KASALLIKLARNI ERTA ANIQLASH UCHUN TIBBIY DIAGNOSTIKA TASVIRLARINI TAHLIL QILISH ALGORITMI VA DASTURIY TA'MINOTINI ISHLAB CHIQISH

Daminova Muborak Mansurbek qizi
E-mail: mdmuborak1812@gmail.com
https://doi.org/10.5281/zenodo.23339123

Annotatsiya: Mazkur maqolada kasalliklarni erta aniqlash maqsadida tibbiy diagnostika tasvirlarini raqamli qayta ishlash, xususiyatlarini ajratib olish va sun'iy intellekt yordamida tahlil qilish algoritmi hamda dasturiy ta'minotini ishlab chiqish masalasi ko'rib chiqiladi. Tadqiqotning asosiy maqsadi rentgen, kompyuter tomografiyasi, magnit-rezonans tomografiya va boshqa tibbiy tasvirlardan patologik o'zgarishlarning ehtimoliy belgilarini aniqlashga ko'maklashuvchi avtomatlashtirilgan tizimning konseptual arxitekturasini ishlab chiqishdan iborat. Taklif etilayotgan yondashuv tasvirlarni dastlabki qayta ishlash, tasvir sifatini nazorat qilish, xususiyatlarni ajratish, chuqur o'qitish asosida tasniflash, shubhali hududlarni belgilash va natijalarni vizual taqdim etish bosqichlarini qamrab oladi. Algoritmning asosiy modeli sifatida konvolyutsion neyron tarmoq (CNN), uning imkoniyatlarini kengaytirish uchun esa transfer learning va izohlanuvchi sun'iy intellekt usullaridan foydalanish taklif qilinadi. Model samaradorligini baholash uchun sezgirlik, spetsifiklik, aniqlik, F1-ko'rsatkich, ROC-AUC va kalibrlash kabi mezonlar belgilanadi. Shuningdek, ma'lumotlar maxfiyligi, klinik xavfsizlik, modelning turli bemor guruhlarida ishlash qobiliyati va shifokor nazorati masalalari tahlil qilinadi. Taklif etilgan tizim shifokorning klinik qarorini almashtirishga emas, balki diagnostik jarayonni qo'llab-quvvatlashga mo'ljallangan.

Kalit so'zlar: tibbiy diagnostika, sun'iy intellekt, tibbiy tasvirlar, chuqur o'qitish, konvolyutsion neyron tarmoq, tasvirlarni segmentatsiyalash, patologik o'zgarishlar, kompyuter ko'rishi, erta diagnostika, dasturiy ta'minot.

Аннотация: В данной статье рассматривается разработка алгоритма и программного обеспечения для цифровой обработки медицинских диагностических изображений, извлечения их признаков и анализа с использованием искусственного интеллекта с целью раннего выявления заболеваний. Основная цель исследования заключается в разработке концептуальной архитектуры автоматизированной системы, предназначенной для выявления вероятных признаков патологических изменений на основе рентгеновских снимков, изображений компьютерной томографии, магнитно-резонансной томографии и других медицинских изображений. Предлагаемый подход охватывает этапы предварительной обработки изображений, контроля их качества, извлечения признаков, классификации на основе глубокого обучения, выделения подозрительных областей и визуального представления результатов. В качестве основной модели алгоритма предлагается использовать свёрточную нейронную сеть (CNN), а для расширения её возможностей — методы переноса обучения (transfer learning) и объяснимого искусственного интеллекта. Для оценки эффективности модели определены такие критерии, как чувствительность, специфичность, точность, F1-мера, ROC-AUC и калибровка. Кроме того, анализируются вопросы конфиденциальности данных, клинической безопасности, способности модели обеспечивать надёжную работу в различных группах пациентов, а также необходимости врачебного контроля.

Предлагаемая система предназначена не для замены клинических решений врача, а для поддержки диагностического процесса.

Ключевые слова: медицинская диагностика, искусственный интеллект, медицинские изображения, глубокое обучение, свёрточная нейронная сеть, сегментация изображений, патологические изменения, компьютерное зрение, ранняя диагностика, программное обеспечение.

Abstract: This article addresses the development of an algorithm and software system for analyzing medical diagnostic images to support early disease detection. The main objective is to design an automated framework capable of processing medical images, extracting relevant features, identifying suspicious regions, and estimating the probability of predefined abnormalities. The proposed architecture includes image acquisition, quality control, preprocessing, deep-learning-based classification, optional lesion segmentation, explainability, and visualization of results. Convolutional neural networks (CNNs), transfer learning, and explainable artificial intelligence methods are considered as the core technical approaches. The performance evaluation framework includes sensitivity, specificity, accuracy, F1-score, ROC-AUC, and probability calibration. Particular attention is given to patient-level data separation, external testing, data privacy, clinical safety, and the limitations of automated decision support. The proposed system is intended to assist healthcare professionals rather than replace clinical judgment. Its practical effectiveness must be established through experiments using appropriately annotated datasets and independent clinical evaluation.

Keywords: medical imaging, artificial intelligence, deep learning, convolutional neural network, early diagnosis, image processing, lesion segmentation, explainable AI, clinical decision support.

Kirish. Kasalliklarni erta aniqlash zamonaviy tibbiyotning muhim vazifalaridan biri hisoblanadi. Ko‘plab patologik jarayonlarning dastlabki bosqichlarida klinik belgilar yaqqol namoyon bo‘lmasligi mumkin. Shu sababli rentgenografiya, kompyuter tomografiyasi (KT), magnit-rezonans tomografiya (MRT), ultratovush tekshiruvi va boshqa diagnostik usullar orqali olingan tasvirlarni to‘g‘ri tahlil qilish kasalliklarni o‘z vaqtida aniqlash va keyingi tekshiruvlarga ehtiyojni baholashda muhim ahamiyat kasb etadi.

Tibbiy tasvirlar katta hajmdagi vizual axborotni o‘z ichiga oladi. Ularni mutaxassis tomonidan tahlil qilish tajriba, vaqt va diqqatni talab qiladi. Tasvirlarning sifati, patologik o‘zgarishlarning kichik o‘lchami, anatomik tuzilmalarning murakkabligi hamda turli kasalliklarning bir-biriga o‘xshash belgilari diagnostik jarayonni murakkablashtiradi. Bundan tashqari, tibbiy tasvirlar turli qurilmalar, protokollar va klinik muassasalarda olinishi sababli ularning kontrasti, aniqligi va statistik xususiyatlari farq qilishi mumkin.

