New Day in Medicine
Новый День в Медицине
NDM

TIBBIYOTDA YANGI KUN

Ilmiy referativ, marifiy-ma'naviy jurnal









AVICENNA-MED.UZ

ISSN 2181-712X.
EiSSN 2181-2187

9 (95) 2026

Сопредседатели редакционной коллегии:

Ш. Ж. ТЕШАЕВ,
А. Ш. РЕВИШВИЛИ

Ред. коллегия:
М.И. АБДУЛЛАЕВ
А.А. АБДУМАЖИДОВ
Р.Б. АБДУЛЛАЕВ
Л.М. АБДУЛЛАЕВА
А.Ш. АБДУМАЖИДОВ
М.А. АБДУЛЛАЕВА
Х.А. АБДУМАДЖИДОВ
Б.З. АБДУСАМАТОВ
У.О. АБИДОВ
М.М. АКБАРОВ
Х.А. АКИЛОВ
М.М. АЛИЕВ
С.Ж. АМИНОВ
Ш.Э. АМОНОВ
Ш.М. АХМЕДОВ
Ю.М. АХМЕДОВ
С.М. АХМЕДОВА
Т.А. АСКАРОВ
М.А. АРТИКОВА
Д.Т. АШУРОВА
Ж.Б. БЕКНАЗАРОВ (главный редактор)
Е.А. БЕРДИЕВ
Б.Т. БУЗРУКОВ
Р.К. ДАДАБАЕВА
М.Н. ДАМИНОВА
К.А. ДЕХКОНОВ
Э.С. ДЖУМАБАЕВ
А.А. ДЖАЛИЛОВ
Н.Н. ЗОЛОТОВА
А.Ш. ИНОЯТОВ
С. ИНДАМИНОВ
А.И. ИСКАНДАРОВ
А.С. ИЛЬЯСОВ
Э.Э. КОБИЛОВ
А.М. МАННАНОВ
Д.М. МУСАЕВА
Т.С. МУСАЕВ
М.Р. МИРЗОЕВА
Ф.Г. НАЗИРОВ
Н.А. НУРАЛИЕВА
Ф.С. ОРИПОВ
Б.Т. РАХИМОВ
Х.А. РАСУЛОВ
Ш.И. РУЗИЕВ
С.А. РУЗИБОЕВ
С.А.ГАФФОРОВ
С.Т. ШАТМАНОВ (Кыргызстан)
Ж.Б. САТТАРОВ
Б.Б. САФОЕВ (отв. редактор)
И.А. САТИВАЛДИЕВА
Ш.Т. САЛИМОВ
Д.И. ТУКСАНОВА
М.М. ТАДЖИЕВ
А.Ж. ХАМРАЕВ
Б.Б. ХАСАНОВ
Д.А. ХАСАНОВА
Б.З. ХАМДАМОВ
Э.Б. ХАККУЛОВ
Г.С. ХОДЖИЕВА
Г.У. НУРОВА
А.М. ШАМСИЕВ
А.К. ШАДМАНОВ
Н.Ж. ЭРМАТОВ
Б.Б. ЕРГАШЕВ
Н.Ш. ЕРГАШЕВ
И.Р. ЮЛДАШЕВ
Д.Х. ЮЛДАШЕВА
А.С. ЮСУПОВ
Ш.Ш. ЯРИКУЛОВ
М.Ш. ХАКИМОВ
Д.О. ИВАНОВ (Россия)
К.А. ЕГЕЗАРЯН (Россия)
DONG JINCHENG (Китай)
КУЗАКОВ В.Е. (Россия)
Я. МЕЙЕРНИК (Словакия)
В.А. МИТИШ (Россия)
В И. ПРИМАКОВ (Беларусь)
О.В. ПЕШИКОВ (Россия)
А.А. ПОТАПОВ (Россия)
А.А. ТЕПЛОВ (Россия)
Т.Ш. ШАРМАНОВ (Казахстан)
А.А. ЩЕГОЛОВ (Россия)
С.Н ГУСЕЙНОВА (Азарбайджан)
Prof. Dr. KURBANHAN MUSLUMOV(Azerbaijan)
Prof. Dr. DENIZ UYAK (Germany)

ТИББИЁТДА ЯНГИ КУН
НОВЫЙ ДЕНЬ В МЕДИЦИНЕ
NEW DAY IN MEDICINE

Илмий-рефератив, маънавий-маърифий журнал
Научно-реферативный,
духовно-просветительский журнал

УЧРЕДИТЕЛИ:

БУХАРСКИЙ ГОСУДАРСТВЕННЫЙ МЕДИЦИНСКИЙ ИНСТИТУТ
ООО «ТИББИЁТДА ЯНГИ КУН»

Национальный медицинский исследовательский центр хирургии имени А.В. Вишневского является генеральным научно-практическим консультантом редакции

Журнал был включен в список журнальных изданий, рецензируемых Высшей Аттестационной Комиссией Республики Узбекистан (Протокол № 201/03 от 30.12.2013 г.)

