

TIBBIY TASVIRLARNI TAHLIL QILISHDA MASHINAVIY O'RGANISH VA SUN'IY  
INTELLEKTNING ROLI

**R.Y.Mamajanov**

Denov tadbirkorlik va pedagogika instituti  
Axborot texnologiyalari kafedrasini mudiri t.f.n., dots.

**R.Suyunova**

Denov tadbirkorlik va pedagogika instituti 2-kurs magistri

**Annotatsiya.** Mazkur maqolada tibbiy tasvirlarni (rentgen, KT, MRT, UTT va boshqalar) tahlil qilish jarayonida mashinaviy o'rganish (Machine Learning) va sun'iy intellekt (Artificial Intelligence) texnologiyalarining nazariy asoslari, algoritmik yondashuvlari hamda amaliy qo'llanilish yo'nalishlari ilmiy jihatdan tahlil qilinadi. Konvolyutsion neyron tarmoqlar (CNN), chuqur o'rganish (Deep Learning), segmentatsiya va klassifikatsiya algoritmlarining diagnostik aniqlikni oshirishdagi o'rni asoslab beriladi. Shuningdek, klinik qaror qabul qilishni qo'llab-quvvatlovchi tizimlarda SI texnologiyalarining integratsiyasi, ularning afzalliklari va muammolari muhokama qilinadi.

**Kalit so'zlar:** tibbiy tasvir, mashinaviy o'rganish, sun'iy intellekt, chuqur o'rganish, segmentatsiya, klassifikatsiya, CNN, diagnostika.

**Аннотация.** В данной статье научно проанализированы теоретические основы, алгоритмические подходы и направления практического применения технологий машинного обучения (Machine Learning) и искусственного интеллекта (Artificial Intelligence) в процессе анализа медицинских изображений (рентгенография, КТ, МРТ, УЗИ и др.). Обоснована роль сверточных нейронных сетей (CNN), методов глубокого обучения (Deep Learning), а также алгоритмов сегментации и классификации в повышении диагностической точности. Кроме того, рассмотрены вопросы интеграции технологий искусственного интеллекта в системы поддержки принятия клинических решений, их преимущества и существующие проблемы.

**Ключевые слова:** медицинское изображение, машинное обучение, искусственный интеллект, глубокое обучение, сегментация, классификация, CNN, диагностика.

**Abstract.** This article scientifically analyzes the theoretical foundations, algorithmic approaches, and practical application areas of Machine Learning and Artificial Intelligence technologies in the process of medical image analysis (radiography, CT, MRI, ultrasound, etc.). The role of Convolutional Neural Networks (CNN), Deep Learning methods, as well as segmentation and classification algorithms in improving diagnostic accuracy is substantiated. In addition, the integration of Artificial Intelligence technologies into clinical decision support systems, along with their advantages and existing challenges, is examined.

**Keywords:** medical image, machine learning, artificial intelligence, deep learning, segmentation, classification, CNN, diagnostics.

**Kirish**

So'nggi o'n yilliklarda raqamli tibbiyot va diagnostika texnologiyalarining jadal rivojlanishi natijasida tibbiy tasvirlar hajmi va murakkabligi sezilarli darajada oshdi [1]. Zamonaviy tasvirlash usullari - Magnetic Resonance Imaging, Computed Tomography, Ultrasound va X-ray - yuqori aniqlikdagi, ko'p qatlamli va ko'p parametrlil tasvirlarni shakllantiradi, bu esa katta hajmdagi ma'lumotlarni tahlil qilish zaruratini keltirib chiqarmoqda [2]. Klinik amaliyotda ayrim diagnostik

tekshiruvlar yuzlab, ba'zan minglab tasvir kesimlarini o'z ichiga oladi, bu esa radiologlar ish yuklamasining ortishiga sabab bo'ladi [3].

Tibbiy tasvirlarni an'anaviy vizual tahlil qilish ko'p jihatdan mutaxassis tajribasi va subyektiv bahosiga bog'liq bo'lib, inson omiliga aloqador xatoliklar xavfini saqlab qoladi [4]. Tadqiqotlar shuni ko'rsatadiki, diagnostik jarayonda inter-observer va intra-observer tafovutlari mavjud bo'lib, bu kasallikni aniqlash aniqligiga ta'sir ko'rsatishi mumkin [5]. Shu sababli tibbiy tasvirlarni avtomatlashtirilgan, obyektiv va takrorlanuvchi tarzda tahlil qiluvchi intellektual tizimlarga ehtiyoj ortib bormoqda [1].

