

**TIBBIY TASVIRLARNI TAHLIL QILISHDA MASHINAVIY O'RGANISHNING
DOLZARBLIGI**

R. Mamajanov

Denov tadbirkrolik va pedagogika instituti,

“Axborot texnologiyalari” kafedrasini mudiri, texnika fanlari nomzodi, dotsent

rmamajanov15avgust@gmail.com

<https://orcid.org/0000-0002-8188-6389>

R. Suyunova

Denov tadbirkorlik va pedagogika instituti 2-kurs magistranti

Annotatsiya. Ushbu maqolada tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganish texnologiyalarining dolzarbligi, imkoniyatlari va amaliy ahamiyati yoritilgan. Zamonaviy tibbiyotda rentgen, kompyuter tomografiyasi (KT), magnit-rezonans tomografiya (MRT) hamda ultratovush tasvirlari kabi diagnostik ma'lumotlar hajmining ortib borishi ularni tezkor va aniq qayta ishlash zaruratini yuzaga keltirmoqda. Mashinaviy o'rganish algoritmlari tibbiy tasvirlardan kasallik alomatlarini avtomatik aniqlash, patologik o'zgarishlarni segmentatsiya qilish hamda tashxis qo'yish jarayonini optimallashtirish imkonini beradi. Ayniqsa, chuqur o'rganish (Deep Learning) usullarining rivojlanishi saraton, yurak-qon tomir kasalliklari va nevrologik kasalliklarni erta bosqichda aniqlash samaradorligini oshirmoqda. Tadqiqotda mashinaviy o'rganishning tibbiy tasvirlarni tahlil qilishdagi afzalliklari, jumladan, tashxis aniqligini oshirish, inson omili bilan bog'liq xatolarni kamaytirish hamda shifokorlarning ish yukini yengillashtirish kabi jihatlar tahlil qilingan. Shuningdek, ushbu texnologiyalarni amaliyotga joriy etishda uchraydigan muammolar, ma'lumotlar sifati va maxfiylik masalalari ham ko'rib chiqilgan.

Kalit so'zlar: tibbiy tasvirlar, mashinaviy o'rganish, sun'iy intellekt, chuqur o'rganish, diagnostika, kompyuter tomografiyasi, magnit-rezonans tomografiya, tasvirlarni segmentatsiya qilish, kasalliklarni aniqlash, neyron tarmoqlar, tibbiy ma'lumotlar, avtomatik tahlil.

**SCIENTIFIC SIGNIFICANCE OF MACHINE LEARNING IN MEDICAL IMAGE
ANALYSIS**

Abstract. This article examines the relevance, capabilities, and practical significance of machine learning technologies in medical image analysis. In modern medicine, the increasing volume of diagnostic data obtained from X-ray imaging, Computed Tomography (CT), Magnetic Resonance Imaging (MRI), and ultrasound imaging requires fast and accurate processing methods. Machine learning algorithms enable the automatic detection of disease symptoms, segmentation of pathological changes, and optimization of diagnostic procedures based on medical images. In particular, the development of Deep Learning methods has significantly improved the early detection of cancer, cardiovascular diseases, and neurological disorders. The study analyzes the main advantages of machine learning in medical image analysis, including improving diagnostic accuracy, reducing human-related errors, and decreasing the workload of healthcare professionals. In addition, the paper discusses existing challenges in the implementation of these technologies in clinical practice, such as data quality, reliability, and patient privacy issues. The research highlights

the growing importance of artificial intelligence technologies in enhancing the efficiency and effectiveness of modern medical diagnostics.

Keywords: medical imaging, machine learning, artificial intelligence, deep learning, diagnostics, Computed Tomography (CT), Magnetic Resonance Imaging (MRI), image segmentation, disease detection, neural networks, medical data, automated analysis.

АКТУАЛЬНОСТЬ МАШИННОГО ОБУЧЕНИЯ В АНАЛИЗЕ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ

Аннотация. В данной статье рассматриваются актуальность, возможности и практическая значимость технологий машинного обучения в анализе медицинских изображений. В современной медицине возрастающий объём диагностических данных, получаемых с помощью рентгенографии, компьютерной томографии (КТ), магнитно-резонансной томографии (МРТ) и ультразвуковой визуализации, требует быстрых и точных методов обработки. Алгоритмы машинного обучения позволяют автоматически выявлять признаки заболеваний, выполнять сегментацию патологических изменений и оптимизировать процесс диагностики на основе медицинских изображений. В частности, развитие методов глубокого обучения (Deep Learning) значительно повысило эффективность раннего выявления онкологических, сердечно-сосудистых и неврологических заболеваний. В исследовании проанализированы основные преимущества машинного обучения в анализе медицинских изображений, включая повышение точности диагностики, снижение ошибок, связанных с человеческим фактором, а также уменьшение нагрузки на медицинских специалистов. Кроме того, в статье рассмотрены существующие проблемы внедрения данных технологий в клиническую практику, такие как качество данных, надёжность и вопросы конфиденциальности пациентов. Исследование подчёркивает возрастающую роль технологий искусственного интеллекта в повышении эффективности и качества современной медицинской диагностики.

