



VILNIAUS UNIVERSITETAS
MEDICINOS FAKULTETAS

Medicinos studijų programa

*Klinikinės medicinos institutas
Širdies ir kraujagyslių ligų klinika*

Dovydas Martusevičius, VI kursas, 11 grupė

VIENTISŲJŲ STUDIJŲ MAGISTRO BAIGIAMASIS DARBAS

Dirbtinis intelektas kardiologijoje-aritmologijoje

Artificial Intelligence in Cardiology-Arrhythmology

Darbo vadovas

Doc. dr. Gediminas Račkauskas

Katedros ar klinikos vadovas

Prof. Sigita Glaveckaitė

Vilnius, 2025-05-10

Studento elektroninio pašto adresas: dovydas.martusevicius@mf.stud.vu.lt

Abstract	4
Santrauka.....	4
Kardiologijos terminai.....	4
Dirbtinio intelekto terminai	6
Kiti svarbūs terminai ir santrumpos	6
Raktažodžiai	7
Įvadas	7
Tyrimo tikslas.....	8
Apžvalgos apimtis	8
Metodologija	10
Įžanga	12
1. Dirbtinis intelektas kardiologijoje-aritmologijoje istoriniame kontekste	13
1.1 Ankstyvieji pagrindai (1940-1960)	13
1.2 Ankstyvoji raida (1961-1980)	14
1.3 Perėjimas prie mašininio mokymosi (1981-2000)	14
1.4 Giliojo mokymosi revoliucija (nuo 2010 m. iki dabar).....	15
1.5 Integracija su mobiliomis ir nešiojamosiomis technologijomis (nuo 2010 m. iki dabar) ...	16
1.6 Šiandieninė būklė ir ateities perspektyvos	16
2. Dirbtinio intelekto technologijų pagrindai ir apžvalga.....	17
2.1 Pagrindinės DI ir mašininio mokymosi sąvokos.....	17
2.2 DI metodai naudojami kardiologijoje.....	18
2.3 Konvoliucinių neuroninių tinklų techniniai aspektai kardiologijoje	19
2.4 Duomenų reikalavimai ir paruošimas.....	20
2.5 Operaciniai neuroniniai tinklai - naujos kartos dirbtinio intelekto sprendimas.....	22
3. Dirbtinio intelekto taikymai aptinkant ir diagnozuojant aritmijas	23
3.1 EKG interpretavimas ir aritmijų klasifikavimas	23
3.2 Prieširdžių virpėjimo aptikimas.....	25
3.3 Paveldimos aritmijos	26
3.4 Kitų aritmijų identifikavimas	28
4. Dirbtinis intelektas prognozuojant aritmijų riziką ir nustatant paciento prognozę	30
4.1 Aritmijų pradžios prognozavimas	30
4.2 Rizikos stratifikacija nepalankiems rezultatams	33
4.3 Rezultatų prognozavimas po intervencijų	34
4.4 Individualizuotas rizikos vertinimas ir gydymo parinkimas	36
5. Dirbtinis intelektas aritmijų stebėsenai ir valdymui	38

5.1 Nešiojamieji įrenginiai ir nuolatinė stebėseną.....	39
5.3 Integracija su elektroniniais sveikatos įrašais	41
5.4 Bekontaktės stebėjimo technologijos	42
5.5 Iššūkiai ir ateities kryptys.....	43
6. Dirbtinis intelektas antiaritminių vaistų valdyme.....	44
6.1 Vaistų dozavimo optimizavimas.....	44
6.2 Dirbtinis intelektas vaistų saugumo tyrimuose	45
7. Dirbtinis intelektas elektrofiziologijos procedūrose.....	47
7.1 Žemėlapių sudarymas ir abliacijos gairės	47
7.2 Robotų asistuojamos procedūros.....	47
8. Dirbtinis intelektas širdies stimuliacijos terapijoje.....	48
8.1 Dirbtinis intelektas širdies resinschronizacijos terapijoje.....	48
8.2 Implantuojami kardioverteriai-defibriliatoriai (IKD).....	49
9. Iššūkiai ir apribojimai.....	51
9.1 Duomenų kokybės ir standartizavimo problemos	51
9.2 DI modelių interpretavimo ir paaiškinamumo problemos.....	52
9.3 Reglamentavimo ir etiniai aspektai	53
9.4 Klinikinis patvirtinimas ir įgyvendinimas	54
9.5 Technologiniai apribojimai.....	55
10. Ateities kryptys.....	57
10.1 Didžiųjų kalbos modelių potencialas aritmologijoje.....	57
10.2 Naujos DI technologijos aritmologijoje	58
10.3 Daugiamodalinių duomenų integracija	60
10.4 Pažangios klinikinių sprendimų palaikymo sistemos.....	60
10.5 Naujos technologijos ir metodai.....	60
10.6 Etiškas DI ir reguliavimo sistemos.....	61
11. Išvados ir praktinės rekomendacijos	61
11.1 Dirbtinio intelekto vaidmuo kardiologijoje	61
11.2 Rizikos vertinimas ir gydymo prognozavimas	61
11.3 Nuolatinė stebėseną ir nuotolinė priežiūra	61
11.4 DI taikymas procedūrose ir vaistų valdyme	62
11.5 Poveikis klinikinei praktikai.....	62
11.6 Iššūkiai ir tyrimų poreikiai	62
11.7 Etinės, teisinės ir integracijos problemos	62
Literatūros sąrašas	62

Abstract

This literature review examines the current state and future prospects of artificial intelligence (AI) applications in cardiology-arrhythmology. The integration of AI, particularly deep learning techniques, has shown significant promise in enhancing various aspects of arrhythmia management. Key areas of impact include ECG interpretation, arrhythmia detection and classification, risk prediction, and continuous monitoring through wearable devices. AI models have demonstrated accuracy comparable to or exceeding that of human experts in many tasks, such as detecting atrial fibrillation and other cardiac abnormalities. The review also explores AI's potential in drug management, electrophysiology procedures, and personalized treatment approaches. Despite these advancements, challenges remain, including issues of data quality, model interpretability, and the need for robust clinical validation. Ethical considerations and regulatory frameworks are discussed as critical factors in the responsible implementation of AI in clinical practice.

Santrauka

Šioje literatūros apžvalgoje nagrinėjama šiandieninė dirbtinio intelekto (DI) taikymo kardiologijoje-aritmologijoje praktika ir ateities perspektyvos. Dirbtinio intelekto, o ypač giliojo mokymosi metodų, integravimas parodė didelį potencialą gerinant įvairius aritmijų valdymo aspektus. Pagrindinės poveikio sritys apima EKG interpretavimą, aritmijų nustatymą ir klasifikavimą, rizikos prognozavimą ir nuolatinę stebėseną naudojant nešiojamus įrenginius. Daugelyje sričių DI modelių tikslumas prilygsta medicinos ekspertų tikslumui arba net jį viršija, pavyzdžiui, nustatant prieširdžių virpėjimą ir kitus širdies ritmo sutrikimus. Apžvalgoje taip pat nagrinėjamas DI potencialas vaistų dozavimo valdyme, elektrofiziologijos procedūrose ir individualizuotuose gydymo metoduose. Nepaisant šių pasiekimų, išlieka daug iššūkių: duomenų kokybės problemos, modelių interpretavimo galimybės ir poreikis atlikti patikimą klinikinį patvirtinimą. Etiniai aspektai ir reguliavimo sistemos aptariami kaip svarbūs veiksniai, užtikrinantys atsakingą DI įgyvendinimą klinikinėje praktikoje.

Kardiologijos terminai

- **Abliacija:** procedūra, skirta pašalinti audinį, sukeliantį aritmijas.

