## SUN'IY INTELLEKT TEXNOLOGIYALARINING GISTOLOGIK DAGNOSTIKADAGI O'RNI VA ISTIQBOLLARI

**Rajabova Sabrina** – talaba
*Toshkent davlat tibbiyot universiteti (Toshkent, O'zbekiston)*

***Annotatsiya.*** *Ushbu maqolada zamonaviy gistologik diagnostikada sun'iy intellekt (SI) texnologiyalarining o'rni, erishilgan natijalar va sohaning rivojlanish istiqbollari tahlil qilinadi. Tadqiqot davomida konvolyutsion neyron tarmoqlari (CNN) va "chuqur o'rganish" (Deep Learning) algoritmlarining patologik to'qimalarni tahlil qilishdagi samaradorligi ko'rib chiqilgan. Natijalar shuni ko'rsatadiki, SI tizimlari diagnostika aniqligini oshirish bilan birga, shifokorlarning ish yukini kamaytirish va subyektiv xatoliklarning oldini olishda muhim vosita hisoblanadi. Maqolada, shuningdek, raqamli patologiyani amaliyotga joriy etishdagi mavjud to'siqlar va kelajakdagi multimodal diagnostika imkoniyatlari muhokama qilinadi.*

***Kalit so'zlar:*** *sun'iy intellekt, gistologiya, raqamli patologiya, chuqur o'rganish, neyron tarmoqlari, onkologik diagnostika, Whole Slide Imaging (WSI), avtomatlashtirilgan tahlil.*

## РОЛЬ И ПЕРСПЕКТИВЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ГИСТОЛОГИЧЕСКОЙ ДИАГНОСТИКЕ

**Раджабова Сабрина** – студентка
*Ташкентский государственный медицинский университет (Ташкент, Узбекистан)*

***Аннотация****. В данной статье анализируются роль, достигнутые результаты и перспективы применения технологий искусственного интеллекта (ИИ) в современной гистологической диагностике. В ходе исследования рассмотрена эффективность алгоритмов глубокого обучения (Deep Learning) и сверточных нейронных сетей (CNN) при анализе патологических тканей. Полученные данные показывают, что системы ИИ способны существенно повысить точность диагностики, снизить нагрузку на врачей-патологов и минимизировать влияние субъективных ошибок. Также в статье обсуждаются существующие препятствия внедрению цифровой патологии в клиническую практику и перспективы развития мультимодальной диагностики на основе интеграции морфологических, молекулярных и клинических данных.*

***Ключевые слова****: искусственный интеллект, гистология, цифровая патология, глубокое обучение, нейронные сети, онкологическая диагностика, Whole Slide Imaging (WSI), автоматизированный анализ.*

## THE ROLE AND PROSPECTS OF ARTIFICIAL INTELLIGENCE TECHNOLOGIES IN HISTOLOGICAL DIAGNOSTICS

**Rajabova Sabrina** – student
*Tashkent State Medical University (Tashkent, Uzbekistan)*

***Abstract.*** *This article analyzes the role, current achievements, and future prospects of artificial intelligence (AI) technologies in modern histological diagnostics. The study examines the effectiveness of deep learning algorithms and convolutional neural networks (CNNs) in the analysis of pathological tissues. The results demonstrate that AI systems significantly improve diagnostic accuracy, reduce the workload of pathologists, and minimize subjective errors. The article also discusses the current challenges of implementing digital pathology in clinical practice and explores the future potential of multimodal diagnostics based on the integration of morphological, molecular, and clinical data.*

***Keywords****: artificial intelligence, histology, digital pathology, deep learning, neural networks, oncological diagnostics, Whole Slide Imaging (WSI), automated analysis.*

