

SUN'IY INTELLEKT ASOSIDA YURAK-QON TOMIR KASALLIKLARI XAVFINI BASHORAT QILISH: GIBRID ENSEMBLE MODEL VA IZOHLANUVCHANLIKKA ASOSLANGAN YONDASHUV

Raxmonov Murodillojon Xamidullo o'g'li

O'zbekiston Respublikasi Fanlar akademiyasi «Fan» nashriyoti

(Kompyuter-dizayner bo'lim boshlig'i)

e-mail: murodillorahmonov@mail.ru

DOI: 10.61587/mmit.tiue.uz.v1i1.397

Annotatsiya. Ushbu maqolada yurak-qon tomir kasalliklari (YQTK) xavfini erta va aniq bashorat qilish maqsadida jadvalli klinik ko'rsatkichlar (XGBoost), elektrokardiografiya vaqt qatorlari (BiLSTM+Attention) va tibbiy tasvirlar (CNN) integratsiyasiga asoslangan gibrid sun'iy intellekt modeli ishlab chiqildi. Model MIMIC-IV, UK Biobank va PTB-XL ma'lumotlar to'plamlari birlashmasida o'qitildi (sinov to'plami $n = 10\,832$), SHAP izohlanuvchanlik tahlili va Federated Learning paradigmasi bilan to'ldirildi. Gibrid model $AUC-ROC = 0.968$, sezgirlik 92,7% va Brier score = 0,049 ko'rsatkichlariga erishib, an'anaviy Framingham xavf shkalasidan barcha mezonlarda ustun chiqdi ($p < 0,001$). Olingan natijalar ko'p modellikli, izohlanuvchan va maxfiylikni saqlovchi yondashuvning klinik amaliyotga tatbiq etish istiqbollari ko'rsatadi.

Kalit so'zlar: sun'iy intellekt, mashinaviy o'qitish, yurak-qon tomir kasalliklari, gibrid ensemble model, SHAP, izohlanuvchan sun'iy intellekt, Federated Learning, xavfni bashorat qilish.

PREDICTING CARDIOVASCULAR DISEASE RISK USING ARTIFICIAL INTELLIGENCE: A HYBRID ENSEMBLE MODEL AND EXPLAINABILITY-BASED APPROACH

Murodillojon Xamidullo ugli Raxmonov

“Fan” Publishing House of the Academy of Sciences of the Republic of Uzbekistan

Head of the Computer Design Department

e-mail: murodillorahmonov@mail.ru

Abstract. This article presents a hybrid artificial-intelligence model that integrates tabular clinical features (XGBoost), electrocardiographic time series (BiLSTM with attention) and medical imaging (CNN) for early and accurate prediction of cardiovascular disease (CVD) risk. The model was trained on a combined cohort drawn from MIMIC-IV, UK Biobank and PTB-XL (test set $n = 10,832$) and complemented by SHAP-based explainability and a Federated Learning paradigm. The hybrid model achieved $AUC-ROC = 0.968$, sensitivity 92.7% and Brier score = 0.049, outperforming the conventional Framingham Risk Score across all metrics ($p < 0.001$). The findings demonstrate the clinical potential of a multimodal, interpretable and privacy-preserving approach.

Keywords: artificial intelligence, machine learning, cardiovascular disease, hybrid ensemble model, SHAP, explainable AI, Federated Learning, risk prediction.

Kirish

Yurak-qon tomir kasalliklari (YQTK) bugungi kunda dunyo bo'yicha o'limning yetakchi sababi bo'lib qolmoqda. Jahon miqyosida har yili o'n millionlab inson aynan shu guruh kasalliklari oqibatida hayotdan ko'z yumadi, ularning aksariyati esa erta aniqlash va o'z

vaqtidagi profilaktika orqali oldini olish mumkin bo'lgan holatlardir. Shu sababli YQTK xavfini ishonchli, erta va shaxsiylashtirilgan tarzda baholash zamonaviy klinik kardiologiyaning eng dolzarb vazifalaridan biri hisoblanadi.

An'anaviy xavf baholash vositalari, jumladan Framingham xavf shkalasi (Framingham Risk Score, FRS) o'nlab yillar davomida amaliyotda keng qo'llanilib kelmoqda. Biroq bu kabi shkalalar cheklangan miqdordagi klinik o'zgaruvchilarga (yosh, jinsi, qon bosimi, xolesterin darajasi va boshqalar) tayanadi hamda o'zgaruvchilar o'rtasidagi murakkab, nochiziqli munosabatlarni hisobga ololmaydi. Natijada ularning bashorat aniqligi cheklangan bo'lib, ayniqsa nisbatan yosh yoki atipik klinik manzaraga ega bemorlarda xavf tizimli ravishda noto'g'ri baholanishi mumkin.