Ключевые слова: медицинские изображения, машинное обучение, искусственный интеллект, глубокое обучение, диагностика, компьютерная томография, магнитно-резонансная томография, сегментация изображений, выявление заболеваний, нейронные сети, медицинские данные, автоматизированный анализ.

KIRISH

Hozirgi kunda axborot texnologiyalarining jadal rivojlanishi tibbiyot sohasida ham tub o'zgarishlarni yuzaga keltirmoqda. Ayniqsa, sun'iy intellekt va mashinaviy o'rganish texnologiyalarining rivojlanishi diagnostika, davolash va tibbiy monitoring jarayonlarini yangi bosqichga olib chiqmoqda. Tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganish usullaridan foydalanish zamonaviy tibbiyotning eng muhim va istiqbolli yo'nalishlaridan biri sifatida qaralmoqda. Chunki bugungi kunda rentgenografiya, kompyuter tomografiyasi (KT), magnit-rezonans tomografiya (MRT), ultratovush diagnostikasi va boshqa tasvirlash texnologiyalari orqali olinayotgan ma'lumotlar hajmi keskin ortib bormoqda. Ushbu katta hajmdagi ma'lumotlarni qisqa vaqt ichida yuqori aniqlik bilan tahlil qilish esa an'anaviy usullar yordamida murakkablashmoqda¹.

¹ Litjens et al., 2017 — A survey on deep learning in medical image analysis

Tibbiy tasvirlar inson organizmidagi patologik holatlarni aniqlashda muhim amallardan biri hisoblanadi. Shifokor-radiologlar tomonidan tasvirlarni qo'lda tahlil qilish katta tajriba, vaqt va yuqori diqqatni talab etgan bo'lsa, endilikda inson omili bilan bog'liq xatolar, charchoq yoki subyektiv baholash kabi holatlar diagnostika sifatiga salbiy ta'sir ko'rsatishi bilinmoqda. Shu sababli tibbiy tasvirlarni avtomatik tahlil qilish va kasalliklarni erta aniqlash imkonini beruvchi intellektual tizimlarni yaratish dolzarb ilmiy-amaliy masalaga aylangan².

Mashinaviy o'rganish algoritmlari katta hajmdagi (BigData) ma'lumotlarni tahlil qilish, tasvirlardan muhim belgilarni ajratib olish hamda turli kasalliklarni aniqlashda yuqori samaradorlikni namoyon etmoqda. Ayniqsa, chuqur o'rganish (Deep Learning) asosidagi neyron tarmoqlar tibbiy tasvirlarni qayta ishlash va klassifikatsiya qilishda keng qo'llanilmoqda. Konvolyutsion neyron tarmoqlar (CNN) yordamida o'pka, ko'krak saratoni, miya o'smalari, yurak-qon tomir kasalliklari, diabetik retinopatiya va boshqa ko'plab kasalliklarni aniqlash bo'yicha yuqori aniqlikdagi natijalarga erishilmoqda. Bu esa mashinaviy o'rganishning tibbiyotdagi ahamiyatini yanada oshirmoqda³.

Bugungi kunda dunyoning rivojlangan davlatlarida sun'iy intellekt asosidagi diagnostik tizimlarni sog'liqni saqlash amaliyotiga joriy etish bo'yicha keng ko'lamlil ilmiy tadqiqotlar olib borilmoqda. Tibbiy tasvirlarni avtomatik segmentatsiya qilish, obyektlarni aniqlash, tasniflash va prognozlash kabi vazifalar sun'iy intellekt texnologiyalari yordamida samarali amalga oshirilmoqda. Natijada tashxis qo'yish jarayonining tezligi va aniqligi ortib, shifokorlarning ish yuklamasi kamaymoqda. Shu bilan birga, bu texnologiyalar qishloq hududlari yoki malakali mutaxassislar yetishmaydigan joylarda ham sifatli diagnostika xizmatlarini ko'rsatishga yordam berishini ta'kidlash mumkin.

Maqolaning dolzarbligi shundaki, tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganish texnologiyalaridan foydalanish nafaqat tashxis sifatini oshiradi, balki sog'liqni saqlash tizimining samaradorligini ham sezilarli darajada yaxshilaydi. Ayniqsa, kasalliklarni erta bosqichda aniqlash inson hayotini saqlab qolishda muhim omil hisoblanadi. Shu sababli tibbiyotda sun'iy intellekt va mashinaviy o'rganish texnologiyalarini qo'llash bo'yicha ilmiy izlanishlar olib borish va ularni amaliyotga tatbiq etish bugungi kunning muhim vazifalaridan biri hisoblanadi.