- **Aritmija:** nereguliarus širdies plakimas arba nenormalus širdies ritmas.
- **Prieširdžių virpėjimas (PV):** dažna aritmija, pasižyminti nereguliariu ir dažnai pagreitėjusiu širdies ritmu, netvarkinga prieširdžių veikla.
- **Širdies ir kraujagyslių ligos (ŠKL):** ligų klasė, apimanti širdies ar kraujagyslių sistemos sutrikimus.
- **Elektrokardiograma (EKG):** tyrimas, registruojantis širdies elektrinį aktyvumą.
- **Elektrofiziologija:** biologinių ląstelių ir audinių, ypač širdies, elektrinių savybių tyrimas.
- **Hipertrofinė kardiomiopatija (HKM):** būklė, kai širdies raumuo tampa nenormaliai storas.
- **Implantuojamas kardioverteris-defibriliatorius (IKD):** į krūtinę implantuojamas prietaisas, skirtas aptikti ir sustabdyti neregulių širdies plakimą.
- **Širdies resinkronizuojamasis gydymas (angl. CRT) -** širdies stimuliacijos metodas, kai dešiniojo prieširdžio ir abiejų skilvelių stimuliavimas leidžia atkurti abiejų skilvelių sinchronišką susitraukimą.
- **Kairiojo skilvelio disfunkcija:** sutrikusi pagrindinės širdies kraujo pumpavimo kameros funkcija.
- **QT intervalas:** laiko tarpas tarp Q bangos pradžios ir T bangos pabaigos širdies elektriniame cikle.
- **Sinusinis ritmas:** normalus širdies ritmas, kuris prasideda sinusiniame mazge.
- **Staigi širdinė mirtis:** netikėta mirtis dėl širdies ligos, įvykstanti greitai po simptomų atsiradimo.
- **Skilvelių virpėjimas (SV):** gyvybei pavojinga širdies aritmija, pasižyminti greitu, chaotišku elektriniu aktyvumu skilveliuose, dėl kurio vietoje sinchronizuotų susitraukimų vyksta nekoordinuotas skilvelių raumens virpėjimas. SV metu širdis neefektyviai pumpuoja kraują, taip sukeldama ūmų kraujotakos nepakankamumą ir širdies sustojimą, jei būklė nedelsiant negydoma defibriliacija. Elektrokardiogramoje matomi nereguliarūs, chaotiški bangų kompleksai be išskiriamų P bangų, QRS kompleksų ar T bangų.

- **Skilvelinė tachikardija (ST):** potencialiai pavojinga širdies aritmija, kylanti iš ektopinių židinių skilveliuose, pasižyminti trimis ar daugiau iš eilės einančiais skilvelinės kilmės susitraukimais, kurių dažnis paprastai viršija 100 susitraukimų per minutę. ST gali būti monomorfinė (vienodi QRS kompleksai) arba polimorfinė (kintanti QRS morfologija), taip pat paroksizminė arba nuolatinė. Ši būklė gali sukelti hemodinaminį nestabilumą dėl sumažėjusio širdies išstumiamo kraujo tūrio ir gali progresuoti į skilvelių virpėjimą. Elektrokardiogramoje stebimi platūs QRS kompleksai (paprastai >120ms) ir atrioventrikulinė disociacija.

Dirbtinio intelekto terminai

- **Dirbtinis intelektas (DI, angliškai AI):** žmogaus intelekto procesų imitavimas kompiuterinėmis sistemomis.
- **Konvoliucinis neuroninis tinklas (KNT, angliškai CNN):** giliojo mokymosi algoritmo tipas, ypač efektyvus analizuojant vaizdus ir modelius.
- **Gilusis mokymasis (angliškai Deep Learning):** mašininio mokymosi poaibis, pagrįstas dirbtiniais neuroniniais tinklais su daugybe sluoksnių.
- **Mašininis mokymasis (MM, angliškai Machine Learning):** DI poaibis, orientuotas į algoritmų, galinčių pasiekti duomenis ir savarankiškai mokytis, kūrimą.
- **Skaitmeninis natūralios kalbos apdorojimas (NKA):** DI šaka, nagrinėjanti sąveiką tarp kompiuterių ir žmonių, naudojant natūralią kalbą.
- **Neuroninis tinklas:** algoritmų serija, kuri atpažįsta pagrindines duomenų rinkinio sąsajas, imituodama žmogaus smegenų veikimą.
- **Rekurentinis neuroninis tinklas (RNT, angliškai RNN):** neuroninio tinklo tipas, kuriame jungtys tarp mazgų sudaro kryptinį grafą išilgai laiko sekos.
- **Atraminių vektorių metodas (AVM, angliškai SVM (support vector machine)):** prižiūrimo mokymosi modelis, naudojamas klasifikavimui ir regresijos analizei.
- **XGBoost:** optimizuota paskirstytojo gradiento stiprinimo biblioteka, sukurta būti itin efektyvi, lanksti ir lengvai perkeliama.

Kiti svarbūs terminai ir santrumpos

- **AUC (PpK):** plotas po kreive, modelio prognozavimo tikslumo matas, apibrėžiantis kreivės plotą ROC (received operating characteristic) grafike.
- **BDAR (GDPR):** Bendrasis duomenų apsaugos reglamentas, ES teisės aktas dėl asmens duomenų apsaugos ir privatumo.
- **HIPAA:** Sveikatos draudimo perkeliamumo ir atskaitomybės aktas, JAV įstatymas, skirtas nustatyti privatumo standartus pacientų medicininiams įrašams ir kitai sveikatos informacijai apsaugoti.
- **Holterio monitorius:** nešiojamas prietaisas, skirtas nuolat stebėti įvairią širdies ir kraujagyslių sistemos elektrinę veiklą mažiausiai 24 valandas.
- **Nešiojamieji įrenginiai:** elektroniniai prietaisai, kurie gali būti dėvimi kaip aksesuarai, įmontuoti į drabužius, implantuoti į vartotojo kūną ar net tatuiruoti ant odos.

Raktažodžiai

Artificial Intelligence, Cardiology, Arrhythmia, Electrocardiogram (ECG), Machine Learning, Risk Prediction, Wearable Devices

Dirbtinis intelektas, kardiologija, aritmija, elektrokardiograma (EKG), mašininis mokymasis, rizikos prognozavimas, nešiojamieji įrenginiai

Įvadas

Širdies ir kraujagyslių ligos, ypač širdies ritmo sutrikimai (aritmijos), išlieka viena pagrindinių sergamumo ir mirtingumo priežasčių visame pasaulyje. Pastaraisiais metais dirbtinio intelekto (DI) technologijos sparčiai vystosi ir yra aktyviai pritaikomos įvairiose medicinos srityse, įskaitant kardiologiją ir aritmologiją. DI potencialas transformuoti širdies ligų diagnostiką, gydymą ir prevenciją yra milžiniškas, žadantis gerinti pacientų priežiūrą ir gydymo rezultatus.

Kardiologijoje DI jau rodo daug žadančius rezultatus: demonstruoja puikų gebėjimą interpretuoti elektrokardiogramas (EKG), aptinka širdies ritmo sutrikimus ir juos klasifikuoja, prognozuoja pacientų riziką ir padeda gydytojams parinkti tinkamiausią gydymą kiekvienam pacientui individualiai. Nuo automatizuotos EKG analizės iki pažangių prognozavimo

modelių, DI atveria naujas galimybes anksčiau ir tiksliau nustatyti širdies ligas, optimizuoti gydymą ir pagerinti pacientų stebėseną.

Tačiau kartu su šiomis galimybėmis kyla ir naujų iššūkių. Kyla klausimų dėl DI modelių patikimumo ir galimybių rezultatus interpretuoti, duomenų privatumo ir saugumo, etinių aspektų bei tinkamo integravimo į klinikinę praktiką. Siekiant užtikrinti, kad DI technologijos būtų naudojamos atsakingai ir efektyviai, šie klausimai reikalauja nuodugnaus nagrinėjimo ir aptarimo.

Ypač aktualu išsamiai ir kritiškai įvertinti DI taikymą kardiologijoje ir aritmologijoje. Svarbu ne tik suprasti dabartinę DI technologijų būklę šioje srityje, bet ir numatyti ateities perspektyvas bei galimas kliūtis jų įgyvendinimui.