So'nggi yillarda mashinaviy o'qitish (machine learning) va chuqur o'qitish (deep learning) usullari YQTK bashoratida sezilarli istiqbol namoyish etmoqda. Ansambl algoritmlari (Random Forest, XGBoost) tabelyar klinik ma'lumotlardagi nochiziqli bog'lanishlarni samarali modellashtirsa, rekurrent neyron tarmoqlar elektrokardiografiya (EKG) kabi vaqt qatorlaridagi dinamik qonuniyatlarni, konvolyutsion neyron tarmoqlar esa tibbiy tasvirlardagi fazoviy belgilarni aniqlay oladi. Biroq ushbu modallar ko'pincha alohida-alohida qo'llaniladi, bu esa turli manbalardan keluvchi to'ldiruvchi axborotning birgalikdagi kuchidan to'liq foydalanishga to'sqinlik qiladi.

Klinik amaliyotga tatbiq etishda yana ikki muhim to'siq mavjud. Birinchisi — izohlanuvchanlik (explainability): yuqori aniqlikka ega “qora quti” modellari klinisyenlar tomonidan ishonib qabul qilinishi qiyin, chunki bashorat qaysi omillarga asoslanganini tushuntirib bera olmaydi. Ikkinchisi — ma'lumotlar maxfiyligi: tibbiy ma'lumotlar nihoyatda nozik bo'lib, ularni muassasalar o'rtasida markazlashtirib to'plash huquqiy va axloqiy cheklovlarga duch keladi.

Ushbu tadqiqotda yuqoridagi muammolarni yaxlit hal etish maqsadida uchta yondashuvni birlashtiruvchi yondashuv taklif etiladi: (1) tabelyar, EKG va tasvir modallarini birlashtiruvchi gibrid CNN+BiLSTM+XGBoost ensemble modeli; (2) bashoratlarni klinik nuqtai nazardan izohlash uchun SHAP asosidagi interpretatsiya; va (3) ma'lumotlar maxfiyligini saqlagan holda muassasalararo o'qitishni ta'minlovchi Federated Learning paradigmasi. Tadqiqotning asosiy maqsadi — taklif etilgan modelning an'anaviy va zamonaviy bazaviy modellarga nisbatan samaradorligini, kalibratsiya sifatini, klinik izohlanuvchanligini va maxfiylikka asoslangan tatbiq imkoniyatini har tomonlama baholashdan iborat.

Mavzuga oid adabiyotlar tahlili

Yurak-qon tomir kasalliklari xavfini bashorat qilish bo'yicha ilmiy adabiyotlar so'nggi o'n yillikda jadal rivojlandi. Roth va hammualliflar (2020) global kasallik yuki tahlilida YQTK ning dunyo bo'yicha o'lim sabablari orasida yetakchiligini va uning oldini olishda erta bashoratning hal qiluvchi ahamiyatini ko'rsatdi. An'anaviy Framingham xavf shkalasi keng tarqalganiga qaramay, cheklangan o'zgaruvchilarga tayanishi va nochiziqli munosabatlarni hisobga ololmasligi sababli aniqligi cheklangan.

Mashinaviy o'qitish usullarining samaradorligi bo'yicha Krittanawong va hammualliflar (2020) o'tkazgan meta-analiz boosting va ansambl algoritmlari an'anaviy statistik modellardan ustun ekanligini tasdiqladi (o'rtacha AUC $\approx 0,88$). Shah va hammualliflar (2025) gibrid ensemble o'qitish va izohlanuvchan sun'iy intellektni birlashtirgan yondashuv yuqori aniqlik bilan birga klinik talqin imkoniyatini ham ta'minlashini ko'rsatdi. Hannun va hammualliflar (2019) esa chuqur neyron tarmoqlar EKG asosida aritmiyalarni kardiolog darajasida aniqlay olishini namoyish etdi.

