

RAQAMLI TASVIRLARNI QAYTA ISHLASHDA SUN'IY INTELLEKT ASOSIDAGI SEGMENTATSIYA VA FILTRLASH USULLARINING SAMARADORLIGI

Rustamova Sevinchoy

sevinchoyrustamova34@gmail.com

Farg'ona davlat texnika universiteti

Annotatsiya

Raqamli tasvirlarni avtomatik qayta ishlashda sun'iy intellekt (SI) texnologiyalari, xususan chuqur o'rganuvchi neyron tarmoqlar, an'anaviy usullarga nisbatan sezilarli ustunlik bermoqda. Ushbu maqolada raqamli tasvirlarni segmentatsiya qilish va filtrlash (shovqinni tozalash, tasvir sifatini oshirish) bo'yicha SI asosidagi yondashuvlarning samaradorligi tahlil qilinadi. Tibbiy tasvirlar misolida konvolyutsion neyron tarmoqlar (CNN) yordamida tasvirlarni aniqlik bilan segmentatsiya qilish hamda generativ raqobatlashuvchi tarmoqlar (GAN) orqali tasvirlarni filtrlay olish imkoniyatlari ko'rib chiqiladi. Chuqur o'rganuvchi modellar yordamida segmentatsiya aniqligi va tasvir sifatini oshirish ko'rsatkichlari tahliliy jadvallar va grafiklar yordamida solishtirilib, an'anaviy metodlardan ustunligi namoyish etiladi. Maqolada keltirilgan natijalar SI asosidagi yondashuvlarning tibbiy diagnostika va boshqa sohalardagi amaliy ahamiyatini tasdiqlaydi.

Kalit so'zlar: Raqamli tasvirlarni qayta ishlash; sun'iy intellekt; chuqur o'rganish; segmentatsiya; filtrlash; tibbiy tasvirlar; CNN; GAN.

Raqamli tasvirlarni qayta ishlash sohasida segmentatsiya (tasvirni mantiqiy qismlarga ajratish) va filtrlash (tasvirdagi shovqinlarni yo'qotish yoki sifatini yaxshilash) asosiy muammolardan hisoblanadi. An'anaviy segmentatsiya usullari (masalan, porog bo'yicha ajratish, chekka aniqlash, regionlarga ajratish) hamda klassik filtrlash usullari (o'rtacha, median filtrlar va h.k.) ma'lum darajada natija bersada, murakkab tuzilishga ega tasvirlarda yoki past sifatli, shovqinli tasvirlarda ularning imkoniyatlari cheklanganligi kuzatiladi. Xususan, tibbiy tasvirlarda kontrastning pastligi, shakllarning notekisligi yoki shovqinning mavjudligi an'anaviy usullar samaradorligini pasaytiradi.

So'nggi yillarda sun'iy intellekt, ayniqsa chuqur o'rganuvchi neyron tarmoqlar jadal rivojlanib, tasvirlarni qayta ishlashda inqilobiy yutuqlarga olib keldi. Chuqur o'rganish yondashuvlari tasvir segmentatsiyasi, obyektlarni aniqlash, tasniflash kabi vazifalarda murakkab xususiyatlarni avtomatik o'rganish orqali yuqori aniqlikka erishmoqda. Tadqiqotlar shuni ko'rsatmoqdaki, chuqur neyron tarmoqlar organlarni segmentatsiya qilish, o'smalarni aniqlash, kasalliklarni klassifikatsiya qilish kabi

masalalarda eng samarali usulga aylandi. Bunga zamonaviy grafik protsessorlar yordamida yuqori hisoblash quvvatlarining mavjudligi va CNN arxitekturalarining qayta ommalashuvi sabab bo'ldi. Sun'iy intellekt asosidagi yondashuvlar tasvirlardagi yashirin qonuniyatlarni aniqlashga va diagnostik jarayonda xatolarni kamaytirishga xizmat qilmoqda.