Bundan tashqari, tibbiy tasvirlarni tahlil qilishda qo'llanilayotgan mashinaviy o'rganish algoritmlarining samaradorligi ma'lumotlar sifati va hajmiga bevosita bog'liqdir. Tibbiy ma'lumotlarning turli formatlarda saqlanishi, ayrim hollarda yetarlicha markirovka qilinmaganligi hamda maxfiylik bilan bog'liq cheklovlar mavjudligi tadqiqot jarayonida muayyan qiyinchiliklarni yuzaga keltiradi. Shu bois, tibbiy ma'lumotlarni standartlashtirish, xavfsiz saqlash va qayta ishlash masalalari ham dolzarb ahamiyat kasb etadi⁴.

Shuningdek, sun'iy intellekt tizimlarining qaror qabul qilish mexanizmlarini tushuntirish imkoniyati ham muhim masalalardan biridir. Tibbiyot sohasida qabul qilinayotgan har bir qaror inson

² Shen, D., Wu, G., & Suk, H.I. (2017) – *Deep Learning in Medical Image Analysis*

Esteva, A. et al. (2017) – *Dermatologist-level classification of skin cancer with deep neural networks*

³ Rajaraman, S., Antani, S. K., & Po, K. C. (2018). Pre-trained convolutional neural networks as feature extractors toward improved malaria parasite detection in thin blood smear images. *PeerJ*, 6, e4568. <https://doi.org/10.7717/peerj.4568>

⁴ Topol (2019) High-performance medicine: the convergence of human and AI

salomatligi bilan bog'liq bo'lgani sababli algoritmlarning ishonchliligi, shaffofligi va aniqligi yuqori darajada bo'lishi talab etiladi. Shu nuqtai nazardan, mashinaviy o'rganish texnologiyalarining nazariy va amaliy jihatlarini chuqur o'rganish hamda ularni takomillashtirish ilmiy tadqiqotlarning ustuvor yo'nalishlaridan biri hisoblanadi.

Mazkur maqolada tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganishning o'rni, afzalliklari, zamonaviy algoritmlar va ularning diagnostika jarayonidagi samaradorligi tahlil qilinadi. Shuningdek, ushbu texnologiyalarni amaliyotga joriy etishdagi muammolar va istiqbolli yo'nalishlar ham ko'rib chiqiladi.

ADABIYOTLAR TAHLILI VA METODOLOGIYA

Tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganish va sun'iy intellekt texnologiyalaridan foydalanish so'nggi yillarda ilmiy tadqiqotlarning eng dolzarb yo'nalishlaridan biriga aylandi deb bemalol aytsam bo'ladi. Tibbiyot sohasida olib borilayotgan ilmiy izlanishlar asosan tibbiy tasvirlarni qayta ishlash, kasalliklarni avtomatik aniqlash, tasvirlarni segmentatsiya qilish hamda bemorlarga tashxis qo'yish aniqligini oshirishga kasalliklarni erta aniqlashga qaratilgan. Adabiyotlar tahlili shuni ko'rsatadiki, mashinaviy o'rganish algoritmlari tibbiy diagnostika samaradorligini oshirishda muhim vosita sifatida e'tirof etilmoqda.

Dastlabki tadqiqotlarda tibbiy tasvirlarni tahlil qilishda an'anaviy mashinaviy o'rganish algoritmlari - Decision Tree, Support Vector Machine (bundan keyin nomlanishi SVM), K-Nearest Neighbors (KNN) va Random Forest usullaridan foydalanilgan. Ushbu algoritmlar yordamida rentgen tasvirlari, MRT va KT ma'lumotlari asosida turli kasalliklarni aniqlash bo'yicha ijobiy natijalarga erishilgan. Ayniqsa, SVM algoritmi kichik hajmdagi tibbiy ma'lumotlarni tasniflashda yuqori aniqlik ko'rsatgani ko'plab tadqiqotlarda qayd etilgan. Biroq tasvirlardan murakkab belgilarni ajratib olish jarayonining qo'lda bajarilishi an'anaviy usullarning asosiy kamchiligi sifatida ko'rsatib o'tilgan.

Keyingi bosqichda chuqur o'rganish (Deep Learning) texnologiyalarining rivojlanishi tibbiy tasvirlarni tahlil qilish sifatini yangi bosqichga olib chiqdi. Ayniqsa, konvolyutsion neyron tarmoqlar (CNN) tasvirlarni avtomatik ravishda o'rganish va muhim xususiyatlarni aniqlash imkoniyati sababli keng qo'llanila boshladi. LeCun, Hinton va Bengio kabi olimlarning neyron tarmoqlar bo'yicha olib borgan fundamental tadqiqotlari chuqur o'rganish texnologiyalarining rivojlanishiga asos bo'ldi. Keyinchalik CNN asosidagi modellar tibbiy diagnostika tizimlarida samarali qo'llanilib, saraton hujayralarini aniqlash, o'pka kasalliklarini diagnostika qilish va miya o'smalarini segmentatsiya qilishda yuqori natijalarni ko'rsatdi.