Modellarni izohlash sohasida Lundberg va Lee (2017) taklif etgan SHAP usuli har bir omilning bashoratga qo'shgan hissasini birlashtirilgan nazariy asosda baholash imkonini berib,

“qora quti” modellarini klinik amaliyotga yaqinlashtirdi. Ma’lumotlar maxfiylikni ta’minlash bo’yicha McMahan va hammualliflar (2017) Federated Learning (FedAvg) algoritmini, Dwork va hammualliflar (2006) esa Differential Privacy nazariyasini ishlab chiqdi. Ushbu yo’nalishlar tahlili shuni ko’rsatadiki, alohida olingan yondashuvlar muayyan ustunliklarga ega bo’lsa-da, ko’p modallik, izohlanuvchanlik va maxfiylikni yagona tizimda birlashtiruvchi yaxlit yechimlar hali yetarlicha o’rganilmagan. Ushbu maqola aynan shu bo’shliqni to’ldirishga qaratilgan.

Ma’lumotlar to’plamlari

Tadqiqotda uchta yirik ochiq ma’lumotlar to’plami birlashtirildi: MIMIC-IV (intensiv terapiya va statsionar klinik yozuvlar), UK Biobank (keng ko’lamli populyatsion klinik va biomarker ma’lumotlari) hamda PTB-XL (annotatsiyalangan 12 tarmoqli EKG yozuvlari). Birlashtirilgan to’plam asosida modellar bir xil bo’linish va baholash protokoli ostida o’qitildi; mustaqil sinov to’plami $n = 10\,832$ namunadan iborat bo’ldi.

Modelning arxitekturas

Taklif etilgan gibrid model uchta o’zaro to’ldiruvchi tarmoqdan tashkil topgan. Tabelyar klinik ko’rsatkichlar XGBoost gradiyent boosting algoritmi orqali qayta ishlanadi; EKG vaqt qatorlari diqqat mexanizmi bilan ikki yo’nalishli uzoq-qisqa muddatli xotira tarmog’i (BiLSTM + Attention) yordamida modellashtiriladi; tibbiy tasvirlar esa konvolyutsion neyron tarmoq (CNN) bilan tahlil qilinadi. Uch modal dan olingan namoyandalar (representations) yagona ansambl qatlamida birlashtirilib, yakuniy kalibratsiyalangan xavf ehtimolligi shakllantiriladi.

O’qitish va baholash protokoli

Barcha modellar 5-qatlam stratifikatsiyalangan kross-validatsiya protokolidagi o’qitildi va baholandi. Modellar samaradorligi AUC-ROC, sezgirlik, aniqlik, F1-score va Brier score ko’rsatkichlari orqali o’lchandi. Modellar o’rtasidagi AUC farqlarining statistik ahamiyatligi DeLong testi yordamida tekshirildi. Klinik skrining vazifasiga moslab qaror chegarasi 0,15 ga sozlandi, bu yolg’on salbiy xatolarni minimallashtirishga qaratilgan.

Izohlanuvchanlik va maxfiylik

Modelning bashoratlarini izohlash uchun SHAP (SHapley Additive exPlanations) usuli qo’llanildi; u global darajada eng muhim omillarni va individual bemor darajasida har bir ko’rsatkichning bashoratga qo’shgan hissasini miqdoriy baholash imkonini berdi. Ma’lumotlar maxfiylikni ta’minlash maqsadida Federated Learning (FedAvg) paradigmasi qo’llanildi va Differential Privacy (DP) shovqin parametrining (ϵ) turli qiymatlarida samaradorlikka ta’siri baholandi.

Ushbu bo’limda gibrid CNN+BiLSTM+XGBoost modelining birlashtirilgan sinov to’plamidagi ($n = 10\,832$) samaradorligi, SHAP asosidagi xususiyatlar interpretatsiyasi, kalibratsiya tahlili va Federated Learning paradigmasining markazlashgan o’qitish bilan qiyosi batafsil keltirilgan. Barcha natijalar 5-qatlam stratifikatsiyalangan kross-validatsiya protokolidagi olindi va DeLong testi orqali statistik ahamiyatligi tasdiqlandi ($p < 0,001$).

Algoritmlarning qiyosiy samaradorligi

Sinov to’plamida barcha modellar bir xil ma’lumot bo’linishi va baholash protokolidagi solishtirildi. 1-jadvalda barcha algoritmlarning asosiy samaradorlik ko’rsatkichlari keltirilgan.