Mazkur muammoni hal etishda mashinaviy o'rganish va sun'iy intellekt metodlari muhim ilmiy yo'nalish sifatida shakllandi [6]. Ayniqsa, chuqur o'rganish asosidagi konvolyutsion neyron tarmoqlar tasvirlardan avtomatik ravishda informativ belgilarni ajratib olish va yuqori aniqlik bilan klassifikatsiya qilish imkonini bermoqda [2, 7]. Ilmiy tadqiqotlar natijalari shuni ko'rsatadiki, sun'iy intellekt asosidagi modellar ayrim diagnostik vazifalarda mutaxassislar bilan teng yoki undan yuqori aniqlik ko'rsatkichlariga erishishi mumkin [8].

Shunday qilib, tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganish va sun'iy intellekt texnologiyalarining joriy etilishi diagnostik jarayonning aniqligi, tezkorligi va samaradorligini oshirishda muhim ilmiy-amaliy ahamiyat kasb etadi.

**Mavzuning dolzarbligi.** XXI asrda sog'liqni saqlash tizimi raqamli transformatsiya bosqichiga o'tdi. Tibbiy tasvirlash texnologiyalarining rivojlanishi natijasida diagnostik ma'lumotlar hajmi jadal sur'atlarda oshib bormoqda. Zamonaviy tasvirlash usullari - Magnetic Resonance Imaging, Computed Tomography, Ultrasound hamda X-ray - yuqori aniqlikdagi, ko'p qatlamli va ko'p o'lchovli tasvirlarni hosil qiladi. Xalqaro statistik ma'lumotlarga ko'ra, dunyo bo'yicha yiliga milliardlab radiologik tekshiruvlar amalga oshiriladi va ularning soni har yili o'sib bormoqda [9]. Bu esa klinik muassasalarda katta hajmdagi tasviriy ma'lumotlarni tezkor, aniq va ishonchli tahlil qilish zaruratini yuzaga keltiradi.

Radiologik amaliyotda ish yuklamasining ortishi inson omiliga bog'liq xatoliklar xavfini oshiradi. Tadqiqotlarga ko'ra, diagnostik tafovutlar (inter-observer variability) va individual talqin farqlari klinik qarorlarning barqarorligiga ta'sir ko'rsatadi [10]. Ayrim holatlarda kechikkan yoki noto'g'ri tashxis qo'yilishi bemor hayotiga salbiy ta'sir ko'rsatishi mumkin. Shu sababli tasvirlarni avtomatlashtirilgan va obyektiv tahlil qiluvchi intellektual tizimlarni yaratish zamonaviy tibbiyotning muhim vazifasiga aylandi.

So'nggi yillarda Machine Learning va Deep Learning asosidagi modellar tibbiy tasvirlarni tahlil qilishda yuqori samaradorlik ko'rsatmoqda. Xususan, Convolutional Neural Network arxitekturasi tasvirlardan avtomatik ravishda informativ xususiyatlarni ajratish va murakkab patologiyalarni aniqlash imkonini beradi [11]. Ilmiy tadqiqotlarda chuqur o'rganish modellarining o'pka kasalliklari, teri saratoni, ko'krak bezi o'smalari va nevrologik patologiyalarni aniqlashda yuqori aniqlik ko'rsatkichlariga erishgani qayd etilgan [11].

Masalan, teri saratonini aniqlash bo'yicha o'tkazilgan tadqiqotda chuqur neyron tarmoq modeli dermatolog mutaxassislar darajasiga teng natija ko'rsatgani aniqlangan [10]. Shuningdek, ko'plab sharhli maqolalarda tibbiy tasvirlarni tahlil qilishda chuqur o'rganish yondashuvlarining samaradorligi ilmiy asoslangan [12]. Bu esa sun'iy intellekt texnologiyalarining klinik qaror qabul qilish jarayonida muhim vosita sifatida shakllanayotganini ko'rsatadi.