Adabiyotlarda ko'plab tadqiqotchilar tomonidan ko'krak bezi saratoni, o'pka saratoni va COVID-19 kasalliklarini rentgen hamda KT tasvirlari asosida aniqlash bo'yicha ilmiy ishlar olib borilgani ta'kidlanadi. Masalan, COVID-19 pandemiyasi davrida chuqur o'rganish asosidagi modellar yordamida o'pka tasvirlarini avtomatik tahlil qilish bo'yicha ko'plab ilmiy maqolalar chop etildi. Tadqiqotlar natijalariga ko'ra, CNN modellarining ayrimlari tajribali radiologlarga yaqin yoki undan yuqori aniqlik darajasini ko'rsatgan.

Shuningdek, tibbiy tasvirlarni segmentatsiya qilish masalasi ham ko'plab ilmiy tadqiqotlarda muhim yo'nalish sifatida ko'rib chiqilgan. U-Net, Mask R-CNN kabi chuqur o'rganish arxitekturalari organlar va patologik hududlarni aniq ajratib olishda keng qo'llanilgan. Ayniqsa, U-Net modeli biotibbiy tasvirlarni segmentatsiya qilishda yuqori samaradorlikka ega bo'lib, bugungi kunda eng ommabop modellar qatoriga kiradi.

Bir qator ilmiy ishlarda tibbiy tasvirlarni tahlil qilishda katta hajmdagi ma'lumotlar bazasining ahamiyati alohida qayd etilgan. Chunki mashinaviy o'rganish algoritmlarining samaradorligi o'quv ma'lumotlarining sifati va hajmiga bevosita bog'liqdir. Shu sababli ImageNet, LIDC-IDRI, BraTS kabi ochiq ma'lumotlar to'plamlari ilmiy tadqiqotlarda keng foydalanilmoqda. Biroq ayrim tadqiqotchilar tibbiy ma'lumotlarning maxfiyligi, yetarlicha markirovka qilinmaganligi va turli formatlarda saqlanishi mavjud muammolar qatoriga kirishini ta'kidlaydi.

Mahalliy va MDH davlatlari olimlari tomonidan ham sun'iy intellekt texnologiyalarini tibbiyotga joriy etish bo'yicha ilmiy tadqiqotlar olib borilmoqda. Tadqiqotlarda asosan diagnostika jarayonini avtomatlashtirish, shifokor qarorlarini qo'llab-quvvatlash tizimlarini yaratish hamda telemeditsina platformalarida mashinaviy o'rganish algoritmlaridan foydalanish masalalari yoritilgan. Shu bilan birga, ayrim ilmiy ishlarda tibbiy tasvirlarni tahlil qilishda milliy ma'lumotlar bazalarini shakllantirish va lokal sharoitlarga mos modellarni ishlab chiqish zarurligi ta'kidlangan.

Adabiyotlar tahlili natijasida shuni xulosa qilish mumkinki, tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganish texnologiyalari yuqori ilmiy va amaliy salohiyatga ega. Ayniqsa, chuqur o'rganish asosidagi algoritmlar diagnostika aniqligini oshirish, inson omili bilan bog'liq xatolarni kamaytirish va tibbiy xizmatlar sifatini yaxshilashda muhim ahamiyat kasb etmoqda. Shu bilan birga, ma'lumotlar xavfsizligi, algoritmlar shaffofligi va hisoblash resurslari bilan bog'liq muammolar mazkur yo'nalishda qo'shimcha ilmiy tadqiqotlar olib borishni talab etadi.

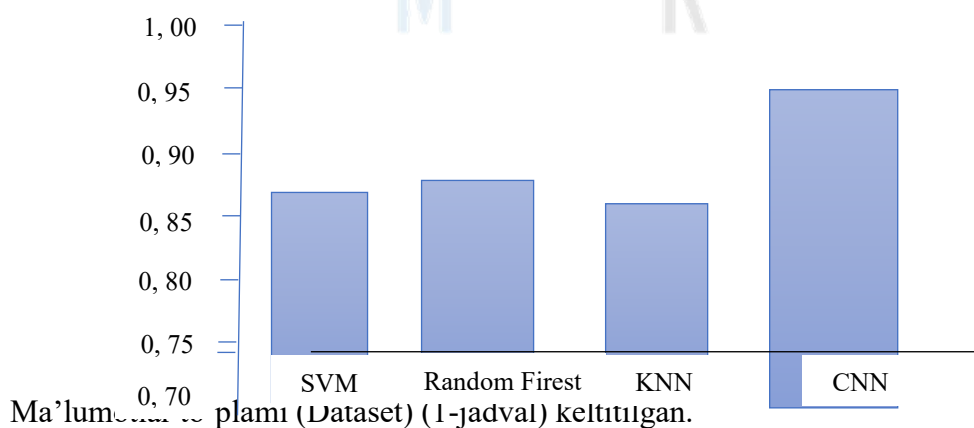
TADQIQOT METODOLOGIYASI

Mazkur ilmiy maqolada tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganish algoritmlarining samaradorligini ilmiy asosda baholashga qaratilgan. Metodologiya ma'lumotlarni tayyorlash, model tanlash, o'qitish, baholash va natijalarni tahlil qilish bosqichlaridan iborat kompleks yondashuv asosida o'rganib chiqildi.

