



U-NET ARXITEKTURASI VA KONVOLYUTSIYA TARMOG'IGA ASOSLANGAN BACHADON TASVIRLARINI SEGMENTATSIYALASH ORQALI MIOMANI ANIQLASH JARAYONI

¹Sadullaeva Shaxlo Azimbaevna,

Belarus-O'zbekiston qo'shma tarmoqlararo amaliy texnik
kvalifikatsiyalar instituti o'quv ishlari bo'yicha prorektori, f.-m.f.d.,
professor,

²Aripova Zulfiya Dilshodovna,

Muxammad al – Xorazmiy nomidagi Toshkent Axborot Texnologiyalari
universiteti Assistenti,

³Rajabova Maftuna Rustamovna,

Muxammad al – Xorazmiy nomidagi Toshkent Axborot
Texnologiyalari universiteti magistranti.

<https://doi.org/10.5281/zenodo.7491127>

ARTICLE INFO

Received: 19th December 2022

Accepted: 28th December 2022

Online: 29th December 2022

KEY WORDS

Mioma, CNN, segmentatsiya, U-
NET, konvolyutsiya, ReLu
qatlami, ODCNDPM algoritmi,
decoder.

ABSTRACT

Ushbu maqolada U-NET arxitekturasi va konvolyutsiya tarmog'iga asoslangan bachadon tasvirlarini segmentatsiyalash orqali miomani aniqlash jarayoni ko'rib chiqilgan. Mashinali o'qitishning chuqur konvolyutsiya tarmoqlari keng imkoniyatlarni bermoqda. Ushbu texnologiyalar tibbiy tasvirlarni tahlil qilish uchun avtomatlashtirilgan tizimlarni yaratishga imkon bermoqda. Kasallikdan zararlangan inson talani a'zolarini tahlil qilish uchun mashinali o'qitishning chuqur konvolyutsiya tarmoqlari keng qo'llanilmoqda.

Kirish. Sog'liqni saqlash tizimida tibbiy tasvir xizmatlariga talab tobora ortmoqda, masalan: kompyuter tomografiyasi (KT), mammografiya tasvirlari (MG), ultratovush tasvirlari, yadroviy tibbiyot tasviri, pozitron emissiya tomografiyasi (PET) va boshqalar. Bundan tashqari, yurtimizda mutahassislarning yetishmasligi ham tibbiy tasvirlarni tahlil qilishda qiyinchiliklar paydo qilmoqda. Mavjud ishdagi qiyinchiliklardan yuqori hisob-kitoblarni bartaraf etish uchun tibbiy tasvirlarni tekshirish uchun optimallashtirilgan chuqur konvolyutsiya tarmog'i qo'llaniladi. Bunda o'sma mintaqalarini bashorat qilish uchun bachadon miomasi bilan bog'liq tibbiy tasvirlardan foydalaniladi. Ushbu tizim bachadon miomasidan zararlangan

hududni bashorat qilish uchun kulrang bo'ri ovlash jarayonidan foydalanadi. Konvolyutsiya tarmog'i oldingi ko'rish tahlilidan zararlangan (tumor-affected region) hududni ko'rsatadigan avtomatik o'rganish funksiyasidan foydalanadi. Zararlangan hududlar qo'shimcha ravishda taqsimlash naqshini moslashtirish qoidasi yordamida tekshiriladi. Taklif etilayotgan tizim minimal xatolik darajasini va tibbiy tasvirni tahlil qilishning yuqori aniqligini ta'minlashda yordam beradi.

Mavzuga oid adabiyotlar tahlili.

Tadqiqodchilar orasida Sadullaeva Sh.A., Aripova Z.D, Rajabova M.R. larning maqolasida mioma kasalligini aniqlashda tibbiy tasvirlarni segmentatsiya orqali

aniqlash usullari va ularning kamchiliklari keltirilgan [1].

