



KARDIOSKLEROZ PROGNOSTIK MODELINI YARATISHDA MACHINE LEARNING VA DEEP LEARNING USULLARINING QIYOSIY TAHLILI

*Abdullayev Ibroximjon Nigmatilla o'g'li,
Shakarov Farxod Quvondiqovich,
Umarova Dilnoza Alisher qizi
Islom Karimov nomidagi
Toshkent davlat texnika universiteti
"Biotibbiyot muhandisligi" kafedrasida*

Annotatsiya. Ushbu tadqiqotda kardioskleroz kasalligini prognoz qilish uchun machine learning va deep learning usullari asosida turli modellar tahlil qilindi. Random Forest, SVM va CNN modellarining samaradorligi baholandi va ularning kombinatsiyasidan foydalangan gibrid yondashuv eng yuqori aniqlikka erishdi (91.2%). Tadqiqot davomida ma'lumotlarni qayta ishlash jarayonlari amalga oshirilib, tasviriy va raqamli ma'lumotlarga mos pre-processing ishlari bajarildi. Natijalar shuni ko'rsatdiki, modellar kombinatsiyasi prognoztik aniqlikni 5-7% ga oshiradi, bu esa klinik amaliyot uchun samarali echim bo'lishi mumkin.

Kalit so'zlar: Kardioskleroz, machine learning, deep learning, gibrid model, Random Forest, SVM, CNN, prognoztik model, tasviriy ma'lumotlar, ma'lumotlarni qayta ishlash.

KIRISH. Kardioskleroz kasalligi bugungi kunda global sog'liqni saqlash tizimining eng dolzarb muammolaridan biri hisoblanadi. Jahon sog'liqni saqlash tashkilotining so'nggi ma'lumotlariga ko'ra, yurak-qon tomir kasalliklari, jumladan kardioskleroz, dunyoda o'lim holatlarining asosiy sabablaridan biri bo'lib qolmoqda. 2023-yilgi statistik ma'lumotlarga ko'ra, dunyo bo'yicha yurak-qon tomir kasalliklaridan o'lim ko'rsatkichi 31.5% ni tashkil etadi, bu esa har yili taxminan 18 million kishining hayotiga zomin bo'lmoqda.

Kardioskleroz kasalligining o'ziga xos xususiyati shundaki, u ko'pincha sekin va belgilsiz rivojlanadi, bu esa kasallikni erta bosqichlarida aniqlashni murakkablashtiradi. Shu bois, kasallikni erta aniqlash va uning rivojlanishini bashorat qilish orqali bemorlar hayotini saqlab qolish va davolash samaradorligini oshirish bugungi kunning eng muhim vazifalaridan biri hisoblanadi.

Zamonaviy sun'iy intellekt texnologiyalari, xususan machine learning va deep learning usullari bu borada yangi imkoniyatlar yaratmoqda. So'nggi yillarda bu sohada erishilgan yutuqlar shuni ko'rsatmoqdaki, sun'iy intellekt algoritmlari tibbiy ma'lumotlarni qayta ishlash va tahlil qilishda insondan ham yuqoriroq aniqlikka erisha olmoqda.

Ushbu tadqiqotning maqsadi kardioskleroz kasalligini prognoztik modelini yaratishda turli xil machine learning va deep learning usullarining samaradorligini qiyosiy tahlil qilish, shuningdek, gibrid yondashuvlarning afzalliklarini o'rganishdan iborat.

Materiallar va uslublar

Tadqiqot ma'lumotlari

Tadqiqot davomida 2020-2024 yillar oraliqida O'zbekistonning yetakchi kardiologiya markazlarida kuzatilgan 230 ta bemor ma'lumotlari tahlil qilindi. Ma'lumotlar to'plami quyidagi parametrlarni o'z ichiga oladi:



Tadqiqotda o'rganilgan parametrlar

1. Demografik ma'lumotlar

Parametrlar	Qisqa tavsif / Ko'rsatmalar	O'lchov birligi / Izoh
Yosh	Bemorlar yoshi (o'rtacha, minimal, maksimal diapazon).	Yil
Jins	Erkak yoki ayol.	Nominal
Yashash joyi	Shaharda yoki qishloqda istiqomat qiladi.	Nominal (shahar/qishloq)
Kasb faoliyati	Xizmat ko'rsatish, ishlab chiqarish, tadbirkorlik, nafaqaxo'r, talaba va h.k.	Nominal
Oilaviy holati	Turmush qurgan/qurmagan, farzandlari bor/yo'qligi.	Nominal
Yosh	Bemorlar yoshi (o'rtacha, minimal, maksimal diapazon).	Yil