**Kirish.**

Gistologik diagnostikaning klassik muammolari va yangi davr ehtiyoji. Zamonaviy tibbiyotda gistologik tahlillar kasalliklarni aniqlash, ayniqsa, onkologik patologiyalarga yakuniy tashxis qo'yishda "oltin standart" hisoblanadi. Biroq, an'anaviy mikroskopik tahlil jarayoni patolog-shifokordan o'ta yuqori konsentratsiya, uzoq vaqt va ko'p yillik klinik tajriba talab etadi. Dunyo miqyosida onkologik kasallanishlar sonining ortishi va malakali patologlar yetishmovchiligi diagnostika tizimiga og'irlik tushirmoqda. Shifokorlar o'rtasidagi subyektiv qarashlar (inter-observer variability) va charchoq omili tashxis aniqligiga ta'sir ko'rsatishi mumkin bo'lgan kognitiv xatoliklarga sabab bo'lishi mumkin [1]. Shu nuqtai nazardan, raqamli patologiya (Digital Pathology) va sun'iy intellekt (SI) texnologiyalarini gistologik diagnostikaga tatbiq etish tibbiyotning eng ustuvor strategik yo'nalishlaridan biriga aylandi.

Raqamli patologiya va neyron tarmoqlarining imkoniyatlari. Sun'iy intellekt, xususan, "chuqur o'rganish" (Deep Learning) va konvolyutsion neyron tarmoqlari (CNN) gistologik preparatlarning yuqori aniqlikdagi raqamli nusxalarini (Whole Slide Images

- WSI) tahlil qilishda mislsiz imkoniyatlarni taqdim etmoqda [2]. WSI texnologiyasi an'anaviy shisha slaydlarni terabaytlab hajmdagi ma'lumotlarga aylantiradi, SI algoritmlari esa ushbu ulkan ma'lumotlar ichidan inson ko'zi ilg'ashi deyarli imkonsiz bo'lgan mikroskopik o'zgarishlarni — yadro polimorfizmini, stroma va epiteliy o'rtasidagi nozik chegaralarni hamda minimal mitotik faollikni yuqori aniqlikda segmentatsiya qiladi.

SI algoritmlarining klinik samaradorligi. So'nggi yillar statistikasi shuni ko'rsatadiki, SI algoritmlari saraton hujayralarini klassifikatsiya qilishda tajribali mutaxassislar bilan raqobatlash darajasiga yetgan. Algoritmlarning afzalligi shundaki, ular "charchoq" nima ekanligini bilmaydi va har bir slaydni bir xil matematik aniqlikda tahlil qiladi [3]. Masalan, sut bezi saratoni metastazlarini limfa tugunlarida aniqlash yoki prostat bezidagi Gleson shkalasi bo'yicha darajalashda algoritmlarning samaradorligi 90-95% gacha aniqlikni qayd etmoqda [4]. Bundan tashqari, SI "bashoratli onkologiya"da ham yangi sahifa ochmoqda: oddiy gistologik tasvirlar orqali o'simtaning genetik mutatsiyalarini (masalan, o'pka saratonida EGFR yoki sut bezida HER2 holati) tahlil qilish bo'yicha tadqiqotlar ijobiy natijalar bermoqda.

**Texnik to'siqlar va "Qora quti" muammosi.** Shunga qaramay, sohani to'liq raqamlashtirishda bir qator to'siqlar mavjud. Birinchidan, WSIning standartlashtirilmaganligi — turli skanerlar va bo'yash usullari tasvir ranglarining farqlanishiga olib keladi, bu esa algoritmlarning xato qilishi (overfitting)ga sabab bo'lishi mumkin. Ikkinchidan, SI qarorlarining "tushunarsizligi" (Black Box muammosi) — algoritm nima uchun aynan shu hududni saraton deb topganini shifokorga tushuntirib bera olmasligi ishonch masalasini keltirib chiqaradi.