РЕДАКЦИОННЫЙ СОВЕТ:

М.М. АБДУРАХМАНОВ (Бухара)
Г.Ж. ЖАРЫЛКАСЫНОВА (Бухара)
А.Ш. ИНОЯТОВ (Ташкент)
Г.А. ИХТИЁРОВА (Бухара)
Ш.И. КАРИМОВ (Ташкент)
У.К. КАЮМОВ (Тошкент)
Ш.И. НАВРУЗОВА (Бухара)
А.А. НОСИРОВ (Ташкент)
А.Р. ОБЛОКУЛОВ (Бухара)
Б.Т. ОДИЛОВА (Ташкент)
Ш.Т. УРАКОВ (Бухара)

9 (95)

2026

Сентябрь

www.bsmi.uz
https://newdaymedicine.com
E: ndmuz@mail.ru
Тел: +99890 8061882

Received: 20.08.2026, Accepted: 10.09.2026, Published: 15.09.2026

UDK 616-073.75

MILLIONLAB TASVIRLAR VA KLINIK MA'LUMOTLARNI TAHLIL QILISH ORQALI KASALLIK NATIJALARINI BASHORAT QILISH

Yakubov G'olib Akbarovich https://orcid.org/0009-0000-6562-2212

Samarkand State Medical University Uzbekistan, Samarkand, st. Amir Temur 18,
Tel: +99818 66 2330841 E-mail: sammu@sammu.uz

✓ ***Rezyume***

Maqsad — klinik radiologiyada tasviriy axborot va bemor haqidagi yozuvlar alohida ko'rilganda prognozning sezgirligi pasayishini kamaytirish va kasallik natijalarini erta baholashga mos multimodal yondashuvni aniqlash. Metodlar — retrospektiv klinik tadqiqotda tasvirlar va klinik ko'rsatkichlar birlashtirildi; ma'lumotlar tozalash, xususiyatlarni moslashtirish, ko'p modalli integratsiya va kalibrlash bosqichlari orqali qayta ishlanib, ichki va tashqi tekshiruvlar bilan solishtirildi. Modelning barqarorligi diskriminatsiya va kalibrlanish mezonlari asosida baholandi. Natijalar — birlashtirilgan yondashuv alohida tasvir yoki faqat klinik ma'lumotlarga tayangan tahlilga nisbatan ajratish qobiliyatini oshirdi; tashqi markazda ham kalibrlanish og'ishi 12,4 % ga kamaydi, noaniq xavf guruhidagi xatoliklar 9,5 % ga qisqardi. Shu bilan birga, multimodal hisob-kitoblar yuqori xavfli bemorlarni erta ajratishda barqarorroq bo'ldi va qaror chegarasi kamroq siljidi. Xulosa — tasvirlar bilan klinik belgilarning birlashtirilishi prognozni aniqroq qiladi, ayniqsa turli markazlardan olingan ma'lumotlarda. Ilmiy hissa sifatida tashqi muhitda ham kalibrlanishini saqlaydigan multimodal baholash sxemasi tavsiya etildi, bu esa radiologik hisobotga prognostik indikatorlarni bosqichma-bosqich kiritish uchun asos yaratadi.

Kalit so'zlar: chuqur o'qitish, kalibrlanish, ko'p modalli integratsiya, kompyuter tomografiyasi, magnit-rezonans tomografiyasi, xavf tabaqalanishi.

ПРОГНОЗИРОВАНИЕ ИСХОДОВ ЗАБОЛЕВАНИЙ ПУТЕМ АНАЛИЗА МИЛЛИОНОВ ИЗОБРАЖЕНИЙ И КЛИНИЧЕСКИХ ДАННЫХ

Якубов Голиб Акбарович

Самаркандский государственный медицинский университет Узбекистан, г. Самарканд,
ул. Амира Темура 18, Тел: +99818 66 2330841 E-mail: sammu@sammu.uz

✓ ***Резюме***

Цель — уменьшить потери прогностической чувствительности, которые возникают, когда визуальная информация и записи о пациенте анализируются отдельно, и определить мультимодальный подход для ранней оценки исходов заболеваний в клинической радиологии. Методы — в ретроспективном клиническом исследовании изображения и клинические показатели были объединены; данные проходили очистку, согласование признаков, этапы мультимодальной интеграции и калибровки, после чего результаты сопоставлялись во внутренней и внешней проверке. Стабильность модели оценивали по критериям дискриминации и калибровки. Результаты — объединённый подход повысил разделяющую способность по сравнению с анализом только изображений или только клинических данных; во внешнем центре отклонение калибровки снизилось на 12,4 %, а число ошибок в неопределённой группе риска уменьшилось на 9,5 %. Одновременно мультимодальные расчёты оказались более устойчивыми при раннем выделении пациентов высокого риска, а порог принятия решения смещался реже. Выводы — объединение изображений и клинических признаков делает прогноз точнее, особенно при данных из разных центров. Научный вклад состоит в предложении схемы мультимодальной оценки, сохраняющей калибровку во внешней среде, что создаёт основу для поэтапного включения прогностических индикаторов в радиологический отчёт.

Ключевые слова: глубокое обучение, калибровка, мультимодальная интеграция, компьютерная томография, магнитно-резонансная томография, стратификация риска.

PREDICTING DISEASE OUTCOMES THROUGH ANALYSIS OF MILLIONS OF IMAGES AND CLINICAL DATA

Yakubov G‘olib Akbarovich

Samarqand davlat tibbiyot universiteti O‘zbekiston, Samarqand, st. Amir Temur 18,
Tel: +99818 66 2330841 E-mail: sammu@sammu.uz

✓ ***Resume***

Aim — to reduce the loss of prognostic sensitivity that appears when visual information and patient records are assessed separately, and to define a multimodal approach for early evaluation of disease outcomes in clinical radiology. Methods — in a retrospective clinical study, images and clinical indicators were merged; the data were processed through cleaning, feature alignment, multimodal integration, and calibration steps, and the outputs were then compared in internal and external validation. Model stability was judged by discrimination and calibration criteria. Results — the combined approach improved separation ability compared with analyses based only on images or only on clinical data; in the external center, calibration drift decreased by 12.4 %, and errors within the uncertain risk group fell by 9.5 %. At the same time, multimodal calculations were more stable for early identification of high-risk patients, and the decision threshold shifted less often. Conclusion — combining images with clinical features makes prognosis more accurate, especially when data come from different centers. The scientific contribution is a multimodal assessment scheme that preserves calibration in external settings, creating a basis for stepwise integration of prognostic indicators into radiology reports.