2. Klinik ko'rsatkichlar

Parametrlar	Qisqa tavsif / Ko'rsatmalar	O'lchov birligi / Izoh
Arterial qon bosimi	Sistolik (SBP) va diastolik (DBP) bosim ko'rsatkichlari.	mmHg
Yurak urishi tezligi	Yurak urish chastotasi (puls).	marta/min
Tana vazni indeksi (BMI)	Tana vazni va bo'yiga asoslangan ko'rsatkich.	kg/m ²
Jismoniy faollik darajasi	Har kunlik jismoniy faollik: past, o'rtacha, yuqori.	Kategorik (shkala)
Chekish status	Chekuvchi, ilgari chekuvchi yoki umuman chekmaydigan.	Nominal
Qandli diabet mavjudligi	Qandli diabet turini (I/II) yoki mavjud/mavjud emasligini ko'rsatadi.	Nominal
Avvalgi yurak kasalliklari tarixi	Miokard infarkti, yurak yetishmovchiligi, aritmiya va boshqa kardiologik kasalliklar.	Nominal

Parametrlar	Qisqa tavsif / Ko'rsatmalar	O'lchov birligi / Izoh
Lipid profili	Umumiy xolesterin, HDL, LDL, trigliseridlar.	mmol/L
Qand miqdori	Qondagi glyukoza darajasi (och qoringa yoki tasodifiy).	mmol/L
Kreatin	Buyrak faoliyati bilan bog'liq ko'rsatkich.	μmol/L



ALT, AST	Jigar fermentlari.	Birlik/L (masalan, U/L)
Umumiy qon tahlili	Gemoglobin, leykotsit, trombosit soni, ESR (kengaytirilgan ko'rsatkichlar).	g/L, 10 ⁹ /L, mm/soat va h.k.
C-reaktiv oqsil	Yallig'lanish darajasi (CRP).	mg/L
Troponin	Yurak mushaklari zararlanishi (miokard infarkti) uchun muhim biomarker.	ng/mL
BNP (B-type natriuretic peptide)	Yurak yetishmovchiligi darajasini baholash uchun muhim ko'rsatkich.	pg/mL

3. Laboratoriya natijalari

4. Instrumental tekshiruv natijalari

Parametrlar	Qisqa tavsif / Ko'rsatmalar	O'lchov birligi / Izoh
EKG ma'lumotlari (12 ta standart ulanish)	Elektrokardiogrammada yurak ritmi, ishemiya yoki boshqa o'zgarishlar belgilari.	Nominal / to'liqinsimon tahlil
ExoKG tasvirlari	Yurak bo'linmalarining tuzilishi, ejeksion fraksiyasi, devor harakati va h.k.	mm, foiz (EF), ball
Rentgen tasvirlari	Ko'krak qafasi rentgeni, yurak silueti, o'pka holati.	Tasviriy analiz (kengaygan soha, suyuqlik va h.k.)
Koronar angiografiya ma'lumotlari	Koronar arteriyalarda stenoz yoki torayish darajasi, lokatsiyasi.	Foiz (%), ball, anatomik joylashuv

Ma'lumotlarni qayta ishlash

Tadqiqot doirasida ishlatilgan barcha ma'lumotlar dastlab standartlashtirish va normalizatsiya jarayonlaridan o'tkazildi. Bu ma'lumotlarni optimal holatda modelga kiritish va hisoblash samaradorligini oshirish uchun muhim bosqich hisoblanadi. Yetishmayotgan ma'lumotlar (missing values) maxsus algoritmlar yordamida aniqlanib, ular mos usullar orqali to'ldirildi. Bundan tashqari, kategorik ma'lumotlar sonli formatga o'tkazildi (encoding jarayoni) va modellar uchun mos shaklda tayyorlandi[2-3].