Tadqiqotning maqsad va vazifalari. Ushbu maqolaning maqsadi — gistologik diagnostikada SI texnologiyalarining hozirgi holatini tizimli tahlil qilish, ularning klinik amaliyotdagi afzalliklari va mavjud texnik-huquqiy to'siqlarni o'rganish hamda sohaning kelajakdagi istiqbollarini prognoz qilishdan iborat. Tadqiqot davomida algoritmlarni o'qitishda qo'llaniladigan ma'lumotlar bazasining (ground truth) sifatini oshirish, "tushuntiriladigan sun'iy intellekt" (XAI) modellarini yaratish va shifokor-AI hamkorligining bioetik jihatlariga alohida e'tibor qaratiladi. Bizning fikrimizcha, SI shifokorning o'rnini bosuvchi kuch emas, balki uning diagnostik imkoniyatlarini kengaytiruvchi eng samarali "ikkinchi fikr" (second opinion) vositasidir. Sun'iy intellektning gistologiyaga kirib kelishi shunchaki texnik yangilanish emas, balki patologiya fanining fundamental transformatsiyasidir. Hozirgi kunda rivojlangan davlatlarda "Virtual mikroskopiya" tizimlariga o'tish orqali markazlashgan diagnostika tarmoqlari shakllanmoqda. Bu tizim chekka hududlardagi shifoxonalardan olingan raqamli slaydlarni dunyoning istalgan nuqtasidagi ekspert-markazlarga soniyalar ichida yuborish va algoritmlar yordamida dastlabki saralashdan (triage) o'tkazish imkonini beradi. Bunday yondashuv diagnostika vaqtini 30-40% ga qisqartirib, saratonni barvaqt aniqlash ko'rsatkichlarini sezilarli darajada yaxshilaydi.

Zamonaviy onkologiyada "bir xil tashxis – bir xil davo" tamoyili o'tmishda qolmoqda. Bugungi kunda SI yordamida amalga oshiriladigan Multiparametrik tahlil o'simta hujayralarining nafaqat turini, balki ularning immun mikromuhit bilan bo'lgan o'zaro aloqasini ham miqdoriy baholash imkonini beradi. Masalan, o'simta infiltratsiya qiluvchi limfotsitlar (TILs) zichligini aniqlashda SI inson ko'zi bilan qilinadigan subyektiv baholashdan ko'ra bir necha barobar aniqroq natija beradi. Bu esa har bir bemor uchun individual immunoterapiya yoki maqsadli (target) terapiya sxemalarini aniq hisobkitoblar asosida tanlash imkonini yaratadi.

Patolog-shifokor ish kunining deyarli yarmini normada bo'lgan yoki diagnostik jihatdan oddiy hisoblangan namunalarni ko'zdan kechirishga sarflaydi. SI algoritmlari ushbu rutin ishlarni o'z zimmasiga olgan holda, "manfiy" (sog'lom) namunalarni avtomatik saralaydi va mutaxassis e'tiborini faqat murakkab, shubhali va yuqori malaka talab etadigan holatlarga qaratishga yordam beradi. Bu nafaqat tibbiyot muassasalarining iqtisodiy samaradorligini oshiradi, balki shifokorlarning professional "yonishi" (burnout syndrome) oldini olishda ham muhim ijtimoiy rol o'ynaydi.

**Adabiyotlar tahlili**

Gistologik tasvirlarni tahlil qilishda sun'iy intellekt (SI) tizimlarini qo'llash bo'yicha dunyo miqyosida keng ko'lamli ilmiy-tadqiqot ishlari olib borilmoqda. Ushbu yo'nalishdagi adabiyotlar tahlili shuni ko'rsatadiki, tadqiqotlar asosan neyron tarmoqlarining tasvirni aniqlash aniqligini oshirish va diagnostika vaqtini qisqartirishga qaratilgan.

C.S. Mayo va uning hammualliflari ta'kidlashicha, SI nafaqat diagnostik vosita, balki patologning ish yukini 30-40% gacha kamaytiruvchi yordamchi tizimdir [5]. Tadqiqotlar shuni ko'rsatadiki, chuqur o'rganish (Deep Learning) modellari gistologik kesmalarda mitoz figuralarini va yadro atipiyasini aniqlashda inson omilidan ko'ra barqarorroq natija beradi [6].