Raqamli tasvirlarni qayta ishlash va mashinaviy o‘qitish usullarining rivojlanishi diagnostik ma’lumotlarni avtomatik tahlil qilish uchun yangi imkoniyatlar yaratmoqda. Ayniqsa, chuqur o‘qitish algoritmlari tasvirlardagi murakkab fazoviy belgilarni o‘rganish, obyektlarni tasniflash va patologik hududlarni ajratib ko‘rsatishda qo‘llaniladi. Biroq yuqori algoritmik ko‘rsatkichning o‘zi tizimning klinik jihatdan xavfsizligini kafolatlamaydi. Model mustaqil ma’lumotlarda tekshirilishi, xatolarining turlari tahlil qilinishi va real klinik sharoitda shifokor nazorati ostida baholanishi kerak.

Tibbiy tasvirlarni sun’iy intellekt yordamida o‘rganish bo‘yicha ilmiy ishlarni tayyorlashda CLAIM 2024 tavsiyalari tadqiqot dizayni, ma’lumotlar manbasi, o‘qitish va sinov to‘plamlari, baholash mezonlari hamda cheklovlarni aniq bayon etishga alohida e’tibor qaratadi [1]. Jahon sog‘liqni saqlash tashkiloti esa sog‘liqni saqlashda sun’iy intellektdan foydalanishda inson huquqlari, xavfsizlik, shaffoflik va javobgarlik tamoyillarini ta’minlash zarurligini ta’kidlaydi [2].

Shu nuqtayi nazardan, tibbiy diagnostika tasvirlarini tahlil qilishning yagona algoritmik ketma-ketligi va undan foydalanishga mo‘ljallangan dasturiy ta’minotni ishlab chiqish dolzarb ilmiy-amaliy vazifa hisoblanadi.

Muammoning o‘rganilganlik darajasi. Tibbiy tasvirlarni avtomatik tahlil qilishda an’anaviy raqamli tasvirlarni qayta ishlash, klassik mashinaviy o‘qitish va chuqur neyron tarmoqlardan foydalaniladi. An’anaviy yondashuvlarda tasvir kontrastini yaxshilash, shovqinni kamaytirish, chegaralarni aniqlash va teksturaviy xususiyatlarni hisoblash kabi operatsiyalar bajariladi. Keyingi bosqichda ajratilgan xususiyatlar tasniflagichga uzatiladi.

Chuqur o‘qitish yondashuvlarida esa xususiyatlarni ajratish va tasniflash jarayonlari birgalikda o‘rganilishi mumkin. CNN arxitekturalari mahalliy tekstura, kontur va shakl belgilarini bosqichma-bosqich o‘zlashtiradi. U-Net kabi encoder–decoder arxitekturalari tasvirning har bir pikseliga tegishli sinfni belgilash, ya’ni segmentatsiyalash vazifalarida qo‘llaniladi. Transfer learning usuli oldindan o‘qitilgan model parametrlaridan foydalanish orqali cheklangan hajmdagi belgilangan ma’lumotlar sharoitida o‘qitish jarayonini soddalashtirishi mumkin.

Shunga qaramay, turli klinikalarda olingan tasvirlarning farqi, sinflar nomutanosibligi, noto‘g‘ri belgilangan ma’lumotlar, modelning o‘qitish to‘plamiga ortiqcha moslashishi va natijalarni izohlashdagi qiyinchiliklar dolzarb muammolar bo‘lib qolmoqda. Shuning uchun taklif etilayotgan yechim faqat tasniflash algoritmini emas, balki ma’lumotlar sifatini tekshirish, mustaqil baholash, natijalarni tushuntirish va xavfsiz foydalanish mexanizmlarini ham qamrab olishi lozim.

Tadqiqotning maqsadi va vazifalari

Tadqiqotning maqsadi — tibbiy diagnostika tasvirlarini raqamli qayta ishlash, patologik o‘zgarishlarning ehtimoliy belgilarini aniqlash va natijalarni foydalanuvchiga tushunarli shaklda taqdim etishga mo‘ljallangan algoritm hamda dasturiy ta’minot arxitekturasini ishlab chiqish.

Ushbu maqsadga erishish uchun quyidagi vazifalar belgilandi:

1. Tibbiy diagnostika tasvirlarini qayta ishlashning mavjud usullarini tahlil qilish.
2. Tasvirlarni qabul qilish, formatini tekshirish va sifat nazoratidan o‘tkazish bosqichlarini ishlab chiqish.
3. Tasvirlarni normallashtirish va shovqinni kamaytirish algoritmlarini belgilash.
4. Chuqur o‘qitish asosida tasvirlarni tasniflash va zarur hollarda patologik hududlarni segmentatsiyalash modelini tanlash.
5. Natijalarni vizual izohlash va ehtimollik ko‘rinishida taqdim etish mexanizmini ishlab chiqish.
6. Algoritm samaradorligini baholash uchun statistik mezonlar va tajriba metodologiyasini belgilash.
7. Dasturiy ta’minotning maxfiylik, xavfsizlik va klinik nazorat talablarini aniqlash.

Tadqiqot obyekti — tibbiy diagnostika tasvirlarini raqamli qayta ishlash va tahlil qilish jarayoni.

Tadqiqot predmeti — tibbiy tasvirlardan diagnostik ahamiyatga ega xususiyatlarni ajratib olish, ularni tasniflash va tahlil natijalarini taqdim etish algoritmlari hamda dasturiy vositalari.

Tadqiqot gipotezasi shundan iboratki, tasvir sifati nazorati, standartlashtirilgan dastlabki qayta ishlash, chuqur o‘qitish va natijalarni izohlash bosqichlarini birlashtirgan tizim diagnostik tahlilni avtomatlashtirishga ko‘maklashishi mumkin. Ushbu gipotezaning tasdiqlanishi eksperimental tekshiruv natijalariga bog‘liq.

Materiallar va usullar. Tadqiqot algoritmni loyihalash, dasturiy arxitekturani shakllantirish va uni tajribada baholash metodologiyasiga asoslanadi. Tadqiqotning amaliy bosqichida tibbiy tasvirlar to‘plami tanlanishi, har bir tasvir uchun klinik jihatdan ishonchli etalon belgi shakllantirilishi va ma’lumotlar mustaqil to‘plamlarga ajratilishi kerak.

Birinchi bosqichda diagnostik vazifa aniq belgilanadi. Masalan, tizim ko‘krak qafasi rentgen tasvirlarida muayyan patologik o‘zgarishlarni tasniflashga yoki KT tasvirlarida shubhali hududlarni segmentatsiyalashga mo‘ljallanishi mumkin. Turli anatomik sohalar va kasalliklarni bir vaqtning o‘zida aniqlashga urinishdan ko‘ra, dastlab bitta klinik vazifani tanlash modelni o‘qitish va natijalarni ishonchli baholashni osonlashtiradi.