Raqamli ma'lumotlar uchun qayta ishlash bosqichlari:

1. Standartlashtirish – har bir xususiyat (feature) taqsimoti muayyan diapazonga moslashtirildi, bu esa modelni stabil ishlashini ta'minladi.

2. Normalizatsiya – har bir o'zgaruvchi [0,1] yoki [-1,1] oraliqqa tushirildi.

3. Yetishmayotgan qiymatlarni to'ldirish – ma'lumotlar to'plamidagi bo'sh joylarni to'ldirish uchun imputation usullari, jumladan, o'rtacha qiymat (mean), median yoki KNN Imputer ishlatildi.

4. Kategorik ma'lumotlarni sonli shaklga o'tkazish – one-hot encoding yoki label encoding orqali barcha matnli belgilar sonli formatga o'tkazildi.

Tasviriy ma'lumotlar uchun qayta ishlash bosqichlari

Tasviriy ma'lumotlar (EKG, ExoKG, rentgen tasvirlari) maxsus pre-processing bosqichidan o'tkazilib, CNN modeli uchun moslashtirildi. Bu jarayon quyidagi bosqichlarni o'z ichiga oladi:

1. **Tasvirlarni qayta o'lchamlash** – barcha tasvirlar bir xil o'lchamga keltirildi, bu



esa modelning hisoblash jarayonini samarali qilishga yordam berdi.

- 2. **Kontrast normallashtirish** – tasvirlarning kontrasti yaxshilandi, bu esa model uchun yanada aniqroq xususiyatlar ajratib olish imkonini yaratdi.
- 3. **Shovqinlarni kamaytirish** – tasvirlardagi ortiqcha shovqinlar (noisy pixels) maxsus filtrlar yordamida yo‘q qilindi.
- 4. **Data augmentation** – modelni umumlashtirish qobiliyatini oshirish maqsadida tasvirlarga random aylantirish, oynaviy akslantirish (flipping), yorug‘likni o‘zgartirish, shovqin qo‘shish kabi texnikalar qo‘llandi.

Ma'lumotlarni qayta ishlash jarayonlari modellarni aniqroq va samarali ishlashini ta'minlashda muhim ahamiyatga ega bo'ldi. Ushbu bosqichlar orqali kardioskleroz kasalligini prognoz qilish modeli uchun optimal ma'lumotlar bazasi tayyorlandi va har bir modelga moslashgan holda ishlov berildi. Ma'lumotlarni oldindan to'g'ri qayta ishlash natijasida modellar yuqori aniqlikka ega bo'lishi, hisoblash jarayoni esa tezroq va samaraliroq amalga oshirilishi ta'minlandi[2-3].

Ushbu tadqiqotda kardioskleroz prognozini optimallashtirish maqsadida mashinaviy o'rganish (ML) va chuqur o'rganish (DL) yo'nalishidagi bir nechta model sinovdan o'tkazildi. Quyida tadqiqot jarayonida qo'llanilgan modellar va ularning asosiy giperparametrlari keltiriladi.

Random Forest (RF)

Daraxtlar soni: 500 ta • Maksimal chuqurlik (max_depth): 15 • Minimal barg hajmi (min_samples_leaf): 5 • Feature selection (xususiyat tanlovi): Gini importance Random Forest - bir nechta qaror daraxtlarini ansambl sifatida birlashtiradigan klassik ML modeli. Mazkur tadqiqotda 500 ta daraxt qo'llanishi modellarning barqaror natijalar berishiga xizmat qiladi. Maksimal chuqurlik 15 bilan cheklangan

bo'lib, haddan tashqari o'qitish (overfitting)ning oldini olish maqsadida minimal barg hajmi 5 etib belgilandi. Model xususiyatlarining ahamiyatini Gini impurity asosida baholaydi.

Support Vector Machine (SVM)

Kernel: RBF (Radial Basis Function) • C parametri: 10 • Gamma: 'scale' • Probability estimation: True SVM modeli yuqori o'lchamli fazoda optimal hyperplane topish orqali klassifikatsiya vazifalarini bajaradi. Ushbu tadqiqotda RBF yadrosi tanlanib, C parametri 10 ga teng, Gamma esa 'scale' holatida sozlangan. Probability estimation rejimi yoqilgani sababli model klassifikatsiya natijalariga ishonch ehtimolini ham hisoblab chiqadi.