Shuningdek, so'nggi yillardagi izlanishlar "Gleron shkalasi" (Gleason grading) bo'yicha prostat bezi saratonini darajalashda algoritmlarning klinik ahamiyatini isbotlamoqda. Xususan, N. Coudray va boshqalar o'z ishlarida o'pka adenokarsinomasi va yassi hujayrali karsinomani differensial diagnostika qilishda CNN (Konvolyutsion neyron tarmoqlari) samaradorligini 97% dan yuqori ekanligini qayd etishgan [7]. Biroq, ko'plab mualliflar, jumladan A. Madabhushi, SIning klinik amaliyotga keng joriy etilishidagi asosiy to'siq sifatida algoritmlarning "tushunarsizligi" (Black Box muammosi) va turli laboratoriyalardan olingan preparatlarni standartlashtirish muammosini ko'rsatib o'tishadi [8].

**Gistologik diagnostikada SI samaradorligi bo‘yicha asosiy tadqiqotlarning qiyosiy tahlili**

| Muallif va yil | Tadqiqot obyekti / Patologiya | Qo‘llanilgan metod (Algorithm) | Asosiy natija va xulosalar |
|---|---|---|---|
| Bejnordi et al. (2017) | Sut bezi saratoni (Metastazlar) | Deep Learning (CNN) | Algoritmlar patologlardan ko‘ra yuqori sezgirlikni namoyon etdi [9]. |
| Coudray et al. (2018) | O‘pka saratoni turlari | Inception-v3 neyron tarmog‘i | Mutatsiyalarni tasvir asosida 99% aniqlikda bashorat qildi [7]. |
| Nagpal et al. (2019) | Prostat bezi biopsiyasi | Deep Learning System | Gleson darajalashda shifokorlar o‘rtasidagi nomuvofiqlikni kamaytirdi [10]. |
| Campanella et al. (2019) | Turli a’zolar (Katta hajmli ma’lumotlar) | Multiple Instance Learning | Katta hajmli (Slide-level) tahlillarda yuqori samaradorlik ko'rsatdi [11]. |

**Metodologiya**

Ushbu tadqiqot gistologik diagnostikada sun’iy intellekt modellarining samaradorligini baholash uchun kompleks tahlil usullariga tayanadi. Tadqiqot jarayoni quyidagi bosqichma-bosqich metodologiyadan tashkil topgan.

**1. Ma’lumotlarni to‘plash va raqamlashtirish**

Tadqiqotning asosi sifatida "Whole Slide Imaging" (WSI) texnologiyasi yordamida skanerlangan yuqori aniqlikdagi (odatda 20x yoki 40x kattalashtirishda) gistologik preparatlar olindi. Raqamli tasvirlar turli laboratoriya sharoitlaridagi o‘zgaruvchanlikni (bo‘yash intensivligi, skaner turi) hisobga olish uchun ko‘p markazli ochiq ma’lumotlar bazalaridan (TCGA, CAMELYON16/17) hamda mahalliy klinik arxivlardan shakllantirildi. Har bir tasvirga malakali patologlar tomonidan "Ground Truth" (haqiqiy etalon tashxis) sifatida belgilar (annotations) qo‘yildi. Tadqiqotning asosi sifatida "Whole Slide Imaging" (WSI) texnologiyasi yordamida skanerlangan yuqori aniqlikdagi gistologik preparatlar olindi. Raqamli tasvirlar turli laboratoriya sharoitlaridagi o‘zgaruvchanlikni hisobga olish uchun ko‘p markazli ma’lumotlar bazalaridan (masalan, TCGA — The Cancer Genome Atlas) shakllantirildi [12].

**2. Ma’lumotlarga dastlabki ishlov berish (Preprocessing)**

Gistologik tasvirlar gigapikselli o‘lchamga ega bo‘lgani sababli, ularni tahlil qilish uchun “Patch-based” yondashuv qo‘llanildi.

- **Stain Normalization.** Turli laboratoriyalarda gematoksilin va eozin ranglarining farqlanishini Macenko yoki Vahadane metodlari yordamida standartlashtirildi. Bu modelning rangga emas, balki to‘qima morfologiyasiga e’tibor qaratishini ta’minlaydi.
- **Data Augmentation.** Modelning barqarorligini (robustness) oshirish uchun patchlarga tasodifiy burish, o‘lchamni o‘zgartirish, shovqin qo‘shish va yorqinlikni o‘zgartirish kabi operatsiyalar qo‘llanildi. Bu algoritmning kam uchraydigan morfologik tuzilmalarni ham taniy olishiga yordam beradi.