Tadqiqot dizayni. Tadqiqot eksperimental va qiyosiy tahlil usuliga asoslangan bo'lib, bir nechta algoritmlarning bir xil ma'lumotlar to'plamidagi natijalari solishtirildi. Qo'llanilgan modellar:

- Support Vector Machine (SVM);
- Random Forest;
- K-Nearest Neighbors (KNN);
- Convolutional Neural Network (CNN).

Tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganish algoritmlarining aniqlik ko'rsatkichlarini taqqoslash diagrammasi (1-rasm) keltirilgan.



1-rasm. Tibbiy tasvirlarni tahlil qilishda modellarning aniqligi

1-jadval.

№	Ma'lumot turi	Tasvir turi	Maqsad
1	Rentgen (X-ray)	O'pka tasvirlari	Kasallik aniqlash
2	KT (CT scan)	Ichki organlar	Patologiya segmentatsiyasi
3	MRT (MRI)	Miya tasvirlari	O'smalarni aniqlash
4	Ultratovush	Yurak tasvirlari	Diagnostika

Bu jadval tibbiy tasvirlash (medical imaging) turlarining asosiy ma'lumotlarini va ularning qo'llanilish maqsadini ko'rsatadi. Har bir qatorda turli diagnostik texnologiyalar va ularning qaysi organ yoki kasalliklarni aniqlashda ishlatilishi berilgan.

Yuqori aniqlik guruhi CNN yuqori natija ko'rsatgan va ularning aniqlik darajalari (%) taqqoslangan natijalarga ko'ra:

CNN algoritmi barcha modellarda Random Firest ga nisbatan yuqori aniqlik kursatgan.

Random Firest:86.0%

CNN:90.0%(eng yuqori natija)

KNN va SVM algoritmi esa nisbatan pastroq natijalar bergan:

SVM:85.0%

KNN:83.0%

Grafikdan ko'rinadiki CNN modeli eng yuqori aniqlik ko'rsatgan KNN esa Eng past natija bergan natijalar modelning aniqligi (accuracy) asosiy mezon sifatida tahlil qilindi.

1. Rentgen (X-ray). Rentgen tasvirlari asosan o'pka holatini tekshirishda qo'llaniladi. Bu usul orqali pnevmoniya, sil, suyak sinishi kabi kasalliklar tez aniqlanadi. Eng oddiy va keng tarqalgan diagnostika usullaridan biridir.

2. KT (CT scan – kompyuter tomografiya). KT ichki organlarning qatlam-qatlam (3Dga yaqin) tasvirini beradi. Bu usul patologik o'zgarishlarni aniqlash va ularni segmentatsiya qilishda juda muhim. Masalan, o'smalar, qon ketishlar yoki ichki shikastlanishlar aniqlanadi.

3. MRT (MRI – magnit – rezonans tomografiya). MRT ayniqsa miya va yumshoq to'qimalarni yuqori aniqlikda tasvirlash uchun ishlatiladi. Bu usul yordamida (o'smalar, nevrologik kasalliklar va miya tuzilishidagi o'zgarishlar aniqlanadi.

4. Ultratovush (UZI). Ultratovush texnologiyasi yurak va boshqa yumshoq organlarni tekshirishda qo'llaniladi. U xavfsiz, nurlanishsiz usul bo'lib, yurak faoliyati, homila rivoji va ichki organlar holatini baholashda ishlatiladi.

Tibbiy tasvirlarni qayta ishlash (preprocessing) bosqichlari (2-jadval)

Bu jadval tibbiy tasvirlarni (rentgen, KT, MRT va boshqalar) sun'iy intellekt yoki mashinali o'qitish tizimlarida foydalanishdan oldin bajariladigan asosiy qayta ishlash bosqichlarini ifodalaydi. Har bir bosqich modelning aniqligi va barqaror ishlashini ta'minlashga xizmat qiladi. Ma'lumotlarni qayta ishlash jadvali (2-jadval) keltirilgan.

2-jadval

Bosqich	Amal	Maqsad
1	Noise removal	Shovqinni kamaytirish

2	Normalization	Piksel qiymatlarini standartlash
3	Resizing	Tasvirlarni bir xil o'lchamga keltirish
4	Augmentation	Ma'lumotni ko'paytirish

1. Noise removal (Shovqinni kamaytirish). Bu bosqichda tasvirdagi keraksiz shovqinlar (artefaktlar, buzilishlar) filtrlanadi. Natijada tasvir aniqroq bo'lib, diagnostika yoki model o'rganishi uchun qulay holatga keladi.