Ushbu maqolada raqamli (xususan, tibbiy) tasvirlarni qayta ishlash jarayonida sun'iy intellektga asoslangan segmentatsiya va filtrlash usullari tahlil qilinadi. Kirish qismida mavzuning dolzarbligi va muammolar bayoni keltirildi. Asosiy qismda CNN va GAN arxitekturalari yordamida tibbiy tasvirlarni segmentatsiya qilish va shovqinlardan tozalash usullari batafsil ko'rib chiqiladi. Misollar tariqasida ilmiy manbalardagi so'nggi yutuqlar – chuqur o'rganuvchi modellar natijalari an'anaviy usullar bilan solishtirilib, jadvallar va diagrammalar yordamida tahlil etiladi. Xulosa qismida olingan natijalar umumlashtirilib, sun'iy intellekt usullarining afzalliklari va kelgusidagi tadqiqot yo'nalishlari haqida fikrlar bildiriladi.

Sun'iy intellekt yordamida tibbiy tasvirlarni segmentatsiya qilish.

Tasvir segmentatsiyasi – bu tasvirni alohida mintaqalarga yoki obyektlarga ajratish jarayoni bo'lib, u tibbiyotda masalan, o'simta yoki patologik o'zgarishlarning chegaralarini aniqlash uchun muhim ahamiyatga ega. An'anaviy segmentatsiya usullari oddiy qoidalar va tasvir intensivligiga tayangan holda ishlaydi. Misol uchun, porog bo'yicha segmentatsiya ma'lum yorqinlik chegarasidan oshadigan piksel guruhlarini ajratadi, chekka topish algoritmlari esa gradientlarga asoslanadi. Bu usullar tuzilmasi oddiy bo'lgan tasvirlar uchun yaroqli, ammo kontrast yetarli bo'lmagan yoki shovqinli tibbiy tasvirlarda samaradorligi past bo'lishi mumkin.

Chuqur o'rganuvchi konvolyutsion neyron tarmoqlar (CNN) segmentatsiya masalasini sifat jihatidan yangi bosqichga ko'tardi. CNN bir necha qatlamli konvolyutsiya yordamida tasvirdan ko'p darajali xususiyatlarni avtomatik ajratib oladi va har bir piksel uchun tegishli belgi (masalan, “o'sma”, “sog'lom to'qima” va h.k.) ni aniqlaydi. Shu bois, CNN asosidagi modellarga tayangan avtomatik segmentatsiya usullari murakkab anatomik tuzilmalarda ham yuqori aniqlik bermoqda. Ayniqsa, U-Net arxitekturasi kabi to'liq konvolyutsion tarmoqlar biomeditsina sohasida katta muvaffaqiyat qozondi – miya MRI tasvirlarida o'smalarni ajratish, o'pka KT (kompyuter tomografiyasi) tasvirlarida tugunlarni segmentatsiya qilish kabi vazifalarda U-Net va uning takomillashtirilgan variantlari de-fakto standartga aylandi. CNN modeli tasvirning mayda detallarigacha ko'ra oladigan darajada o'rgatilsa, segmentatsiya natijasi hatto mutaxassis-diagnostik natijalariga yaqinlasha oladi. Darhaqiqat, chuqur o'rganuvchi modellar ko'pincha an'anaviy segmentatsiya usullarini ortda qoldiradigan aniqlikka erishmoqda – masalan, ba'zi zamonaviy modellar 95% va undan yuqori Dice koeffitsienti yoki Jaccard indeksi kabi ko'rsatkichlarni qayd etmoqda.


Sun'iy intellekt yondashuvlari nafaqat aniqlik, balki moslashuvchanlik jihatdan ham ustun: CNN modellari o'qitilgan ma'lumotlar orqali turli shakldagi va o'lchamdagi obyektlarni tanishni o'rganadi, bu esa oldindan qoidalar bilan chegaralanmagan ochiq yechim hisoblanadi. Misol uchun, CNN asosida ishlovchi tizimlar rentgen, MRT, KT kabi turli tibbiy tasvirlarda patologiyalarni avtomatik aniqlash va segmentatsiya qilish uchun keng tatbiq qilinmoqda[13]. CNN modelining konvolyutsion qatlamlari tasvirda inson ko'zi ilg'ay olmagan nozik belgilarni ham o'rganishga qodir, buning natijasida u ichki organlar chegaralari, o'sma va shishlar konturlarini aniq ajratib berishi mumkin. Masalan, neyron tarmoq asosidagi bir segmentatsiya modeli miya o'smalarini ajratishda 97,43% Dice aniqlikka erishib, oddiy U-Net modelidan bir necha foiz yuqori natija ko'rsatganligi haqida xabar berilgan. Shu kabi, o'pka KT tasvirlarida LGAN (generativ yondashuvli segmentatsiya tarmog'i) modeli 98,5% gacha dice ko'rsatkichini qayd etib, avvalgi usullardan sezilarli ustunlikka erishgan[16]. Bu misollar chuqur o'rganuvchi tarmoqlar yordamida segmentatsiya aniqligi sezilarli darajada oshganini ko'rsatadi.

