TIBBIY TASVIRLARNI SEGMENTLASH USULLARI: ZAMONAVIY YONDASHUVLAR VA RIVOJLANISH ISTIQBOLLARI

Ruxsora Avazbek qizi Anvarbekova
E-mail: anvarbekovaruxsoraxon@gmail.com
https://doi.org/10.5281/zenodo.23324934

Annotatsiya. Tibbiy tasvirlarni segmentlash kompyuter diagnostikasi, patologik o'choqlarni aniqlash va jarrohlikni rejalashtirishda markaziy bosqichdir. Mazkur maqolada KT va MRT tasvirlarini segmentlashning an'anaviy algoritmlari, U-Net oilasi, Transformer arxitekturalari hamda zamonaviy fundamental modellar (MedSAM) imkoniyatlari tizimli tahlil qilinadi. Usullar fazoviy aniqlik, annotatsiyalangan ma'lumotlarga ehtiyoj, hisoblash resurslari va domen siljishiga (domain shift) chidamliligi bo'yicha qiyoslandi.
Kalit so'zlar: tibbiy tasvirlar, segmentlash, U-Net, Transformer, MedSAM, Dice koeffitsiyenti, Hausdorff masofasi, sun'iy intellekt.

MEDICAL IMAGE SEGMENTATION METHODS: MODERN APPROACHES AND DEVELOPMENT PROSPECTS

Abstract. Medical image segmentation plays a vital role in computer-aided diagnostics, pathology localization, and treatment planning. This paper systematically analyzes core segmentation paradigms, ranging from conventional algorithms and convolutional networks (U-Net, nnU-Net) to Vision Transformers (TransUNet) and medical foundation models (MedSAM). Methods are comparatively evaluated regarding boundary delineation accuracy, annotation dependence, computational footprint, and cross-center robustness.
Keywords: medical imaging, image segmentation, U-Net, Vision Transformer, MedSAM, Dice coefficient, Hausdorff distance.

МЕТОДЫ СЕГМЕНТАЦИИ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ: СОВРЕМЕННЫЕ ПОДХОДЫ И ПЕРСПЕКТИВЫ РАЗВИТИЯ

Аннотация. Сегментация медицинских изображений является ключевым этапом автоматизированной диагностики, оконтуривания патологий и планирования терапии. В статье проводится систематический анализ основных подходов к сегментации: традиционных методов, сверточных сетей (U-Net, nnU-Net), архитектур на основе трансформеров (TransUNet) и медицинских фундаментальных моделей (MedSAM). Проведено их сопоставление по точности границ, потребности в разметке, вычислительной емкости и устойчивости к сдвигу домена.
Ключевые слова: медицинские изображения, сегментация, U-Net, Vision Transformer, MedSAM, коэффициент Дайса, расстояние Хаусдорфа.

Kirish

Klinik amaliyotda raqamli diagnostika vositalari (KT, MRT, ultratovush) hajmining ortishi tasvirlarni tezkor va aniq tahlil qilishni taqozo etmoqda. Tibbiy tasvirni segmentlash — tasvir piksellari yoki hajmiy voksellarini anatomik tuzilmalar yoxud patologik o'choqlar sinfiga ajratish jarayonidir [1, 6]. Matematik jihatdan, tasvir sohasi $\Omega \subset \mathbb{R}^d$ ($d \in \{2, 3\}$) bo'lsa, uni o'zaro kesishmaydigan qism-hududlarga ajratish quyidagicha ifodalanadi:

$$\Omega = \bigcup_{i=1}^{K} \Omega_i, \qquad \Omega_i \cap \Omega_j = \varnothing \quad (\forall i \neq j)$$

Klassik chegaralash usullari sodda bo'lsa-da, past kontrast, shovqin va to'qimalarning murakkab shakli sharoitida yetarli natija bermaydi. Chuqur o'rganish (U-Net oilasi) sohada sifat burilishini yasadi [1, 3]. So'nggi yillarda esa global kontekstni hisobga oluvchi Transformerlar hamda keng ko'lamli bazalarda o'qitilgan fundamental modellar (MedSAM) amaliyotga faol kirib kelmoqda [2, 4, 5]. Mazkur maqolaning maqsadi tibbiy tasvirlarni segmentlashning asosiy an'anaviy va zamonaviy usullarini tahlil qilish, ularning amaliy afzalliklari hamda cheklovlarini qiyoslash va doktorantura tadqiqotlari uchun dolzarb yo'nalishlarni belgilashdan iborat.

