

ENDOSKOPIK TASVIRLARDA OSHQOZON YARALARINI ANIQLASH UCHUN SUN'YIY INTELLEKT TEXNOLOGIYALARINING QO'LLANILISHI

Jalgasbayeva Aziza Artiqbaevna

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti magistranti,
Toshkent, O'zbekiston

Sabitova Nazokat Qobuljon qizi

Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti Kompyuter
tizimlari kafedrasida asistenti, Toshkent, O'zbekiston

<https://doi.org/10.5281/zenodo.20269835>

Annotatsiya:

Ushbu tadqiqotda endoskopik tasvirlarda oshqozon yaralarini RetinaNet modeli yordamida avtomatik aniqlash va klassifikatsiya qilish masalasi yoritilgan. Tadqiqot davomida Kvasir, HyperKvasir, GastroVision va Kvasir-Capsule ma'lumotlar bazalaridan foydalanilib, maxsus o'quv tanlanma shakllantirildi. Tasvirlarga dastlabki ishlov berish bosqichida CLAHE, Median Filter va Telea inpainting algoritmlari qo'llanildi hamda augmentatsiya usullari orqali o'quv tanlanma kengaytirildi. RetinaNet modeli endoskopik tasvirlar asosida o'qitilib, uning ishlash samaradorligi Precision, Recall va mAP ko'rsatkichlari asosida baholandi. Tajriba natijalari modelning oshqozon yaralarini aniqlashda yuqori samaradorlikka ega ekanligini ko'rsatdi.

Kalit so'zlar: endoskopik tasvirlar, oshqozon yarasi, sun'iy intellekt, kompyuter ko'rish, RetinaNet, dastlabki ishlov berish, augmentatsiya, Focal Loss, Feature Pyramid Network.

Kirish

Oshqozon-ichak tizimi kasalliklari, xususan oshqozon yarasi, jahon miqyosida keng tarqalgan patologiyalardan biri bo'lib, har yili 968 784 ta yangi saraton holati qayd etiladi va oshqozon saratoni barcha onkologik kasalliklar orasida 5-o'rinni egallaydi [1]. Kasallik ko'pincha dastlabki bosqichlarda aniq klinik belgilarsiz kechadigan bo'lib, erta aniqlanmasa og'ir asoratlarga va onkologik o'zgarishlarga olib kelishi mumkin.

An'anaviy endoskopik diagnostikada shifokorning subyektiv baholashiga kuchli bog'liqlik saqlanib qolmoqda. Ilmiy adabiyotlarda ta'kidlanganidek, standart gastroskopiya amaliyoti davomida oshqozon saraton holatlarining 4.6% dan 14.3% gacha qismi mutaxassislar tomonidan e'tibordan chetda qolishi mumkin [2]. Katta hajmdagi endoskopik ma'lumotlarni qo'lda tahlil qilish ko'p vaqt talab qiladi va inson omiliga bog'liq xatoliklarni yuzaga keltiradi.

Ushbu muammolarni bartaraf etish maqsadida kompyuter ko'rish va chuqur o'rganish algoritmlarini tibbiy tasvirlarda qo'llash yo'nalishi jadal rivojlanmoqda. Mazkur maqolada endoskopik tasvirlarga dastlabki ishlov berish metodologiyasi hamda RetinaNet modeli yordamida oshqozon yaralarini aniqlash tadqiqoti natijalari keltirilgan.

Tadqiqot metodologiyasi

1. O'quv tanlanmasini shakllantirish

Tadqiqot uchun maxsus o'quv tanlanma bir necha ochiq manbalardan yig'ildi: Kvasir, HyperKvasir, GastroVision, Kvasir-Capsule va Roboflow platformasidagi endoskopik tasvir loyihalari. Oshqozon yaralarining rang va morfologik belgilariga asoslanib, tasvirlar to'rtta sinfga ajratildi:


Normal holat - sog'lom oshqozon shilliq qavati;

Faol yara (qizil) - faol yallig'lanish, ayrim hollarda qon ketish belgilari mavjud bo'lgan yara(1-rasm(a));

Bitayotgan yara (sariq/oq) - fibrin qoplama bilan xarakterlanadigan tiklanish bosqichi(1-rasm(b));

Bitgan yara (oq/pushti) - chandiqliq hosil bo'lgan, to'liq bitgan holat(1-rasm(c)).