Gistologik tasvirlar juda katta hajmli (bir necha gigabayt) bo‘lganligi sababli, ular kichikroq bo‘laklarga — **patchlarga** (odatda 256x256 yoki 512x512 pikselli) bo‘lindi. Shuningdek, turli mikroskoplardagi rang farqlarini yo‘qotish maqsadida tasvirlarni rang normalizatsiyasi (Stain Normalization) metodlari qo‘llanildi [13].

**3. Algoritmni tanlash va arxitekturani shakllantirish**

Tadqiqotda tasvirni segmentatsiya qilish uchun **U-Net** (hujayra chegaralarini aniqlashda samarali) va klassifikatsiyalash uchun **EfficientNet** arxitekturalari tanlab olindi.

- **Transfer Learning:** Modellar ImageNet kabi ulkan bazalarda oldindan o‘qitilgan vaznlar bilan initsializatsiya qilindi, bu esa o‘qitish vaqtini qisqartiradi va kichikroq tibbiy ma’lumotlar bilan ham yuqori natijaga erishish imkonini beradi.
- **Multiple Instance Learning (MIL).** Gistologik slaydning barcha qismlari ham saraton hujayralariga ega bo‘lmasligi mumkin. MIL yordamida algoritm slaydning qaysi patchlari tashxis uchun eng muhim ekanligini “e’tibor mexanizmi” orqali o‘zi aniqlashga o‘rgatildi.

Tadqiqotda tasvirni segmentatsiya qilish va klassifikatsiyalash uchun konvolyutsion neyron tarmoqlarining (CNN) zamonaviy arxitekturalari (ResNet, U-Net yoki EfficientNet) tanlab olindi. Ushbu modellar "Transfer Learning" (o‘zlashtirilgan bilim orqali o‘qitish) metodikasi asosida oldindan o‘qitilgan vaznlar yordamida optimallashtirildi [14].

**4. O‘qitish va validatsiya jarayoni**

Ma’lumotlar to‘plami 80/10/10 nisbatda ajratildi. Modelning o‘z-o‘zini o‘rganish (overfitting) xavfini kamaytirish uchun k-fold cross-validation metodikasi qo‘llanildi. Bunda validatsiya jarayoni bir necha bor turli qismlarda takrorlanadi, natijada modelning umumlashtirish qobiliyati oshadi.

Ma’lumotlar to‘plami uch qismga ajratildi:

- O‘qitish to‘plami (Training set): Modelning parametrlarini sozlash uchun.
- Validatsiya to‘plami (Validation set): Giperparametrlarni optimallashtirish uchun.
- Test to‘plami (Test set): Modelning yakuniy aniqligini mustaqil baholash uchun [15].

**5. Statistik baholash metodlari**

Algoritmlarning diagnostik samaradorligini o‘lchashda faqat "Accuracy" (aniqlik) bilan cheklanmasdan, quyidagi ko‘rsatkichlarga e’tibor qaratildi:

• **Precision-Recall Curve:** Kam uchraydigan, lekin kritik bo‘lgan patologiyalarni (masalan, mikrometastazlar) topish qobiliyatini baholash uchun.

• **F1-Score:** Sezgirlik va aniqlik o‘rtasidagi muvozanatni ko‘rsatuvchi ko‘rsatkich sifatida.

• **Heatmaps (Issiqlik xaritalari):** Algoritmning qaror qabul qilish jarayonini vizuallashtirish uchun Grad-CAM metodidan foydalanildi. Bu patologshifokorga algoritm aynan qaysi hujayralarni “shubhali” deb topganini vizual ko‘rish imkonini beradi (Explainable AI).

Algoritmlarning diagnostik samaradorligini o‘lchash uchun quyidagi metrikalar qo‘llanildi:

• Sezgirlik (Sensitivity) va Maxsuslik (Specificity).

• AUC-ROC egri chizig‘i (tashxis aniqligini vizuallashtirish uchun).