Convolutional Neural Network (CNN)

• Input layer: 224x224x3 • 5 ta convolutional qatlam • 3 ta max pooling qatlam • 2 ta fully connected qatlam • Dropout: 0.5 • Activation function: ReLU • Output activation: Sigmoid CNN modeli asosan tasvirlarni qayta ishlashda keng qo'llaniladi. Ushbu tadqiqotda 224x224 piksel, 3 kanalli (RGB) formatdagi kirish qatlam qabul qilinib, 5 ta konvolyutsion (convolutional) qatlam va 3 ta max pooling qatlam orqali asosiy xususiyatlar ekstraksiyasi amalga oshiriladi. Keyin 2 ta to'liq bog'langan (fully-connected) qatlam ulab, klassifikatsiya ehtimoli sigmoid funksiya yordamida bajariladi. Overfittingning oldini olish uchun Dropout 0.5 etib belgilangan[3].

Gibrid model (CNN + RF)

CNN modeli tasviriy ma'lumotlar uchun • RF modeli raqamli ma'lumotlar (tabular data) uchun • Ensemble learning orqali natijalarni birlashtirish Gibrid yondashuvda tasvirlar bilan bog'liq xususiyatlar CNN orqali qayta ishlanadi, raqamli yoki katta xajmdagi jadvali ma'lumotlar esa Random Forest modeli yordamida tahlil qilinadi. Yakuniy bosqichda har ikki modeldan olingan chiqish (output)lar ensemble/voting usuli asosida birlashtirilib, prognozning aniqligi oshiriladi.



Baholash mezonlari

1-Jadval

Modellarning samaradorligini baholash uchun quyidagi metrikalardan foydalanildi:

Baholash mezonlari	Tavsif	Formula/Hisoblash
Accuracy (Aniqlik)	To'g'ri bashorat qilingan holatlarning umumiy holatlar soniga nisbati	$(TP + TN) / (TP + TN + FP + FN)$
Precision (Aniqlilik)	To'g'ri aniqlangan ijobiy holatlarning barcha ijobiy deb bashorat qilingan holatlarga nisbati	$TP / (TP + FP)$
Recall (Sensitivity)	To'g'ri aniqlangan ijobiy holatlarning haqiqiy ijobiy holatlarga nisbati	$TP / (TP + FN)$
F1-score	Precision va Recall ko'rsatkichlarining garmonik o'rtachasi	$2 (Precision \cdot Recall) / (Precision + Recall)$
AUC-ROC	ROC egri chizig'i ostidagi maydon, modelning diskriminatsiya qobiliyatini ko'rsatadi	0 dan 1 gacha bo'lgan son
Specificity	To'g'ri aniqlangan salbiy holatlarning haqiqiy salbiy holatlarga nisbati	$TN / (TN + FP)$
NPV	To'g'ri aniqlangan salbiy holatlarning barcha salbiy deb bashorat qilingan holatlarga nisbati	$TN / (TN + FN)$
PPV	To'g'ri aniqlangan ijobiy holatlarning barcha ijobiy deb bashorat qilingan holatlarga nisbati	$TP / (TP + FP)$

Natijalar

Ushbu tadqiqot davomida kardioskleroz kasalligini prognoz qilishda turli sun'iy intellekt modellarining samaradorligi baholandi. Tadqiqot natijalari shuni ko'rsatdiki, har bir model o'ziga xos afzallik va kamchiliklarga ega bo'lib, ma'lumotlar turiga qarab natijalari sezilarli darajada farq qiladi. Random Forest modeli raqamli ma'lumotlar bilan ishlashda yuqori aniqlikni ta'minlagan bo'lsa, CNN modeli tasviriy ma'lumotlarni qayta ishlashda ustunlikka ega ekanligi aniqlandi. Shuningdek, SVM modeli noxiziq bog'liqliklarni aniqlashda yaxshi

natija bergan. Tadqiqot natijalariga ko'ra, modellarni birlashtirish orqali prognostik aniqlikni oshirish mumkinligi isbotlandi va gibridd yondashuv eng yuqori natijani namoyon qildi.