Roboflow platformasida “ulcers”, “stomach ulcer” va “gastric ulcer” kalit so'zlari orqali qidiruv o'tkazildi va tadqiqot maqsadiga mos loyihalar tanlab olindi. Ortiqcha qora fon mavjud bo'lgan 295 ta tasvir Python va OpenCV yordamida qayta ishlanib, diagnostik hududlar ajratib olindi. Dataset train, validation va test to'plamlariga bo'linib, bounding box annotatsiyalari shakllantirildi.



a)

b)

c)

1-rasm. Oshqozon yaralarining ranglari boyicha tasniflanishi

2. Dastlabki ishlov berish

Endoskopik tasvirlarda ko'p uchraydigan artefaktlar - spekulyar yaltirashlar, pufakchalar, yorug'likning notekis taqsimlanishi va harakatdan kelib chiqadigan xiralanish - diagnostika aniqligiga salbiy ta'sir ko'rsatadi. Bu artefaktlarni bartaraf etish uchun ikki bosqichli shovqindan tozalash algoritmi qo'llanildi.

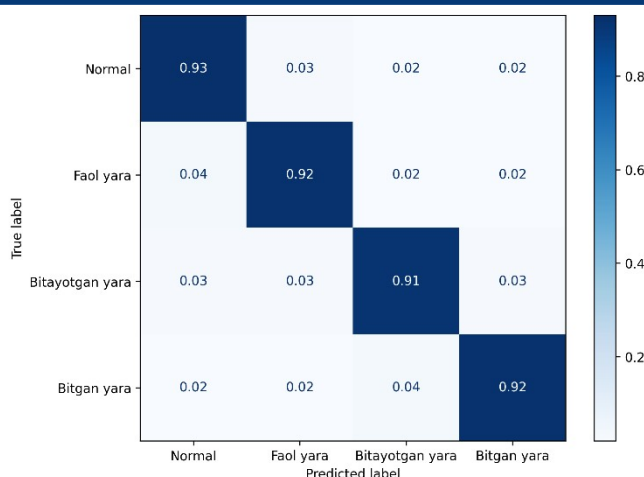
Birinci bosqichda Median filtr yordamida impulsli shovqinlar va kichik pufakchalar yumshatildi. Median filtr tasvir chegaralarini saqlab qolgan holda ortiqcha yorqin nuqtalarni bartaraf etadi. Ikkinchi bosqichda Telea Fast Marching Method (FMM) asosidagi inpainting algoritmi qo'llanilib, aniqlangan pufakcha hududlari atrofdagi to'qima gradientlari va piksel intensivliklariga mos ravishda tiklandi. Pufakchalarni aniqlash jarayonida kulrang tasvirga o'tkazish, ikkilik chegaralash (thresholding), morfologik kengaytirish va Hough aylana transformatsiyasidan foydalanildi.

3. Augmentatsiya

O'quv tanlanma hajmini oshirish va modelning umumlashuv qobiliyatini yaxshilash maqsadida Python dasturlash muhitida Albumentations kutubxonasi yordamida augmentatsiya amalga oshirildi. Quyidagi transformatsiyalar qo'llanildi: gorizontaal akslantirish; belgilangan burchak oralig'ida aylantirish; yorug'lik va kontrastni tasodifiy o'zgartirish; siljitish, masshtablash va qirqish. Har bir asl tasvirdan bir nechta yangi variant hosil qilindi. Augmentatsiya jarayonida oshqozon yarasi joylashgan hududlarning asosiy diagnostik xususiyatlari saqlab qolindi.

4. RetinaNet modeli va o'qitish jarayoni

Oshqozon yaralarini aniqlash va lokalizatsiya qilish uchun RetinaNet modelidan foydalanildi. RetinaNet ResNet asosiy tarmog'i va Feature Pyramid Network (FPN) arxitekturasiga asoslangan bo'lib, classification subnet va box regression subnet dan tashkil topgan. Classification subnet anchor boxlarni sinfga ajratish uchun, box regression subnet esa bounding box koordinatalarini aniqlashtirish uchun xizmat qiladi.



2-rasm. RetinaNet modeli uchun confusion matrix natijasi

FPN arxitekturasi bottom-up va top-down yo'llarini birlashtiradi: bottom-up yo'lda tasvirdan turli masshtabdagi xususiyat xaritalari ajratib olinadi, top-down yo'lda esa yuqori

semantik ma'lumot past darajadagi xususiyat xaritalariga o'tkaziladi. Bu yondashuv modelga kichik o'lchamdagi patologik hududlarni - noaniq chegarali yara zonalarini - yuqori aniqlikda aniqlash imkonini beradi.