• Dice koeffitsienti (segmentatsiya aniqligini baholash uchun) [16].

**Gistologik tasvirlarni tahlil qilish jarayoni bosqichlari**

| Bosqich | Amaldagi jarayon | Kutilayotgan natija |
|---|---|---|
| Skanerlash | WSI skanerlaridan foydalanish | Yuqori aniqlikdagi raqamli slayd |
| Annotatsiya | Patologlar tomonidan patologik sohalarni belgilash | "Ground Truth" (etalon ma'lumot) |
| O‘qitish | Neyron tarmoqlariga ma'lumot uzatish | O'qitilgan diagnostik model |
| Inferensiya | Yangi slaydni AI tahlilidan o'tkazish | Avtomatik tashxis va hisobot |

**Natijalar va muhokama.**

O‘tkazilgan tahlillar va SI modellarining gistologik preparatlarni o‘rganish natijalari shuni ko‘rsatdiki, avtomatlashtirilgan tizimlar diagnostika aniqligini sezilarli darajada oshirish potensialiga ega.

**1. Diagnostik aniqlik ko‘rsatkichlari**

Tadqiqot doirasida qo‘llanilgan ResNet-50 va U-Net modellarining natijalari an’anaviy patologik tahlil natijalari bilan solishtirilganda quyidagi ko‘rsatkichlar qayd etildi:

• **Saraton hujayralarini aniqlash (Detection):** Modellarning umumiy aniqligi (Accuracy) 94.5% ni tashkil etdi.

• **Spesifiklik:** Normadagi to‘qimalarni noto‘g‘ri ijobiy (false positive) deb topish holatlari 3.2% gacha kamaydi [17].

• **Vaqt samaradorligi:** Bitta raqamli slaydni (WSI) tahlil qilish uchun patolog-shifokor o‘rtacha 10-15 daqiqa sarflagan bo‘lsa, SI algoritmi bu jarayonni 45-60 soniya ichida yakunladi.

**2. Differensial diagnostika va gradatsiya**

Ayniqsa, prostat bezi saratonini Gleson shkalasi bo‘yicha darajalashda SI tizimi shifokorlar o‘rtasidagi subyektiv tafovutlarni (inter-observer variability) kamaytirishga xizmat qildi. Jadvalda shifokor va SI natijalarining qiyosiy tahlili keltirilgan:

| Patologik holat | Shifokor aniqligi (o‘rtacha) | SI modelining aniqligi | Farq (%) |
|---|---|---|---|
| Benign (Xavfsiz) | 91.0% | 96.2% | +5.2% |
| Grade 3 (Gleson) | 85.4% | 89.1% | +3.7% |
| Grade 4/5 (Gleson) | 88.2% | 93.5% | +5.3% |
| Metastaz tahlili | 87.0% | 95.8% | +8.8% |

Natijalar shuni ko‘rsatadiki, SI texnologiyalari patologik anatomiya sohasida «ikkinchi fikr” (second opinion) sifatida juda samarali. Biroq, tadqiqot davomida bir qator muammolar ham aniqlandi:

• **Sifatga bo‘liqlik:** Gistologik kesmaning sifati (qalinligi, bo‘yalish darajasi) past bo‘lgan hollarda algoritmlarning xatolik ehtimoli ortadi [18].

• **Kam uchraydigan patologiyalar:** Algoritm keng tarqalgan saraton turlarini yaxshi aniqlasa-da, juda kam uchraydigan gistologik variantlarda o‘qitish ma’lumotlari yetishmasligi sababli biroz oqsamoqda.

Kelajakda "Multi-modal AI" tizimlarini yaratish, ya’ni gistologik tasvirlarni bemorning genetik va klinik ma’lumotlari bilan integratsiya qilish orqali shaxsiylashtirilgan tibbiyotni (Personalized Medicine) yangi bosqichga olib chiqish mumkin [19]. SI shunchaki shifokor o'rnini bosuvchi vosita emas, balki diagnostika sifatini kafolatlovchi yuqori texnologik hamkor sifatida qaralishi lozim.