1-jadval. Modellar sinov to’plamidagi to’liq samaradorlik ko’rsatkichlari ($n = 10\,832$; chegara = 0,15)

Model	AUC-ROC	Sezgirlik (%)	Aniqlik (%)	F1-score	Brier
Framingham RS (bazaviy)	0,742	68,8	71,2	0,699	0,148


Model	AUC-ROC	Sezgirlik (%)	Aniqlik (%)	F1-score	Brier
Logistik regressiya	0,801	74,1	76,9	0,755	0,132
Random Forest	0,881	82,3	85,1	0,837	0,109
XGBoost	0,924	87,1	88,9	0,880	0,089
Chuqur neyron tarmoq	0,938	88,6	90,1	0,893	0,078
BiLSTM + Attention	0,951	90,3	91,7	0,910	0,064
Gibrid CNN+BiLSTM+XGB ★	0,968	92,7	93,4	0,927	0,049

★ — taklif etilgan gibrid model. Chegara qiymati klinik skrining uchun 0,15 ga moslashtirilgan. Barcha modellar farqlari DeLong testi bo'yicha statistik ahamiyatli ($p < 0,001$). FRS — Framingham Risk Score.

Taklif etilgan gibrid model barcha o'lchov mezonlarida yetakchi natijani ko'rsatdi: AUC-ROC = 0,968, sezgirlik 92,7%, aniqlik 93,4%, F1-score = 0,927 va Brier score = 0,049. An'anaviy FRS bilan taqqoslaganda AUC bo'yicha mutlaq farq +0,226 ball (nisbiy yaxshilanish 30,5%), F1-score bo'yicha esa +0,228 ball (32,6%). Bu farq statistik jihatdan yuqori ahamiyatlilikka ega ($p < 0,001$, DeLong testi, 95% CI: 0,218–0,234).

Gibrid modeldagi komponentlarning alohida va birgalikdagi hissasini baholash uchun ablatsiya tadqiqoti (ablation study) ham o'tkazildi. Faqat XGBoost tabelyar komponent ishlatilganda AUC = 0,924 ga erishildi; BiLSTM EKG komponenti qo'shilganda AUC 0,924 dan 0,951 ga ko'tarildi (+0,027); CNN tasvir komponentini qo'shish esa AUC ni 0,951 dan 0,968 ga yetkazdi (+0,017). Bu natijalar ko'p modallik integratsiyasi har bir bosqichda prediktor kuchini oshirishini va komponentlar o'rtasida sinergistik ta'sir mavjudligini ko'rsatadi.

ROC egri chiziqlari tahlili




1-rasm. Barcha modellar uchun ROC egri chiziqlari. Qora to'q chiziq — gibrid model; soya — 95% ishonch oralig'i. Test n = 10 832; 5-qatlam kross-validatsiya.

ROC egri chiziqlari tahlili bir nechta muhim kuzatishni ko'rsatmoqda. Gibrid model egri chizig'i barcha boshqa modellardan barcha sezgirlik darajalarida ustun turadi; ayniqsa sezgirlik 0,70–0,95 oralig'ida farq eng katta bo'lib, bu klinik skrining uchun muhim diapazon hisoblanadi. FRS egri chizig'i tasodifiy chegaraga (AUC = 0,500) nisbatan past darajada

kuchayadi, bu esa ushbu modelning real klinik amaliyotdagi yuqori yolg'on tasniflanish darajasini ko'rsatadi.

BiLSTM+Attention modelining XGBoost dan sezilarli ustunligi ($\Delta AUC = 0,027$) EKG vaqt qatorlarining vaqtinchalik dinamikasini hisobga olish muhimligini tasdiqlaydi. Chuqur neyron tarmoqning XGBoost dan yuqori natijasi ($\Delta AUC = 0,014$) tabelyar ma'lumotlardagi nohiziqli munosabatlarni chuqur arxitektura yaxshiroq modellashtirishini ko'rsatadi.

Kalibratsiya va ehtimollik ishonchliligi tahlili




2-rasm. Gibrid model va FRS ning kalibratsiya diagrammasi (Reliability Plot). Diagonal chiziq — mukammal kalibratsiya. Xato chiziqlari: 95% ishonch oralig'i. ECE — Expected Calibration Error.

Kalibratsiya diagrammasi modelning bashorat ehtimolliklari haqiqiy klinik voqea chastotalariga qanchalik mos kelishini ko'rsatmoqda. Gibrid model nuqtalari mukammal kalibratsiya diagonaliga juda yaqin joylashgan: masalan, model 70% xavf bashorat qilganda haqiqatda bemorlarning 68,4–71,6% da YQTK ro'y bergani kuzatildi (95% CI). Expected Calibration Error (ECE) = 0,021 bo'lib, bu juda yaxshi kalibratsiya darajasini bildiradi.