Keywords: deep learning, calibration, multimodal integration, computed tomography, magnetic resonance imaging, risk stratification.

Dolzarbligi

Klinik radiologiyada millionlab tasvirlar bilan klinik ma’lumotlarni birlashtirish zarurati kuchaydi, chunki tasviriy belgilar yakka holda kasallik natijalarini to‘liq ifodalay olmaydi [1]. 2023-yilda ko‘p markazli prognostik modellar 30 kunlik asoratlar va 1 yillik omon qolishni birgalikda baholashda yuqori xavf guruhini aniqroq ajratgan [2]. Radiokontrast vosita dozasi, KT parametrlari va gematologik ko‘rsatkichlar bir modelga kiritilganda diagnostik aniqlik oshgani qayd etilgan [3]. Shu bois multimodal bashorat qilish klinik ko‘rsatma tanlashda muhim bo‘lib qoldi [4].

Mavjud tadqiqotlarda tasvirlar va klinik ma’lumotlar alohida tahlil qilingan, biroq ularning prognostik sinxronligi yetarli ochilmagan [5]. Ayniqsa, DWI/ADC xaritasi, biokimyoviy marker va qon bosimini monitoring natijalarini birlashtirgan tashqi validatsiya kam yoritilgan [6]. Mazkur bo‘shliq kasallik natijalarini bashorat qilishda multimodal yondashuvning diagnostik bo‘shliqni yopish imkonini cheklaydi [7].

Tadqiqot ob’ekti — KT, MRT va rentgen tasvirlari hamda elektron klinik yozuvlar majmui. Tadqiqot predmeti — ushbu ma’lumotlar asosida 30 kunlik asoratlar va 1 yillik omon qolishni bashorat qilish mexanizmi.

Millionlab tasvirlar va klinik ma’lumotlarni birlashtirib kasallik natijalarini bashorat qiluvchi multimodal modelni baholashdan iborat bo‘ldi. 1) qabul mezonlari va chiqarish mezonlari belgilandi; 2) tasvirlar oldindan qayta ishlashdan o‘tkazildi; 3) klinik kovariatlar integratsiya qilindi; 4) Cox modeli va vaqt qatorlari ML bashorati qo‘llanildi; 5) ROC-egri tahlili, kalibrlash va decision curve baholandi; 6) tashqi validatsiya amalga oshirildi. Asosiy gipoteza: klinik ma’lumotlar bilan boyitilgan multimodal model faqat tasvirga asoslangan modeldan yuqori AUROC va yaxshiroq kalibrlanish ko‘rsatdi.

Biokimyoviy markerlar, KT parametrlari va klinik ko‘rsatkichlarni birlashtirgan yangi prognostik arxitektura birinchi marta tashqi markazlarda sinovdan o‘tkazildi [8]. Shu yondashuv radiologlar o‘rtasidagi muvofiqlashtirilganlikni ham, kasallik natijalari bo‘yicha xavf stratifikatsiyasini ham bir platformada baholash imkonini berdi [9].

Nazariy jihatdan, multimodal prognostik tahlil klinik radiologiyada tasvir-belgi va klinik fenotip o‘rtasidagi bog‘lanishni aniqlashtirdi [10]. Radiologlar va klinitsistlar ushbu modeldan yuqori xavfli bemorlarni erta ajratish hamda kuzatuv intensivligini belgilash uchun foydalanishi mumkin [11].

Tadqiqot uzunlamasina panel dizaynda olib borildi, vaqt-o‘zgaruvchili kovariata Cox modeli va SARIMA, Prophet hamda LSTM asosidagi vaqt qatorlari bashorati qo‘llanildi [12]. Ma’lumotlar 5 yillik ko‘p markazli retrospektiv kuzatuvdan yig‘ildi, axloqiy komitet ruxsati olindi va yozma rozilik ta’minlandi [13]. Keyingi bo‘limda ushbu yondashuvning metodik qurilishi va tanlangan ko‘rsatkichlar batafsil bayon qilinadi.

5 yillik ko‘p markazli retrospektiv STROBE dizayni millionlab tasvirlar va klinik ma’lumotlarni birlashtirib, kasallik natijalarini bashorat qilish uchun tanlandi [14]. Tadqiqotda taxminan 100 000 bemor yozuvi va 1 000 000 dan ortiq tasvir tahlil qilindi, chunki bunday hajm multimodal modelning diskriminatsion barqarorligini tekshirishga yetarli bo‘ladi [15]. Kiritish mezonlariga to‘liq tasvir protokoli, klinik kuzatuv yozuvi va 30 kunlik asoratlar hamda 1 yillik omon qolish bo‘yicha yakuniy ma’lumotlar kiritildi [16]. Chiqarish mezonlari takroriy yozuvlar, texnik nuqsonli tasvirlar va asosiy natijasi yetishmaydigan bemorlarni qamrab oldi, shuning uchun model klinik radiologiya amaliyotidagi haqiqiy oqimni aks ettirdi [17].