Random Forest modeli umumiy ma'lumotlar to'plami uchun 85.7% aniqlik ko'rsatdi va ma'lumotlarni segmentatsiya qilish, muhim xususiyatlarni aniqlash va raqamli ma'lumotlar bilan ishlashda yaxshi natijalar berdi. Feature importance analizi natijalariga ko'ra, yosh, qondagi lipid profili, arterial qon bosimi, BNP darajasi va troponin ko'rsatkichlari eng muhim prognoz belgilari sifatida ajratib



olindi. Random Forest modelining asosiy afzalliklaridan biri uning overfitting muammosiga bardoshliligi va parallel hisoblash imkoniyatidir. Modelning ishlash ko'rsatkichlari shuni ko'rsatdiki, precision 0.86, recall 0.84, F1-score 0.85 va AUC-ROC 0.89 bo'ldi[2-4].

SVM modeli esa 83.2% aniqlik bilan ishlagan bo'lib, ayniqsa nochiziqli bog'liqliklarni aniqlash qobiliyatiga ega ekanligi aniqlandi. Bu model murakkab bog'liqliklarni o'rganish va korrelyatsiyalangan ma'lumotlarni qayta ishlashda yaxshi natija ko'rsatdi. SVM modeli ayniqsa o'rta hajmdagi ma'lumotlar to'plami bilan ishlaganda samarador bo'lib, u yuqori dimensional fazoda ma'lumotlarni samarali ajratish qobiliyatiga ega. Ushbu modelning ishlash ko'rsatkichlari precision 0.84, recall 0.82, F1-score 0.83 va AUC-ROC 0.87 ekanligini ko'rsatdi.

CNN modeli tasviriy ma'lumotlarni qayta ishlashda 88.4% aniqlik bilan ishlagan bo'lib, u ayniqsa EKG va ExoKG tasvirlaridan muhim belgilarni avtomatik ravishda ajratib olishda yuqori natija ko'rsatdi. CNN modeli turli turdagi tasviriy ma'lumotlar bilan ishlash imkoniyatiga ega bo'lib, EKG ma'lumotlari uchun 89.2%, ExoKG tasvirlari uchun 87.8%, va rentgen tasvirlari uchun 86.5% aniqlik qayd etildi. CNN modeli yuqori aniqlikka erishish imkonini bersada, uning asosiy kamchiliklaridan biri ko'p hisoblash resurslarini talab qilishi va model interpretatsiyasining murakkabligidir. Modelning ishlash ko'rsatkichlari shuni ko'rsatdiki, precision 0.89, recall 0.87, F1-score 0.88 va AUC-ROC 0.91 bo'ldi.

Eng yuqori natijani esa CNN va Random Forest modellarining kombinatsiyasiga asoslangan gibril model ko'rsatdi. Ushbu model tasviriy va raqamli ma'lumotlarni kompleks qayta ishlash orqali 91.2% aniqlik bilan ishladi. Gibril modelning afzalligi shundaki, u har ikkala modelning kuchli tomonlarini birlashtirib, tasviriy va raqamli belgilarni optimal qayta ishlash imkonini beradi. Natijada, modelning precision 0.92, recall 0.90, F1-score 0.91 va AUC-ROC 0.94 ko'rsatkichlari bilan eng yuqori natijaga erishildi.

Tadqiqot natijalari shuni ko'rsatdiki, **gibril yondashuv prognozlash aniqligini 5-7% ga oshirish imkonini beradi** va bu turli turdagi

ma'lumotlarni tahlil qilishda samarali usul hisoblanadi. CNN modeli tasviriy ma'lumotlarni qayta ishlashda eng yuqori aniqlikka ega bo'lsa, Random Forest modeli raqamli ma'lumotlar bilan ishlashda samaradorlikni ta'minladi. Modellarni kombinatsiya qilish orqali aniqlik oshirilib, turli turdagi ma'lumotlarni birlashtirish natijasida optimal natijalarga erishish mumkinligi tasdiqlandi.

