to'plamlariga ajratildi. Ushbu bo'linish modelni o'qitish, gipermparametrlarni sozlash va yakuniy baholash bosqichlarini to'g'ri tashkil etish imkonini berdi.



2-rasm. Train, validation va test to'plamlari

Validatsiya to'plami modelning o'qitilish jarayonida uning umumlashtirish qobiliyatini nazorat qilish hamda 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. Mazkur tadqiqotda U-Net modeli umurtqa pog'onasi segmentatsiyasi vazifasini bajarish uchun o'qitildi. Hisoblash jarayonlari Kaggle platformasida Tesla P100 16GB grafik protsessor (GPU) yordamida amalga oshirildi, bu esa katta hajmdagi tibbiy tasvirlar bilan samarali ishlash imkonini berdi. Modelni optimallashtirish jarayonida chuqur o'qitish sohasida keng qo'llaniladigan zamonaviy texnikalar, jumladan, learning rate scheduling, early stopping hamda model checkpoint kabi callback mexanizmlari qo'llanildi [15]. Ushbu yondashuvlar modelning optimal parametrlarini aniqlash, ortiqcha o'qitilish holatini oldini olish hamda eng yaxshi natijalarni saqlab qolishga xizmat qildi.

Modelni o'qitishdan avval barcha kirish tasvirlari 512×512 piksel o'lchamga keltirildi va ularning piksel qiymatlari [0, 1] oralig'iga normallashtirildi. Dataset hajmining nisbatan cheklanganligi sababli modelning umumlashtirish qobiliyatini oshirish maqsadida turli geometrik va fotometrik data augmentatsiya usullari qo'llanildi [16]. Xususan, aylantirish, akslantirish, masshtablash, yorug'lik va kontrastni o'zgartirish hamda shovqin qo'shish kabi transformatsiyalar bajarildi. Ushbu yondashuv modelning turli

© A.X. Nishanov, F.M. Zaripov, N.S. Jo'raqulov, B.P. Qambarov

yoritilish sharoitlari, kontrast darajalari va tasvirdagi kichik deformatsiyalarga nisbatan barqaror ishlashini ta'minladi. Model parametrlarini yangilash uchun Adam optimizatori tanlandi. Ushbu optimizatorning asosiy afzalligi gradientlarning moslashuvchan (adaptive) yangilanish mexanizmi orqali modelni tez va barqaror konvergentsiyaga olib kelish qobiliyatidadir [17]. Adam parametrlari quyidagicha tanlandi:

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

Umurtqa 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:

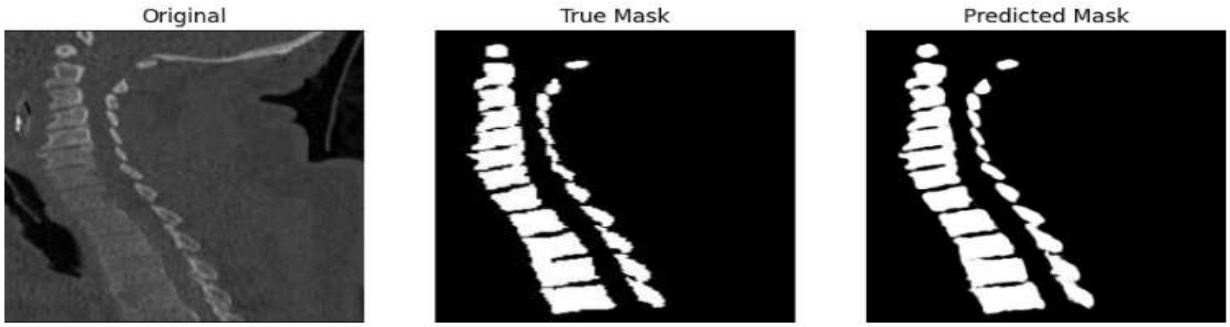
$$\mathcal{L}_{total} = \alpha\cdot\mathcal{L}_{BCE} + (1-\alpha)\cdot\left(1 - Dice\left(Y,\hat{Y}\right)\right)$$

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

III. NATIJALAR

Model TensorFlow/Keras dasturiy muhitida o'qitildi. O'qitish jarayonida model samaradorligini oshirish va ortiqcha moslashuv (overfitting) holatini oldini olish maqsadida bir qator callback mexanizmlari qo'llanildi. Jumladan, ModelCheckpoint modeli eng yaxshi ko'rsatkichlarga ega bo'lgan vaznlarni saqlash uchun, EarlyStopping o'qitish jarayonini optimal nuqtada to'xtatish uchun hamda ReduceLROnPlateau o'rganish tezligini (learning rate) moslashuvchan tarzda kamaytirish uchun ishlatildi.