Tyrimo tikslas

Šios literatūros apžvalgos tikslas yra apžvelgti dabartinį dirbtinio intelekto naudojimą ir ateities galimybes kardiologijoje-aritmologijoje. Siekiama išsiaiškinti, kaip DI padeda aptikti, diagnozuoti ir gydyti širdies ritmo sutrikimus. Kartu kritiškai vertinami iššūkiai ir apribojimai diegiant šias technologijas. Taip pat nagrinėjama, kaip DI integracija į kasdienę gydytojų praktiką paveiks pacientų priežiūrą, atsižvelgiant į etikos, teisės ir praktinio įgyvendinimo klausimus. Apibendrinama dabartinius tyrimus ir identifikuodama pagrindines tendencijas, ši apžvalga siekia tapti vertingu šaltiniu kliniciams, tyrėjams ir sveikatos politikos formuotojams, padedančiu suprasti ir orientuotis sparčiai besikeičiančioje DI aplinkoje kardiologijoje.

Apžvalgos apimtis

Ši literatūros apžvalga apima šias sritis:

- Laikotarpis:
 - Pagrindinis dėmesys skiriamas pastarųjų penkiolikos metų (nuo 2010 m. iki dabar) tyrimams ir pokyčiams
 - Trumpas istorinis kontekstas iš ankstesnių laikotarpių (apžvelgiant istorinį kontekstą)
- DI technologijos:

- Giliojo mokymosi metodai (deep learning), ypač konvoliuciniai neuroniniai tinklai (KNT)
- Mašininio mokymosi (machine learning) algoritmai, įskaitant atraminių vektorių metodus (support vector machines), atsitiktinius miškus (Random Forests) ir XGBoost
- Taisyklėmis pagrįstos sistemos (istoriniame kontekste)
- Taikymai kardiologijoje-aritmologijoje:
 - EKG interpretavimas ir aritmijų klasifikavimas
 - Specifinių aritmijų nustatymas ir diagnostika (pvz., prieširdžių virpėjimas, skilvelinės aritmijos)
 - Rizikos prognozavimas ir prognozė aritmologijoje
 - DI antiaritminių vaistų valdyme
 - DI taikymas elektrofiziologijos procedūrose
 - Nuolatinis stebėjimas naudojant nešiojamuosius įrenginius ir mobiliąsias sveikatos programėles
- Duomenų šaltiniai:
 - Standartinės 12 derivacijų EKG
 - Duomenys iš nešiojamųjų įrenginių ir mobiliųjų sveikatos programėlių
 - Elektroniniai sveikatos įrašai
 - Vaizdinimo duomenys (tuomet, kai integruoti su EKG duomenimis)
- Klinikiniai aspektai:
 - DI veikimo palyginimas su tradiciniais metodais ir ekspertais
 - DI galimas poveikis klinikinių sprendimų priėmimui ir darbo procesams
 - Pritaikymo individualizuotai medicinai potencialas
- Etiniai ir reguliavimo aspektai:
 - Duomenų privatumas ir saugumas

- Algoritmų teisingumas ir nešališkumas
- DI teisinio reguliavimo įstatyminė bazė taikymui sveikatos priežiūroje
- Iššūkiai ir apribojimai:
 - Duomenų kokybės ir standartizavimo problemos
 - Modelių interpretavimo ir paaiškinamumo klausimai
 - Klinikinio patvirtinimo ir įgyvendinimo iššūkiai
- Ateities kryptys:
 - Naujos DI technologijos aritmologijoje
 - Daugiamodalinių duomenų integracijos potencialas
 - DI perspektyvos personalizuotoje medicinoje aritmijų gydymui

Neįtraukiama:

- Išsamūs techniniai DI algoritmų aprašymai
- Išsami specifinių komercinių DI produktų analizė
- Ekonominė DI įgyvendinimo sveikatos priežiūros sistemose analizė
- DI taikymai kardiovaskuliniame vaizdinime (išskyrus atvejus, kai tai tiesiogiai susiję su aritmijų valdymu)
- DI širdies ir kraujagyslių ligų, nesusijusių su aritmijomis, srityje

Ši apžvalga siekia pateikti išsamią DI kardiologijoje-aritmologijoje apžvalgą, išlaikant dėmesį kliniškai aktualiems taikymams ir pasekmėms.

Metodologija

Šioje literatūros apžvalgoje buvo taikoma kryptinga paieškos strategija, siekiant nustatyti aktualias publikacijas apie dirbtinio intelekto taikymą kardiologijoje-aritmologijoje. Paieška buvo atlikta išimtinai naudojant Scopus duomenų bazę, kuri buvo pasirinkta dėl išsamios recenzuojamos mokslinės literatūros aprėpties.

Duomenų bazėje buvo naudojama ši paieškos eilutė: („Artificial Intelligence” OR „Machine Learning” OR „Deep Learning”) AND („Cardiology” OR „Arrhythmia” OR „ECG”)

Šis terminų derinys buvo sukurtas siekiant apimti platų DI taikymų spektrą kardiologijos srityje, ypač koncentruojantis į aritmijas ir EKG analizę.

Paieška buvo apribota straipsniais, paskelbtais nuo 2018 m. iki dabar, daugiausia dėmesio skiriant naujausiems pokyčiams šioje sparčiai besivystančioje srityje. Buvo nagrinėjamos tik anglų kalba paskelbtos publikacijos. Siekiant užtikrinti įtrauktos literatūros kokybę ir aktualumą, paieška buvo apribota recenzuojamais straipsniais ir klinikiniais tyrimais.

Po pradinės paieškos rezultatai buvo surūšiuoti pagal citatų skaičių. Šis metodas buvo pasirinktas, siekiant nustatyti įtakingiausias ir plačiausiai pripažintas publikacijas šioje srityje. Iš šių surūšiuotų rezultatų apžvalgai buvo atrinktos aktualios publikacijos su didžiausiu citatų skaičiumi.

Įtraukimo kriterijai:

- Recenzuojami straipsniai
- Klinikiniai tyrimai
- Originalūs moksliniai straipsniai
- Sisteminės apžvalgos ir meta-analizės
- Straipsniai, tiesiogiai susiję su DI taikymais kardiologijoje-aritmologijoje

Atmetimo kriterijai nebuvo formaliai taikomi, tačiau straipsniai, neatitinkantys įtraukimo kriterijų arba tiesiogiai nesusiję su apžvalgos tikslais, nebuvo įtraukti.

Atrinktoms publikacijoms tvarkyti ir valdyti buvo naudojama nuorodų tvarkymo programinė įranga Zotero.

Dirbtinio intelekto taikymo kardiologijoje ir aritmologijoje sritis vystosi itin sparčiai, o tai kelia specifinius metodologinius iššūkius literatūros apžvalgai. Publikacijų skaičius šioje srityje nuo 2010 iki 2023 metų išaugo eksponentiškai. Toks spartus augimas reiškia, kad vien per šios literatūros apžvalgos rengimo laikotarpį galėjo pasirodyti keli šimtai naujų mokslinių straipsnių.

Atsižvelgiant į šį iššūkį, paieškos strategija buvo patikslinta, įtraukiant papildomą filtravimo kriterijų, – laiko kriterijų. Pirminis literatūros paieškos etapas buvo užbaigtas 2023 rugsėjo mėnesį, tačiau buvo atliktas papildomas paieškos atnaujinimas 2025 metų sausio mėnesį, siekiant įtraukti naujausius ir reikšmingiausius tyrimus, publikuotus 2023-2025 metais. Šis

metodologinis sprendimas leido apžvalgoje atsižvelgti į pačius aktualiausius mokslinius tyrimus, išlaikant sistemiškumą ir metodologinį nuoseklumą.