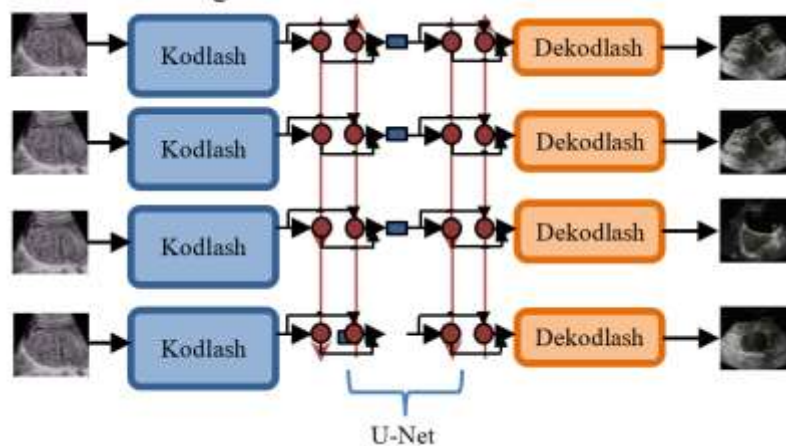
PhD., dotsent T.A. Kuchkorovning olib borgan ilmiy ishlarida tasvirlarni segmentlash uchun ko'p foydalaniladigan chuqur o'rganish modellari oxirgi olib borilgan ilmiy tadqiqot ishlari asosida tahlil qilingan, modellarning o'qitish strategiyalari va sohaga qo'shgan asosiy hissalarini kabi har xil xususiyatlari tahlili va xulosalarni taqdim etgan. Shuningdek, ko'rib chiqilgan usullar bo'yicha taqqoslovchi xulosalar va chuqur o'rganishga asoslangan tasvirlarni segmentlash modellarining kamchiliklari borasida ma'lumotlar keltirilgan [2].

Weng, Y., Zhou, T., Li, Y., va Qiu, X. ilmiy ishlarida U-Net arxitekturasi, U-Net arxitekturasi modeli, tibbiy tasvirlardan zararlangan hududni ajratib olish, Konvolyutsiya tarmog'i va turli konvolyutsiya yadrolari hududlarni

segmentlashda uchraydigan qiyinchiliklar keltirilgan [3].

Tadqiqot metodologiyasi. Maqolada umumiy qabul qilingan metodlar aniqlik, zararlangan hududni segmentlash, CNN yordamida tibbiy tasvirlarni tasniflash algoritmlari keltirilgan.

Tahlil va natijalar. Tasvirni segmentatsiyalash bunda shovqin olib tashlangan tibbiy tasvirlardan zararlangan hududlar olinadi. Bu yerda optimallashtirilgan chuqur CNN mintaqani segmentatsiyalash jarayonini amalga oshirish uchun ishlatiladi. Segmentatsiya texnikasi tasvirning fazoviy tafsilotlarini o'rganish orqali zararlangan hududni ajratib oladi. Bu jarayon uch bosqichda, ya'ni kodlovchi, U-net va dekoder orqali amalga oshiriladi. Bachadon tasvirini segmentatsiyalashning ish jarayoni 2-rasmda tasvirlangan.



1- rasm. Konvolyutsiya tarmog'iga asoslangan tasvir segmentatsiyasi.


Konvolyutsiya tarmog'i 1-rasmda ko'rsatilgan to'plangan tibbiy tasvirlardan zararlangan hududni ajratib oladi. Konvolyutsiya tarmog'i mahalliy va global ma'lumotlarni olish uchun kichik va katta yadrolarga ega. Turli konvolyutsiya yadrolari hududlarni segmentlashda

qiyinchiliklarga olib keladi. Shuning uchun, kasallikdan zararlangan hudud bilan bog'liq xususiyatlarni aniqlash uchun joriy ishda uchta konvolyutsiya qatlami, ya'ni $1 * 1$, $3 * 3$ va $5 * 5$ qo'llaniladi. Bundan tashqari, assimetrik konvolyutsiya yadrolari yordamida hisoblash minimallashtiriladi. Bu jarayon 2D ($N * N$) konvolyutsiyani ikkita 1D konvolyutsiyaga