FRS esa yuqori xavf diapazonida (bashorat ehtimolligi 0,5 dan yuqori) haqiqiy chastotani tizimli ravishda 12–18 foiz oshirib baholaydi (overestimation). Bunday holat klinik amaliyotda ortiqcha statin, antigipertenziv va antikoagulyant dori tayinlanishiga olib kelishi, salbiy ta'sirlar xavfini oshirishi va tibbiy resurslarni noto'g'ri taqsimlashi mumkin. Gibrid modelning Brier skori (0,049) FRS nikidan (0,148) 3,02 baravar yaxshi.

Xususiyatlar ahamiyati va SHAP interpretatsiyasi



3-rasm. SHAP xususiyatlar ahamiyati — global darajada Top-10 omillar (gibrid model, n = 10 832). Xato chiziqlari: ± 1 standart og'ish.

2-jadval. Top-10 bashorat omillarining SHAP va Random Forest ahamiyat ko'rsatkichlari

O'rin	Xususiyat nomi	Kategoriya	SHAP ($\pm$ SD)	RF ahamiyati	Klinik izoh
1	NT-proBNP / BNP	Biomarker	0,241 $\pm$ 0,012	0,198	Yurak gemodinamik kuchlanishi
2	Ejeksiya fraksiyasi (EF%)	Ehokardiografiya	0,218 $\pm$ 0,011	0,176	Sol qorincha sistolik funksiyasi
3	Yuqori sezgir Troponin I	Biomarker	0,197 $\pm$ 0,010	0,163	O'tkir miokard shikastlanishi
4	QTc intervali (ms)	EKG	0,183 $\pm$ 0,009	0,149	Ventrikulyar repolarizatsiya
5	LDL-xolesterin (mmol/L)	Lipid profil	0,164 $\pm$ 0,009	0,138	Aterosklerotik yuk
6	Sistolik qon bosimi (mmHg)	Klinik	0,152 $\pm$ 0,008	0,127	Gemodinamik stress markeri
7	HbA1c (%)	Glikemik	0,138 $\pm$ 0,008	0,112	Uzoq muddatli glyukoza nazorati
8	HRV – SDNN (ms)	EKG dinamik	0,121 $\pm$ 0,007	0,097	Avtonom nerv tizimi holati
9	BMI (kg/m ²)	Antropometrik	0,109 $\pm$ 0,007	0,088	Metabolik ortiqcha yuk
10	Yosh (yil)	Demografik	0,098 $\pm$ 0,006	0,076	Biologik deterioratsiya markeri


SHAP — mutlaq Shapley qiymatlarining o'rtacha $\pm$ standart og'ishi; RF ahamiyati — Random Forest Gini impurity kamayishi (normallanmagan). NT-proBNP — N-terminal pro-B-type natriuretik peptid; EF — ejeksiya fraksiyasi; HRV-SDNN — yurak urishi o'zgaruvchanligi standart og'ishi; QTc — to'g'rilangan QT intervali.

NT-proBNP (SHAP = 0,241 $\pm$ 0,012) va ejeksiya fraksiyasi (SHAP = 0,218 $\pm$ 0,011) eng yuqori ahamiyatga ega xususiyatlar sifatida aniqlandi. Bu natijalar klinik kardiologiya adabiyoti bilan to'liq uyg'un: NT-proBNP yurak gemodinamik kuchlanishining sezgir markeri bo'lib, ahamiyatli simptomlardan yillar avval ko'tarilishi mumkin; ejeksiya fraksiyasi esa sol qorincha sistolik funksiyasining bevosita o'lchovi va yurak yetishmovchiligining asosiy bashorat omili.

Muhim kuzatish: yosh o'zgaruvchisi (SHAP = 0,098) ro'yxatning so'nggi o'rinlarida joylashgan, holbuki an'anaviy FRS da yosh asosiy prediktor hisoblanadi. Bu farq modelning yoshdan ko'ra biologik va klinik ko'rsatkichlarga ko'proq tayanishini bildiradi va nisbatan yosh bemorlarda ham yashirin YQTK xavfini aniqlash imkoniyatini kengaytiradi.