Modelning muhim jihatlaridan biri Focal Loss yo'qotish funksiyasidan foydalanilishidir. Klassik cross-entropy funksiyasidan farqli ravishda, Focal Loss oson tasniflangan namunalarning yo'qotishga ta'sirini kamaytiradi va qiyin namunalarga - kichik hamda chegaralari noaniq yara hududlariga - e'tiborni kuchaytiradi. Bu mexanizm endoskopik tasvirlardagi sinflar nomutanosibligi muammosini sezilarli darajada kamaytiradi. Model endoskopik tasvirlardan tashkil topgan maxsus dataset asosida o'qitildi va samaradorligi Precision, Recall, mAP50, mAP50-95 hamda IoU ko'rsatkichlari asosida baholandi.

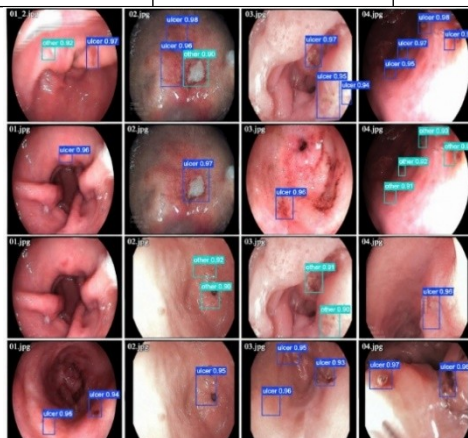
Natijalar

1. Validatsiya natijalari

RetinaNet modeli o'qitish va validatsiya bosqichlaridan so'ng quyidagi ko'rsatkichlarni qayd etdi: Precision - 90.1%, Recall - 89.3%, mAP50 - 86.4%, mAP50-95 - 85.8%. Confusion matrix tahlili shuni ko'rsatdiki, model barcha to'rtta sinf bo'yicha yuqori to'g'ri tasniflash natijalarini ko'rsatdi. Ayniqsa, kichik o'lchamdagi va chegaralari noaniq bo'lgan faol yara hududlarini aniqlashda model barqaror natijalarni qayd etdi.

1-jadval. RetinaNet modelining validatsiya natijalari

Model	Precision	Recall	mAP50	mAP50-95
RetinaNet	90.1 %	89.3 %	86.4 %	85.8 %



3-rasm. RetinaNet modeli yordamida endoskopik tasvirlarda yara hududlarini aniqlash natijasi

2. Klinik sinov natijalari

RetinaNet modeli 128 ta endoskopik tasvir asosida klinik sinovdan o'tkazildi (har bir sinf uchun 32 tadan tasvir). Sinov natijalari quyidagilarni ko'rsatdi: Faol yara - 87.5%, Normal holat - 81.3%, Bitayotgan yara - 78.1%, Bitgan yara - 75.0%. Umumiy o'rtacha aniqlik 80.5% ni tashkil etdi.

Bounding box lokalizatsiyasini baholash uchun IoU (Intersection over Union) ko'rsatkichidan foydalanildi. O'rtacha IoU qiymati 0.58 ni tashkil etdi; $\text{IoU} \geq 0.5$ bo'lgan holatlar umumiy natijalarning 64% ini, $\text{IoU} < 0.3$ bo'lgan holatlar esa 18% ini tashkil qildi. Faol yara kategoriyasida eng yuqori aniqlikka erishilganining asosiy sababi yara hududidagi qizil rang intensivligining boshqa to'qimalarga nisbatan keskin farq qilishi hisoblanadi. Bitgan yara kategoriyasida aniqlik biroz pastroq bo'ldi, chunki chandiqlik to'qimalari va normal shilliq qavat o'rtasida vizual o'xshashlik kuzatilishi mumkin.

Muhokama

Olingan natijalar RetinaNet modelining endoskopik tasvirlarda oshqozon yaralarini aniqlashdagi yuqori samaradorligini tasdiqlaydi. Focal Loss funksiyasi va FPN arxitekturasi birgalikda qo'llanilishi kichik o'lchamdagi va chegaralari noaniq bo'lgan patologik hududlarni aniqlashda modelning barqarorligini ta'minladi. Bu natija Singh va hamkasblari [3] hamda Sobhaninia va Abharian [4] tomonidan o'tkazilgan tadqiqotlardagi xulosalar bilan hamohang.

Dastlabki ishlov berish bosqichida CLAHE va Telea Inpainting kombinatsiyasini qo'llash model aniqligini oshirishda muhim rol o'ynadi. Xususan, CLAHE algoritmi yordamida kontrastni lokal darajada oshirish turli yorug'lik sharoitlarida olingan tasvirlar uchun modelning umumlashuv qobiliyatini yaxshiladi. Albucentations kutubxonasi orqali amalga oshirilgan augmentatsiya o'quv tanlanma xilma-xilligini oshirib, modelning yangi klinik holatlarga moslashuvini ta'minladi.