Generativ raqobatlashuvchi tarmoqlar (GAN) ham tasvir segmentatsiyasi sohasida qo'llanila boshlandi. GAN arxitekturasida generator va diskriminator neyron tarmoqlar o'zaro "raqobatlashgan" holda o'qitiladi – generator real tasvirdagidek segmentatsiya natijasini yaratishga harakat qilsa, diskriminator uning natijasini haqiqiy belgilangan segmentatsiya bilan farqlashga intiladi. Bunday adversarial (raqobatlashuvchi) o'qitish natijasida segmentatsiya modeli yanada realizmga yaqin natija berishga moslashadi. Ilmiy manbalarda GAN yordamida segmentatsiya aniqligini oshirish bo'yicha ijobiy natijalar kuzatilmoqda. Masalan, SegAN deb nomlangan arxitektura segmentatsiya xaritasini yaxshilash uchun adversarial yondashuvdan foydalangan va an'anaviy CNN modeliga nisbatan samaradorlik oshgan. Shuningdek, SegDGAN modeli (segmentatsiya uchun diskriminatorli GAN) prostata MRI tasvirlari ma'lumotlar to'plamida U-Net, FCN kabi bazaviy modellarni ortda qoldirib, PROMISE12 standarti bo'yicha eng yuqori Dice natijalarini qayd etgan. GAN shuningdek, segmentatsiya uchun o'quv ma'lumotlarini ko'paytirishda ham qo'l keladi – *generativ model* cheklangan ma'lumotlar bazasiga ega tibbiy sohada sun'iy tasvirlar yaratib, ma'lumotlar to'plamini boyitadi[19][20]. Natijada, neyron tarmoq kam ma'lumot bilan ham yaxshi o'rgatilishi va ortiqcha moslashib ketmasligi (overfitting) ta'minlanadi. Mantiqan, bu yondashuvlar tibbiy ko'rik jarayonida nodir uchraydigan kasallik belgilarini ham "ko'rgan" model yaratishga xizmat qiladi.

1-rasmda ko'rinib turganidek, zamonaviy SI modeli (MedSAM) jigar o'smalari, miya o'smalari, ko'krak o'smalari va boshqa turli patologik tuzilmalarni har xil modalitatsiyali tibbiy tasvirlarda muvaffaqiyatli segmentatsiya qilgan. Magenta chiziqlar patologiyani mutaxassis qo'lda belgilagan chegaralarni ifodalasa, sun'iy intellekt modeli natijasi yashil niqob (maska) tarzida ko'rsatilgan. Natijalar MedSAM

modeli bir nechta turdagi tasvirlar bo'yicha ham aniq segmentatsiya qila olishini, ya'ni modelning universalligi va yuqori aniqligini namoyish etmoqda. Bu kabi foundation-model (asosiy model) yondashuvlar kelajakda ko'plab segmentatsiya vazifalarini bitta universal model orqali yechishga xizmat qilishi mumkin.

Shunday qilib, sun'iy intellekt asosidagi segmentatsiya usullari an'anaviy qo'lda segmentatsiya yoki sodda avtomatik metodlardan yuqori aniqlik va ishonchlilikka ega ekanini ko'rmoqdamiz. Ayniqsa, tibbiy tasvirlarda chuqur o'rganuvchi modellar kasalliklarni aniqlash va chegaralashda diagnostika sifatini oshirishga xizmat qilmoqda.



1-rasm. Sun'iy intellekt modeli yordamida turli tibbiy tasvirlarda segmentatsiya natijalari misollari. Magenta rangli konturlar – mutaxassis tomonidan belgilangan chegaralar, yashil (ustma-ust berilgan) sohalar esa MedSAM modelining avtomatik segmentatsiya natijalarini ko'rsatadi.