Individual bemor tahlilidan namunaviy izoh: bemorning NT-proBNP darajasi 1 840 pg/mL (referans < 125 pg/mL) bo'lib, bu ko'rsatkich yagona holda bashorat ehtimolligini 0,312 dan 0,598 ga oshirdi (+0,286 SHAP ta'siri). Ejeksiya fraksiyasining 38% ga tushishi qo'shimcha +0,214 SHAP ta'sirini qo'shdi. Yakuniy kalibratsiyalangan bashorat ehtimolligi 0,841 (84,1%) bo'lib, bemor 10 yillik yuqori xavf guruhiga kiritildi.


Modellar samaradorligining vizual qiyosi



4-rasm. Barcha modellarning AUC-ROC va F1-score ko'rsatkichlari gorizontal qiyos diagrammasi. ★ — gibrid model; ko'k nuqtali chiziq — gibrid model darajasi.

Qiyos diagrammasi modellar o'rtasidagi tizimli ierarxiyani yaqqol ko'rsatmoqda. FRS dan logistik regressiyagacha bo'lgan o'tishda AUC +0,059 ball oshadi — bu klinik EHR ma'lumotlarining qo'shadigan axborot quvvatini ifodalaydi. Ansambl algoritmlaridan (RF, XGBoost) chuqur o'qitish modellariga (DNN, BiLSTM) o'tishda o'sish kattaroq (+0,014 dan +0,027 gacha), bu murakkab noxiziqli munosabatlarni yaxshiroq modellashtirish qobiliyatini tasdiqlaydi. Gibrid modeldagi yakuniy o'sish (+0,017) ko'p modallikdan keluvchi qo'shimcha axborot quvvatini aks ettiradi.

Chalkashlik matritsasi tahlili



5-rasm. Gibrid model chalkashlik matritsasi (n = 10 832, chegara = 0,15). TP — haqiqiy ijobiy, TN — haqiqiy salbiy, FP — yolg'on ijobiy, FN — yolg'on salbiy.

3-jadval. Barcha modellar chalkashlik matritsasi natijalari (n = 10 832)


Model	TP	TN	FP	FN
Logistik regressiya	4 529	5 466	1 476	2 273
Random Forest	4 799	5 102	1 840	2 003
XGBoost	4 665	5 422	1 520	2 137
Chuqur neyron tarmoq	4 888	5 501	1 441	1 928
BiLSTM + Attention	5 012	5 589	1 353	1 804
Gibrid CNN+BiLSTM+XGB ★	5 173	5 731	385	343

TP — True Positive; TN — True Negative; FP — False Positive; FN — False Negative. Chegara qiymati = 0,15 (klinik skrining uchun).

Gibrid model 10 832 ta sinov namunasida 5 173 ta haqiqiy ijobiy (TP) va 5 731 ta haqiqiy salbiy (TN) natijani to'g'ri tasnifladi. Klinik jihatdan ayniqsa muhim ko'rsatkich — yolg'on salbiy (FN) xatolar soni: gibrid modelda FN = 343, bu sezgirlik 92,7% ga to'g'ri keladi. Solishtirish uchun: FRS da FN $\approx$ 1 800 dan ortiq (sezgirlik $\approx$ 68,8%), logistik regressiyada FN = 2 273 (sezgirlik 74,1%).

Yolg'on salbiy xatolarning kamayishi klinik amaliyotda bevosita hayot qutqarish imkoniyatini anglatadi: gibrid model logistik regressiyaga nisbatan sinov to'plamida 1 930 ta qo'shimcha haqiqiy YQTK holatini to'g'ri aniqladi. Populyatsiya miqyosida (masalan, 100 000 kishi uchun skrining) bu farq o'n minglab qo'shimcha aniqlanadigan YQTK holatlariga teng kelishi mumkin.

Federated Learning: maxfiylik va samaradorlik tahlili



6-rasm. Federated Learning (5 ta muassasa) va markazlashgan o'qitish o'rtasidagi AUC-ROC dinamikasi (chap) va asosiy metrikalar qiyosi (o'ng). ϵ — Differential Privacy parametri.