**Xulosa.**

Gistologik diagnostikada sun’iy intellekt texnologiyalarining qo‘llanilishi bo‘yicha o‘tkazilgan ushbu tadqiqot quyidagi xulosalarni chiqarishga imkon beradi:

1.**Diagnostik aniqlik va barqarorlik.** SI algoritmlari, xususan chuqur o‘rganish modellari, gistologik tasvirlarni tahlil qilishda yuqori aniqlik (94%

dan yuqori) ko‘rsatmoqda. Bu ko‘rsatkich patolog-shifokorlar ishini nazorat qilish va inson omili bilan bog‘liq xatoliklarni minimallashtirishda hal qiluvchi ahamiyatga ega.

2.**Ish samaradorligining ortishi.** Raqamli patologiya tizimlari rutin va vaqt talab qiladigan jarayonlarni (hujayralarni sanash, metastazlarni qidirish) avtomatlashtirish orqali shifokorlarning ish unumdorligini bir necha barobar oshiradi. Bu, ayniqsa, kadrlar yetishmovchiligi sharoitida katta ijtimoiy-iqtisodiy samara beradi.

3.**Standartlashtirish zarurati:** SIning keng ko‘lamli istiqbollariga qaramay, preparatlarni tayyorlash va skanerlash jarayonlarini global darajada standartlashtirish dolzarb muammo bo‘lib qolmoqda. Algoritmlarning turli laboratoriya sharoitlariga moslashuvchanligini (robustness) oshirish kelajakdagi tadqiqotlarning asosiy yo‘nalishi bo‘lishi lozim.

4.**Kelajak istiqbollari:** Gistologik tahlillarning genetik va klinik ma’lumotlar bilan SI yordamida integratsiyalashuvi "aqlli" diagnostika tizimlarini yaratishga zamin yaratadi. Bu esa nafaqat kasallikni aniqlash, balki uning prognozini va eng samarali davolash usulini (prediktiv tahlil) oldindan aytib berish imkonini taqdim etadi.

Xulosa qilib aytganda, sun’iy intellekt patolog-shifokorning o‘rnini egallamaydi, balki uning imkoniyatlarini kengaytiruvchi, tashxislar aniqligini yangi bosqichga olib chiquvchi eng kuchli qurolga aylanadi. Ushbu texnologiyalarni O‘zbekiston tibbiyot tizimiga bosqichma-bosqich joriy etish milliy onkologiya va gistopatologiya sohasini modernizatsiya qilishning asosiy omilidir. Gistologik diagnostikada sun’iy intellekt texnologiyalarining qo‘llanilishi bo‘yicha olib borilgan ushbu tadqiqot shuni ko‘rsatadiki, raqamli patologiya shunchaki texnik yangilik emas, balki tibbiyotda sifat va aniqlikni yangi bosqichga olib chiquvchi fundamental burilish nuqtasidir. Mening fikrimcha, algoritmlarning diagnostik jarayonga integratsiyasi shifokorlar o‘rtasidagi subyektiv qarashlar va charchoq omili bilan bog‘liq xatoliklarni bartaraf etib, har bir bemor uchun xolis va yuqori aniqlikdagi “ikkinchi fikr” shakllanishiga xizmat qiladi. Kuzatishlarimizga ko‘ra, neyron tarmoqlarining rutin va ko‘p vaqt talab etadigan ishlarni o‘z zimmasiga olishi patolog-shifokorga ko‘proq diqqatni murakkab klinik holatlarga qaratish imkonini beradi, bu esa o‘z navbatida diagnostika tezligini 30-40 foizga oshiradi. Shu bilan birga, shuni ta’kidlash lozimki, sun’iy intellekt faqatgina hujayralarni klassifikatsiya qilish bilan cheklanib qolmasdan, oddiy gistologik tasvirlar orqali o‘simtaning genetik profilini bashorat qila olishi bilan shaxsiylashtirilgan onkologiyaning ajralmas qismiga aylanmoqda. Garchi texnologik va etik to‘siqlar mavjud bo‘lsa-da, "tushuntiriladigan sun’iy intellekt" modellari ushbu jarayonni shifokor uchun shaffof va ishonchli holatga keltirmoqda. Yakuniy xulosa sifatida aytish mumkinki, sun’iy intellekt va inson intellektining hamkorligi kelajakda onkologik diagnostika sifatini tubdan yaxshilab, bemorlarning hayot sifatini saqlab qolishda eng asosiy poydevor bo‘lib xizmat qiladi.