Ikkinchi bosqichda tasvirlar ma’lumotlar bazasidan olinadi. Ochiq ma’lumotlar to‘plamlaridan foydalanilganda ularning litsenziyasi, belgilash usuli, bemorlar tarkibi, tasvir olish protokoli va cheklovlari tekshiriladi. Klinik ma’lumotlardan foydalanishda tegishli ruxsatlar, etik talablar va shaxsiy ma’lumotlarni himoya qilish choralariga rioya etiladi.

Uchinchi bosqichda tasvirlar dastlabki qayta ishlanadi va modelga mos shaklga keltiriladi. To‘rtinchi bosqichda CNN asosidagi tasniflash modeli o‘qitiladi. Agar patologiyaning aniq joylashuvini ko‘rsatish talab qilinsa, segmentatsiyalash modeli ham qo‘llanadi. Yakuniy bosqichda tizimning natijalari mustaqil test ma’lumotlarida baholanadi.

Ma’lumotlar to‘plamini shakllantirish. Tizim samaradorligi foydalaniladigan ma’lumotlar to‘plamining hajmi va sifati bilan chambarchas bog‘liq. To‘plamda patologiya aniqlangan hamda patologiya aniqlanmagan holatlar, turli yosh guruhlari, jinslar, tasvir olish qurilmalari va klinik sharoitlar imkon qadar muvozanatli ifodalanishi kerak.

Har bir tasvir uchun quyidagi ma’lumotlar qayd etilishi maqsadga muvofiq:

- anonimlashtirilgan tasvir identifikatori;
- tasvir modaliteti va olish protokoli;
- diagnostik sinf yoki klinik etalon belgi;
- mavjud bo‘lsa, patologik hududning segmentatsiya niqobi;
- tasvir sifati va texnik yaroqlilik holati;
- ma’lumotlar manbasi va foydalanish shartlari.

Etalon belgilar tegishli klinik mutaxassis xulosasi, zarur holatlarda esa qo‘shimcha tekshiruvlar yoki klinik kuzatuvlar bilan asoslanishi lozim. Tasvirning o‘zidan olingan taxminiy belgi mustaqil klinik etalon o‘rnini avtomatik ravishda bosa olmaydi.

Ma’lumotlarni o‘qitish, sozlash va sinov to‘plamlariga ajratishda bemor darajasidagi ajratish tamoyili qo‘llanadi. Bitta bemorga tegishli bir nechta tasvir turli to‘plamlarga tushib qolsa, model ilgari ko‘rgan bemor tasvirlariga ortiqcha moslashib, natijalar sun’iy ravishda yuqori ko‘rinishi mumkin. Shu sababli bir bemorga tegishli tasvirlar faqat bitta to‘plamda saqlanishi kerak.

Taklif etilayotgan dastlabki nisbat quyidagicha:

- O‘qitish to‘plami — 70%.
- Validatsiya to‘plami — 15%.
- Ichki test to‘plami — 15%.

Bu nisbat qat’iy qoida emas. Ma’lumotlar hajmi, sinflar soni va bemorlar tarkibiga qarab o‘zgartirilishi mumkin. Imkoniyat mavjud bo‘lsa, boshqa klinik muassasadan olingan mustaqil tashqi test to‘plamida qo‘shimcha baholash o‘tkaziladi.

Tasvirlarni dastlabki qayta ishlash. Dastlabki qayta ishlash bosqichining maqsadi tasvirlardagi texnik farqlarni kamaytirish, model uchun mos kirish formatini shakllantirish va diagnostik ahamiyatga ega ma’lumotlarni saqlab qolishdan iborat.

1. Tasvirni yuklash va formatini tekshirish. Dastur PNG, JPEG yoki TIFF kabi umumiy formatlarni, zarur klinik sharoitda esa DICOM formatini qabul qilishi mumkin. DICOM tasvirlari bilan ishlaganda piksel qiymatlari, tasvir orientatsiyasi, fotometrik interpretatsiya va zarur bo‘lsa, modallikka xos transformatsiyalar hisobga olinadi.

2. Tasvir sifatini nazorat qilish. Tasvirning bo‘shligi, noto‘g‘ri o‘qilishi, keskin xiralashishi, haddan tashqari qorong‘i yoki yorqinligi hamda diagnostik jihatdan yaroqsiz artefaktlar tekshiriladi. Sifatsiz tasvirni avtomatik ravishda normal yoki patologik deb tasniflash o‘rniga, tizim uni qayta tekshirish uchun foydalanuvchiga qaytarishi kerak.

3. O‘lchamni standartlashtirish. Tasvirlar tanlangan model talablariga muvofiq qayta o‘lchamlanadi. Biroq juda kichik o‘lchamga keltirish kichik patologik belgilarni yo‘qotishi mumkin. Shu sababli o‘lcham modalitet, anatomik soha va diagnostik vazifaga qarab belgilanadi.

4. Intensivlikni normallashtirish. Tasvir qiymatlari tanlangan model uchun mos diapazonga keltiriladi. Masalan, oddiy kulrang tasvirlar uchun piksel qiymatlarini [0,1] diapazoniga o‘tkazish mumkin. KT tasvirlarida esa tegishli Hounsfield birliklari va klinik vazifaga mos oynalash usullari qo‘llanishi mumkin. Barcha modalitetlarga bir xil normallashtirish usulini qo‘llash to‘g‘ri bo‘lmasligi mumkin.

5. Shovqinni kamaytirish. Median filtri yoki boshqa mos filtrlash usullari tasvir shovqinini kamaytirishda qo‘llanishi mumkin. Filtrlash patologiyaning chegaralari va mayda tuzilmalarga zarar yetkazmasligi kerak. Shuning uchun qayta ishlashdan oldingi va keyingi tasvirlar sifat jihatidan taqqoslanadi.

6. Ma’lumotlarni kengaytirish. O‘qitish jarayonida kichik burchakli aylantirish, yengil siljitish yoki boshqa anatomik jihatdan asoslangan transformatsiyalar ishlatilishi mumkin. Bunda tasvirga tegishli klinik ma’noni o‘zgartiradigan yoki patologiya belgilarini yo‘qotadigan transformatsiyalardan foydalanilmaydi.

Taklif etilayotgan algoritm. Tizimning asosiy algoritmi ketma-ket bajariladigan modullardan tashkil topadi.