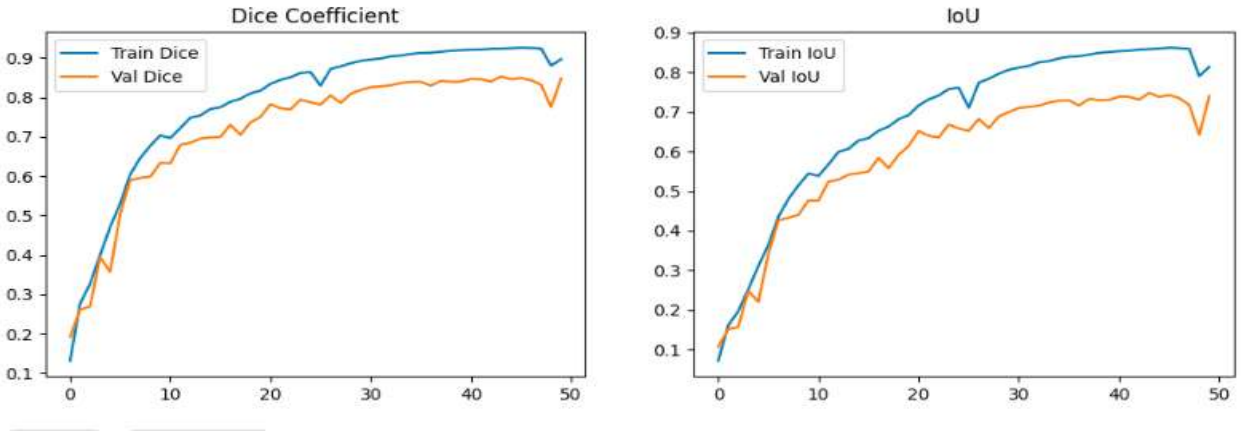


3-rasm. Asl KT, haqiqiy maska va bashorat qilingan maska .

Segmentatsiya natijalari vizual tahlil orqali ham qo'shimcha ravishda baholandi. Yuqoridagi 3-rasmda haqiqiy KT, asl segmentatsiya maskasi va model tomonidan bashorat qilingan maska tasvirlangan. Natijalar shuni ko'rsatdiki, bashorat qilingan segmentatsiya maskasi asl maska bilan mos keladi hamda umurtqa pog'onasi hududlari aniq va izchil ajratib olingan. Vizual tekshiruv davomida vertebra tuzilmalarining chegaralari aniq saqlanganligi, segmentatsiya natijalarida sezilarli deformatsiyalar yoki noto'g'ri ajratishlar

© A.X. Nishanov, F.M. Zaripov, N.S. Jo'raqulov, B.P. Qambarov

kuzatilmaganligi modelning yuqori aniqlik va barqarorlik bilan ishlayotganini tasdiqlaydi. Ushbu natijalar modelning nafaqat miqdoriy ko‘rsatkichlar, balki sifat jihatidan ham samarali ekanligini ko‘rsatadi.



4-rasm. Dice va IoU koeffitsenti [13].

Model 50 ta epoch davomida o‘qitildi va mavjud ma’lumotlarning 20% qismi validatsiya to‘plami sifatida ajratildi. Ushbu yondashuv modelning o‘qitish jarayonida umumlashtirish qobiliyatini nazorat qilish hamda optimal parametrlarni tanlash imkonini berdi. Tajriba natijalari modelning yuqori samaradorlikka ega ekanligini ko‘rsatdi. Xususan, validatsiya to‘plamida Dice koeffitsienti 92% ni, Intersection over Union (IoU) ko‘rsatkichi esa 90% ni tashkil etdi. Ushbu natijalar modelning segmentatsiya vazifasini yuqori aniqlik bilan bajarayotganini tasdiqlaydi.