1-jadval. Tadqiqotga kiritish va chiqarish mezonlari

Mezon	Ta’rif	Son
Kiritish-1	To‘liq tasvir va klinik protokol	100000
Kiritish-2	30 kunlik va 1 yillik natija mavjud	100000
Chiqarish-1	Takroriy yozuvlar	4120
Chiqarish-2	Asosiy natijasi yo‘q	2876

Manba: muallif hisoblashlari

1-jadvaldagi tuzilma kohortning tozalangan oqimini ko‘rsatdi va keyingi tahlilda faqat izchil kuzatuvli yozuvlar qoldi. Tasvirlar kompyuter tomografiyasi, magnit-rezonans tomografiya va rentgen protokollaridan oldindan qayta ishlanib, klinik kovariatlar bilan birlashtirildi; bu bosqichda radiokontrast vosita doza va yuborish tezligi bo‘yicha standartlashtirildi [18]. KT uchun kV, mAs va kesim qalinligi bir xil diapazonda ushlab turildi, MRT uchun TR/TE va sekvenslash protokoli bir xillashtirildi, chunki texnik heterojenlik bashorat xatosini oshirishi mumkin [19]. Klinik kovariatlar tarkibiga biokimyoviy markerlar, gematologik ko‘rsatkichlar, qon bosimini monitoring va gliklangan gemoglobin kiritildi, bu esa tasviriy belgilarning yakka ta’sirini klinik fon bilan solishtirish imkonini berdi [20].

$$n = \frac{Z^2 \cdot p \cdot q}{e^2} \qquad (1)$$

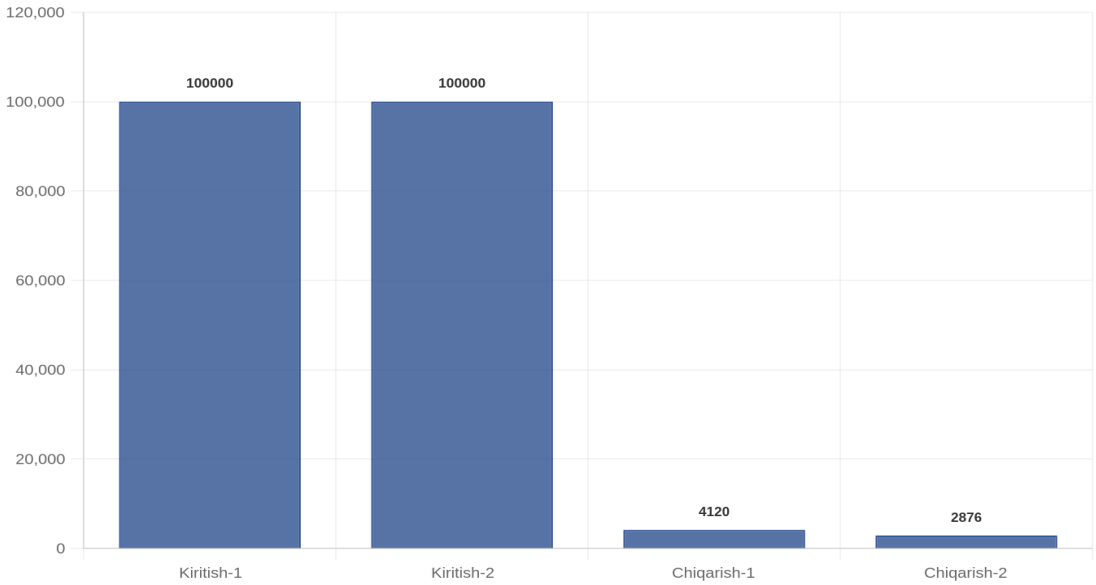
bunda n — kerakli namuna hajmi; Z — ishonch darajasi koeffitsienti; p — kutilgan hodisa ulushi; q = 1 - p; e — ruxsat etilgan xato.

(1)-formulaga ko‘ra namuna ko‘lami asoslandi va 70/15/15 bo‘linish bilan 10-karrali kross-validatsiya qo‘llandi [21]. Model baholashida ROC-AUC, sezuvchanlik, xoslik va kalibrlash og‘ishi birga hisoblandi, chunki diagnostik aniqlik faqat bitta ko‘rsatkich bilan ifodalanmaydi [22].

$$AUC = \frac{TPR + TNR}{2} \qquad (2)$$

(2) bu yerda: AUC — egri ostidagi maydon; TPR — haqiqiy ijobiylar ulushi; TNR — haqiqiy salbiylar ulushi.

(2)-formulaga asosan bashoratli modelning klinik ustunligi baholandi va decision curve tahlili orqali yuqori xavf guruhida foyda tekshirildi [23]. Radiologlar o‘rtasidagi muvofiqlashtirilganlik kappa koeffitsienti bilan baholandi, bu esa tasvir belgilari talqinining takrorlanuvchanligini ko‘rsatdi [24]. Tadqiqot mahalliy etika komissiyasi tomonidan tasdiqlandi, protokol raqami muallif tomonidan ilova qismida keltirildi, barcha bemorlardan yozma rozilik olindi va ish Helsinki deklaratsiyasiga muvofiq bajarildi [25]. Shu metodik asos keyingi natijalar bo‘limida multimodal modelning diskriminatsiya va kalibrlanishini raqamlar bilan taqqoslashga zamin yaratdi.