Bundan tashqari, global sog'liqni saqlash tizimida kasalliklarni erta aniqlash va prognozlash muhim strategik vazifa hisoblanadi. Individual tibbiyot (precision medicine) konsepsiyasi har bir bemor uchun moslashtirilgan davolash strategiyasini ishlab chiqishni talab etadi. Tibbiy tasvirlarni chuqur tahlil qilish orqali kasalliklarning subklinik bosqichlarini aniqlash va davolash samaradorligini oshirish mumkin. Shu nuqtai nazardan, sun'iy intellekt asosidagi diagnostik tizimlar sog'liqni saqlash tizimining samaradorligini oshirishda strategik ahamiyatga ega.

Shu bilan birga, katta hajmdagi ma'lumotlar bilan ishlash, modelning umumlashtirish qobiliyati, klinik validatsiya, etik va huquqiy masalalar dolzarb ilmiy muammolar sifatida qolmoqda. Ayniqsa, modelning tushuntiriluvchanligi (Explainable AI) va shaffofligi klinik muhitda joriy etish uchun muhim talab hisoblanadi [13].

Yuqoridagilardan kelib chiqib, tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganish va sun'iy intellekt metodlarini takomillashtirish zamonaviy ilm-fan va sog'liqni saqlash tizimining eng dolzarb yo'nalishlaridan biri bo'lib, diagnostik aniqlikni oshirish, inson omiliga bog'liq xatoliklarni kamaytirish va klinik qaror qabul qilishni optimallashtirishda muhim ilmiy-amaliy ahamiyat kasb etadi.

**Muammoni yechish yo'llari.** Tibbiy tasvirlarni tahlil qilish sohasidagi asosiy muammolar – katta hajmdagi tasviriy ma'lumotlar bilan ishlash zarurati, inson omiliga bog'liq xatoliklar, modelning umumlashtirish qobiliyati va klinik amaliyotga joriy etishda yuzaga keladigan texnik va etik to'siqlar – bir qator integrated yechimlar orqali samarali tarzda hal qilinishi mumkin.

Sun'iy intellekt (SI) va mashinaviy o'rganish (MO) – tibbiy tasvir tahlilidagi eng kuchli metodologik yechimlardan biri bo'lib, bu texnologiyalar tasvirlar asosidagi murakkab qonuniyatlarni avtomatik anglash va aniqlash imkonini beradi. Chuqur o'rganish (Deep Learning) asosidagi modellar ayniqsa tasvirlarni segmentatsiya, klassifikatsiya va detektsiya vazifalarida ustun natijalar ko'rsatmoqda. Tibbiy tasvirlarda chuqur o'rganish yondashuvlari avvalgi klassik metodlar bilan solishtirganda yanada yuqori samaradorlik va aniqlik beradi, chunki ular murakkab naqshlarni o'rganadi va katta o'lchamli ma'lumotlarga moslashadi. Bu metodlar, xususan konvolyutsion neyron tarmoqlar (CNN), tasvirlardan avtomatik xususiyatlarni ajratishni amalga oshiradi, bu esa inson tomonidan qo'lda belgilar ajratilishidan ancha ustundir.

Konvolyutsion neyron tarmoqlarda avtomatik xususiyat ajratishning matematik asoslari. Masalan bizga tibbiy tasvirlar fazosi berilgan bo'lsin.

$$X \subset \mathbb{R}^{H \times W \times C}$$

va diagnostic qarorlar fazosi  $Y \subset \mathbb{R}^K$

Tasniflash masalasi quyidagi funksiyani yaqinlashtirishdan iborat:

$$f_{\theta} : X \rightarrow Y$$

Bu yerda  $\theta$  – CNN parametrlari (yadrolar, og'irliklar, bias).

An'anaviy yondashuvda esa:

$$x \xrightarrow{\emptyset} z \xrightarrow{g} y$$

Bu yerda  $\emptyset$  – inson tomonidan qo'lda tanlangan belgilar (texture, edges, histogram va h.k.).

CNN da esa:

$$x \xrightarrow{f_{\theta}} y$$

va belgilar  $\emptyset(x)$  tarmoqning o'zi tomonidan o'rganiladi.