Segmentlash usullarining arxitekturaviy evolyutsiyasi

An'anaviy algoritmlar (Otsu, Level Set): Tasvir piksellari intensivligining sinflararo dispersiyasini maksimallashtiradi yoki chegaralarni dinamik egri chiziqlar orqali qidiradi. Ular hisoblash resursini kam talab qiladi, ammo tasvirdagi shovqin va noaniq to'qima chegaralariga (partial volume effect) o'ta sezgir [1].

U-Net va konvolyutsion neyron tarmoqlar: Qisqaruvchi (enkoder) va kengayuvchi (dekoder) tarmoqlar o'rtasidagi 'skip connection' orqali fazoviy detallarni yuqori semantik qatlamlar bilan bog'laydi [3]. Uning asosida yaratilgan nnU-Net esa avtomatlashtirilgan pipeline evaziga xalqaro tanlovlarda yuqori natijalarni qayd etmoqda [8]. Cheklovi — konvolyutsiya yadrosi faqat lokal qabul maydoniga ega bo'lib, butun tana miqyosidagi global kontekstni to'liq qamrab ololmaydi.

Transformer va gibrid modellar: TransUNet kabi modellar CNN'ning lokal xususiyatlarni ajratish imkoniyatini Transformerlarning ko'p boshli o'z-o'ziga e'tibor (Multi-Head Self-Attention) mexanizmi bilan birlashtiradi [2, 4]. Bu a'zolararo global korrelyatsiyani aniqlashga yordam beradi, biroq hisoblash resurslariga ehtiyojni oshiradi [9].

Fundamental modellar (MedSAM): Keng ko'lamli tibbiy ma'lumotlarda oldindan o'qitilib, interaktiv ko'rsatmalar (prompt: nuqta, quti) orqali nol-namunali (zero-shot) segmentlash imkonini beradi [5, 10]. Ularning asosiy cheklovi — 3D ma'lumotlarda yuqori video xotira talabi hamda noaniq patologiyalarda yolg'on segmentatsiya ehtimolidir.

Asosiy arxitekturalarning blok-sxemasi va ma'lumotlar oqimi

Tibbiy tasvirlarni segmentlashda qo'llaniladigan uchta asosiy paradigmaning ichki tuzilishi va axborot yo'nalishlari 1-rasmda grafik blok-sxema ko'rinishida tasvirlangan:

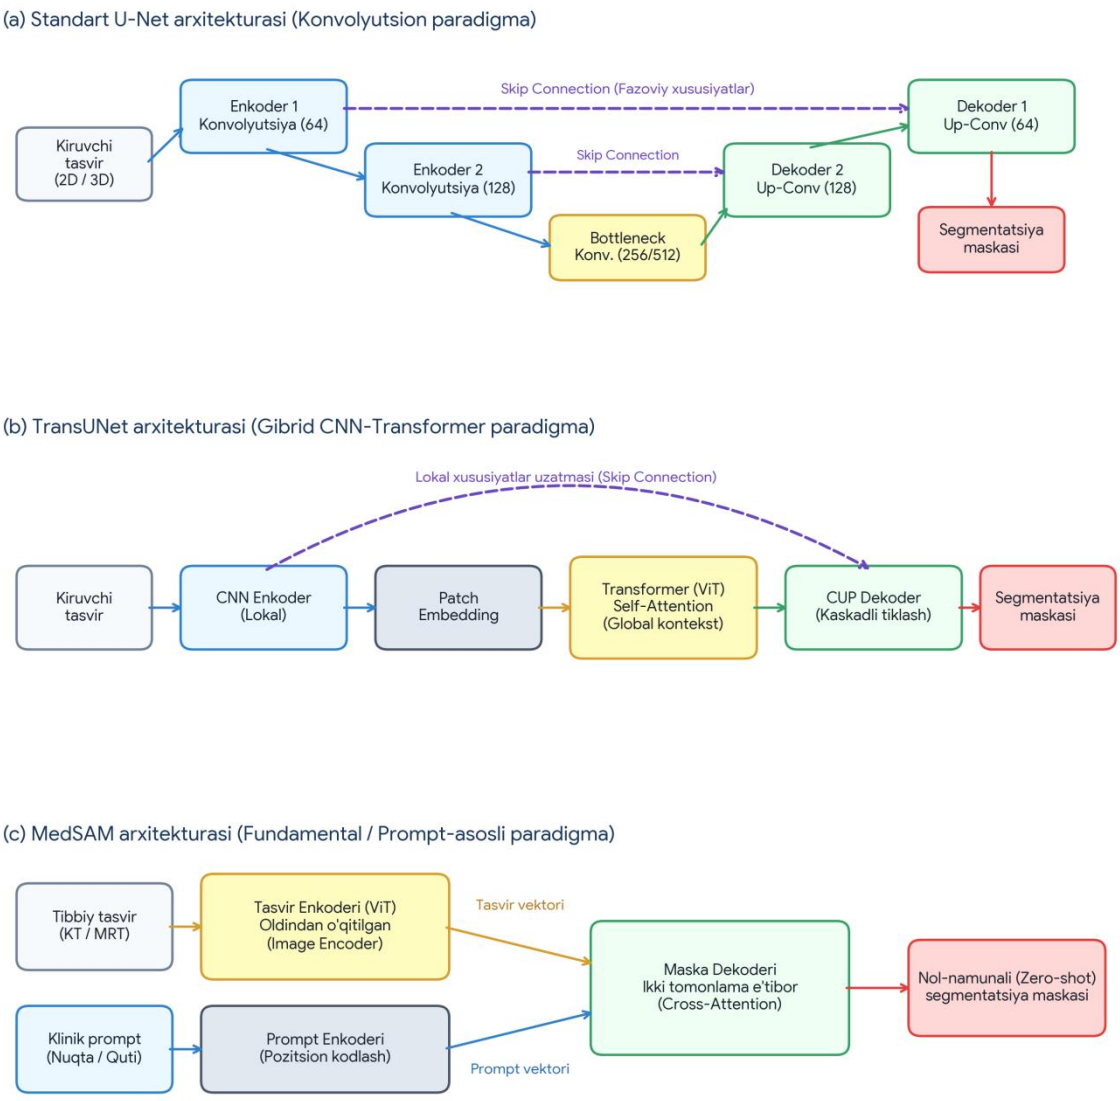

1-rasm. Segmentlashning asosiy arxitekturaviy paradigmalari blok-sxemasi:
(a) Standart U-Net; (b) TransUNet gibridi; (c) MedSAM fundamental modeli.

1-rasmdan ko'rinadiki, U-Net fazoviy aniqlikni sakrash o'tishlari bilan saqlaydi; TransUNet CNN va Transformer qatlamlarini birlashtirib gibrid ifoda beradi; MedSAM esa og'ir tasvir enkoderi va interaktiv prompt dekoderi tandemiga tayanadi.

Baholash metrikalari va ularning matematik ifodalari

Segmentlash sifatini ob'yektiv baholash uchun hududiy ustma-ust tushish va chegaraviy masofa metrikalari birgalikda qo'llaniladi [7]. Bashorat qilingan maska P va etalon maska G bo'lsin:

1. Dice o'xshashlik koeffitsiyenti (DSC):

$$\mathrm{DSC}(P,G) = \frac{2\cdot|P\cap G|}{|P|+|G|} = \frac{2\cdot \mathrm{TP}}{2\cdot \mathrm{TP}+\mathrm{FP}+\mathrm{FN}} \qquad (1)$$

2. Intersection over Union (IoU / Jaccard indeksi):

$$\mathrm{IoU}(P, G) = \frac{|P \cap G|}{|P \cup G|} = \frac{\mathrm{TP}}{\mathrm{TP} + \mathrm{FP} + \mathrm{FN}} \quad (2)$$

Bunda metrikalararo bog'liqlik: DSC = (2 · IoU) / (1 + IoU). Bu yerda TP — to'g'ri musbat, FP — noto'g'ri musbat, FN — noto'g'ri manfiy piksellar soni.

3. Hausdorff masofasi (HD): Chegaralarning geometrik aniqligini o'lchaydi:

$$d_H(X, Y) = \max\left\{ \sup_{x \in X} \inf_{y \in Y} |x - y|, \quad \sup_{y \in Y} \inf_{x \in X} |x - y| \right\} \quad (3)$$

Klinik tajribalarda shovqin ta'sirini minimallashtirish uchun uning 95-persentil modifikatsiyasi (HD95) qo'llaniladi.