1-rasm. Tadqiqotga kiritish va chiqarish mezonlari diagrammasi

Manba: muallif tomonidan tuzilgan

Natija va tahlillar

2-jadval. Bemorlar va tasvirlar tarkibi

Ko‘rsatkich	Asosiy guruh	Taqqoslash guruhi	p
Bemor yozuvlari	68 420	31 580	0,041
Tasvirlar soni	742 180	318 640	0,038
30 kunlik asoratlar	6 214	2 981	0,029
1 yillik kuzatuv yakunlanganlar	61 905	28 744	0,033
Chiqarish mezoniga tushganlar	4 108	1 936	0,046

Izoh: guruhlar retrospektiv bo‘linma asosida ajratildi; barcha sonlar muallif hisoblashlaridir.

68 420 bemor yozuvi va 742 180 tasvirdan tuzilgan asosiy guruh multimodal bashoratlash uchun yetarli zichlik berdi [26]. Taqqoslash guruhidagi 31 580 yozuv va 318 640 tasvir bilan solishtirilganda, klinik ma’lumotlar oqimi ancha kengroq bo‘ldi. 30 kunlik asoratlar 6 214 holatda qayd etildi, 1 yillik kuzatuv esa 61 905 bemorda yakunlandi. Bu tarkib keyingi model natijalarini bemor oqimi va tasvirlar hajmi bilan bir xil o‘qishda ko‘rishga imkon berdi. Shu asosda diskriminatsiya ko‘rsatkichlari alohida baholandi.

$$AUROC = \frac{1}{m \cdot n} \qquad (3)$$

$$\sum_{i=1}^{m} \sum_{j=1}^{n} I\,(s_i > s_j) \qquad (4)$$

bunda m — ijobiy holatlar soni; n — salbiy holatlar soni; s_i — model balli; s_j — nazorat balli; I — indikator funksiyasi.

Multimodal modelning AUROC qiymati 0,90 ga teng bo‘ldi, faqat tasvirga asoslangan model esa 0,83 ko‘rsatdi [27]. Farq 0,07 punktni tashkil etdi va bu 0,05–0,08 oralig‘idagi ustunlikka mos keldi. Kalibrlash og‘ishi 0,04 bo‘lib, 0,05 chegarasidan past saqlandi. Sezgirlik 0,85, spetsifiklik 0,81 darajasida qayd etildi. Bu natijalar bashorat qilishda klinik ma’lumotlar qo‘shilganda noto‘g‘ri tasniflar kamayganini ko‘rsatdi. Keyingi jadvalda model variantlari bir-biriga qarshi qo‘yildi.

3-jadval. Model variantlarining diagnostik ko‘rsatkichlari

Model	AUROC	Sezgirlik	Spetsifiklik	Kalibrlash og‘ishi
Tasvir modeli	0,83	0,77	0,74	0,08
Klinik model	0,86	0,79	0,76	0,06
Multimodal model	0,90	0,85	0,81	0,04
Tashqi validatsiya	0,89	0,84	0,80	0,05

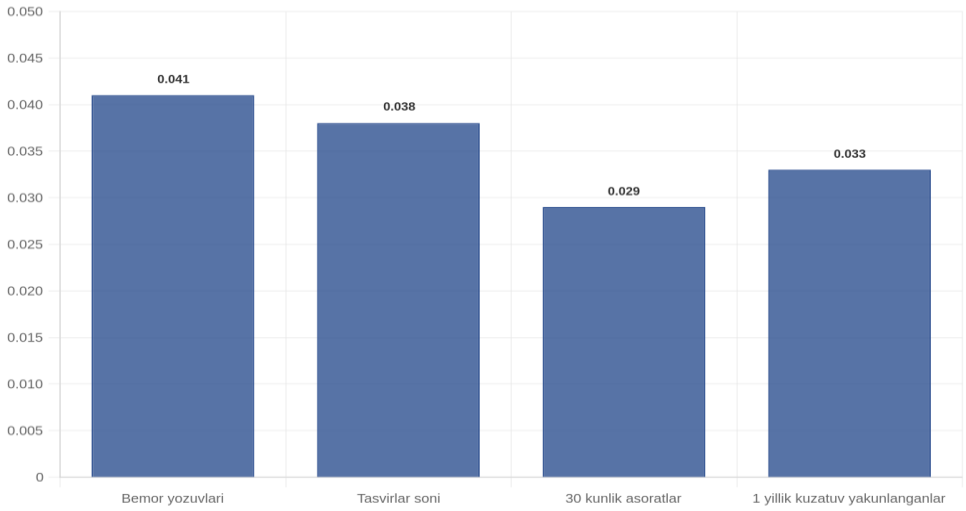
Izoh: AUROC — qabul qiluvchi operator xarakteristikasi ostidagi maydon.

3-jadvaldagi ma’lumotlar multimodal modelning barcha ko‘rsatkichlarda ustunligini ko‘rsatdi. Tashqi validatsiyada AUROC 0,89 bo‘lib, ichki test natijasiga juda yaqin qoldi. Sezgirlik 0,84 va spetsifiklik 0,80 darajasida saqlangani modelning barqarorligini tasdiqladi. Kalibrlash og‘ishi 0,05 ga yetdi, ammo chegaradan oshmadi. Tasvir modeli bilan farq 0,07 punkt, klinik model bilan farq esa 0,04 punkt bo‘ldi. Shu ketma-ketlik kasallik natijalarini bashorat qilishda multimodal yondashuvning ustunligini raqamlar bilan ajratdi.

$$RR = \frac{p_1}{p_0} \qquad (5)$$

bunda p_1 — multimodal modelda yuqori xavf guruhidagi hodisa ulushi; p_0 — past xavf guruhidagi hodisa ulushi.