1-algoritm. Tibbiy diagnostika tasvirlarini avtomatlashtirilgan tahlil qilish

Kirish: tibbiy tasvir I, o‘qitilgan model M va tasvir modalitetiga mos qayta ishlash parametrlari.

Chiqish: tasvir sifati holati, ehtimoliy diagnostik sinf, model ishonchliligi haqidagi ma’lumot va zarur bo‘lsa, shubhali hudud xaritasi.

1. Tasvirni yuklash va uning formatini aniqlash.
2. Fayl yaxlitligi va tasvirning texnik yaroqliligini tekshirish.
3. Tasvirni tegishli modalitet uchun standartlashtirish.
4. Tasvirni normallashtirish va zarur hollarda shovqinni kamaytirish.
5. Tayyorlangan tasvirni CNN modeliga uzatish.
6. Har bir diagnostik sinf uchun model chiqish qiymatlarini hisoblash.
7. Zarur vazifalarda segmentatsiyalash modelini ishga tushirish.
8. Natijani izohlash uchun e’tibor xaritasi yoki boshqa mos vizualizatsiyani shakllantirish.
9. Natijani belgilangan qaror chegarasi va sifat mezonlari asosida tekshirish.
10. Natijani “shubhali belgi mavjud”, “model patologik belgi aniqlamadi” yoki “qo‘shimcha tekshiruv zarur” kabi ehtiyotkor shaklda taqdim etish.
11. Tasvir identifikatori, model versiyasi va tahlil vaqtini maxfiylik talablariga muvofiq qayd etish.

Agar kiruvchi tasvir sifat talablariga javob bermasa yoki tizim uni ishonchli tahlil qila olmasa, algoritm majburiy ravishda tashxis chiqarishi kerak emas. Bunday holatda “tahlil uchun yaroqsiz” yoki “natija noaniq” xabari chiqariladi.

Chuqur o‘qitish modelini tanlash. Tasvirlarni tasniflash uchun konvolyutsion neyron tarmoqdan foydalanish taklif etiladi. CNN tasvirning boshlang‘ich qatlamlarida oddiy chegaralar va teksturalarni, chuqur qatlamlarida esa murakkabroq fazoviy belgilarni o‘rganishi mumkin.

Modelning umumiy matematik ifodasi quyidagicha:

$\hat{y} = f\theta(I)$

bu yerda I — dastlabki qayta ishlangan tasvir, fθ — o‘rganiladigan parametrlar θ ga ega neyron tarmoq, ŷ esa modelning chiqish natijasidir.

Ko‘p sinfli tasniflash vazifasida Softmax funksiyasidan foydalanish mumkin:

$p_k = e^{zk} / \Sigma_j e^{zj}$

bu yerda z_k — k-sinf uchun modelning chiqish qiymati, K — sinflar soni, p_k esa model hisoblagan ehtimollik qiymati. Ushbu qiymatlar modelning o‘rganilgan ma’lumotlar asosidagi bahosini ifodalaydi. Ularni klinik kasallik ehtimolining mutlaq yoki kalibrlangan bahosi deb qabul qilishdan oldin alohida tekshiruv talab etiladi.

Modelni o‘qitishda ko‘p sinfli tasniflash uchun quyidagi kross-entropiya yo‘qotish funksiyasidan foydalanish mumkin:

$L = -\Sigma_k y_k \log(p_k)$

bu yerda y_k — etalon sinfning indikator qiymati, p_k esa modelning tegishli sinfga bergan ehtimollik bahosi.

Ma’lumotlar hajmi cheklangan holatlarda transfer learning yondashuvi ko‘rib chiqiladi. Bunda oldindan o‘qitilgan modelning dastlabki qatlamlari saqlanib, oxirgi qatlamlari tanlangan diagnostik vazifaga moslashtiriladi. Yakuniy model arxitekturasi ma’lumotlar to‘plami, tasvir turi, apparat resurslari va klinik vazifaga muvofiq tanlanishi kerak.

Patologik hududlarni segmentatsiyalash. Faqat tasniflash natijasi patologik o‘zgarish tasvirning qaysi qismida joylashganini ko‘rsatmasligi mumkin. Shu sababli zarur hollarda segmentatsiyalash moduli qo‘shiladi.

Segmentatsiyalashda U-Net kabi encoder–decoder arxitekturasi qo‘llanishi mumkin. Encoder tasvirdan ko‘p darajali xususiyatlarni ajratadi, decoder esa ularni fazoviy aniqlikni tiklash uchun birlashtiradi. Natijada har bir piksel uchun patologik hududga tegishlilik bahosi hosil qilinadi.

Segmentatsiya xaritasi quyidagi ko‘rinishda ifodalanishi mumkin:

$S(x,y) = P(\text{patologik hudud} \mid I, x, y)$

Bu yerda S(x,y) — tasvirning (x,y) koordinatasidagi piksel uchun model bahosi. Belgilangan chegaraga ko‘ra xarita ikkilik niqobga aylantirilishi mumkin.

Segmentatsiyalash modeli faqat tegishli etalon niqoblar mavjud bo‘lganda ishonchli tarzda o‘qitilishi mumkin. Aks holda, Grad-CAM kabi vizual izohlash usullari yordamida model qaroriga ta’sir qilgan hududlar ko‘rsatilishi mumkin. Biroq bunday xaritalar patologiyaning aniq anatomik chegarasini yoki sababiy bog‘lanishni isbotlamaydi.

Dasturiy ta’minot arxitekturasi

Taklif etilayotgan dastur modulli arxitekturaga asoslanadi. Bu yondashuv tasvirlarni yuklash, qayta ishlash, modelni ishga tushirish, natijalarni ko‘rsatish va ma’lumotlarni boshqarish funksiyalarini bir-biridan ajratishga imkon beradi.

Dasturiy yechim quyidagi modullardan tashkil topadi:

1. Foydalanuvchi interfeysi: tasvirni yuklash, tahlilni boshlash va natijalarni ko‘rish.
2. Ma’lumotlarni qabul qilish moduli: formatni tekshirish, anonimlashtirish va texnik nazorat.

3. Tasvirlarni qayta ishlash moduli: normallashtirish, o‘lchamni moslashtirish va shovqinni kamaytirish.

4. Sun’iy intellekt moduli: tasniflash, ehtimollik baholarini hisoblash va zarur hollarda segmentatsiyalash.

5. Izohlash moduli: shubhali hududlarni yoki model e’tibor xaritasini vizual ko‘rsatish.

6. Hisobot moduli: natija, model versiyasi, tahlil holati va texnik ogohlantirishlarni chiqarish.

7. Xavfsizlik moduli: foydalanuvchi huquqlarini boshqarish, maxfiy ma’lumotlarni himoyalash va audit qaydlarini yuritish.