Ižanga

Dirbtinis intelektas (DI) tapo transformuojančia jėga sveikatos priežiūroje, turinti didelį potencialą revoliucionizuoti įvairias medicinos sritis, įskaitant kardiologiją. (1) DI taikymas kardiovaskulinėje medicinoje, ypač aritmologijoje, yra sparčiai besivystanti tyrimų ir klinikinės medicinos sritis, atverianti naujas galimybes diagnozuojant ir gydant. (3) Širdies ir kraujagyslių ligos (ŠKL) išlieka pagrindine mirties priežastimi visame pasaulyje, sudarydamos 30 % mirčių Jungtinėse Amerikos Valstijose 2014 metais ir 45 % mirčių Europoje. ŠKL finansinė našta yra didžiulė – vien Europos Sąjungai ji kainuoja apie 210 milijardus eurų per metus. (13)

Elektrokardiograma (EKG) yra visuotinai paplitęs ir standartizuotas tyrimas klinikinėje medicinoje, suteikiantis vertingų įžvalgų apie širdies sveikatą ir ligas. Tačiau tradicinis EKG interpretavimas reikalauja didelės žmogiškosios patirties ir gali skirtis priklausomai nuo interpretuotojo patirties bei įgūdžių lygio. (3) Šis faktorius gali lemti neatitikimus tarp medicinos specialistų ir padidinti klaidingų diagnozių riziką. (13)

Pažangūs DI metodai, ypač giliojo mokymosi konvoliuciniai neuroniniai tinklai, geba EKG interpretuoti taip pat tiksliai kaip ir žmogus. Jie taip pat aptinka modelius, kurie yra neatpažįstami interpretuojantiems žmonėms. (3) Šios technologijos ne tik pasižymi dideliu tikslumu, bet ir gali paaiškinti savo sprendimus, todėl tampa itin vertingu įrankiu klinicinei analizei ir kardiologinei diagnostikai. (15)

DI integravimas su dideliais skaitmeninių EKG rinkiniais, susietais su gausia klinicine informacija, leido sukurti DI modelius, galinčius aptikti įvairias širdies patologijas, įskaitant kairiojo skilvelio disfunkciją, tylųjį prieširdžių virpėjimą ir hipertrofinę kardiomiopatiją. Šios DI augmentuotos EKG (DI-EKG) technologijos pademonstravo potencialą pagerinti diagnostikos tikslumą, darbo proceso efektyvumą ir galimai pacientų gydymo rezultatus. (3)

Mobiliųjų ir nešiojamųjų EKG technologijų atsiradimas dar labiau išplėtė DI taikymo galimybes aritmologijoje, suteikdamas galimybes nuolat stebėti ir anksti aptikti širdies veiklos anomalijas. (3) Šis DI ir mobiliųjų sveikatos technologijų susiliejimas turi potencialo revoliucionizuoti, tai kaip mes aptinkame, diagnozuojame ir gydome širdies ritmo sutrikimus.

Ši literatūros apžvalga siekia pateikti išsamią šiandieninio progreso ir ateities perspektyvų analizę DI taikymo kardiologijos-aritmologijos srityje. Nagrinėsime įvairius naudojamus DI metodus, jų taikymą nustatant, diagnozuojant ir valdant aritmijas, aptarsime potencialų poveikį priimant klinikinius sprendimus ir prižiūrint pacientus. Be to, aptarsime DI įgyvendinimo iššūkius ir apribojimus šioje srityje bei apibrėšime ateities tyrimų kryptis.


Abibendrinant naujausių tyrimų ir technologinių pasiekimų išvadas, šioje apžvalgoje siekiama suteikti įžvalgų apie transformuojantį DI vaidmenį gerinant širdies priežiūrą ir pacientų gydymo rezultatus. Nagrinėjant šią sparčiai besivystančią sritį, svarbu pažymėti, kad nors DI kardiologijoje turi didžiulį potencialą, jis dar nėra iki galo išnaudotas. Šio potencialo atidus įvertinimas bei įgyvendinimas bus labai svarbūs DI sėkmei klinikinėje praktikoje.

1. Dirbtinis intelektas kardiologijoje-aritmologijoje istoriniame kontekste

Dirbtinio intelekto taikymas kardiologijoje, o ypač aritmologijoje, turi turtingą istoriją, trunkančią kelis dešimtmečius. Dirbtinio intelekto evoliucija kardiologijoje atspindi platesnę neuroninių tinklų ir mašininio mokymosi raidą, pažymėtą keliais ryškiais inovacijų ir transformacijos periodais. Šio istorinio konteksto supratimas yra labai svarbus norint įvertinti dabartinę DI būklę šioje srityje ir numatyti jo ateities kryptis.

1.1 Ankstyvieji pagrindai (1940-1960)

Šiuolaikinio dirbtinio intelekto kardiologijoje pagrindai buvo padėti 1943 metais, kai Warren McCulloch ir Walter Pitts pasiūlė pirmąjį „**dirbtinio neurono**“ modelį. Šis novatoriškas darbas pristatė neuronų, kaip tiesinių modelių, kurie atlieka įvesties svorių sumavimą, koncepciją – fundamentalų principą, išliekanti ir šiandienos neuroniniuose tinkluose. (1) Sritis toliau vystėsi, kai Frank Rosenblatt pristatė „**Perceptrono**“ koncepciją, kuri padėjo pagrindus šiuolaikinėms neuroninių tinklų architektūroms. (1)



1 pav. McCulloch ir Walter Pitts „**dirbtinio neurono**” modelis. Funkcija f gauna įvestį ir perduoda jos sumą funkcijai g , kuri tada palygina reikšmę su slenksčio verte sprendimui priimti.

1.2 Ankstyvoji raida (1961-1980)

Lygiagrečiai vyko esminis vystymasis neuromokslinių tyrimų srityje. David H. Hubel ir Torsten N. Wiesel fundamentalūs kačių regos žievinės sistemos tyrimai, trukę daugiau nei 25 metus, revoliucionizavo mūsų supratimą apie informacijos apdorojimą neuronuose. Jų darbas atskleidė hierarchinę informacijos apdorojimo pobūdį smegenyse, pristatydamas tokias esmines koncepcijas kaip receptyvinis laukas ir žievinių neuronų funkcinės savybės. Šis tyrimas, už kurį 1981 metais buvo suteikta Nobelio premija fiziologijos ir medicinos srityje, vėliau įkvėpė neuroninių tinklų, naudojamų medicininių vaizdų ir signalų apdorojimui, architektūrinį dizainą. (1)

DI taikymas kardiologijoje siekia XX amžiaus 7-ąjį dešimtmetį, kai buvo sukurta pirmoji kompiuterizuota elektrokardiogramų interpretavimo sistema. (14) Tai žymėjo automatizuotos EKG analizės, srities, kuri reikšmingai vystėsi per ateinančius dešimtmečius, pradžią.

Šiuo ankstyvuoju laikotarpiu DI sistemos kardiologijoje daugiausia buvo pagrįstos taisyklėmis, paremtomis iš anksto apibrėžtais EKG interpretavimo kriterijais. (2) Šios sistemos naudojo sprendimų medžius ir kitas logines struktūras EKG bangų formoms analizuoti ir anomalijoms nustatyti. Nors tuo metu jos buvo novatoriškos, šios ankstyvosios sistemos turėjo rimtų apribojimų. Jos sunkiai tvarkėsi su sudėtingais ar netipiniais atvejais ir stokojo lankstumo prisitaikyti prie plataus EKG modelių spektro, pastebimo klinikinėje praktikoje.

1.3 Perėjimas prie mašininio mokymosi (1981-2000)

Remiantis David H. Hubel ir Torsten N. Wiesel neuromokslinėmis išvalgomis, Kunihiro Fukushima ir Sei Miyake 1982 metais pristatė „**Neocognitron**” – pirmąjį neuroninį tinklą, gebantį atpažinti šablonus, nepriklausomai nuo jų pozicijos ar nedidelių morfologinių variacijų. Šį proveržį sekė kitas esminis vystymasis 1986 metais, kai David E. Rumelhart ir Geoffrey E. Hinton išrado atgalinio sklaidimo (Back-Propagation) algoritmą, suteikdami sisteminį metodą neuroninių tinklų apmokymui.

XX amžiaus 10-asis dešimtmetis ir pirmieji XXI amžiaus metai žymėjo laipsnišką perėjimą nuo taisyklėmis pagrįstų sistemų prie statistinių metodų EKG analizėje. Šį perėjimą palengvino skaičiavimo galios padidėjimas ir didėjantis skaitmeninių EKG duomenų prieinamumas.