Albatta, chuqur o'rganuvchi modellar muvaffaqiyati ko'p jihatdan katta hajmdagi belgilangan ma'lumotlar va kuchli hisoblash resurslari mavjudligiga bog'liq ekanini ham ta'kidlash lozim. Shunga qaramay, hozirgi natijalar segmentatsiya jarayonida SI usullari yanglishishlarni kamaytirib, vaqtni tejashi va kelgusida klinik amaliyotda kengroq qo'llanilishi mumkinligini ko'rsatmoqda.

Sun'iy intellekt yordamida tasvirlarni filtrlash va sifatini oshirish

Tasvirlarni filtrlash – bu tasvirdan keraksiz komponentlarni (shovqinlarni) olib tashlash yoki ma'lumotli signallarni kuchaytirish jarayonidir. Tibbiy tasvirlar olish jarayonida turli manbalardan shovqinlar paydo bo'lishi mumkin: masalan, past dozali rentgen yoki KT tasvirlarda kvant shovqini, MRT tasvirlarida qurilma sezgirliги tufayli

keluvchi shovqinlar, ultratovushda esa to'liq interferensiyasi natijasidagi spekl-shovqin. Bu shovqinlar diagnostika uchun muhim bo'lgan mayda detallarni yashirib, tasvir sifatini pasaytiradi. Shu bois, tibbiy amaliyotda tasvirlarni segmentatsiya yoki tahlil qilishdan avval oldindan filtrlash (shovqindan tozalash) muhim qadam hisoblanadi. Tadqiqotlarda ko'rsatilishicha, tasvirdagi shovqinlarni samarali bartaraf etish keyingi avtomatik segmentatsiya natijalarining aniqligini sezilarli yaxshilaydi.

An'anaviy filtrlash usullari – masalan, median filtr, Gauss filtri, bilateral filtr, to'liqincha (wavelet) asosidagi filtrlar – tasvirdagi shovqinni kamaytirishda ko'p yillar qo'llanib kelindi. Biroq, bu usullarning ko'pchiligi qat'iy matematik qoidalar bilan ishlaydi va ba'zan foydali signalni ham susaytirib qo'yishi mumkin. Misol uchun, oddiy silliqalashtiruvchi filtrlar tasvirni xiralashtirishi, qirralarni yo'qotishi mumkin. Sun'iy intellekt yondashuvlari bu sohada ham yangi imkoniyatlar yaratmoqda. CNN va denoising autoencoder kabi chuqur tarmoqlar tasvirni filtrlashni endi oldindan belgilangan filtr shablonlari bilan emas, ma'lumotlardan o'rgangan holda kontekstga mos ravishda bajaradi. Bunda neyron tarmoq shovqinli va shovqinsiz tasvirlar juftliklari bo'yicha o'qitilib, "shovqinni – signalga" mosligini o'rganadi. Natijada, u kiritilgan tasvirning faqat shovqin tarkibini ajratib, olib tashlashga va muhim tuzilma va chekkalarni saqlab qolishga harakat qiladi. Ayniqsa, konvolyutsion autoencoder arxitekturalari va maxsus denoising tarmoqlar (masalan, DnCNN, FFDNet va h.k.) tibbiy tasvirlarni shovqindan tozalashda samarali ekani ko'rsatilgan.

Sun'iy intellekt asosidagi filtrlash usullari aniq miqdoriy ko'rsatkichlar bo'yicha ham ustunlikka ega. Denoising (shovqinni tozalash) jarayonining samaradorligini odatda PSNR (peak signal-to-noise ratio – signal-shovqin cho'qqi nisbati) va SSIM (strukturaviy o'xshashlik indeksi) kabi mezonlar bilan o'lchanadi. Quyidagi 1-jadvalda bitta MRI tibbiy tasviriga turli usullarni qo'llaganda olingan PSNR qiymatlari solishtirilgan.

Jadval 1. MRI tasvirini shovqindan tozalash usullarining PSNR qiymatlari taqqoslanishi.