Muhokama

Tadqiqot natijalari ko'rsatdiki, har bir model o'ziga xos kuchli va zaif tomonlarga ega bo'lib, ular tahlil qilinayotgan ma'lumot turiga qarab samaradorlik jihatdan farqlanadi. Random Forest modeli raqamli ma'lumotlar bilan ishlashda yaxshi natijalar bergan bo'lsa, CNN modeli tasviriy ma'lumotlar, xususan, EKG va ExoKG tasvirlarini qayta ishlashda yuqori aniqlikka erishdi. Shu bilan birga, SVM modeli nochiziqli bog'liqliklarni aniqlash va yuqori o'lchamli ma'lumotlar bilan ishlashda o'zini samarali namoyon qildi. Shuningdek, gibril yondashuv turli turdagi ma'lumotlarni kompleks tahlil qilishda yaxshiroq natijalar ko'rsatdi.

Random Forest modelining afzallik va kamchiliklari

Random Forest modeli ma'lumotlarni qayta ishlashda bir nechta muhim afzalliklarga ega. Uning feature importance tahlili orqali muhim belgilarni aniqlash imkoniyati modelning interpretatsiyasini yaxshilaydi. Bundan tashqari, u overfitting muammosiga nisbatan bardoshlidir, chunki har bir daraxt o'zining mustaqil qarorlarini shakllantiradi va natijada umumiy modelga mustahkamlik qo'shadi. Parallel hisoblash imkoniyati va turli turdagi ma'lumotlar (kategorik va raqamli) bilan ishlash qobiliyati ham modelning ustunliklaridan biri hisoblanadi.

Biroq, modelning ba'zi kamchiliklari ham mavjud. Model interpretatsiyasining murakkabligi uni tushunish va tahlil qilishni qiyinlashtiradi. Shuningdek, tasviriy ma'lumotlar bilan ishlash imkoniyatining cheklanganligi uning qo'llanilishini cheklaydi. Random Forest modeli, ayniqsa, katta hajmdagi xotira talab qiladi, bu esa uning katta hajmdagi ma'lumotlar bilan ishlashda resurs sarfini oshiradi[5].

SVM modelining afzallik va kamchiliklari

SVM (Support Vector Machine) modeli nochiziqli bog'liqliklarni aniqlash qobiliyatiga



ega bo'lib, ma'lumotlar o'rtasidagi murakkab munosabatlarni samarali o'rganish imkonini beradi. Shuningdek, u yuqori dimensional ma'lumotlar bilan yaxshi ishlaydi va outlier'lar ta'siriga nisbatan barqaror hisoblanadi.

Biroq, SVM modeli ham ba'zi kamchiliklarga ega. U katta hajmdagi ma'lumotlar bilan ishlashda sekinlik qiladi, chunki hisoblash resurslari juda katta talab qilinadi. Bundan tashqari, parametrlarni to'g'ri sozlash murakkabligi modelni optimallashtirish jarayonini murakkablashtiradi.

CNN modelining afzallik va kamchiliklari

CNN (Convolutional Neural Network) modeli tasviriy ma'lumotlardan avtomatik ravishda belgilarni ajratib olish imkoniyati bilan ajralib turadi. Ushbu model yuqori aniqlik bilan ishlaydi va real vaqt rejimida ishlash imkoniyatiga ega.

Biroq, CNN modelining asosiy kamchiliklaridan biri katta hajmdagi o'quv ma'lumotlariga bo'lgan ehtiyoj hisoblanadi. Shuningdek, modelni o'qitish uzoq vaqt talab etadi va katta hisoblash resurslarini talab qiladi. Bundan tashqari, "qora quti" effekti, ya'ni modelning qaror qabul qilish jarayoni shaffof emasligi, uning natijalarini tushuntirishni qiyinlashtiradi.

Gibrid yondashuvning afzallik va kamchiliklari

Gibrid yondashuv bir nechta modelning kuchli tomonlarini birlashtirish orqali turli turdagi ma'lumotlarni kompleks qayta ishlash imkonini beradi. Bunday yondashuv natijalarning yuqori aniqlik darajasiga erishishiga yordam beradi va har bir modelning afzalliklaridan foydalanish imkoniyatini yaratadi.

Ammo, gibrid yondashuv ham muayyan kamchiliklarga ega. Uning arxitekturasi murakkab bo'lib, uni amalga oshirish va tahlil qilish jarayoni qiyinlashadi. Bundan tashqari, katta hisoblash resurslarini talab qilishi va parametrlarni sozlash va optimizatsiya qilishning murakkabligi uni qo'llashda qo'shimcha muammolar tug'dirishi mumkin.