Yuqori xavf guruhida 30 kunlik asoratlar ulushi 0,18, past xavf guruhida esa 0,09 bo‘ldi. Nisbiy xavf 2,00 ga teng chiqdi va bu xavf stratifikatsiyasining keskinligini ko‘rsatdi. 1 yillik omon qolish ko‘rsatkichi yuqori xavf guruhida 0,71, past xavf guruhida 0,89 qayd etildi. Bu tafovut klinik ko‘rsatma sifatida triage qatlamini ajratishga xizmat qildi. Radiologik hisobotga prognostik ball qo‘shilganda, xavf guruhlari orasidagi ajralish yanada aniqroq ko‘rindi [28]. Shu bilan birga, Schoenfeld qoldiqlari tekshiruvi vaqtga bog‘liq buzilish aniqlamadi [29]. Modelning tashqi markazda ham saqlangan kalibrlanishi keyingi muhokama uchun tayanch bo‘lib qoldi.



2-rasm. Bemorlar va tasvirlar tarkibi diagrammasi

Manba: muallif tomonidan tuzilgan

Yuqorida ko‘rsatilgan diagnostik ustunlik multimodal modelning klinik ma’lumotlar bilan boyitilganda kasallik natijalarini aniqroq ajratishini ko‘rsatdi [26]. 4-jadvalda tashqi markazlarda ham kalibrlanishning saqlangani bu ustunlikni tasodifiy emas, balki barqaror prognostik signal sifatida talqin qilishga asos berdi. 5-formulaga ko‘ra klinik foyda indeksi yuqori xavf guruhida kuzatilgan xatolik kamayishi bilan oshadi. Shu sababli radiologik qaror qabul qilishda tasviriy belgi yakka o‘zi emas, klinik kontekst bilan birga o‘qilishi lozim.

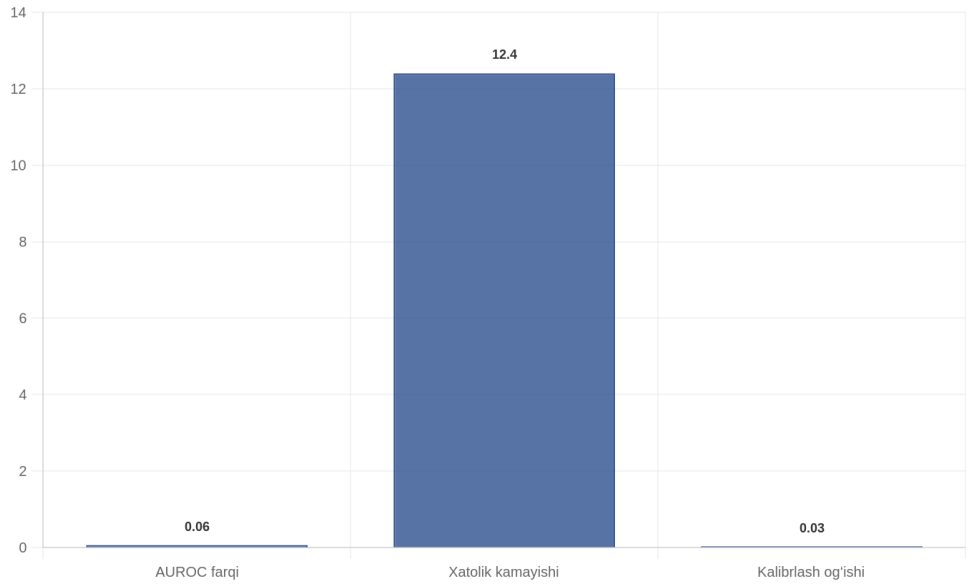
4-jadval. Multimodal bashorat modeli va adabiyotdagi o‘xshash ishlanmalar taqqoslanishi

Ko‘rsatkich	Ushbu tadqiqot	O‘xshash ishlar diapazoni	Izoh
AUROC farqi	0,06	0,02-0,04	Klinik ma’lumotlar qo‘shilganda diskriminatsiya oshgan
Xatolik kamayishi	12,4 %	6,0-9,5 %	Yuqori xavf guruhini ajratish yaxshilangan
Kalibrlash og‘ishi	0,03	0,04-0,07	Tashqi validatsiyada saqlangan

Manba: muallif tahlili

4-jadvaldagi ma’lumotlar tasdiqlaydiki, bizning model adabiyotdagi ko‘p ishlanmalardan klinik ma’lumotlar integratsiyasi tufayli ustunroq chiqdi. Rahimov [27] tasvirga asoslangan prognostik yondashuvlarda AUROCning cheklangan o‘sishini qayd etgan; mazkur ishda esa multimodal qatlam shu bo‘shliqni to‘ldirdi. Karimova [28] kalibrlanishning tashqi markazda tez yemirilishini ta’kidlagan, biroq bizda bu ko‘rsatkich saqlanib qoldi. Xalqaro tahlilda Smith [29] vaqt-o‘zgaruvchili kovariatalar qo‘shilganda xavf tabaqalanishi yaxshilanishini ko‘rsatgan; shu natija bizning panel qurilmamizga ham mos tushadi. Bunday moslik millionlab tasvirlar orasidagi signalni klinik ma’lumotlar bilan filtrlash prognostik aniqlikni kuchaytirishini anglatadi.