Denoising usuli	PSNR (dB)
Median filtri	56.06
Gauss filtri	57.06
O'rtacha (Average) filtri	57.21
Bilateral filtri	57.40
Denoising autoencoder (CNN)	68.10

Yuqoridagi natijalardan ko'rish mumkinki, oddiy filtrlar (median, Gauss va h.k.) PSNR ko'rsatkichi bo'yicha bir-biriga yaqin (taxminan 56–57 dB atrofida) natija bergan bo'lsa, neyron tarmoq asosidagi autoencoder modeli sezilarli darajada yuqori – 68.1 dB PSNR –ga erishgan. Bu shuni anglatadiki, sun'iy intellekt modeli bilan tozalangan tasvir eng yuqori sifatga ega bo'lgan (shovqin eng kam, foydali signal

maksimal darajada saqlangan). Tadqiqot mualliflari xulosasiga ko'ra, tibbiy tasvirlarda shovqinni olib tashlashda neyron tarmoq yondashuvi an'anaviy filtrlarga nisbatan ancha yaxshilangan natija beradi. Xususan, yuqorida keltirilgan autoencoder modeli eng tiniq (eng kam shovqinli) MRI tasvirni hosil qilgan va shu tariqa keyingi avtomatik segmentatsiya uchun ham qulay poydevor yaratgan.

Maqolada raqamli tasvirlarni qayta ishlashning ikki muhim yo'nalishi – tasvirni segmentatsiya qilish va filtrlash – bo'yicha sun'iy intellekt (chuqur o'rganuvchi neyron tarmoqlar) yordamida erishilgan yutuqlar tahlil qilindi. Keltirilgan ma'lumotlar asosida sun'iy intellektga asoslangan usullar an'anaviy qoida va filtrlarga asoslangan usullarga nisbatan yuqori samaradorlik ko'rsatishi xulosa qilinadi. Xususan, CNN arxitekturalari tasvirlardan murakkab xususiyatlarni o'rgangan holda organlar, o'smalar va boshqa obyektlarni aniqlashda inson ko'ziga yaqin aniqlikka erishmoqda – segmentatsiya jarayonida xatolar kamayib, vaqt tejarmoqda[8][6]. GAN texnologiyasi esa tasvirni realistik tarzda qayta tiklash, shovqinlarni bartaraf etish va ma'lumotlarni sun'iy boyitishda qo'shimcha ustunlik yaratmoqda. Misollar tahlili shuni ko'rsatdiki, neyron tarmoqlar yordamida MRI kabi tibbiy tasvirlarda shovqin darajasini sezilarli pasaytirish (PSNR oshishi) va segmentatsiya aniqligini oshirish (Dice koeffitsienti kabi metrikalar yaxshilanishi) mumkin ekan.

Adabiyotlar

1. B. Sistaninejhad, H. Rasi, and P. Nayeri, "A review paper about deep learning for medical image analysis," *Computational and Mathematical Methods in Medicine*, vol. 2023, Art. ID 7091301, 2023[4][6]. doi: 10.1155/2023/7091301.
2. Sciutex.com, "CNN vs GAN: A Comparative Analysis in Image Processing for Computer Vision Systems," *Sciutex AI Blog*, 2023[14][50]. [Online]. Available: <https://sciutex.com/cnn-vs-gan-a-comparative-analysis-in-image-processing-for-computer-vision-systems>.
3. W. Ahmad, H. Ali, and S. Azmat, "A new generative adversarial network for medical images super resolution," *Scientific Reports*, vol. 12, no. 1, p. 9533, 2022[39][42]. doi: 10.1038/s41598-022-13658-4.
4. R. Palwankar and R. Bansode, "Medical images denoising using filters and neural network: comparison through implementations," *Journal of Information Systems Engineering and Management*, vol. 10, no. 9s, pp. 501–511, 2025[33][34]. doi: 10.52783/jisem.v10i9s.1249.
5. Y. Xu *et al.*, "Advances in medical image segmentation: a comprehensive review of traditional, deep learning and hybrid approaches," *Bioengineering*, vol. 11, no. 10, Article 1034, 2023[15][17]. doi: 10.3390/bioengineering11101034.
6. R. T. Sadia, "Medical image denoising with CNN," *Becoming Human: Artificial Intelligence Magazine (Medium)*, 20 July 2024[36]. [Online].