Xulosa qilib aytganda konvolyutsion neyron tarmoqlar:

- xususiyatlarni avtomatik optimallashtirib o'rganadi;
- local invariantlik va parameter tejamkorlikni ta'minlaydi;
- ierarxik semantic reprezentaviya hosil qiladi;

Bu o'z navbatida tibbiy tasvirlarda diagnostika aniqligini oshiradi va inson omilini kamaytiradi. Shu sababli CNN lar qo'lda belgilar ajratish usullariga nisbatan nazariy va amaliy jihatdan ustun hisoblanadi [14].

Kutilgan natijalar. Ushbu tadqiqot ishini amalga oshirish natijasida quyidagi ilmiy va amaliy natijalarga erishish 5 ta ko'rsatkichlarda aniqlash kutilmoqda:

#### 1. Nazariy natijalar

- Tibbiy tasvirlarni qayta ishlash uchun konvolyusion neyron tarmoqlar (CNN) asosida matematik model ishlab chiqiladi.
- Avtomatik xususiyat ajratishning qo'lda belgilar shakllantirish usullariga nisbatan ustunligi nazariy jihatdan asoslanadi.
- konvolyusion qatlam parametrlarining diagnostic aniqlikka ta'siri tahlil qilinadi.
- Model umumlashtirish qobiliyati (generalization ability) va barqarorligi baholanadi.

#### 2. Metodik natijalar quyidagilar:

- Tibbiy tasvirlar (roentgen, MRI, CT) uchun optimal CNN arxitekturasi taklif etiladi.
- Ma'lumotlarni oldindan qayta ishlash (normalization, augmentation) algoritmi ishlab chiqiladi.
- Tasniflash va segmentasiya jarayonlari uchun samarali o'qitish strategiyasi (learning rate scheduling, regularization) ishlab chiqiladi.
- Diagnostic qaror qabul qilish jarayonini avtomatlashtiruvchi algoritm yaratiladi.


#### 3. Amaliy natijalarga erishish uchun:

- Ko'krak qafasi rentgen tasvirlarida kasalliklarni aniqlash aniqligi oshiriladi.
- MRI tasvirlarda saratonni avtomatik segmentasiya qilish imkoniyati yaratiladi.
- Inson omilidan kelib chiqadigan subektiv xatoliklar kamaytiriladi.
- Diagnostika vaqti qisqarishi ta'minlanadi.
- Tibbiy qaror qabul qilish jarayonida qo'llab-quvvatlovchi intellektual tizim prototipi yaratiladi.

#### 4. Kutilgan ilmiy yangiliklar.

1. Tibbiy tasvirlar uchun maxsuslashtirilgan CNN arxitekturasi taklif etiladi.
2. avtomatik xususiyat ajratishning diagnostik samaradorligi matematik asosda isbotlanadi.
3. Tasvirlar turiga mos adaptive o'qitish mexanizmi ishlab chiqiladi.
5. Samaradorlik ko'rsatkichlari. Tadqiqot natijalari quyidagi mezonlar orqali baholanadi: Accuracy, Precision, Recall, F1-score, ROC-AUC, Sensitivity/Specificity [15].

Konvolyusion neyron tarmoq (CNN) asosida tibbiy tasvirlarni klassifikatsiya qilish modelining ROC tahlili (1-rasm).



1-rasm. Taklif etilgan konvolyusion neyron tarmoq (CNN) asosidagi diagnostic modelning ROC tahlili: sezgirlik (Sensitivity) va xoslik (Specificity) o'rtasidagi nisbat (AUC = 0.522).

Bu yerda AUC = 0.522 nimani anglatadi?

AUC = 0.522 qiymati:

- Model ijobiy sinfni salbiy sinfdan ajratish ehtimoli 52.2%
- Bu tasodifiy klassifikator (50%) dan juda ozgina ustun
- Diagnostik jihatdan past samaradorlik.

Boshqacha aytganda:

$$P(\text{score}_{\text{positive}} > \text{score}_{\text{negative}}) = 0.522$$

yani model tasodifiydan atigi 2.2% yaxshi.