Tadqiqotning asosiy cheklovlaridan biri o'quv tanlanmadagi oshqozon yaralariga oid tasvirlar sonining yetarli emasligi bo'lib, bu kelajakda yanada keng qamrovli datasetlardan foydalanish zaruratini ko'rsatadi. Bitgan yara va normal holat o'rtasidagi vizual o'xshashlik ayrim noto'g'ri tasniflash holatlarini yuzaga keltirdi. Kelgusida transformer asosidagi arxitekturalar hamda kattaroq annotatsiya qilingan datasetlardan foydalanish modelning umumiy aniqligini yanada oshirishi kutilmoqda.

Xulosa

Ushbu tadqiqotda kompyuter ko'rish usullaridan foydalangan holda endoskopik tasvirlarga dastlabki ishlov berish va RetinaNet modelini qo'llash orqali oshqozon yaralarini aniqlashga mo'ljallangan yondashuv muvaffaqiyatli sinab ko'rildi. Quyidagi asosiy xulosalarga kelindi:

Birinchidan, Kvasir, HyperKvasir, GastroVision, Kvasir-Capsule va Roboflow manbalaridan yig'ilgan, to'rtta klinik sinfni qamrab olgan maxsus o'quv tanlanma shakllantirildi va sifat mezonlari asosida saralandi.

Ikkinchidan, Median Filter va Telea Inpainting kombinatsiyasidan iborat dastlabki ishlov berish endoskopik tasvirlardagi spekyular yaltirashlar, pufakcha artefaktlari va past kontrast muammolarini samarali bartaraf etdi.

Uchinchidan, Albucentations kutubxonasi orqali amalga oshirilgan augmentatsiya o'quv tanlanma hajmini va xilma-xilligini oshirib, modelning turli klinik sharoitlardagi barqarorligini ta'minladi.

To'rtinchidan, RetinaNet modeli endoskopik tasvirlarda oshqozon yaralarini aniqlashda 90.1% Precision va 89.3% Recall ko'rsatkichlari bilan yuqori samaradorlik namoyish etdi; klinik sinovlarda umumiy o'rtacha aniqlik 80.5%, o'rtacha IoU qiymati esa 0.58 ni tashkil etdi. Olingan natijalar RetinaNet modelining kichik o'lchamdagi va chegaralari noaniq bo'lgan patologik hududlarni aniqlashdagi ustunligini hamda ishlab chiqilgan preprocessing pipelinining model aniqligiga ijobiy ta'sirini tasdiqlaydi.

Adabiyotlar, References, Литературы:

1. World Health Organization. GLOBOCAN 2022. Stomach cancer fact sheet. <https://gco.iarc.who.int>
2. Hernanz N., et al. (2019). Characteristics and consequences of missed gastric cancer. *Digestive and Liver Disease*.
3. Singh S.P., Yadla M., et al. (2023). Vision Transformer based gastrointestinal disease classification. *Scientific Reports*, 13, 11562.
4. Sobhaninia Z., Abharian N., et al. (2021). Hybrid deep learning model for gastrointestinal disease classification. *Biomedical Signal Processing and Control*, 68, 102742.
5. Lin T.Y., Goyal P., Girshick R., He K., Dollar P. (2017). Focal Loss for Dense Object Detection. *ICCV*, 2980-2988.
6. He K., Zhang X., Ren S., Sun J. (2016). Deep Residual Learning for Image Recognition. *CVPR*, 770-778.
7. Pogorelov K., et al. (2017). Kvasir: A multi-class image dataset for computer aided gastrointestinal disease detection. *MMSys*, 164-169.
8. Jha D., et al. (2020). Kvasir-SEG: A segmented polyp dataset. *MMM*, 451-462.
9. Gonzalez R.C., Woods R.E. (2018). *Digital Image Processing*. Pearson Education.
10. Qiu Z., et al. (2019). Automatic diagnosis of gastric ulcer using deep convolutional neural networks. *IEEE Access*, 7, 138632-138641.
11. Zhang X., Zhao S., et al. (2022). Deep learning-based ulcer detection in wireless capsule endoscopy. *Computers in Biology and Medicine*, 141, 105134.
12. Litjens G., et al. (2017). A Survey on Deep Learning in Medical Image Analysis. *Medical Image Analysis*, 42, 60-88.