($1 * N$ va $N * 1$) parchalaydi. Tasvirlarni yadro bilan parchalagandan so'ng, konvolyutsiyani qabul qilish maydoni parametr hajmini maksimal darajada oshirmasdan kengayadi. Bu yerda 2 va 4 parametrlar kengayish koeffitsientlari sifatida ishlatiladi. Konvolyutsiya qatlami odatda $3 * 3$ retseptiv maydonga ega, ammo kengaygan konvolyutsiya tufayli parametr o'lchamlari o'zgarishsiz qoladi [4]. Shuning uchun, bu ishda qo'llaniladigan konvolyutsiya yadrosining retseptiv maydonlari $7 * 7$ va $15 * 15$ dir. Belgilangan qabul qiluvchi maydon va konvolyutsiya qatlamining kengayish koeffitsientlari sifati yaxshilangan tibbiy tasvirlardan patologik hududlarni aniqlashga yordam beradi. Shundan so'ng, kaskadlash jarayoni $3 * 3$ yordamida erishilgan turli konvolyutsiya qatlamlaridan amalga oshirilishi kerak. Bu yerda 16 kanaldan foydalaniladi,

qisqartirilgan xususiyat xaritalari maksimal birlashtiruvchi qatlam bilan bog'lanadi. Keyinchalik, zararlangan hududni baholash uchun faollashtirish funksiyasidan foydalangan holda, to'g'rilangan chiziqli birlik (ReLU) qatlami bilan partiyani normalizatsiya qilish amalga oshiriladi.

Keyin mintaqa qismlarini tekshirish uchun U-Net arxitekturasidan foydalaniladi. Ushbu arxitektura ikki bosqichdan iborat: kontraktil kodlovchi (kiruvchi tibbiy tasvirlarni qayta ishlaydi) va dekoder qismi (chiqish qiymatini ishlab chiqaradi). Nihoyat, o'tkazib yuborish ulanishi kodlovchi bloklarning dekonvolyutsiya operatsiyalari natijasida olingan xususiyatlarni kaskadlaydi. Muhokama natijasida U-Net arxitektura modelining tuzilishi 2-rasmda tasvirlangan [4].



2-rasm: U-Net modeli.

3-rasmda ko'rsatilganidek, U-net modeli 28 ta konvolyutsiya qatlamiga ega va ular orasida 24 ta konvolyutsiya qatlami 4 ta konvolyutsiya va dekonvolyutsiya bloklari ustiga yoyilgan. Har bir konvolyutsiya blokida $3 * 3$ konvolyutsion yadroli 2 ta konvolyutsiya qatlami mavjud. Ushbu jarayon davomida qadam hajmi 1 ga teng; tarmoq ish faoliyatini yaxshilash uchun ReLU qatlami bilan ommaviy normalizatsiyadan o'tadi. Foydalanilgan faollashtirish funksiyasi xususiyatlarni ajratishda muhim rol o'ynaydigan o'rganish

qobiliyatiga ega. Bu yerda 2-bosqich maksimal birlashtirish jarayonini amalga oshirish uchun $2 * 2$ konvolyutsiya yadrosi bilan ishlatiladi [6]. Bu jarayonda xususiyat grafigining o'lchami iterativ ravishda $128 * 128$ qatlamdan $8 * 8$ qatlamga qisqartiriladi. Keyin, oxirgi dekonvolyutsiya bloki kiritilgan tibbiy tasvirdan xususiyatlarni oladi. Dekonvolyutsiya operatsiyalariga asoslangan ajratilgan xususiyatlar $3 * 3$ konvolyutsiya yadrosi bilan kaskadlangan va yakuniy natija quyidagi tenglama yordamida olinadi.



$$I_{output} = \frac{(I_{input} - F - 2P)}{S + 1} \quad (1)$$

bu yerda I_{output} va I_{input} tasvirlari kirish va chiqish sifatida belgilanadi.