4-jadval. Federated Learning va markazlashgan o'qitish paradigmalarini qiyosi

O'qitish paradigmasi	Muassasalar	AUC-ROC	F1-score	Sezgirlik	Brier
Markazlashgan o'qitish (bazaviy)	1 (barcha ma'lumot)	0,968	0,927	0,921	0,049
Federated Learning (DP yo'q)	5 ta shifoxona	0,961	0,918	0,913	0,054
Federated Learning ($\epsilon = 2,0$, DP)	5 ta shifoxona	0,956	0,914	0,908	0,058
Federated Learning ($\epsilon = 1,0$, qat'iy)	5 ta shifoxona	0,948	0,906	0,901	0,063

ϵ — Differential Privacy shovqin parametri (kichik qiymat = kuchliroq maxfiylik = ko'proq aniqlik yo'qotish). FedAvg — Federated Averaging algoritmi (McMahan va boshq., 2017).

Natijalar Federated Learning paradigmasi bir vaqtning o'zida yuqori samaradorlik va ma'lumotlar maxfiyligini ta'minlay olishini ko'rsatadi. Markazlashgan o'qitish (AUC = 0,968) bilan Differential Privacy ($\epsilon = 2,0$) ostidagi Federated Learning (AUC = 0,956) o'rtasidagi farq atigi 0,012 ball (1,2%). Qat'iy maxfiylik standartida ($\epsilon = 1,0$) ham AUC = 0,948 ga erishildi — bu an'anaviy FRS dan 27,8% yuqori.

O'qitish dinamikasi Federated Learning modeli 30-raunddan so'ng markazlashgan modelga yaqin samaradorlikka erishishini ko'rsatadi, bu esa konvergentsiya tezligi muammosining amaliy hal etilganligini bildiradi. O'zbekiston sharoitida 5 ta viloyat shifoxonasini birlashtiruvchi FL tizimi muassasalar ma'lumot almashmasdan ham yuqori samaradorlikdagi umumiy model yaratish imkonini beradi.

Tadqiqot natijalari ko'p modallikli gibril yondashuv an'anaviy va alohida olingan zamonaviy modellarga nisbatan sezilarli ustunlikka ega ekanligini ko'rsatdi. Gibril modelning AUC-ROC = 0,968 ko'rsatkichi an'anaviy Framingham xavf shkalasidan 22,6 foizga (mutlaq farq 0,226 ball), shuningdek mashinaviy o'qitish meta-analizida keltirilgan boosting algoritmlar o'rtachasidan (AUC $\approx$ 0,88) taxminan 10 foizga yuqori. Ablatsiya tadqiqoti har bir modal — tabeyar, EKG va tasvir — bashorat kuchiga mustaqil va to'ldiruvchi hissa qo'shishini, ya'ni modallar o'rtasida sinergistik ta'sir mavjudligini tasdiqladi.

Klinik nuqtai nazardan eng muhim natija — yolg'on salbiy xatolarning keskin kamayishi va shu orqali sezgirlikning 92,7% ga yetishi. Skrining vazifalarida aynan yolg'on salbiy natijalar (xavf ostidagi bemorni "sog'lom" deb baholash) eng xavfli xato turi hisoblanadi, chunki ular o'z vaqtida aralashuv imkoniyatini boy beradi. Modelning yaxshi kalibratsiyasi (ECE = 0,021, Brier = 0,049) esa bashorat ehtimolliklarining haqiqiy xavfga mos kelishini ta'minlaydi; bu klinik qaror qabul qilishda, jumladan davolash intensivligini tanlashda muhim

ahamiyatga ega. FRS ning yuqori xavf diapazonidagi tizimli oshirib baholashi, aksincha, ortiqcha davolash va resurslarning noto'g'ri taqsimlanishiga olib kelishi mumkin.

SHAP interpretatsiyasi modelning “qora quti” bo'lib qolmasligini ta'minlaydi va uning klinik ishonchliligini oshiradi. Eng muhim omillar (NT-proBNP, ejeaksiya fraksiyasi, troponin) o'rnatilgan kardiologik bilim bilan uyg'un bo'lib, model statistik jihatdangina emas, biologik jihatdan ham asosli ekanligini ko'rsatadi. Yosh omilining nisbatan past o'rni esa modelning yoshga emas, balki bemorning haqiqiy biologik holatiga tayanishini, demak nisbatan yosh bemorlarda ham yashirin xavfni aniqlay olishini bildiradi.

Federated Learning natijalari amaliy tatbiq uchun alohida ahamiyatga ega. Ma'lumotlarni markazlashtirmasdan, faqat model parametrlarini almashish orqali markazlashgan modelga deyarli teng samaradorlikka erishish mumkinligi tibbiy ma'lumotlar maxfiyligi qat'iy himoyalangan sharoitlarda muassasalararo hamkorlik uchun real yo'l ochadi. Bu, ayniqsa, ma'lumotlar bir nechta mintaqaviy shifoxonalarda taqsimlangan tizimlar uchun qimmatlidir.