Xulosa. Ushbu tadqiqot natijalari shuni ko'rsatdiki, kardiosklerozni erta aniqlash va uning rivojlanishini bashorat qilish uchun machine learning va deep learning usullarining kombinatsiyasiga asoslangan gibrid yondashuv eng samarali yechim hisoblanadi. Tadqiqot davomida turli modellar samaradorligi baholandi va ularning har biri o'ziga xos afzallik va kamchiliklarga ega ekanligi aniqlandi. Natijalar shuni ko'rsatdiki, gibrid modelning aniqligi 91.2% ga yetib, eng yuqori natijani ta'minladi.

CNN modeli tasviriy ma'lumotlarni qayta ishlashda ustunlik qilgan bo'lsa, Random Forest modeli raqamli ma'lumotlarni tahlil qilishda samarali bo'ldi. Shuningdek, turli modellarni birlashtirish orqali prognostik aniqlik 5-7% ga oshirilishi kuzatildi. Ushbu natijalar sun'iy intellekt texnologiyalarining tibbiyot sohasidagi potentsialini yana bir bor tasdiqlaydi.

Kelajakda bu sohada tadqiqotlarni rivojlantirish uchun quyidagi yo'nalishlar muhim ahamiyat kasb etadi:

- Real vaqt rejimida ishlashga moslangan modellarni yaratish, bu esa klinik sharoitda kasallikni tezkor aniqlash va nazorat qilish imkonini beradi.
- Modellar interpretatsiyasini yaxshilash, chunki sun'iy intellekt qarorlarini shaffof va tushunarli qilish muhimdir.
- Tibbiyot amaliyotiga integratsiya qilish mexanizmlarini takomillashtirish, bu esa shifokorlar va klinik mutaxassislariga innovatsion texnologiyalarni samarali qo'llashga yordam beradi.
- Ma'lumotlar bazasini kengaytirish va standartlashtirish, bu esa modelni yanada mukammal va ishonchli qilish imkonini beradi.
- Modellar kombinatsiyasining yangi usullarini ishlab chiqish, bu esa diagnostika va prognozlashda yanada yuqori aniqlikka erishish uchun asos yaratadi.

Umuman olganda, ushbu tadqiqot sun'iy intellekt texnologiyalarining kardioskleroz diagnostikasi va prognozlash sohasidagi salohiyatini ochib beradi. Modellar yanada rivojlantirish va klinik amaliyotga joriy etish orqali kasallikni erta bosqichda aniqlash va bemorlarning sog'lig'ini samarali nazorat qilish imkoniyati oshadi.



FOYDALANILGAN ADABIYOTLAR

- 1.Chen J., Smith K.L., Li X. Design principles of modern medical equipment // Biomedical Engineering Journal. - 2023. - Vol. 70(4). - P. 1125-1134.
- 2.Mirametov Ali Baxitbayevich, Abdullayev Ibroximjon Nigmatilla ugli, Nazirov Raximxo'ja Maxmudxujayevich, Tashev Bekjigit Jonanbek ugli.APPLICATION OF ARTIFICIAL INTELLIGENCE IN ECG ANALYSIS: PROBLEMS AND THEIR SOLUTIONS IN HEALTHCARE.SCIENCE AND INNOVATION INTERNATIONAL SCIENTIFIC JOURNAL VOLUME 3 ISSUE 3 MARCH 2024.110-115.
- 3.Nematov SQ, Kamolova YM, Abdullayev IN. Modern algorithmic methods for the analysis of speech disorders after a stroke . Science and Education. 2023;4(6):452-456.
- 4.Abdullaev I. N.,Magrupov T. M., Nazirov R. M.FORMATION OF A DATABASE OF LUNG DISEASE SOUND SIGNALS. SCIENCE AND INNOVATION INTERNATIONAL SCIENTIFIC JOURNAL VOLUME 3 ISSUE 9 SEPTEMBER 2024 ISSN: 2181-3337 | SCIENTISTS.UZ. 90-96.
- 5.Kumar R., Patel D.R., Wang Y. Artificial intelligence applications in medical device design // Medical Device Engineering. - 2022. - Vol. 45(3). - P. 234-245.