$3 * 3$ qatlamga ega bo'lgan konvolyutsiya yadrosi F shaklida ifodalanadi.

$1 * 1$ qatlamga ega bo'lgan to'ldirish hajmi P sifatida hisoblanadi. S 1 ga teng qadam hajmini bildiradi.


Hisoblangan chiqish sigmasimon faollashtirish funksiyasidan baholanadi. Bu qiymat 0 va 1 oralig'ida o'zgarib turadigan piksel qiymati taqsimotiga tegishli. Har qanday o'sma bemorga ta'sir qilgandan so'ng, lezyon maydoni butun qismga taqsimlanadi. Shuning uchun, ehtimollik taqsimoti qiymatidan olingan chiqish va ushbu ehtimollik qiymatiga tegishli piksel zararlangan hudud hisoblanadi.

Nihoyat, dekoder qismi xususiyat grafigini ko'paytirish uchun qo'llaniladi. Dekoder jarayonida bitta konvolyutsiya qatlami va bitta dekonvolyutsiya qatlami mavjud. Ikkala qatlamda ReLu mavjud va ommaviy normalizatsiya qilinadi, bu esa softmax klassifikatori yordamida zararlangan hududni samarali yo'naltiradi. Mintaqa segmentatsiyasi jarayonida o'smani aniqlash aniqligini kamaytiradigan yo'qotish funksiyasi paydo bo'lishi mumkin. Keyinchalik, konvolyutsiya tarmog'ida qo'llaniladigan optimallashtirilgan parametrlarni tanlash orqali yo'qotish funksiyasi minimallashtiriladi.

Bundan tashqari, tibbiy ma'lumotlarning kontsentratsiyasi piksel darajasi qiymati

orqali hisoblanishi kerak. Agar piksel qiymati markaziy qiymatga qarab yopilgan bo'lsa, markaziy qiymat median qiymatdan foydalangan holda baholanadi. Shundan so'ng, olingan hududning statistik tavsifi orqali tibbiy ma'lumotlarning tarqalishi hisoblanadi. Hududdan kvartil diapazon, dispersiya, standart og'ish, o'rtacha farq va dispersiya koeffitsientlari olinadi. Olingan tafsilotlar ma'lumotlar bazasida shablon sifatida saqlanadi. Agar ushbu ma'lumot mavjud ma'lumotlarga mos kelsa, u o'simta bilan bog'liq hududlar hisoblanadi. Shunday qilib, optimallashtirilgan konvolyutsiya tarmog'iga asoslangan ekstrakte qilingan tibbiy hududlar o'simta hududini aniqroq aniqlashi mumkin. Tizimning samaradorligi simulyatsiya natijalari yordamida baholanadi [7,8].

Tarqatish naqshini moslashtirish qoidasi (ODCNDPM) algoritmgiga asoslangan tibbiy tasvirni tahlil qilish jarayoni bilan optimallashtirilgan chuqur konvolyutsiya tarmog'ining mukammal ishlashi muhokama qilinadi. Ushbu ish tibbiy tasvir namunasini tahlil qilish jarayonining samaradorligini tekshirish uchun turli tibbiy tasvirlardan foydalanadi. Bu yerda tizim samaradorligini aniqlash ma'lumotlar to'plami, xususan, bachadon miomasi tasvirlari ma'lumotlar bazasidan foydalaniladi. Ma'lumotlar to'plamidan zararlangan hududlarni samarali ajratib olish uchun ishlatiladigan UZI apparati tasvirlari mavjud. Quyida bachadon miomasining tibbiy tasvirlari shakllarda keltirilgan. 4a va 4b.



3-rasm. Bachadon miomasining tibbiy tasvirlari namunasi.