Dasturiy prototipni Python dasturlash tilida ishlab chiqish mumkin. Tasvirlarni qayta ishlash uchun OpenCV yoki scikit-image, neyron tarmoqlar uchun PyTorch yoki TensorFlow, foydalanuvchi interfeysi uchun Streamlit yoki FastAPI asosidagi veb-interfeysdan foydalanish mumkin. DICOM ma’lumotlarini qayta ishlashda tegishli tibbiy tasvir kutubxonalari tanlanadi.

Mazkur vositalar ishlab chiqish uchun tavsiya etilayotgan texnologik variantlardir; ularning tanlanishi dasturiy prototip talablari va mavjud hisoblash resurslariga bog‘liq.

Samaradorlikni baholash mezonlari

Modelni baholashda bitta ko‘rsatkich bilan cheklanib qolish maqsadga muvofiq emas. Ayniqsa, kasallik aniqlangan holatlar umumiy ma’lumotlarning kichik qismini tashkil qilganda, umumiy aniqlik noto‘g‘ri taassurot berishi mumkin.

Aniqlik (Accuracy):

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN)$$

Sezgirlik (Sensitivity):

$$\text{Sensitivity} = TP / (TP + FN)$$

Spetsifiklik (Specificity):

$$\text{Specificity} = TN / (TN + FP)$$

Musbat bashorat qiymati (Precision):

$$\text{Precision} = TP / (TP + FP)$$

F1-ko‘rsatkich:

$$F1 = 2 \times (\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall})$$

Bu formulalarda TP — to‘g‘ri aniqlangan patologik holatlar, TN — to‘g‘ri aniqlangan patologiyasiz holatlar, FP — noto‘g‘ri musbat natijalar va FN — aniqlanmay qolgan patologik holatlar sonidir.

ROC-AUC modeli turli qaror chegaralarida musbat va manfiy sinflarni farqlash qobiliyatini umumlashtirib baholashga yordam beradi. Shu bilan birga, ehtimollik baholarining kalibrlanishi, ishonch intervallari va turli bemor guruhlaridagi ko‘rsatkichlar ham o‘rganilishi kerak.

Kasalliklarni erta aniqlash vazifasida sezgirlik muhim bo‘lishi mumkin, chunki soxta manfiy natijalar patologiyaning o‘z vaqtida aniqlanmasligiga olib kelishi ehtimoli mavjud. Biroq soxta musbat natijalar ham ortiqcha tekshiruvlar va bemor xavotirini keltirib chiqarishi mumkin. Shuning uchun qaror chegarasi klinik vazifa, xavf darajasi va mutaxassislar tavsiyalari asosida tanlanadi.

Natijalar. Tadqiqotning ushbu bosqichida tibbiy diagnostika tasvirlarini tahlil qilish uchun algoritm va dasturiy ta’minotning konseptual modeli shakllantirildi. Taklif etilgan yechimning asosiy natijasi diagnostik tasvirni qabul qilishdan boshlab, uni qayta ishlash, model yordamida tahlil qilish va natijani foydalanuvchiga yetkazishgacha bo‘lgan amallarni yagona jarayonga birlashtirishdan iborat.

Tizimning kutilayotgan funksional imkoniyatlari quyidagilarni qamrab oladi:

- tibbiy tasvirlarni yuklash va texnik yaroqliligini tekshirish;
- tasvirlarni belgilangan format va o‘lchamga keltirish;

- sun’iy intellekt modeli yordamida tasvirlarni tasniflash;
- zarur hollarda shubhali hududlarni segmentatsiyalash;
- modelning qaroriga ta’sir qilgan hududlarni vizual ko‘rsatish;
- tahlil natijalarini strukturaviy hisobot shaklida chiqarish;
- tahlil qilish mumkin bo‘lmagan tasvirlar uchun ogohlantirish berish;
- tahlil natijalarini shifokor tomonidan qayta ko‘rib chiqish imkoniyatini ta’minlash.

Mazkur imkoniyatlar algoritmning funksional loyihasi sifatida qaraladi. Ularning amalda to‘liq ishlashi dasturiy prototipni yaratish va funksional sinovlardan o‘tkazish orqali tasdiqlanishi kerak.

Algoritmning ishlash ketma-ketligi

Taklif etilayotgan tizimda tibbiy tasvirlar quyidagi ketma-ketlik asosida tahlil qilinadi:

1-bosqich — tasvirni qabul qilish. Foydalanuvchi tibbiy tasvirni dasturga yuklaydi. Tizim faylning o‘qilishi, formatning qo‘llab-quvvatlanishi va texnik yaroqliligini tekshiradi.

2-bosqich — dastlabki qayta ishlash. Tasvir modalitetga mos ravishda standartlashtiriladi, normallashtiriladi va zarur hollarda shovqindan tozalanadi.

3-bosqich — avtomatik tahlil. Tayyorlangan tasvir o‘qitilgan neyron tarmoq tomonidan qayta ishlanadi. Model tanlangan vazifaga muvofiq bir yoki bir nechta diagnostik sinf uchun baho beradi.

4-bosqich — shubhali hududni ko‘rsatish. Agar tizimda segmentatsiyalash yoki izohlash moduli mavjud bo‘lsa, shubhali hududlar tasvir ustida rangli qatlam yoki niqob shaklida aks ettiriladi.

5-bosqich — natijani tekshirish. Model natijasi sifat nazorati, noaniqlik va belgilangan qaror chegarasi nuqtayi nazaridan baholanadi. Tahlil uchun yaroqsiz tasvir yoki noaniq natija avtomatik tashxis sifatida taqdim etilmaydi.

6-bosqich — hisobot shakllantirish. Dastur model xulosasi, ehtimollik bahosi, texnik ogohlantirishlar va model versiyasini ko‘rsatadi. Yakuniy klinik talqin mutaxassis tomonidan amalga oshiriladi.

Ushbu ketma-ketlikni amaliyotga joriy etish tasvirni qo‘lda ko‘rib chiqish jarayoniga qo‘shimcha avtomatlashtirilgan tahlil qatlamini kiritishi mumkin. Biroq tizimning tahlil vaqtini qisqartirishi yoki diagnostik samaradorlikni oshirishi haqidagi xulosalar faqat qiyosiy tajriba orqali asoslanishi lozim.

Dasturiy ta’minotning kutilayotgan chiqish ma’lumotlari

Tizimning natijasi faqat “kasallik bor” yoki “kasallik yo‘q” kabi ikkilik xulosa bilan cheklanmasligi kerak. Bunday soddalashtirish diagnostik vazifaning murakkabligini yetarlicha ifodalamaydi.