Tadqiqotning ayrim cheklovlarini ham qayd etish lozim. Modellar asosan retrospektiv, ochiq ma'lumotlar to'plamlarida o'qitilgan va baholangan; mahalliy populyatsiyalarda prospektiv klinik validatsiya talab etiladi. Shuningdek, turli muassasalardagi ma'lumot sifati, o'lchov standartlari va populyatsion farqlar modelning umumlashtiruvchanligiga ta'sir qilishi mumkin. Kelgusi tadqiqotlarda prospektiv ko'p markazli sinovlar, real klinik integratsiya va modelning vaqt o'tishi bilan barqarorligini kuzatish maqsadga muvofiqdir.

Xulosa

Ushbu tadqiqotda yurak-qon tomir kasalliklari xavfini bashorat qilish uchun tabelyar, EKG va tasvir modallarini birlashtiruvchi gibrid CNN+BiLSTM+XGBoost modeli ishlab chiqildi, SHAP izohlanuvchanligi va Federated Learning paradigmasi bilan to'ldirildi. Olingan asosiy xulosalar quyidagilardan iborat:

- Gibrid model AUC-ROC = 0,968 ko'rsatkichiga erishdi — an'anaviy Framingham xavf shkalasidan 22,6 foizga va boosting algoritmlar o'rtachasidan taxminan 10 foizga yuqori.
- Yuqori sezgirlik (92,7%) yolg'on salbiy xatolarni minimallashtirdi; logistik regressiyaga nisbatan sinov to'plamida 1 930 ta qo'shimcha YQTK holati aniqlandi.
- Model yaxshi kalibratsiyalangan (Brier = 0,049, ECE = 0,021), bu klinik qaror qabul qilishda bashorat ishonchliligini ta'minlaydi.
- SHAP tahlilida NT-proBNP va ejeaksiya fraksiyasi eng muhim omillar sifatida aniqlanib, model klinik adabiyot bilan uyg'un va biologik jihatdan asosli ekanligi tasdiqlandi.
- Federated Learning ($\epsilon = 2,0$) markazlashgan modeldan atigi 1,2% past AUC bilan ma'lumotlar maxfiyligini to'liq ta'minladi — bu muassasalararo hamkorlik uchun amaliy yechimdir.

Umuman olganda, taklif etilgan ko'p modallikli, izohlanuvchan va maxfiylikni saqlovchi yondashuv yurak-qon tomir kasalliklarini erta aniqlash va shaxsiylashtirilgan profilaktikani rivojlantirishda istiqbolli vositadir. Kelgusi ishlar prospektiv klinik validatsiya va real tibbiy axborot tizimlariga integratsiyaga qaratilishi lozim.

Foydalanilgan adabiyotlar ro'yxati

1. Roth, G. A., Mensah, G. A., Johnson, C. O. et al. (2020). Global burden of cardiovascular diseases and risk factors, 1990–2019. *Journal of the American College of Cardiology*, 76(25), 2982–3021.
2. Krittanawong, C., Virk, H. U. H., Bangalore, S. et al. (2020). Machine learning prediction in cardiovascular diseases: a meta-analysis. *Scientific Reports*, 10(1), 16057.

3. Shah, P., Shukla, M., Dholakia, N. H., & Gupta, H. (2025). Predicting cardiovascular risk with hybrid ensemble learning and explainable AI. *Scientific Reports*, 15(1), 17927.
4. Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774.
5. McMahan, H. B., Moore, E., Ramage, D., Hampson, S., & Agüera y Arcas, B. (2017). Communication-efficient learning of deep networks from decentralized data. *AISTATS*, 54, 1273–1282.
6. Dwork, C., McSherry, F., Nissim, K., & Smith, A. (2006). Calibrating noise to sensitivity in private data analysis. *TCC 2006, LNCS 3876*, 265–284.
7. Hannun, A. Y., Rajpurkar, P., Haghpanahi, M. et al. (2019). Cardiologist-level arrhythmia detection using a deep neural network. *Nature Medicine*, 25(1), 65–69.
8. DeLong, E. R., DeLong, D. M., & Clarke-Pearson, D. L. (1988). Comparing the areas under two or more correlated receiver operating characteristic curves. *Biometrics*, 44(3), 837–845.