Olingan natijalarga ko'ra, taklif etilgan CNN asosidagi diagnostic modelning ROC egri chizig'i ostidagi maydon (AUC) 0.522 ni tashkil etdi. Ushbu qiymat modelning tasniflash qobiliyati tasodifiy klassifikatordan ozgina yuqori ekanligini ko'rsatadi. Mazkur natija model arxitekturasini takomillashtirish va o'qitish jarayonini optimallashtirish zarurligini anglatadi [16].

### Xulosa

Olingan natijalardan ko'rinib turibdiki, taklif etilgan CNN asosidagi tibbiy tasvirlarni tasniflash modeli ROC egri chizig'i ostidagi maydon (AUC) qiymati **0.522** ni tashkil etdi. Shu sababli, klinik qo'llash uchun model hozirda yetarli samaradorlikka ega emas va uning aniqligini oshirish maqsadida qo'shimcha tadqiqot va optimizasiya zarur.

Tadqiqot natijasida tibbiy tasvirlarni tahlil qilish jarayonini intellektuallashtiruvchi, yuqori aniqlikka ega va amaliyotga joriy etish mumkin bo'lgan algoritm asosida dasturiy majmuasi yaratilishi kutilmoqda.

### FOYDALANILGAN ADABIYOTLAR RO'YXATI:

1. Litjens G., Kooi T., Bejnordi B. E., et al. A survey on deep learning in medical image analysis // *Medical Image Analysis*. – 2017. – Vol. 42. – P. 60–88.
2. Lundervold A. S., Lundervold A. An overview of deep learning in medical imaging focusing on MRI // *Zeitschrift für Medizinische Physik*. – 2019. – Vol. 29. – No. 2. – P. 102–127.
3. Erickson B. J., Korfiatis P., Akkus Z., Kline T. L. Machine learning for medical imaging // *Radiographics*. – 2017. – Vol. 37. – No. 2. – P. 505–515.
4. Brady A. P. Error and discrepancy in radiology: inevitable or avoidable? // *Insights into Imaging*. – 2017. – Vol. 8. – No. 1. – P. 171–182.
5. Elmore J. G., Wells C. K., Lee C. H., et al. Variability in radiologists' interpretations of mammograms // *New England Journal of Medicine*. – 1994. – Vol. 331. – P. 1493–1499.
6. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. – Cambridge: MIT Press, 2016. – 800 p.
7. LeCun Y., Bengio Y., Hinton G. Deep learning // *Nature*. – 2015. – Vol. 521. – P. 436–444.
8. Esteva A., Kuprel B., Novoa R. A., et al. Dermatologist-level classification of skin cancer with deep neural networks // *Nature*. – 2017. – Vol. 542. – P. 115–118.
9. Brady A. P. Error and discrepancy in radiology: inevitable or avoidable? // *Insights into Imaging*. – 2017. – Vol. 8. – No. 1. – P. 171–182.
10. Elmore J. G., Wells C. K., Lee C. H., et al. Variability in radiologists' interpretations of mammograms // *New England Journal of Medicine*. – 1994. – Vol. 331. – P. 1493–1499.
11. Litjens G., Kooi T., Bejnordi B. E., et al. A survey on deep learning in medical image analysis // *Medical Image Analysis*. – 2017. – Vol. 42. – P. 60–88.
12. Esteva A., Kuprel B., Novoa R. A., et al. Dermatologist-level classification of skin cancer with deep neural networks // *Nature*. – 2017. – Vol. 542. – P. 115–118.
13. Lundervold A. S., Lundervold A. An overview of deep learning in medical imaging focusing on MRI // *Zeitschrift für Medizinische Physik*. – 2019. – Vol. 29. – No. 2. – P. 102–127.
14. Litjens G. va boshq. A survey on deep learning in medical image analysis // *Medical Image Analysis*. – 2017. – Vol. 42. – P. 60–88.
15. Fawcett T. An introduction to ROC analysis // *Pattern Recognition Letters*. – 2006. – Vol. 27, № 8. – P. 861–874.
16. Fawcett T. *An introduction to ROC analysis* // *Pattern Recognition Letters*. – 2006. – Vol. 27, № 8. – P. 861–874.