Dastur quyidagi ma’lumotlarni chiqarishi tavsiya etiladi:

1. Tasvirning texnik holati: tahlil uchun yaroqli yoki yaroqsiz.
2. Model natijasi: tanlangan sinf yoki ehtimoliy patologik belgi.
3. Ehtimollik bahosi: modelning muayyan sinfga tegishli hisoblangan chiqish qiymati.
4. Vizual izoh: mavjud bo‘lsa, e’tibor xaritasi yoki segmentatsiya niqobi.
5. Noaniqlik holati: model natijasi qo‘shimcha tekshiruvni talab qiladimi yoki yo‘qmi.
6. Texnik ma’lumotlar: model versiyasi, tahlil vaqti va tasvir identifikatori.

Ehtimollik bahosi klinik jihatdan kalibrlanmagan bo‘lsa, u tashxisning haqiqiy ehtimoli sifatida talqin qilinmasligi kerak. Shuningdek, vizual izoh modeli qarorining asoslanganligini to‘liq isbotlamaydi.

Eksperimental baholash uchun natijalar jadvali

Modelning amaliy samaradorligini aniqlash uchun tajriba natijalari quyidagi jadval asosida qayd etilishi mumkin.

1-jadval. Taklif etilayotgan algoritmni baholash mezonlari

№	Ko‘rsatkich	Baholash maqsadi	Natija
1	Accuracy	Umumiy tasniflash aniqligi	Tajribada aniqlanadi
2	Sensitivity	Patologik holatlarni aniqlash qobiliyati	Tajribada aniqlanadi
3	Specificity	Patologiyasiz holatlarni to‘g‘ri ajratish	Tajribada aniqlanadi
4	Precision	Musbat natijalarning to‘g‘riligini baholash	Tajribada aniqlanadi
5	F1-score	Precision va sezgirlik muvozanati	Tajribada aniqlanadi
6	ROC-AUC	Sinflarni ajratish qobiliyati	Tajribada aniqlanadi
7	Kalibrlash	Ehtimollik baholarining ishonchliligi	Tajribada aniqlanadi
8	Tahlil vaqti	Bitta tasvirni qayta ishlash davomiyligi	Tajribada aniqlanadi

Jadvaldagi qiymatlar tajriba natijalari olinmaguncha to‘ldirilmaydi. Yakuniy tadqiqotda har bir ko‘rsatkich uchun qiymat, zarur hollarda 95 foizlik ishonch oralig‘i va test to‘plamining hajmi ko‘rsatilishi kerak.

Algoritmni qiyosiy baholash metodikasi

Taklif etilgan modelning afzalliklarini aniqlash uchun uni kamida bitta asosiy taqqoslash usuli bilan baholash tavsiya etiladi. Masalan, klassik mashinaviy o‘qitish modeli, dastlabki CNN modeli va transfer learning asosidagi model o‘zaro taqqoslanishi mumkin.

Bunda barcha modellar uchun bir xil bemorlar bo‘yicha ajratilgan test to‘plami va bir xil etalon belgilaridan foydalanish lozim. Model tanlash va parametrlarni sozlash test to‘plamidan foydalanmasdan, o‘qitish hamda validatsiya ma’lumotlari asosida bajariladi.

Tajriba quyidagi yo‘nalishlarni qamrab olishi mumkin:

- dastlabki qayta ishlash bosqichining ta’sirini baholash;
- model arxitekturalarini bir xil sharoitda taqqoslash;
- tasvir sifatining pastligi sharoitida natijalar barqarorligini tekshirish;
- turli yosh guruhlari va tasvir olish qurilmalarida ko‘rsatkichlarni tahlil qilish;
- modelning noto‘g‘ri musbat va noto‘g‘ri manfiy holatlarini o‘rganish;
- boshqa klinik manbadan olingan ma’lumotlarda tashqi test o‘tkazish.

Agar bir nechta model taqqoslansa, farqlar statistik jihatdan asoslanishi kerak. Faqat eng yuqori ko‘rsatkichga ega modelni tanlash yetarli emas: uning ishonchliligi, hisoblash xarajatlari, natijalarni izohlash imkoniyati va turli ma’lumotlar to‘plamlarida barqarorligi ham hisobga olinadi.

Muhokama. Taklif etilgan algoritmning asosiy xususiyati tibbiy tasvirlarni tahlil qilishning alohida bosqichlarini yagona dasturiy arxitektura doirasida birlashtirishdir. Tasvir sifati nazorati, standartlashtirish, chuqur o‘qitish, vizual izohlash va natijalarni strukturaviy shaklda chiqarish diagnostik tahlil jarayonini tartibga solishga yordam beradi.

An’anaviy tasvirni qayta ishlash usullari ayrim sharoitlarda samarali bo‘lishi mumkin, ammo ularning ko‘p parametrlari oldindan belgilanishi va tasvir xususiyatlariga bog‘liq bo‘lishi mumkin. Chuqur o‘qitish esa yetarli miqdordagi sifatli va ishonchli belgilangan ma’lumotlar mavjud bo‘lganda murakkab tasviriy belgilarni o‘rganish imkonini beradi.

Biroq CNN yoki boshqa neyron tarmoqdan foydalanishning o‘zi klinik samaradorlikni kafolatlamaydi. Model tasvirning haqiqiy patologik belgilariga emas, balki tasvir olish qurilmasi, tasvir chetidagi yozuvlar, klinika belgisi yoki ma’lumotlar to‘plamiga xos boshqa omillarga asoslanib qaror chiqarishi mumkin. Bunday xatarlar modelni vizual tahlil qilish, ma’lumotlar to‘plamini tekshirish va tashqi sinovlar orqali o‘rganilishi kerak.

Erta aniqlashda sezgirlik va spetsifiklikning o‘rni

Kasalliklarni erta aniqlash tizimida sezgirlikning yuqori bo‘lishi patologik holatlarni o‘tkazib yuborish xavfini kamaytirishga yordam berishi mumkin. Shu bilan birga, sezgirlikni oshirish maqsadida qaror chegarasini pasaytirish noto‘g‘ri musbat natijalar sonini ko‘paytirishi mumkin.

Noto‘g‘ri musbat natijalar qo‘shimcha tekshiruvlar, vaqt va moliyaviy xarajatlarni oshirishi mumkin. Noto‘g‘ri manfiy natijalar esa kasallik mavjud bo‘lishiga qaramay, tizimning uni aniqlamasligiga olib kelishi mumkin. Shu sababli modelni baholashda sezgirlik va spetsifiklik birgalikda ko‘rib chiqiladi.