Sritis pasiekė kitą svarbų etapą 1990 metais, kai Yann LeCun sukūrė „LeNet” – pirmąjį praktinį konvoliucinį neuroninį tinklą (KNT). Iki 1998 metų „LeNet” pademonstravo išskirtinę sėkmę ranka rašytų skaitmenų atpažinime ir parodė potencialą medicininių signalų analizėje. Nors KNT rodė potencialą, jie užleido vietą kitiems mašininio mokymosi metodams, tokiems kaip atraminių vektorių metodai ir Bajeso (Bayes) tinklai, kurie buvo efektyvesni dirbant su mažesniais duomenų rinkiniais. (1)

Šiuo laikotarpiu ankstyvieji mašininio mokymosi metodai pradėti taikyti aritmijų aptikimui ir klasifikavimui. Tokie metodai kaip atraminių vektorių metodas (AVM) ir sprendimų medžiai parodė potencialą automatizuojant EKG interpretavimą. (16) Šie mašininio mokymosi metodai, lyginant su ankstesnėmis taisyklėmis pagrįstomis sistemomis, parodė didesnę lankstumą ir efektyvumą tvarkantis su įvairiais EKG modeliais.

Šiuo laikotarpiu taip pat prasidėjo pastangos integruoti DI valdomą EKG interpretavimą į klinikinio darbo algoritmus. Tačiau šių sistemų diegimą dažnai riboja jų skaičiavimo galios reikalavimai ir išliekantys nuogastavimai dėl jų tikslumo ir patikimumo.

1.4 Giliojo mokymosi revoliucija (nuo 2010 m. iki dabar)

XXI amžiaus 2-asis dešimtmetis buvo svarbus dėl giliojo mokymosi metodų, ypač konvoliucinių neuroninių tinklų (KNT), iškilimu EKG analizėje. (3) Šią giliojo mokymosi revoliuciją skatino GPU technologijų pažanga, didelių EKG duomenų rinkinių prieinamumas ir proveržiai neuroninių tinklų architektūrose.

Transformacinis momentas įvyko 2012 metais, pristačius AlexNet, kuris pademonstravo precedento neturintį tikslumą atpažįstant vaizdus. Šis giliojo mokymosi proveržis pristatė keletą esminių inovacijų per savo naują architektūrą. Ištiesintų tiesinių vienetų (ReLU) įdiegimas pagerino apmokymo efektyvumą, o iškritimo (dropout) technika patobulino apibendrinimo galimybes. Galbūt svarbiausia tai, kad AlexNet pademonstravo praktinį grafinių procesorių (GPU) pritaikymą neuroninių tinklų apmokymui, padarydamas gilųjį mokymąsi įgyvendinamą medicininiuose taikymuose. (1)

Keli svarbūs tyrimai šiuo laikotarpiu parodė žmogaus lygio ar jį viršijantį DI efektyvumą aptinkant aritmijas. (3) Pavyzdžiui, buvo sukurti giliojo mokymosi modeliai, galintys tiksliai diagnozuoti platų aritmijų spektrą iš standartinių 12 derivacijų EKG, dažnai prilygstant ar viršijant patyrusių kardiologų diagnostinį efektyvumą.

Esminis vystymasis kardiologijoje įvyko 2015 metais, pristatant kompaktinius ir adaptyvius 1D KNT, specialiai sukurtus EKG signalų analizei. Tai žymėjo perėjimą nuo

bendrosios paskirties DI adaptavimo prie specializuotų įrankių kardiologiniams taikymams kūrimo. Šie 1D KNT parodė, kad turi stiprių pranašumų lyginant su tradiciniais 2D metodais, ypač mažesniu skaičiavimo sudėtingumu ir tinkamumu realaus laiko apdorojimui. Skirtingai nuo 2D analogų, šie specializuoti tinklai galėjo efektyviai veikti standartinėje kompiuterinėje įrangoje ir reikalavo mažiau apmokymo duomenų. Šis vystymasis lėmė daugybę praktinių pritaikymų, nuo paciento specifinės aritmijų detekcijos iki realaus laiko širdies stebėsenos ir automatizuotos EKG interpretacijos. Gebėjimas tiesiogiai apdoroti vienmačius signalus, be konversijos į dvimatę reprezentaciją, pasirodė ypač vertingas kardiologijoje, kur laiko eilučių duomenys yra vyraujantys. (1)

DI taikymas kardiologijoje-aritmologijoje šiuo laikotarpiu taip pat išsiplėtė už EKG interpretavimo ribų. DI metodai pradėti taikyti rizikos prognozavimui, gydymo optimizavimui ir vaizdų analizei kardiologijoje. (15) Šis DI taikymų išplėtimas žymėjo poslinkį link išsamesnės, DI valdomos širdies ligų priežiūros.

1.5 Integracija su mobiliomis ir nešiojamosiomis technologijomis (nuo 2010 m. iki dabar)

Antroji XX amžiaus 2-o dešimtmečio pusė pažymėjo DI susiliejimą su mobiliomis ir nešiojamosiomis technologijomis, atveriant naujas galimybes aritmijų aptikime ir stebėsenoje. Buvo sukurti DI algoritmai, skirti aritmijoms aptikti naudojant duomenis iš išmaniųjų laikrodžių ir kitų nešiojamųjų įrenginių. (3)

Buvo pristatyti su išmaniaisiais telefonais suderinami EKG įrenginiai, turintys DI valdomas interpretavimo funkcijas, padarė asmeninę EKG stebėseną labiau prieinamą pacientams. (12) Šie pokyčiai žymėjo perėjimą link nuolatinės, realaus laiko aritmijų stebėsenos, įgalintos DI ir mobiliųjų technologijų. (15)

1.6 Šiandieninė būklė ir ateities perspektyvos

Šiuo metu DI tapo neatsiejama tyrimų ir inovacijų dalimi kardiologijoje-aritmologijoje, vis labiau integruojantis į klinikinę praktiką. (3) DI modeliai kuriami ir validuojami plataus spektro taikymams – nuo ankstyvo subklinikinių aritmijų aptikimo iki individualizuoto gydymo planavimo.

Tačiau iššūkių išlieka. Interpretavimo, apibendrinamumo ir reguliavimo patvirtinimo klausimai išlieka aktyvios tyrimų ir diskusijų sritys. (3) Taip pat auga suvokimas apie poreikį spręsti galimo DI modelių šališkumo problemą ir užtikrinti lygias galimybes naudotis DI valdomoms sveikatos priežiūros technologijoms.


Žvelgiant į ateitį, kylančios tendencijos apima daugiamodalinių DI sistemų, integruojančių duomenis iš įvairių šaltinių (EKG, vaizdinimo, genomikos ir kt.), kūrimą, DI naudojimą tiksliosios medicinos metoduose aritmijų valdymui, ir DI valdomų virtualios bei papildytos realybės įrankių tyrinėjimą elektrofiziologijos procedūrose. (18)

2. Dirbtinio intelekto technologijų pagrindai ir apžvalga

2.1 Pagrindinės DI ir mašininio mokymosi sąvokos

Dirbtinis intelektas reiškia kompiuterines sistemas, galinčias atlikti užduotis, kurioms paprastai reikalingas žmogaus intelektas. (2) Kardiologijos kontekste DI naudojamas jau dešimtmečius, ypač interpretuojant elektrokardiogramas (EKG). (2) DI apima įvairius metodus, leidžiančius kompiuteriams imituoti žmogaus intelektą, o mašininis mokymasis (MM) yra pagrindinis jo poaibis. (18)

Mašininis mokymasis apima kompiuterinius algoritmus, kurie gali išmokti sudėtingus modelius iš duomenų ir atlikti prognozes. (2) Mašininio mokymosi algoritmai gerina savo veikimą mokydami iš duomenų, o tai leidžia jiems laikui bėgant automatiškai tobulėti. (15) Šis gebėjimas mokytis iš duomenų leidžia mašininio mokymosi algoritmus pritaikyti sudėtingos ir įvairios kardiologinės informacijos analizei.