1-jadval

Modelning eksperimental natijalari

Model	Dataset	Metrika	Qiymat
U-Net	VerSe19+ VerSe20	Dice	0.92
		IoU	0.90
		Global Accuracy	0.94

2-jadval

Boshqa modellarga nisbatan taqqoslash

Modellar	Dataset	GA	IoU	Dice
U-Net	VerSe19+ VerSe20	94%	90%	92%
U-Net++	VerSe19+ VerSe20	92%	83%	87%
Deeplabv3	VerSe19+ VerSe20	90%	83%	71%

Olingan natijalar qo‘llanilgan model arxitekturasining boshqa segmentatsiya modellariga nisbatan ustunligini ko‘rsatdi. Bunga bir qator muhim omillar sabab bo‘ladi. Xususan, modelda qo‘llanilgan ASPP (Atrous Spatial Pyramid Pooling) moduli tasvirdagi ko‘p miqyosli (multi-scale) kontekstual ma’lumotlarni bir vaqtning o‘zida o‘rganish imkonini beradi. Bundan tashqari, dilated (atrous) konvolyutsiyalar yordamida receptive field kengaytiriladi, bu esa tasvirdagi global kontekstni yaxshiroq qamrab olishga xizmat qiladi. Shu bilan birga, encoder–decoder tuzilmasi past qatlamlarda yo‘qolishi mumkin bo‘lgan fazoviy ma’lumotlarni tiklash imkonini beradi. Mazkur omillar birgalikda murakkab konturga ega anatomik tuzilmalarni aniq segmentatsiya qilishni ta’minlab, modelning yakuniy ko‘rsatkichlarini yuqori darajaga olib chiqadi.

IV. XULOSA

Ushbu tadqiqotda umurtqa pog‘onasi kompyuter tomografiyasi (KT) tasvirlaridan vertebra hududlarini aniqlik bilan segmentatsiya qilish maqsadida U-Net arxitekturasi qo‘llanildi. Modelni o‘qitish jarayonida VerSe19 va VerSe20

© A.X. Nishanov, F.M. Zaripov, N.S. Jo‘raqulov, B.P. Qambarov

ma'lumotlar to'plamlarining birlashtirilishi modelning umumlashtirish qobiliyatini sezilarli darajada oshirdi hamda real klinik sharoitlarga yaqin muhitda barqaror natijalar olish imkonini berdi. Tajriba natijalari Dice koeffitsientining 92% dan yuqori qiymatga ega ekanligini ko'rsatib, modelning segmentatsiya aniqligi yuqori darajada ekanligini tasdiqladi. ASPP modulining ko'p miqyosli kontekstni tahlil qilish imkoniyati hamda dilated konvolyutsiyalar orqali receptive field'ning kengaytirilishi modelning murakkab va noaniq chegaralarga ega anatomik tuzilmalarni ham samarali ajratib olishiga xizmat qildi. Shuningdek, qo'llanilgan data augmentatsiya usullari modelning turli yorug'lik sharoitlari, shovqin darajalari va geometrik o'zgarishlarga nisbatan barqarorligini oshirdi.Olingan natijalar asosida U-Net arxitekturasini umurtqa pog'onasi KT tasvirlarida vertebra segmentatsiyasi uchun ishonchli va samarali vosita sifatida baholash mumkin. Kelgusida modelni yanada kengroq va xilma-xil datasetlar asosida o'qitish, shuningdek segmentatsiya natijalarini klassifikatsiya yoki diagnostika modullari bilan integratsiya qilish uning klinik qo'llanish imkoniyatlarini yanada kengaytirishi mumkin