Modelning ishlash chegarasi faqat statistik mezon asosida emas, balki muayyan kasallikning klinik xavfi, tekshiruvning keyingi bosqichlari va mutaxassislar ishtiroki asosida tanlanishi kerak. Turli kasalliklar uchun bir xil qaror chegarasini qo‘llash har doim ham maqsadga muvofiq emas.

Izohlanuvchi sun’iy intellekt imkoniyatlari

Tibbiy diagnostika tizimlarida model natijasini izohlash muhim ahamiyatga ega. Shifokor uchun faqat ehtimollik qiymatini ko‘rishdan ko‘ra, model qaysi hududlarga ko‘proq e’tibor qaratganini ko‘rish foydali bo‘lishi mumkin.

Grad-CAM kabi usullar CNN qatlamlaridagi xususiyatlar asosida e’tibor xaritasini shakllantirishga yordam beradi. Ushbu xarita dastlabki tasvir ustiga joylashtirilib, modelning qaysi hududlar bilan bog‘liq belgilar asosida qaror chiqargani taxminan ko‘rsatiladi.

Biroq e’tibor xaritasini patologik hududning aniq chegarasi sifatida talqin qilish mumkin emas. Agar klinik jihatdan aniq chegaralarni ko‘rsatish talab qilinsa, tegishli etalon segmentatsiya belgilarida o‘qitilgan segmentatsiyalash modeli kerak bo‘ladi. Shuning uchun izohlash vositalari shifokorning klinik bahosini to‘ldiruvchi vosita sifatida qo‘llanilishi kerak.

Ma’lumotlar sifati va umumlashtirish muammosi

Modelning ishonchliligi ma’lumotlar to‘plamining sifati va xilma-xilligiga bog‘liq. Birgina klinik muassasada yoki bitta turdagi qurilmada olingan tasvirlarda yuqori natija ko‘rsatgan model boshqa muassasada ham xuddi shunday ishlashiga kafolat yo‘q.

Ma’lumotlar to‘plamida ayrim yosh guruhlari yoki kasallik holatlari kam ifodalangan bo‘lsa, model ushbu guruhlar uchun yetarlicha ishonchli bo‘lmasligi mumkin. Bundan tashqari, tasvir olish protokollari va klinik amaliyotdagi farqlar ma’lumotlarning taqsimlanishiga ta’sir ko‘rsatadi.

Ushbu muammolarni kamaytirish uchun ko‘p manbali ma’lumotlardan foydalanish, bemor darajasidagi ajratish, tashqi test va guruhlar kesimidagi ko‘rsatkichlarni hisoblash tavsiya etiladi. Tashqi test natijalari modelni klinik amaliyotga tatbiq etishdan oldin muhim dalil hisoblanadi.

Dasturiy ta’minotning cheklovlari

Taklif etilgan dasturiy arxitekturaning amaliy samaradorligi bir qator omillarga bog‘liq.

Birinchidan, turli diagnostik modalitetlar o‘ziga xos qayta ishlash usullarini talab qiladi. Rentgen tasvirlari uchun mos yondashuv MRT yoki KT tasvirlariga to‘g‘ridan-to‘g‘ri ko‘chirilmasligi kerak.

Ikkinchidan, yetarli hajmdagi, ishonchli belgilangan ma’lumotlarning mavjudligi model sifatini belgilovchi muhim omildir. Noto‘g‘ri yoki noaniq etalon belgilar modelning o‘rganish jarayoniga salbiy ta’sir ko‘rsatishi mumkin.

Uchinchidan, modelning natijalari klinik tashxis bilan tenglashtirilmasligi lozim. Yakuniy tashxis anamnez, klinik belgilar, laboratoriya natijalari, boshqa tekshiruvlar va shifokor xulosasi bilan birgalikda shakllantiriladi.

To‘rtinchidan, modelni yangilash yoki yangi klinik muhitga ko‘chirishdan oldin uning ishlashi qayta tekshirilishi kerak. Dasturiy ta’minotning versiyalari nazorat qilinishi va natijalarga ta’sir qiluvchi o‘zgarishlar qayd etilishi maqsadga muvofiq.

Tibbiy ma’lumotlar xavfsizligi va etik talablar

Tibbiy tasvirlar bemorlarning shaxsiy ma’lumotlarini o‘z ichiga olishi mumkin. Shu sababli tasvirlarni qayta ishlash, saqlash va uzatishda maxfiylikni ta’minlash zarur. DICOM fayllaridagi identifikatsiyalovchi metama’lumotlar ham tekshirilishi va qonuniy asos mavjud bo‘lganda anonimlashtirilishi kerak.

Tizimga kirish huquqlarini cheklash, ma’lumotlarni uzatishda himoyalangan aloqa kanallaridan foydalanish, saqlanadigan ma’lumotlarni himoyalash va audit qaydlarini yuritish tavsiya etiladi. Ma’lumotlarni uchinchi tomon xizmatlariga yuborishdan oldin ularning maxfiylik siyosati va qonuniy talablariga muvofiqligi baholanishi kerak.

Jahon sog‘liqni saqlash tashkiloti sog‘liqni saqlashda sun’iy intellektni ishlab chiqish va qo‘llashda inson manfaatlari, shaffoflik, xavfsizlik, javobgarlik va tenglik tamoyillariga amal qilish zarurligini qayd etadi [2]. Shu bois taklif etilayotgan tizim shifokor nazorati ostida ishlashi, noaniq natijalarni yashirmasligi va avtomatik qarorlarni klinik tekshiruv o‘rniga qo‘ymasligi lozim.

Kelgusidagi tadqiqot yo‘nalishlari

Keyingi bosqichda taklif etilgan algoritmni aniq klinik vazifa bo‘yicha amaliy sinovdan o‘tkazish rejalashtirilishi mumkin. Buning uchun bitta kasallik turi, aniq tasvir modaliteti va klinik jihatdan ishonchli etalon belgilar tanlanadi.

Kelgusidagi tadqiqotlarda quyidagi vazifalarni bajarish maqsadga muvofiq:

1. Tegishli ochiq yoki ruxsat etilgan klinik ma’lumotlar to‘plamini shakllantirish.
2. Tasvirlarni anonimlashtirish va sifat nazoratidan o‘tkazish.
3. CNN va transfer learning modellarini o‘qitish.
4. Model natijalarini mustaqil test to‘plamida baholash.
5. Xatolar va noaniq holatlarni alohida tahlil qilish.
6. Imkoniyat mavjud bo‘lsa, boshqa klinik muassasadan olingan ma’lumotlarda tashqi test o‘tkazish.
7. Shifokorlar ishtirokida foydalanish qulayligi va klinik ahamiyatini baholash.
8. Tizimni real klinik jarayonga joriy etishdan oldin tegishli tartibga solish va xavfsizlik talablariga muvofiqligini tekshirish.