Pav. 2: Dirbtinis intelektas ir jo poaibiai

Gilusis mokymasis, dar vienas mašininio mokymosi poaibis, naudoja dirbtinius neuroninius tinklus su daugybe sluoksnių, kad išmokyti funkciją tarp įvesties ir išvesties rinkinių. (4) Šie giliai neuroniniai tinklai gali automatiškai nustatyti savo veikimo efektyvumą ir atlikti automatinius pakeitimus, leisdami jiems identifikuoti subtilias modelių variacijas duomenyse, kurias gali praleisti žmogaus akis ar paprastesni algoritmai. (18)

Dirbtinis intelektas ir jo poaibiai bei jų sąsajos vizualizuotos 2-ajame paveiksliuke.

2.2 DI metodai naudojami kardiologijoje

Kardiologijoje sėkmingai pritaikyti keli DI algoritmai, kiekvienas turintis savo stiprybes ir taikymo sritis.

Konvoliuciniai neuroniniai tinklai (KNT)

Šie tinklai ypač tinka EKG signalų analizei ir vaizdų apdorojimui. KNT naudoja konvoliucinius filtrus požymiams, kurie yra naudojami įvesties duomenims atvaizduoti ir atrinkti, todėl jie efektyviai identifikuoja erdvinės hierarchijas ir modelius EKG signaluose. (5)

Rekurentiniai neuroniniai tinklai (RNT)

Sukurti laiko sekų duomenims (temporal data sequences) analizuoti. RNT ypač naudingi ilgų EKG įrašų modeliams identifikuoti. Jų gebėjimas palaikyti vidinę būseną arba „atmintį“ daro juos tinkamus laiko sekos duomenų, tokių kaip EKG signalai, analizei. (2)

Atraminių vektorių metodas (AVM)

Jis naudojamas klasifikavimo užduotims, tokioms kaip aritmijų aptikimas. (16) AVM veikia nustatydamas hiperplokštumą, kuri geriausiai atskiria skirtingas klases daugiamatėje erdvėje, todėl jos efektyvios dvejetainėms klasifikavimo užduotims.

Atsitiktiniai miškai

Šis mašininio mokymosi metodas efektyvus klinikiškiams duomenims su mažu kintamųjų skaičiumi, bet daugybe stebėjimų. (16) Atsitiktiniai miškai sujungia kelis sprendimų medžius, kad sukurtų patvaresnį ir tikslesnį modelį, kuris gali būti ypač naudingas tvarkant sudėtingus klinikiškus duomenis.

XGBoost

Gradientinio stiprinimo algoritmas, parodęs potencialą prognozuojant kardiovaskulinius įvykius. XGBoost žinomas dėl savo greičio ir efektyvumo, todėl jis populiarus daugelyje mašininio mokymosi konkursų ir realaus pasaulio taikymų.

2.3 Konvoliucinių neuroninių tinklų techniniai aspektai kardiologijoje

Kardiologijoje, o ypač EKG analizėje pritaikomų konvoliucinių neuroninių tinklų (KNT) architektūra ir įgyvendinimas ženkiai evoliucionavo, prisitaikydami prie specifinių širdies signalų analizės poreikių. Ypatinę reikšmę turi skirtumas tarp tradicinių dvimatį vaizdą apdorojančių (2D) ir vienmačius signalus analizuojančių (1D) KNT.

Architektūriniai ir skaičiavimo skirtumai

Fundamentalus skirtumas tarp 2D ir 1D KNT slypi jų skaičiavimo sudėtingume. Tradiciniai 2D KNT, apdorodami $N \times N$ dimensijų vaizdą su $K \times K$ branduoliu, pasižymi $O(N^2K^2)$ skaičiavimo sudėtingumu. Tuo tarpu 1D konvoliuciniai neuroniniai tinklai (KNT), apdorodami N ilgio signalą ir K dydžio branduoliu, veikia žymiai efektyviau – jų skaičiavimo sudėtingumas yra tik $O(NK)$. Šis esminis skirtumas lemia ne tik teorinį efektyvumą, bet ir praktines įgyvendinimo galimybes.

1D KNT architektūra susideda iš dviejų pagrindinių sluoksnių tipų. Pirmasis – KNT sluoksniai, kuriuose vyksta vienmačių konvoliucijų operacijos, aktyvacijos funkcijų taikymas ir duomenų sumažinimas (redukcija). Antrasis – pilnai sujungti (dense) sluoksniai, analogiški tradiciniams daugiasluoksniams perceptronams. Ši architektūra leidžia efektyviai apdoroti laiko eilučių duomenis, tokius kaip EKG signalai, išlaikant svarbias laikines charakteristikas.

Praktinis pritaikymas ir privalumai

1D KNT praktinis pritaikymas kardiologijoje pasižymi keliais esminiais privalumais. Pirmiausia, dėl mažesnio skaičiavimo sudėtingumo, šie tinklai gali būti efektyviai apmokomi ir naudojami standartiniuose kompiuteriuose, nereikalaujant specializuotos aparatūrinės įrangos. Tai ypač svarbu klinikiame kontekste, kur specializuota skaičiavimo įranga gali būti nepasiekiamas.

Dar vienas svarbus privalumas – efektyvus veikimas su ribotais duomenų kiekiais. Tipinės 1D KNT implementacijos kardiologijoje naudoja kompaktiškas konfigūracijas su mažiau nei 10 000 parametrų, kai tuo tarpu 2D KNT dažnai reikalauja milijonų parametrų. Tai ne tik palengvina apmokymą, bet ir leidžia sukurti efektyvius modelius specifiniams pacientams ar mažesnėms pacientų grupėms.

Signalų apdorojimo ypatumai

1D KNT geba tiesiogiai analizuoti neapdorotus EKG signalus, eliminuojant poreikį konvertuoti duomenis į dvimatę reprezentaciją. Šis tiesioginis apdorojimas ne tik išsaugo svarbias laikines signalo charakteristikas, bet ir leidžia tinklui automatiškai išmokti optimalias

požymių išskyrimo strategijas konkrečiai klasifikavimo užduočiai. KNT sluoksniai apdoroja vienmačius duomenis ir „išmoksta išskirti“ tokius požymius, kurie yra naudojami klasifikavimo užduotyje, atliekamoje pilnai sujungtų sluoksnių.

Adaptyvi 1D KNT implementacija taip pat leidžia prisitaikyti prie įvesties sluoksnio dimensijų variacijų, automatiškai koreguojant sumažinimo faktorius išvesties KNT sluoksnyje. Ši savybė ypač vertinga klinikiniam kontekste, kur signalų ilgis ir charakteristikos gali skirtis tarp pacientų ir matavimų. (1)

2.4 Duomenų reikalavimai ir paruošimas

DI algoritmams kardiologijoje dažnai reikia didelių duomenų rinkinių mokymui ir validavimui. Viešos duomenų bazės, tokios kaip PhysioNet, MIT-BIH aritmijų duomenų bazė ir UK Biobank, buvo labai svarbios teikiant duomenis DI modelių kūrimui. (18) Šie dideli, įvairūs duomenų rinkiniai yra labai svarbūs kuriant patikimus DI modelius, kurie gali gerai apibendrinti naujus, nematytus duomenis.

Duomenų paruošimas yra kritinis žingsnis, kuriant DI modelius, gali apimti kelis procesus:

1. Signalų apdorojimas. Tai apima triukšmo ir artefaktų pašalinimą iš EKG signalų. (15) Dažnai naudojamos tokios technikos kaip filtravimas, bazinės linijos dreifavimo šalinimas ir elektros tinklo trukdžių minusavimas, siekiant pagerinti EKG signalo kokybę.
2. Požymių išskyrimas. Tokios technikos kaip diskrečioji bangelių transformacija (discrete wavelet transform) naudojamos išskirti svarbius požymius iš EKG signalų. (16) Šie požymiai gali būti morfologinės EKG bangos formos charakteristikos, širdies ritmo kintamumo matai ir dažnių srities požymiai.
3. Duomenų papildymas: Tai yra sintetinių duomenų kūrimas, sprendžiant nesubalansuotų duomenų rinkinių problemas. (15) Tokios technikos, kaip mažumos klasių perėmimas arba sintetinių pavyzdžių generavimas, gali pagerinti modelio gebėjimą mokytis iš nepakankamai atstovaujamų klasių.
4. Standartizavimas ir normalizavimas. Duomenų nuoseklumo užtikrinimas iš skirtingų šaltinių ir skalių yra labai svarbus. (16) Šis procesas padeda išvengti tam tikrų požymių dominavimo mašininio mokymosi procese dėl jų didesnės skalės ir gali pagerinti daugelio mašininio mokymosi algoritmų konvergenciją.