3-rasmdan biz o'simtadan zararlangan hududni tekshirish uchun har qanday tibbiy tasvirlarni to'plashimiz mumkin. Jumladan, to'plangan hududlardan olingan ma'lumotlarning 80 foizi o'quv mashg'ulotlariga, 20 foizi test sinovlariga yo'naltiriladi. Tibbiy tasvirlarni yig'ib bo'lgach, ular yuqoridagi bosqichlar orqali qayta ishlanadi va usullar yagona platforma yordamida amalga oshiriladi. Bu yerda tizimni ishlab chiqish uchun NVIDIA GTX1060Ti, Intel i7 Core protsessorlari va MATLAB ishlatiladi. Amalga oshirish jarayonida zararlangan hududni segmentlash uchun 0,001 o'rganish tezligi, 8 partiya hajmi va 0,0001 L2 tartibga solishdan foydalaniladi. Belgilangan tizimning mukammalligi Dice o'xshashlik koeffitsienti (DSC), bashoratli pozitivlik qiymati (PPV) va sezgirlik ko'rsatkichlari yordamida baholanadi. Ushbu ko'rsatkichlar tibbiy tasvirni segmentatsiyalash jarayonining

samaradorligini tekshirish uchun ishlatiladi. Qiymatlar quyidagicha hisoblanadi [9]:

$$DSC = 2 \frac{P \cap T}{P + T}, \quad (2)$$

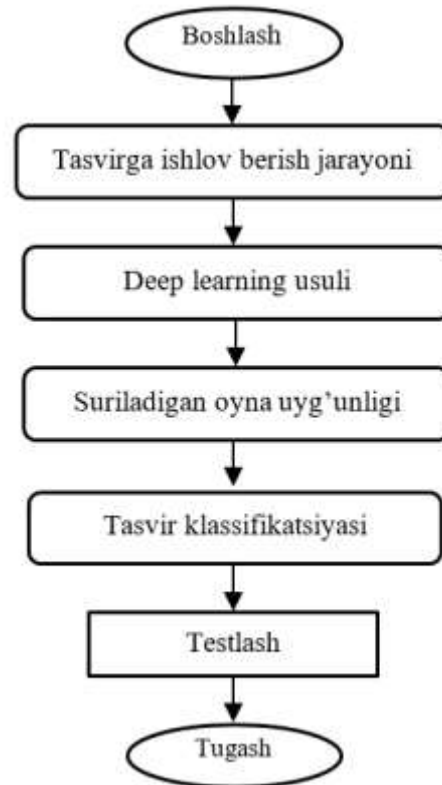
$$Sensitivity = \frac{P \cap T}{T}, \quad (3)$$

$$PPV = \frac{P \cap T}{P} \quad (4)$$

Bu yerda T asosiy haqiqat mintaqasi sifatida belgilanadi, P - belgilangan algoritmdan foydalanadigan segmentlangan mintaq va $P \cap T$ haqiqiy va algoritmgga asoslangan segmentatsiya o'rtasidagi kesishish sifatida belgilanadi. Ushbu ko'rsatkichlar ikkala ma'lumot to'plamidagi tibbiy tasvirlarni tahlil qilish uchun ishlatiladi. Ushbu qism avval taqdim etilgan ma'lumotlarga asoslanib, og'irlikni ishga tushirish / surmali oyna termoyadroviy CNN yordamida tibbiy rasm tasniflash algoritmini yaratadi (4-rasm). Birinchidan, CNN vaznini ishga tushirish usuli ishlab chiqiladi, u modelning

yaqinlashishi va umumlashtirilishini kuchaytiradi, shu bilan birga vaznni ishga tushirish muammolari tufayli CNNdagi

gradientlar kabi muammolarni oldini oladi. [10].



4-rasm. Tasniflash algoritmining sxemasi.