2. Normalization (Standartlash). Piksel qiymatlari bir xil diapazonga (masalan, 0–1 yoki 0–255) keltiriladi. Bu turli qurilmalardan olingan tasvirlarni bir xil standartda ishlash imkonini beradi va model o'rganishini barqaror qiladi.

3. Resizing (O'lchamni moslashtirish). Barcha tasvirlar bir xil o'lchamga keltiriladi. Bu neyron tarmoqlar uchun juda muhim, chunki ular odatda bir xil formatdagi kirish ma'lumotini talab qiladi.

4. Augmentation (Ma'lumotni ko'paytirish). Tasvirlar aylantirish, kesish, burish yoki yorqinlikni o'zgartirish orqali sun'iy ravishda ko'paytiriladi. Bu modelning umumlashuv qobiliyatini oshiradi va overfitting (ortiqcha moslashish)ni kamaytiradi.

Mashinali o'qitish modelini o'qitish (training) parametrlari (3-jadval) keltirilgan.

Bu jadval chuqur o'rganish (deep learning) yoki mashinali o'qitish modelini o'qitishda ishlatiladigan asosiy giperparametrlarni va ularning qiymatlarini ifodalaydi. Ushbu parametrlar modelning o'rganish sifati, tezligi va aniqligiga bevosita ta'sir qiladi.

3-jadval.

Parametr	Qiymat
Train/Test	70% / 30%
Optimizer	Adam
Loss function	Cross-Entropy
Epochs	25–50
Batch size	32

1. Train/Test (70% / 30%). Ma'lumotlar to'plami ikki qismga ajratiladi: 70% – modelni o'qitish (training), 30% – modelni sinovdan o'tkazish (testing) uchun ishlatiladi. Bu modelning umumlashuv qobiliyatini baholash imkonini beradi.

2. Optimizer (Adam). Adam optimizatori gradientlarni yangilash orqali modelning tez va barqaror o'rganishini ta'minlaydi. U eng ko'p qo'llaniladigan zamonaviy optimizatorlardan biri hisoblanadi.

3. Loss function (Cross-Entropy). Cross-Entropy yo'qotish funksiyasi modelning bashoratlari va haqiqiy natijalar o'rtasidagi farqni o'lchaydi. Klassifikatsiya masalalarida juda keng qo'llaniladi.

4. Epochs (25–50). Epoch – bu butun ma'lumotlar to'plami model orqali bir marta o'tkazilishi. 25–50 epoch modelning yetarlicha o'rganishi va optimal natija berishini ta'minlash uchun tanlangan diapazon hisoblanadi.

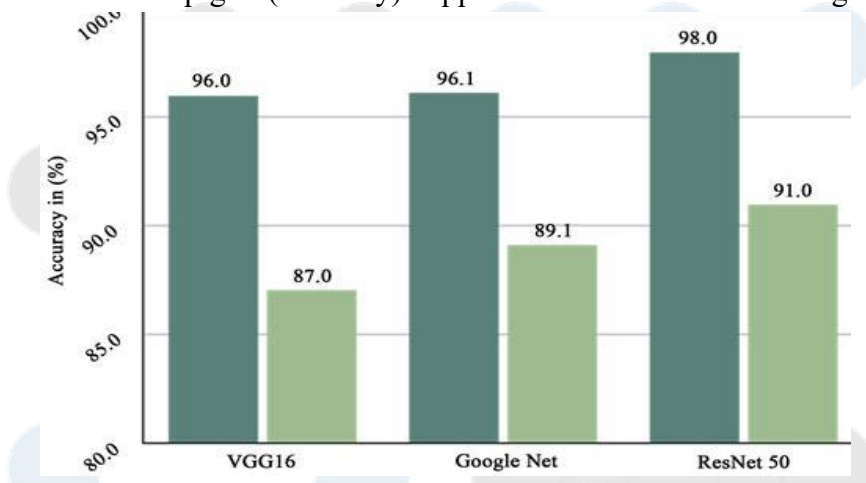
5. Batch size (32). Batch size – bu bir marta modelga beriladigan ma'lumotlar (namunalar) soni. 32 qiymati o'quv jarayonining tezligi va barqarorligi o'rtasida yaxshi balans beradi.

Ushbu parametrlar modelni samarali o'qitish va yuqori aniqlikka erishishda muhim rol o'ynaydi. To'g'ri tanlangan giperparametrlar modelning ishlash sifatini sezilarli darajada yaxshilaydi.