Pavadinimas	Metai	EKG skaičius	EKG trukmė	Žymėjimas
MIMIC-III	2017	67 830	kintamas	jokio
Computing in Cardiology 2017	2017	12 186	30 sek.	Prieširdžių virpėjimo klasifikacija
Computing in Cardiology 2020	2020	6887	30 sek.	EKG nenormalūs radiniai
Computing in Cardiology 2011	2011	2000	10 sek.	EKG kokybė
Computing in Cardiology 2018	2018	1985	Valandos	Miego-budrumo klasifikacija
Computing in Cardiology 2015	2015	1250	5 min.	Netikrų aritmijų klasifikacija
Chinese Cardiovascular Disease Database	2010	1000	10 sek.	Ritmų klasifikacija, nenormalių radinių klasifikacija
Computing in Cardiology 2014	2014	700	10 min.	QRS klasifikacija
PTB diagnostic ECG	1995	549	2 min.	Diagnozės (MI, PV, ŠN etc)
SHAREE	2015	139	24 h	Kraujagyslinių įvykių klasifikavimas
Long-term ST DB	2003	86	21-24 h	ST segmento pokyčiai
MIT-BIH supraventricular arrhythmia	1990	78	30 min.	Ritmų klasifikacija, nenormalių radinių klasifikacija
St. Petersburg INCART DB	2008	75	30 min.	Ritmų klasifikavimas
MIT-BIH arrhythmia DB	2001	48	30 min.	Ritmų klasifikavimas
MIT-BIH ST change DB	1999	28	Kintamas	Ritmų klasifikavimas
MIT-BIH atrial fibrillation DB	1983	25	10 h	Prieširdžių virpėjimas/plazdėjimas, AV jungties ritmas
Sudden cardiac death	1989	23	apie 24 h	Skilvelių virpėjimas

DB				
MIT-BIH malignant ventricular ectopy DB	1986	22	30 min.	SVT, VT, Skilvelių virpėjimas
MIT-BIH normal sinus rhythm DB	1999	18	Kintamas	Ritmų klasifikavimas
BIDMC CHF DB	1986	15	20 h	Ritmų klasifikavimas
MIT-BIH arrhythmia database P-wave annotations	2018	12	30 min.	P-bangos žymėjimas

1 lentelė: Šioje lentelėje išvardinti visi viešai prieinami EKG duomenų rinkiniai, kurie yra pagrindiniai dirbtinio intelekto modelių apmokymo šaltiniai.

Duomenų kokybė ir kiekis reikšmingai įtakoja DI modelių veikimą ir apibendrinimo galimybes kardiologijos-aritmologijos taikymuose. Prastos kokybės duomenys gali trukdyti efektyviam DI-EKG technologijų kūrimui ir taikymui. (5) Todėl atidus dėmesys duomenų paruošimui ir kokybės kontrolei yra būtinas kuriant patikimus ir efektyvius DI modelius kardiologijoje.

2.5 Operaciniai neuroniniai tinklai - naujos kartos dirbtinio intelekto sprendimas

Operaciniai neuroniniai tinklai (ONT) žymi naują etapą dirbtinio intelekto evoliucijoje. Priešingai nei tradiciniai konvoliuciniai neuroniniai tinklai (KNT), kurie remiasi homogenine architektūra ir tiesiniais neuronų modeliais iš 1950-ųjų, ONT pristato fundamentaliai naują požiūrį į neuroninių tinklų struktūrą ir funkcionalumą. (1)

ONT išsiskiria savo heterogenine architektūra, kuri labiau primena biologinę nervų sistemą. Šie tinklai gali apjungti įvairių tipų neuronus, naudojančius skirtingus operatorius - tiek tiesinius, tiek netiesinius. Toks lankstumas leidžia ONT efektyviau mokytis sudėtingų ir daugimodalinių funkcijų, naudojant minimalų tinklo sudėtingumą ir mažesnę mokymo duomenų kiekį.

Lyginant su tradiciniais KNT, ONT demonstruoja kelis esminius privalumus. Pirmiausia, jų gebėjimas integruoti įvairių tipų neuronus leidžia geriau prisitaikyti prie sudėtingų duomenų struktūrų. Antra, jų heterogeninė architektūra suteikia didesnę lankstumą modeliuojant sudėtingas sistemas. Trečia, ONT gali mokytis efektyviau su mažesniu parametų skaičiumi ir ribotu duomenų kiekiu.

Naujausi tyrimai rodo, kad ONT gali žymiai pranokti tradicinius KNT, sprendžiant sudėtingas klasifikavimo ir prognozavimo užduotis. Ypač svarbu tai, kad ONT demonstruoja puikius

rezultatus tuose uždaviniuose, kurie tradiciniams KNT kelia didžiausius iššūkius – kai duomenų yra mažai, kai jie sudėtingi ir įvairialypiai.

Atsižvelgiant į šiuos privalumus, tikėtina, kad ateityje ONT gali pakeisti 1D KNT kardiologijos srityje, ypač aritmijų diagnostikoje ir širdies signalų analizėje. Jų gebėjimas efektyviai veikti turint ribotas duomenų apimtis ir prisitaikyti prie sudėtingų signalų struktūrų atveria plačias perspektyvas medicinos srityje, kur dažnai susiduriama su duomenų trūkumu ir sudėtingomis signalų charakteristikomis. (1)

2.6 Paaiškinamasis dirbtinis intelektas (eXplainable AI)

Paaiškinamas dirbtinis intelektas (xAI) tampa vis svarbesniu elementu, siekiant padidinti klinikinių algoritmų skaidrumą ir patikimumą kardiovaskulinėje medicinoje. Priešingai nei tradiciniai „juodosios dėžės“ DI modeliai, xAI metodai suteikia gydytojams galimybę geriau suprasti, kaip priimami algoritminiai sprendimai ir kodėl. Šis skaidrumas yra ypač svarbus aritmijų diagnostikoje, kur sprendimai gali būti itin svarbūs paciento gydymo parinkimui. (76)

Kardiologijoje dažniausiai taikomi xAI metodai apima gradientais pagrįstus metodus (Grad-CAM), lokaliai interpretuojamus modelius (LIME), Shapley adityvius paaiškinimus (SHAP – SHapley Additive exPlanations) ir prototipų tinklus. Nepaisant neabejotinos pažangos, xAI metodų taikymas kardiologijoje susiduria su iššūkiais. Paaiškinimų kokybės ir patikimumo vertinimas išlieka sudėtingas. (76)

3. Dirbtinio intelekto taikymai aptinkant ir diagnozuojant aritmijas

3.1 EKG interpretavimas ir aritmijų klasifikavimas

DI, o ypač giliojo mokymosi konvoliuciniai neuroniniai tinklai (KNT), pasiekė įspūdingus rezultatus automatizuotame EKG interpretavime ir aritmijų klasifikavime.