FOYDALANILGAN ADABIYOTLAR

1. World Health Organization. *Musculoskeletal conditions*. Available: https://www.who.int/news-room/fact-sheets/detail/musculoskeletal-conditions
2. Doi K. Computer-aided diagnosis in medical imaging: Historical review, current status and future potential. *Computerized Medical Imaging and Graphics*, 2007, vol. 31, no. 4–5, pp. 198–211.
3. Litjens G., Kooi T., Bejnordi B. E., et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*, 2017, vol. 42, pp. 60–88.
4. Suzani A., Seitel A., Rasoulian A., et al. Automatic vertebrae detection and localization in CT images. *IEEE Transactions on Medical Imaging*, 2015, vol. 34, no. 2, pp. 530–541.
5. Shen D., Wu G., Suk H. Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 2017, vol. 19, pp. 221–248.
6. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, 2015, pp. 234–241.
7. Shorten C., Khoshgoftaar T. A survey on image data augmentation for deep learning. *Journal of Big Data*, 2019, vol. 6, no. 1, pp. 60.
8. Chen L. C., Zhu Y., Papandreou G., Schroff F., Adam H. Encoder–decoder with atrous separable convolution for semantic image segmentation. *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018, pp. 801–818.
9. Jaeger S., Candemir S., Antani S., Wang Y., Lu P., Thoma G. Two public chest X-ray datasets for computer-aided screening of pulmonary diseases. *Quantitative Imaging in Medicine and Surgery*, 2014, vol. 4, no. 6, pp. 475–484.
10. Ghesu F. C., Georgescu B., Zheng Y., et al. Multi-scale deep reinforcement learning for real-time 3D vertebrae localization in CT images. *IEEE Transactions on Medical Imaging*, 2017, vol. 36, no. 6, pp. 1264–1274.
11. Korez R., Ibragimov B., Likar B., Pernuš F., Vrtovec T. A framework for automated spine and vertebrae interpolation-based detection and model-based segmentation. *IEEE Transactions on Medical Imaging*, 2015, vol. 34, no. 8, pp. 1649–1662.
12. Sekuboyina A., Bayat A., Husseini M. E., et al. VerSe: A vertebrae segmentation challenge. *Medical Image Analysis*, 2021, vol. 73, 102166.
13. M. Arabboev and S. Begmatov, "U-NET BASED POLYP SEGMENTATION ON KVASIR- SEG DATASET: PERFORMANCE EVALUATION AND COMPARISON WITH STATE-OF-THE-ART METHODS," *MUHANDISLIK VA IQTISODIYOT*, no. 12, pp. 289–299, 2025, doi: https://doi.org/10.5281/zenodo.17874308.

© A.X. Nishanov, F.M. Zaripov, N.S. Jo'raqulov, B.P. Qambarov

14. M. Arabboev and S. Begmatov, "Deep learning-based pneumonia detection from chest X-ray images using a convolutional neural network," *Современные инновации, системы и технологии - Mod. Innov. Syst. Technol.*, vol. 5, no. 3, pp. 1018–1026, 2025, doi: 10.47813/2782-2818-2025-5-3-1018-1026.
15. H. Batool *et al.*, "Knowledge Distillation and Transformer-Based Framework for Automatic Spine CT Report Generation," *IEEE Access*, vol. 13, no. January, pp. 42949–42964, 2025, doi: 10.1109/ACCESS.2025.3546131.
16. S. F. Qadri, L. Shen, M. Ahmad, S. Qadri, S. S. Zareen, and S. Khan, "OP-convNet: A Patch Classification-Based Framework for CT Vertebrae Segmentation," *IEEE Access*, vol. 9, pp. 158227–158240, 2021, doi: 10.1109/ACCESS.2021.3131216.
17. R. Kumar, M. Gupta, and A. Abraham, "A Critical Analysis on Vertebra Identification and Cobb Angle Estimation Using Deep Learning for Scoliosis Detection," *IEEE Access*, vol. 12, no. December 2023, pp. 11170–11184, 2024, doi: 10.1109/ACCESS.2024.3353794.
18. R. Singh, C. Prabha, M. Malik, and R. K. Lodhi, "Leveraging DeepLabv3+ and U-Net Models for Accurate Spine Segmentation in CT Scans," *Int. J. Math. Eng. Manag. Sci.*, vol. 10, no. 6, pp. 2125–2145, 2025, doi: 10.33889/IJMEMS.2025.10.6.099
19. N. Micallef, D. Seychell, and C. J. Bajada, "Exploring the U-Net++ Model for Automatic Brain Tumor Segmentation," *IEEE Access*, vol. 9, pp. 125523–125539, 2021, doi: 10.1109/ACCESS.2021.3111131
20. T. Nemoto *et al.*, "Efficacy evaluation of 2D, 3D U-Net semantic segmentation and atlas-based segmentation of normal lungs excluding the trachea and main bronchi," *J. Radiat. Res.*, vol. 61, no. 2, pp. 257–264, 2020, doi: 10.1093/jrr/rrz086.\
21. Loffler, M. T. et al. Improved prediction of incident vertebral fractures using opportunistic QCT compared to DXA. Eur Radiol 29,4980–4989 (2019).
22. Sekuboyina, A. et al. VerSe: a vertebrae labelling and segmentation benchmark for multi-detector CT images. Med Image Anal 73,102166 (2021)

© *A.X. Nishanov, F.M. Zaripov, N.S. Jo'raqulov, B.P. Qambarov*