Xulosa. Ushbu tadqiqot ODCNDPM algoritmgiga asoslangan tibbiy tasvir namunasini tahlil qilish jarayonini taqdim etadi. Birinchidan, adaptiv filtrlash usuli yordamida turli xil tibbiy tasvirlar to'planadi va qayta ishlanadi. Ushbu usul biomarker tafsilotlariga ta'sir qilmasdan tasvirdagi Gauss shovqinini yo'q qiladi. Shunday qilib, optimallashtirilgan konvolyutsiya tarmoqlarini yanada tahlil qiladigan gistogramma qiymatini hisoblash orqali tasvirlarning sifati yaxshilanadi. Ushbu usul tibbiy tasvirlarda keltirilgan piksellarni tahlil qilish uchun turli konvolyutsiya qatlamlari va yadro

qiymatlaridan foydalanadi. Ushbu jarayon davomida kulrang bo'ri optimallashtirilgan algoritmlar zararlangan hududni segmentlashda xatolik darajasini minimallashtiradigan eng yaxshi xususiyatni tanlaydi. Chiqarilgan hududning samaradorligi tibbiy tasvirning deyarli barcha xususiyatlarini qamrab oluvchi taqsimot shaklini moslashtirish qoidasi yordamida aniqlanadi va umumiy tibbiy tasvir namunasini tahlil qilish jarayonini yaxshilashga yordam beradi. Bu jarayon hisoblash murakkabligini minimallashtiradi va kasallikdan zararlangan hududlarni aniqlash darajasini 99% gacha oshirishga imkon beradi.

References:

1. Sadullaeva Sh.A., Aripova Z.D, Rajabova M.R., "Ayollarda uchraydigan mioma kasalligini segmentatsiyalash orqali aniqlash" "Zamonaviy Axborot, Kommunikatsiya Texnologiyalari Va



At-Ta'lim Tatbiqui Muammolari" Mavzusidagi Respublika Ilmiy-Amaliy Anjumani, Samarqand, pp. 88–90, 2022.

2. Садуллаева Шахло Азимбаевна, Арипова Зульфия Дилшодовна (Ташкент, Узбекистан) Распознавание миомы матки с помощью методов распознавание объектов и пятен 135ст. актуальные научные исследования в современном мире выпуск 11(79) Часть 10 Ноябрь 2021 г. ЖУРНАЛ ISSN 2524-0986.

3. Kuchkorov T.A., Ochilov T.D. Tasvirlarni segmentlashning chuqur o'qitishga asoslangan arxitektura va algoritmlari. 2021 y.

4. Weng, Y., Zhou, T., Li, Y., and Qiu, X. (2019). NAS-UNet: neural architecture search for medical image segmentation. IEEE Access 7, 44247–44257. doi: 10.1109/ACCESS.2019.2908991

5. Chen, L.-C., Papandreou, G., Schroff, F., and Adam, H. (2017b). Rethinking atrous convolution for semantic image segmentation. arXiv preprint arXiv:1706.05587.

6. Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., and Adam, H. (2018). "Encoder-decoder with atrous separable convolution for semantic image segmentation," in Proceedings of the European conference on computer vision (ECCV) (Munich), 801–818. doi: 10.1007/978-3-030-01234-2_49

7. Shelhamer, E.; Long, J.; Darrell, T. Fully Convolutional Networks for Semantic Segmentation. IEEE Trans. Pattern Anal. Mach. Intell. 2017, 39, 640–651.

8. Dai, J.; Li, Y.; He, K.; Sun, J. R-fcn: Object detection via region-based fully convolutional networks. Neural Inf. Process. Syst. 2016, 29, 379–387.

9. C. Wachinger, M. Reuter, and T. Klein, "DeepNAT: Deep convolutional neural network for segmenting neuroanatomy," NeuroImage, vol. 170, pp. 434–445, apr 2018.

10. S. Anwar, M. Majid, A. Qayyum, M. Awais, M. Alnowami et al., "Medical image analysis using convolutional neural networks: A review," Journal of Medical Systems, vol. 42, no. 11, pp. 226, 2018

11. Dilshodovna, Aripova Zulfiya. "ALGORITHMS FOR PROCESSING MEDICAL GRAPHIC IMAGES FOR UTREIN FIBROID SEGMENTATION." *Web of Scientist: International Scientific Research Journal* 3.4 (2022): 1060-1069.