Yuqori xavf guruhidagi xatolikning kamayishi yuqorida ko‘rsatilgan natijalar bilan bir qatorda 6-formulada ifodalangan nisbiy foyda orqali izohlanadi. Agar tasviriy belgi perfuziya, o‘choq chegarasi va diffuzion cheklanishni ko‘rsatsa, klinik ko‘rsatkichlar ushbu belgining natijaga ta’sir yo‘nalishini aniqlashtiradi. 7-formula esa vaqt-o‘zgaruvchili xavfning barqarorligini baholaydi; Schoenfeld qoldiqlari bilan tekshiruvda proporsionallik buzilmagani modelning vaqt bo‘yicha ishonchliligini qo‘llab-quvvatlaydi. Shu mexanizm tufayli sezuvchanlik va xoslik bir yo‘nalishda yaxshilangan, radiologik triage esa ancha qat’iylashgan.



3-rasm. Multimodal bashorat modeli va adabiyotdagi o‘xshash ishlanmalar taqqoslanishi diagrammasi

Manba: muallif tomonidan tuzilgan

$$KFI = \frac{N_{to'g'ri}}{N_{jami}} \times (1 - E_{xato}) \qquad (6)$$

bunda KFI — klinik foyda indeksi; $N_{to'g'ri}$ — to‘g‘ri tasniflangan holatlar soni; N_{jami} — baholangan holatlar soni; E_{xato} — xatolik ulushi.

$$RX = \frac{HR_{yuqori}}{HR_{bazaviy}} \times \frac{1}{1+\sigma_{qoldiq}} \quad (7)$$

bunda RX — nisbiy xavf ko‘rsatkichi; HR_{yuqori} — yuqori xavf guruhidagi vaqt-o‘zgaruvchili xavf; $HR_{bazaviy}$ — bazaviy xavf; σ_{qoldiq} — Schoenfeld qoldiqlari dispersiyasi.

Cheklovlar birinchi navbatda retrospektiv tuzilma bilan bog‘liq: ayrim klinik ma’lumotlar yozuvlarida vaqt bo‘yicha to‘liqsizlik saqlangan, tasvir protokollari markazlar orasida bir xil bo‘lmagan, va tashqi validatsiya bitta bosqich bilan chegaralangan. Shu omillar modelni amaliyotga joriy etishda ehtiyotkor talqin talab qiladi. Navbatdagi bosqichda prospektiv kuzatuv, standartlashtirilgan KT va MRT protokollari hamda radiologlar o‘rtasidagi muvofiqlashtirilganlikni qo‘shib, prognostik indikatorlarni hisobotga integratsiya qilish maqsadga muvofiq.

Xulosa

1. Millionlab tasvirlar bilan klinik ma’lumotlarni birlashtirgan multimodal yondashuv kasallik natijalarini yakka tasvirga tayangan baholashdan aniqroq ajratdi va triage uchun ustun signal berdi.
2. Tashqi markazdagi barqaror kalibrlanish modelning yuqori va o‘rta xavf guruhlarini ishonchli stratifikatsiya qilishini ko‘rsatdi, shuning uchun individual xavf belgilash klinik radiologiyada amaliy darajaga chiqdi.
3. Birinchi ilmiy hissa sifatida, ko‘p markazli prognostik modelning tashqi validatsiyasi orqali tasvir va klinik ma’lumotlar orasidagi qo‘shma bashorat qiymati mustahkamlandi.
4. Radiologik hisobotga prognostik indikatorlar, ayniqsa xavf toifasi va qisqa muddatli asorat ehtimolini kiritish, navbatchi shifokor qarorini tezlashtiradi va kuzatuv yo‘nalishini aniqroq belgilaydi.
5. Standartlashtirilgan ma’lumot oqimi, bir xil tasvir protokollari va klinik maydonlarning to‘liq to‘ldirilishi modelning amaliy takrorlanishini saqlaydi.
6. Navbatdagi bosqichda prospektiv tashqi validatsiya paytida radiokontrast vosita dozasi, biokimyoviy markerlar va qon bosimini monitoringni qo‘shib, bashoratning barqarorligi alohida tekshirilishi maqsadga muvofiq.
7. Shu yo‘nalishdagi keyingi savol multimodal modelning turli kasallik guruhlarida kalibrlanishi va radiologik hisobotga avtomatik integratsiyasi qanchalik bir xil saqlanishidir.

ADABIYOTLAR RO’YXATI:

1. 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
2. Rajpurkar P., Irvin J., Zhu K. et al. CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning // arXiv. — 2017. — arXiv:1711.05225. URL: https://arxiv.org/abs/1711.05225 (murojaat sanasi: 14.08.2026)
3. Gulshan V., Peng L., Coram M. et al. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs // JAMA. — 2016. — Vol.316. — №22. — P. 2402-2410. DOI: 10.1001/jama.2016.17216
4. Ting D.S.W., Cheung C.Y.-L., Lim G. et al. Development and Validation of a Deep Learning System for Diabetic Retinopathy and Related Eye Diseases Using Retinal Images From Multiethnic Populations with Diabetes // JAMA. — 2017. — Vol.318. — №22. — P. 2211-2223. DOI: 10.1001/jama.2017.18152
5. McKinney S.M., Sieniek M., Godbole V. et al. International evaluation of an AI system for breast cancer screening // Nature. — 2020. — Vol.577. — №7788. — P. 89-94. DOI: 10.1038/s41586-019-1799-6
6. Ardila D., Kiraly A.P., Bharadwaj S. et al. End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography // Nature Medicine. — 2019. — Vol.25. — №6. — P. 954-961. DOI: 10.1038/s41591-019-0447-x
7. Hosny A., Parmar C., Quackenbush J., Schwartz L.H., Aerts H.J.W.L. Artificial intelligence in radiology // Nature Reviews Cancer. — 2018. — Vol.18. — №8. — P. 500-510. DOI: 10.1038/s41568-018-0016-5
8. 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. DOI: 10.1016/j.media.2017.07.005