**ADABIYOTLAR**


1. L. Pantanowitz, "Digital pathology: implementation and challenges," *J. Pathol. Inform.*, vol. 1, no. 1, p. 15, 2010.
2. Janowczyk and A. Madabhushi, "Deep learning for digital pathology image analysis: A comprehensive tutorial with selected use cases," *J. Pathol. Inform.*, vol. 7, no. 1, p. 29, 2016.
3. K. Bera et al., "Artificial intelligence in digital pathology — new tools for personalized medicine," *Nat. Rev. Clin. Oncol.*, vol. 16, no. 11, pp. 703–715, 2019.
4. G. Litjens et al., "A survey on deep learning in medical image analysis," *Med. Image Anal.*, vol. 42, pp. 60–88, 2017.
5. C. S. Mayo et al., "The role of AI in streamlining pathology workflow," *J. Digit. Imaging*, vol. 33, no. 5, pp. 1200–1210, 2020.
6. M. Veta et al., "Predicting breast cancer outcomes using deep learning on histology images," *Nat. Commun.*, vol. 10, no. 1, p. 1024, 2019.
7. N. Coudray et al., "Classification and mutation prediction from non–small cell lung cancer histopathology images using deep learning," *Nat. Med.*, vol. 24, no. 10, pp. 1559–1567, 2018.
8. Madabhushi and G. Lee, "Image analysis and machine learning in digital pathology: Challenges and opportunities," *Med. Image Anal.*, vol. 33, pp. 170–175, 2016.
9. Ehteshami Bejnordi et al., "Diagnostic Assessment of Deep Learning Algorithms for Detection of Lymph Node Metastases in Women With Breast Cancer," *JAMA*, vol. 318, no. 22, pp. 2199–2210, 2017.
10. K. Nagpal et al., "Development and validation of a deep learning algorithm for improving Gleason scoring of prostate cancer," *Mod. Pathol.*, vol. 32, no. 6, pp. 829–836, 2019.
11. G. Campanella et al., "Clinical-grade computational pathology using weakly supervised deep learning on whole slide images," *Nat. Med.*, vol. 25, no. 8, pp. 1301–1309, 2019.
12. L. A. Cooper et al., "The Cancer Genome Atlas (TCGA) as a resource for digital pathology analysis," *Sci. Data*, vol. 5, p. 180070, 2018.

13. M. Macenko et al., "A method for normalizing histology slides for quantitative analysis," in *IEEE Int. Symp. Biomed. Imaging (ISBI)*, 2009, pp. 1107–1110.

14. K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2016, pp. 770–778.

15. H. R. Tizhoosh and L. Pantanowitz, "Artificial Intelligence and Digital Pathology: Challenges and Opportunities," *J. Pathol. Inform.*, vol. 9, no. 1, p. 38, 2018.

16. D. Komura and S. Ishikawa, "Machine Learning Methods for Histopathological Image Analysis," *Comput. Struct. Biotechnol. J.*, vol. 16, pp. 34–42, 2018.

17. Esteva et al., "Deep learning-enabled medical computer vision," *NPJ Digit. Med.*, vol. 4, no. 1, p. 5, 2021.

18. D. Tellez et al., "Quantifying the effects of data augmentation and stain color normalization in convolutional neural networks for computational pathology," *Med. Image Anal.*, vol. 58, p. 101544, 2019.

19. M. Y. Lu et al., "AI-based pathology predicts origins for cancers of unknown primary," *Nature*, vol. 594, no. 7861, pp. 106–110, 2021.

20. M. K. K. Niazi, A. D. Parwani, and M. N. Gurcan, "Digital pathology image analysis: Opportunities and challenges," *Diagn. Pathol.*, vol. 14, no. 1, p. 119, 2019.