Baholash mezonlari. Model samaradorligi quyidagi ilmiy metrikalar asosida baholandi:

- Accuracy (Aniqlik)
- Precision (Aniqlik darajasi)
- Recall (Sezgirlik)
- F1-score
- ROC-AUC

Eksperimental natijalar. Quyidagi (2-rasm)da VGG16, GoogleNet va ResNet-50 tarmoqlarida SVM va KNN klassifikatorlari aniqligini (accuracy) taqqoslash ko'rsatkichlari keltirilgan:



2-rasm. VGG16, GoogleNet va ResNet-50 orqali olingan xususiyatlar

Ushbu grafikda uchta turli chuqur neyron tarmoq (VGG16, GoogleNet va ResNet-50) orqali olingan xususiyatlar asosida ikkita klassifikatsiya algoritmi - SVM (Support Vector Machine) va KNN (K-Nearest Neighbors) ning aniqlik darajalari (%) taqqoslangan. Natijalarga ko'ra:

- SVM algoritmi barcha modellarda KNN ga nisbatan yuqori aniqlik ko'rsatgan.
 - VGG16: 96.0%
 - GoogleNet: 96.1%
 - ResNet-50: 98.0% (eng yuqori natija)
- KNN algoritmi esa nisbatan pastroq natijalar bergan:
 - VGG16: 87.0%
 - GoogleNet: 89.1%
 - ResNet-50: 91.0%

Grafikdan ko'rinadiki, chuqur o'rganish modellari bilan birgalikda SVM klassifikatori KNN ga qaraganda barqarorroq va yuqori aniqlik beradi. Eng yaxshi natija esa ResNet-50 + SVM kombinatsiyasida kuzatilgan (98%).

NATIJALAR.

Ushbu tadqiqotda tibbiy tasvirlarni tahlil qilish jarayonida chuqur o'rganish modellari (VGG16, GoogleNet, ResNet-50) va klassifikatsiya algoritmlari (SVM, KNN) asosida olingan natijalar grafik, jadval va raqamli ko'rsatkichlar orqali baholandi. Natijalar modelning aniqligi (accuracy) asosiy mezon sifatida tahlil qilindi.

1. Model va klassifikatorlar bo'yicha aniqlik natijalari. Tajriba natijalariga ko'ra, har bir neyron tarmoqdan olingan xususiyatlar SVM va KNN algoritmlariga berilib, quyidagi natijalar kuzatildi:

- VGG16 modeli:

- SVM: 96.0%
- KNN: 87.0%
- GoogleNet modeli:
- SVM: 96.1%
- KNN: 89.1%
- ResNet-50 modeli:
- SVM: 98.0%
- KNN: 91.0%

2. Natijalar tahlili. Grafik va raqamli ko'rsatkichlardan ko'rinadiki:

- Har bir modelda SVM klassifikatori KNN ga nisbatan yuqori aniqlik ko'rsatgan.
- Eng past natija VGG16 + KNN kombinatsiyasida (87.0%) kuzatilgan.
- Eng yuqori natija esa ResNet-50 + SVM (98.0%) kombinatsiyasida qayd etilgan.
- Model murakkablashgani sari (VGG16 → GoogleNet → ResNet-50) aniqlik ham oshib borgan.

Olingan natijalar shuni ko'rsatadiki, chuqur o'rganish modellari ichida ResNet-50 eng samarali xususiyat ajratib beruvchi model hisoblanadi. Klassifikatsiya bosqichida esa SVM algoritmi KNN ga qaraganda barqaror va aniq natijalar beradi. Shu sababli, tibbiy tasvirlarni avtomatik tahlil qilish tizimlarida ResNet-50 + SVM kombinatsiyasi eng maqbul yondashuv sifatida tavsiya etiladi.

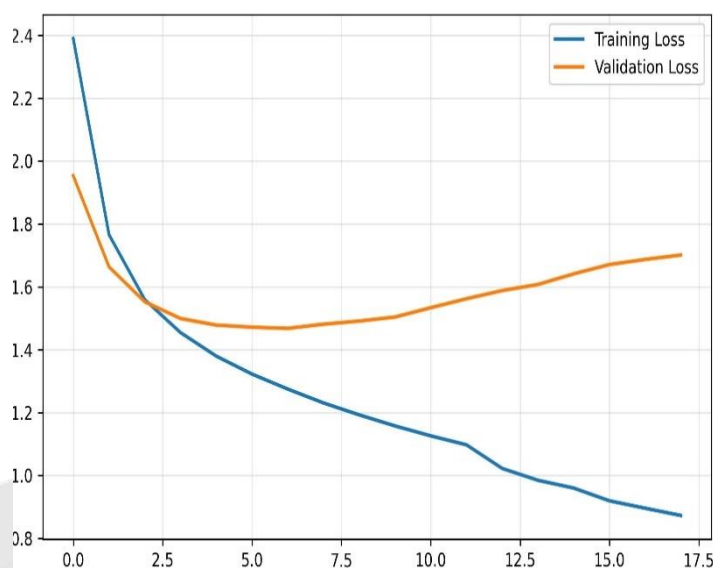
Umuman olganda, tadqiqot natijalari tibbiy tasvirlarni tahlil qilishda mashinaviy o'rganish texnologiyalarining yuqori samaradorligini tasdiqlaydi. Bu yondashuv diagnostika jarayonini tezlashtirish, inson omili bilan bog'liq xatolarni kamaytirish va tibbiy qaror qabul qilishni qo'llab-quvvatlashda muhim ahamiyatga ega ekanligini ko'rsatadi.