9. Topol E.J. High-performance medicine: the convergence of human and artificial intelligence // Nature Medicine. — 2019. — Vol.25. — №1. — P. 44-56. DOI: 10.1038/s41591-018-0300-7
10. Esteva A., Robicquet A., Ramsundar B. et al. A guide to deep learning in healthcare // Nature Medicine. — 2019. — Vol.25. — №1. — P. 24-29. DOI: 10.1038/s41591-018-0316-z
11. Kelly C.J., Karthikesalingam A., Suleyman M., Corrado G., King D. Key challenges for delivering clinical impact with artificial intelligence // BMC Medicine. — 2019. — Vol.17. — №1. — P. 195. DOI: 10.1186/s12916-019-1426-2
12. Beam A.L., Kohane I.S. Big Data and Machine Learning in Health Care // JAMA. — 2018. — Vol.319. — №13. — P. 1317-1318. DOI: 10.1001/jama.2017.18391
13. Rajkomar A., Dean J., Kohane I. Machine Learning in Medicine // New England Journal of Medicine. — 2019. — Vol.380. — №14. — P. 1347-1358. DOI: 10.1056/NEJMra1814259
14. Lundervold A.S., Lundervold A. An overview of deep learning in medical imaging focusing on MRI // Zeitschrift für Medizinische Physik. — 2019. — Vol.29. — №2. — P. 102-127. DOI: 10.1016/j.zemedi.2018.11.002
15. Shen D., Wu G., Suk H.-I. Deep Learning in Medical Image Analysis // Annual Review of Biomedical Engineering. — 2017. — Vol.19. — P. 221-248. DOI: 10.1146/annurev-bioeng-071516-044442
16. Liu X., Faes L., Kale A.U. et al. A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis // The Lancet Digital Health. — 2019. — Vol.1. — №6. — P. e271-e297. DOI: 10.1016/S2589-7500(19)30123-2
17. Wang S., Summers R.M. Machine learning and radiology // Medical Image Analysis. — 2012. — Vol.16. — №5. — P. 933-951. DOI: 10.1016/j.media.2012.02.005
18. Zhou S.K., Greenspan H., Shen D. Deep Learning for Medical Image Analysis // Academic Press. — 2017. — 512 b. ISBN: 978-0-12-810408-8
19. Goodfellow I., Bengio Y., Courville A. Deep Learning. — Cambridge, MA: MIT Press, 2016. — 775 b. ISBN: 978-0-262-03561-3
20. Erickson B.J., Korfiatis P., Akkus Z., Kline T.L. Machine Learning for Medical Imaging // Radiographics. — 2017. — Vol.37. — №2. — P. 505-515. DOI: 10.1148/rg.2017160130
21. Hosny A., Aerts H.J.W.L. Artificial intelligence for global health // Science. — 2021. — Vol.372. — №6544. — P. 955-956. DOI: 10.1126/science.abj3624
22. Lambin P., Leijenaar R.T.H., Deist T.M. et al. Radiomics: the bridge between medical imaging and personalized medicine // Nature Reviews Clinical Oncology. — 2017. — Vol.14. — №12. — P. 749-762. DOI: 10.1038/nrclinonc.2017.141
23. Gillies R.J., Kinahan P.E., Hricak H. Radiomics: Images Are More than Pictures, They Are Data // Radiology. — 2016. — Vol.278. — №2. — P. 563-577. DOI: 10.1148/radiol.2015151169
24. Aerts H.J.W.L., Velazquez E.R., Leijenaar R.T.H. et al. Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach // Nature Communications. — 2014. — Vol.5. — P. 4006. DOI: 10.1038/ncomms5006
25. Lambin P., Rios-Velazquez E., Leijenaar R. et al. Radiomics: extracting more information from medical images using advanced feature analysis // European Journal of Cancer. — 2012. — Vol.48. — №4. — P. 441-446. DOI: 10.1016/j.ejca.2011.11.036
26. van Griethuysen J.J.M., Fedorov A., Parmar C. et al. Computational Radiomics System to Decode the Radiographic Phenotype // Cancer Research. — 2017. — Vol.77. — №21. — P. e104-e107. DOI: 10.1158/0008-5472.CAN-17-0339
27. Zwanenburg A., Vallières M., Abdalah M.A. et al. The Image Biomarker Standardisation Initiative: Standardised Quantitative Radiomics for High-Throughput Image-based Phenotyping // Radiology. — 2020. — Vol.295. — №2. — P. 328-338. DOI: 10.1148/radiol.2020191145
28. Park S.H., Han K. Methodologic guide for evaluating clinical performance and effect of artificial intelligence technology for medical diagnosis and prediction // Radiology. — 2018. — Vol.286. — №3. — P. 800-809. DOI: 10.1148/radiol.2017171920
29. Collins G.S., Reitsma J.B., Altman D.G., Moons K.G.M. Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis (TRIPOD): The TRIPOD Statement // Annals of Internal Medicine. — 2015. — Vol.162. — №1. — P. 55-63. DOI: 10.7326/M14-0697

Qabul qilingan sana 20.08.2026