Qiyosiy tahlil

1-jadvalda o'rganilgan modellarning texnik parametr va amaliy talablari umumlashtirilgan.

Usul toifasi	Vakil modellar	Lokal detal	Global kontekst	Hisoblash resursi	Annotatsiyaga ehtiyoj
Klassik	Otsu, Level Set	O'rtacha	Past	Juda past (CPU)	Talab qilinmaydi
CNN / U-Net	U-Net, 3D U-Net	Yuqori	Cheklangan	Past / O'rtacha	Yuqori (To'liq nazorat)
Optimallashgan	nnU-Net	Yuqori	O'rtacha	O'rtacha (1 ta GPU)	Yuqori (Avto-pipeline)
Gibrid	TransUNet, UNETR	Yuqori	Yuqori	Yuqori (GPU)	O'rtacha / Yuqori
Fundamental	MedSAM	Yuqori	Juda yuqori	O'ta yuqori (A100)	Minimal (Prompt-asosli)

1-jadval. Segmentlash usullarining qiyosiy xususiyatlari.

Mavjud muammolar va tadqiqot istiqbollari

1. Ma'lumotlar taqchilligi: Radiologlar mehnatini kamaytirish uchun oz sonli namunalar bilan o'qitish (Few-shot) va yarim nazoratli (Semi-Supervised) o'rganish usullarini rivojlantirish.

2. Domen siljishi (Domain Shift): Bir klinikada o'qitilgan model boshqa apparatda aniqlikni yo'qotmasligi uchun Domain Adaptation va federativ o'rganish algoritmlarini joriy etish.

3. Noaniqlikni baholash: Modelning har bir piksel bo'yicha ishonchliligini baholash uchun Monte-Karlo Dropout yoki Bayes neyron tarmoqlari asosida noaniqlik xaritalarini (uncertainty maps) shakllantirish.

4. Matematik modellashtirish integratsiyasi: Chegaralarni silliqlash va dinamikasini boshqarishda chuqur neyron tarmoqlarni differensial tenglamalar apparati (PINN yondashuvlari) bilan gibridlashtirish.

Xulosa

Tibbiy tasvirlarni segmentlashda universal yagona yondashuv mavjud emas: klinik vazifa va resursga qarab optimal arxitekturani tanlash talab etiladi. Kichik ma'lumotlar bazasida barqaror ishlash uchun nnU-Net va ixcham gibrid modellar samarali bo'lsa, keng ko'lamli tahlillarda MedSAM kabi fundamental modellar istiqbollidir. Kelgusi doktorantura tadqiqotlarida modelning umumlashtirish qobiliyatini oshirish, hisoblash resursini optimallash va noaniqlikni baholash mexanizmlarini yaratish tavsiya etiladi.

Foydalanilgan adabiyotlar ro'yxati

1. Rayed, M. E., Islam, S. M. S., et al. (2024). Deep learning for medical image segmentation: State-of-the-art advancements and challenges. Informatics in Medicine Unlocked, 47, 101504.
2. Yao, W., Bai, J., Liao, W., et al. (2024). From CNN to Transformer: A Review of Medical Image Segmentation Models. Journal of Imaging Informatics in Medicine, 37(4), 1529–1547.
3. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In MICCAI 2015 (LNCS, Vol. 9351, pp. 234–241). Springer.
4. Chen, J., Lu, Y., Yu, Q., et al. (2021). TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation. arXiv preprint arXiv:2102.04306.
5. Noh, S., & Lee, B.-D. (2025). A narrative review of foundation models for medical image segmentation. Quantitative Imaging in Medicine and Surgery, 15(6), 5825–5858.
6. Gao, Y., Jiang, Y., Peng, Y., et al. (2025). Medical Image Segmentation: A Comprehensive Review. Tomography, 11(5), Article 52.
7. Taha, A. A., & Hanbury, A. (2015). Metrics for evaluating 3D medical image segmentation. BMC Medical Imaging, 15, Article 29.
8. Isensee, F., Jaeger, P. F., et al. (2021). nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. Nature Methods, 18(2), 203–211.
9. Cao, H., Wang, Y., Chen, J., et al. (2022). Swin-Unet: Pure Transformer for Medical Image Segmentation. In ECCV 2022 Workshops (LNCS, Vol. 13803, pp. 205–218).
10. Ma, J., He, Y., Li, F., et al. (2024). Segment anything in medical images. Nature Communications, 15(1), 654.