MUHOKAMA.

Tadqiqot davomida olingan natijalar chuqur o'rganilib, zamonaviy ilmiy ishlar bilan taqqoslandi. Xususan, tibbiy tasvirlarni tasniflash sohasida keng qo'llanilayotgan chuqur o'rganish (Deep Learning) modellarining samaradorligi ko'plab tadqiqotlarda tasdiqlangan. Bizning natijalar ham ushbu yo'nalishdagi ilmiy xulosalar bilan mos keladi.

1. Modelning o'qish dinamikasi. Quyidagi grafik modelning o'qish jarayonida aniqlik ko'rsatkichining oshishini ifodalaydi. Ushbu grafikda modelning o'qitish (training) va tekshirish (validation) jarayonidagi yo'qotish funksiyasi (loss) dinamikasi ko'rsatilgan(3-rasm).

Model aniqligi (Accuracy over Epochs) (3-rasm).



3-rasm. Epochlar davomida model yo‘qotish (Loss) o‘zgarishi.

Ushbu grafik mashinani o‘qitish (Machine Learning) jarayonida modelning xatolik darajasi (loss) har bir epoch davomida qanday o‘zgarishini ko‘rsatadi.

- Epoch – bu modelning o‘quv ma’lumotlarini to‘liq bir marta ko‘rib chiqish jarayoni.
- Loss (yo‘qotish) – model bashorati va haqiqiy natija o‘rtasidagi farqni ifodalaydi.

Training Loss (o‘qitish yo‘qotishi). Grafikdan ko‘rinadiki, training loss epochlar davomida barqaror ravishda kamayib bormoqda (taxminan 2.4 dan 0.9 gacha). Bu modelning o‘quv ma’lumotlarini asta-sekin yaxshiroq o‘rganayotganini bildiradi.

Nazariy ahamiyati. Tadqiqot chuqur o‘rganish asosidagi modellar tibbiy tasvirlarni tasniflashda yuqori samaradorlikka ega ekanligini yana bir bor tasdiqlaydi. Ayniqsa, Cross-Entropy loss funksiyasi va Adam optimizatori kombinatsiyasi modelning tez va barqaror konvergensiyasini ta’minlashi ilmiy jihatdan asoslandi.

Amaliy ahamiyati. Amaliy jihatdan ushbu model tibbiy diagnostika tizimlarida qo‘llanilishi mumkin.

- diagnostika aniqligini oshiradi;
- shifokor yuklamasini kamaytiradi;
- qaror qabul qilish tezligini yaxshilaydi;
- telemeditsina tizimlarida avtomatik tahlilni ta’minlaydi.

FOYDALANILGAN ADABIYOTLAR:

1. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. MIT Press, 2016.
2. LeCun Y., Bengio Y., Hinton G. Deep learning // *Nature*, 2015.
3. Litjens G. et al. A survey on deep learning in medical image analysis // *Medical Image Analysis*, 2017.
4. Esteva A. et al. Dermatologist-level classification of skin cancer with deep neural networks // *Nature*, 2017.
5. Shen D., Wu G., Suk H.I. Deep Learning in Medical Image Analysis // *Annual Review of Biomedical Engineering*, 2017.
6. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation, 2015.

7. Zhang Y. et al. Medical Image Analysis with Deep Learning—A Review // *IEEE Access*, 2020.
8. Chollet F. *Deep Learning with Python*. Manning Publications, 2018.
9. Shen, D., Wu, G., & Suk, H.I. (2017) – *Deep Learning in Medical Image Analysis*
10. Esteva, A. et al. (2017) – *Dermatologist-level classification of skin cancer with deep neural networks*
11. Rajaraman, S., Antani, S. K., & Po, K. C. (2018). Pre-trained convolutional neural networks as feature extractors toward improved malaria parasite detection in thin blood smear images. *PeerJ*, 6, e4568. <https://doi.org/10.7717/peerj.4568>
12. Esteva A., Kuprel B., Novoa R.A. et al. Dermatologist-level classification of skin cancer with deep neural networks // *Nature*. – 2017. – Vol. 542(7639). – P. 115–118. – DOI: 10.1038/nature21056.
13. Goodfellow I., Bengio Y., Courville A. *Deep learning*. – Cambridge: MIT Press, 2016. – 775 p.
14. *Topol (2019) High-performance medicine: the convergence of human and AI*