XULOSA. Mazkur tadqiqotda kasalliklarni erta aniqlash maqsadida tibbiy diagnostika tasvirlarini tahlil qilish algoritmi va dasturiy ta’minotining konseptual modeli ishlab chiqildi. Taklif etilgan yondashuv tasvirlarni qabul qilish, sifatini nazorat qilish, dastlabki qayta ishlash, chuqur o‘qitish asosida tasniflash, zarur hollarda patologik hududlarni segmentatsiyalash va natijalarni vizual taqdim etish bosqichlarini yagona tizimga birlashtiradi.

Tadqiqot natijasida quyidagi ilmiy-amaliy xulosalar shakllantirildi.

Birinchidan, tibbiy diagnostika tasvirlarini avtomatik tahlil qilishda tasvir sifati nazorati va dastlabki qayta ishlash bosqichlarini hisobga olish zarurligi asoslandi. Tasvirni standartlashtirish, normallashtirish va shovqinni kamaytirish usullari tanlangan diagnostik modalitet xususiyatlariga mos ravishda qo‘llanishi kerak.

Ikkinchidan, konvolyutsion neyron tarmoqlar va transfer learning yondashuvlari tibbiy tasvirlarni tasniflash uchun asosiy algoritmik vositalar sifatida taklif etildi. Patologik hududning joylashuvini

aniqlash zarur bo‘lganda, segmentatsiyalash moduli bilan kengaytirilgan arxitekturadan foydalanish imkoniyati belgilandi.

Uchinchidan, dasturiy ta’minotning modulli arxitekturasi ishlab chiqildi. U tasvirlarni yuklash, qayta ishlash, sun’iy intellekt modelini ishga tushirish, natijalarni izohlash, hisobot shakllantirish va xavfsizlik nazoratini alohida funksional qismlarga ajratishni nazarda tutadi.

To‘rtinchidan, algoritm samaradorligini baholash uchun aniqlik, sezgirlik, spetsifiklik, F1-ko‘rsatkich, ROC-AUC va ehtimollik baholarining kalibrlanishi kabi mezonlar belgilandi. Modelni baholashda bemor darajasidagi ma’lumotlar ajratilishi, mustaqil test va imkoniyat mavjud bo‘lganda tashqi testdan foydalanish zarurligi ta’kidlandi.

Beshinchidan, tibbiy sun’iy intellekt tizimlarida shaxsiy ma’lumotlarni himoyalash, algoritmik xatolarni nazorat qilish, natijalarni tushunarli shaklda ko‘rsatish va shifokor nazoratini saqlash muhim talablar sifatida belgilandi.

Shu bilan birga, mazkur ishning natijalari algoritm va dasturiy arxitektura loyihasini ishlab chiqish darajasida ekanligini ta’kidlash lozim. Modelning diagnostik aniqligi, klinik samaradorligi va amaliy ustunligi hali real ma’lumotlar asosida eksperimental tekshirilishi kerak. Kelgusida tanlangan kasallik turi va tasvir modaliteti bo‘yicha ma’lumotlar to‘plamini shakllantirish, modelni o‘qitish, mustaqil sinovdan o‘tkazish hamda klinik mutaxassislar ishtirokida baholash tadqiqotning asosiy amaliy yo‘nalishlarini tashkil etadi.

Umuman olganda, taklif etilgan algoritmik yondashuv tibbiy diagnostika tasvirlarini avtomatlashtirilgan tahlil qilish uchun dasturiy asos yaratadi. Tegishli klinik va texnik sinovlardan muvaffaqiyatli o‘tgandan keyingina bunday tizimni shifokor qarorini qo‘llab-quvvatlash vositasi sifatida amaliyotga joriy etish masalasi ko‘rib chiqilishi mumkin.

FOYDALANILGAN ADABIYOTLAR:

1. Tejani A. S., Klontzas M. E., Gatti A. A., Mongan J. T., Moy L., Park S. H., Kahn C. E. Jr., for the CLAIM 2024 Update Panel. Checklist for Artificial Intelligence in Medical Imaging (CLAIM): 2024 Update. Radiology: Artificial Intelligence. 2024; 6(4): e240300. DOI: https://doi.org/10.1148/ryai.240300.
2. World Health Organization. Ethics and Governance of Artificial Intelligence for Health: WHO Guidance. Geneva: World Health Organization; 2021. ISBN: 978-92-4-002920-0. URL: https://www.who.int/publications/i/item/9789240029200.
3. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015. Lecture Notes in Computer Science. Vol. 9351. Springer; 2015. pp. 234–241. DOI: https://doi.org/10.1007/978-3-319-24574-4_28.
4. Selvaraju R. R., Cogswell M., Das A., Vedantam R., Parikh D., Batra D. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. In: Proceedings of the IEEE International Conference on Computer Vision (ICCV). 2017. pp. 618–626. DOI: https://doi.org/10.1109/ICCV.2017.74.
5. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. pp. 770–778. DOI: https://doi.org/10.1109/CVPR.2016.90.
6. Litjens G., Kooi T., Bejnordi B. E., Setio A. A. A., Ciompi F., Ghafoorian M., van der Laak J. A. W. M., van Ginneken B., Sánchez C. I. A Survey on Deep Learning in Medical Image Analysis. Medical Image Analysis. 2017; 42: 60–88. DOI: https://doi.org/10.1016/j.media.2017.07.005.

7. LeCun Y., Bengio Y., Hinton G. Deep Learning. Nature. 2015; 521: 436–444. DOI: https://doi.org/10.1038/nature14539.
8. Esteva A., Kuprel B., Novoa R. A., Ko J., Swetter S. M., Blau H. M., Thrun S. Dermatologist-Level Classification of Skin Cancer with Deep Neural Networks. Nature. 2017; 542: 115–118. DOI: https://doi.org/10.1038/nature21056.
9. Topol E. J. High-Performance Medicine: The Convergence of Human and Artificial Intelligence. Nature Medicine. 2019; 25: 44–56. DOI: https://doi.org/10.1038/s41591-018-0300-7.
10. Rajpurkar P., Chen E., Banerjee O., Topol E. J. AI in Health and Medicine. Nature Medicine. 2022; 28: 31–38. DOI: https://doi.org/10.1038/s41591-021-01614-0.