Daugiaklasė aritmijų detekcija

DI algoritmai pasiekė didelį tikslumą kontroliuojamuose testiniuose duomenų rinkiniuose. (15) Pavyzdžiui, buvo sukurtas KNT, kuris pagal 12 derivacijų EKG diagnozuoja 21 skirtingą širdies ritmą. Tinklas apmokytas naudojant duomenis iš daugiau nei 80 000 EKG įrašų, surinktų iš 70 000 pacientų. Šis modelis pasiekė vidutinį 98 % plotą po ROC (receiver operating characteristic) kreive (AUC), su 87 % jautrumu ir 99 % specifiškumu. Šis Zhu H. et al. atliktas tyrimas žymi didelį žingsnį automatizuotos EKG interpretacijos srityje, ypač dėl gebėjimo tiksliau nei ekspertai aptikti kelias vienu metu pasireiškiančias aritmijas. Tyrimas atskleidė DI potencialą padėti mažiau patyrusiems specialistams bei teikti greitas ir tikslias interpretacijas, esant ribotiems ištekliams. (20)

Išsami EKG analizė

Kai kurie DI modeliai gali tiksliai identifikuoti 27-30 EKG anomalijas, remdamiesi įvairiais derivacijų deriniais. (15) Kitas tyrimas parodė, kad KNT galėjo identifikuoti 66 atskirus kodus arba diagnozes iš EKG su teigiamu diagnostiniu efektyvumu. Kashou et al. atliktas tyrimas įvertino konvoliucinio neuroninio tinklo pagrindu veikiančią algoritmą, gebantį automatiškai interpretuoti 12 derivacijų EKG ir nustatyti 66 skirtingas diagnostines kategorijas. Modelio jautrumas siekė >95 % visose kategorijose. Algoritmas buvo ypač tikslus nustatant ritmo sutrikimus, laidumo sutrikimus, išemijos požymius, EKG bangų morfologijos pokyčius. Šis tyrimas pademonstravo, kad dirbtinio intelekto algoritmas gali atlikti išsamią 12 derivacijų EKG interpretaciją, kurios tikslumas prilygsta kardiologų ekspertų interpretacijai. (21)

Pranašumas prieš klinicistus

DI algoritmai aptiko ir klasifikavo aritmijas efektyviau nei kardiologai, parodydami didesnę jautrumą visose ritmo kategorijose. Hannun et al. panaudojo 91 232 vienos derivacijos EKG įrašus konvoliuciniam neuroniniam tinklui (KNT) sukurti, kuris geba klasifikuoti 12 skirtingų širdies ritmo tipų. KNT pasiekė 0,91 plotą po ROC kreive šių ritmų identifikavimui ir pranoko kardiologų rezultatus visose diagnozėse, įskaitant prieširdžių virpėjimą. Svarbu pažymėti, kad šis metodas naudojo neapdorotus EKG signalų duomenis ir nereikalavo požymių išskyrimo ar išankstinio apdorojimo. (42) Tai rodo, kad DI potencialiai galėtų papildyti klinikinius sprendimus ir pagerinti diagnostikos tikslumą.

Holterio analizė

DI pagrįstos Holterio įrašų analizės strategijos pasirodė esančios greitesnės ir bent jau tokios pat tikslios, kaip įprasta elektrofiziologų atliekama analizė. (15) Fiorina et al. 2022 metais atliktame tyrime, publikuotame Journal of the American Heart Association, pristatomas dirbtinio intelekto platformos panaudojimas Holterio EKG analizei klinikinėje praktikoje.

Buvo tirta 1 000 Holterio (24 valandų) įrašų iš 3 tretinio lygio ligoninių. Įrašus nepriklausomai analizavo tiek DI platforma, tiek elektrofiziologai, kurie naudojo įprastą Sorin Synescope platformą. Vertinti 5 iš anksto apibrėžti širdies ritmo sutrikimai (pauzės, skilvelinė tachikardija, prieširdžių virpėjimas / plazdėjimas / tachikardija, aukšto laipsnio AV blokada, didelis priešlaikinių skilvelinių susitraukimų kiekis (>10 %)). DI platforma nebuvo prastesnė už įprastą, taip pat buvo jautresnė aptinkant prieširdžių virpėjimą (98 % prieš 91 %) ir skilvelinę tachikardiją (97 % prieš 68 %). Analizės trukmė su DI platforma buvo 4,4 min., o su įprasta platforma – apie 6,0 min. (naudojant DI sutaupyta 26,6 % laiko). (22) Tyrimas parodė, kad DI gali padėti efektyviau ir greičiau analizuoti Holterio įrašus, potencialiai

sumažinti darbo krūvį klinacistams. Tai galėtų stipriai pagerinti ilgalaikės EKG stebėsenos interpretavimo efektyvumą.

3.2 Prieširdžių virpėjimo aptikimas

DI parodė itin didelį potencialą aptinkant prieširdžių virpėjimą (PV), įskaitant tylųjį ar paroksizminį PV.

Aptikimas normalaus sinusinio ritmo metu

Mayo klinikos tyrėjų (Attia et al.) sukurtas KNT gali prognozuoti PV iš standartinės 12 derivacijų 10 sekundžių trukmės EKG, gautos sinusinio ritmo metu (tylusis prieširdžių virpėjimas). Šis algoritmas parodė 0,87 plotą po ROC kreive (AUC), 79,0 % jautrumą, 79,5 % specifiškumą ir 79,4 % tikslumą, nustatant pacientus su dokumentuotu PV, kai naudojama tik sinusinio ritmo EKG informacija. Ši studija gali turėti svarbių praktinių implikacijų PV patikrai ir pacientų su nežinomos kilmės insultu gydymui. (23)

Aptikimas nešiojamuosiuose įrenginiuose

DI buvo pritaikytas prieširdžių virpėjimui (PV) atpažinti, naudojant vienos derivacijos EKG įrašus, gautus iš mobiliųjų įrenginių ir išmaniųjų laikrodžių. (3) Geoffrey H. Tison ir bendraautorių 2018 m. tyrime, publikuotame JAMA Cardiology, pristatoma, kaip išmanusis laikrodis panaudojamas pasyviai prieširdžių virpėjimo (PV) aptikimui. Tyrimo tikslas buvo sukurti ir validuoti giliojo neuroninio tinklo algoritmą, gebantį automatiškai identifikuoti prieširdžių virpėjimą iš išmaniojo laikrodžio jutiklių duomenų. Šio metodo unikalumas slypi jo gebėjime pasyviai stebėti širdies ritmą kasdieniniame gyvenime. Tyrimo rezultatai atskleidė nemažą algoritmo potencialą stacionariomis sąlygomis. Šioje kohortoje algoritmas pasiekė įspūdingus rezultatus – ROC kreivės plotas siekė 0,97; algoritmas pasiekė 98,0 % jautrumą ir 90,2 % specifiškumą. Teigiama ir neigiama prognostinės vertės atitinkamai buvo 90,9 % ir 97,8 %. Ambulatorinėje kohortoje rezultatai buvo kuklesni, bet vis tiek reikšmingi. ROC kreivės plotas siekė 0,72, su 67,7 % jautrumu ir 67,6 % specifiškumu. Nors teigiama prognostinė vertė buvo žema (7,9 %), neigiama prognostinė vertė išliko aukšta (98,1 %).

Tyrimas parodė, kad išmaniųjų laikrodžių ir dirbtinio intelekto derinys gali būti efektyvus įrankis PV diagnostikai, ypač kontroliuojamomis sąlygomis. (24)

KardiaBand

Šis EKG jutiklis, skirtas Apple Watch, kartu su SmartRhythm programine įranga, parodė 93 % jautrumą ir 84 % specifiškumą prieširdžių virpėjimui aptikti. (18) Šiame tyrime buvo nagrinėjamas išmaniojo laikrodžio (Apple Watch su KardiaBand) efektyvumas, aptinkant prieširdžių virpėjimą (PV), lyginant jį su implantuojamu širdies monitoriumi (IŠM). Buvo

ištirti 24 pacientai, kuriems anksčiau buvo implantuoti Reveal LINQ širdies monitoriai ir diagnozuotas paroksizminis prieširdžių virpėjimas. Pacientai nešiojo išmanųjį laikrodį su specialia SmartRhythm programine įranga, kuri analizavo širdies ritmą, naudodama dirbtinio intelekto algoritmus. Rezultatai buvo itin įtikinami - iš 82 prieširdžių virpėjimo epizodų, trunkančių ilgiau nei valandą ir užfiksuotų IŠM, išmanusis laikrodis aptiko 80 epizodų (97,5 % jautrumas). Bendros PV trukmės atpažinimo tikslumas siekė 97,7 %.

Šie rezultatai rodo išskirtinį išmaniojo laikrodžio efektyvumą, aptinkant ir stebint prieširdžių virpėjimą. Ypač svarbu paminėti, kad sistema pasižymėjo aukštu specifiškumu (98,9 %) ir neigiama prognozinė vertė (99,9 %), vertinant bendrą PV trukmę. Tai rodo, kad technologija ne tik efektyviai aptinka PV epizodus, bet ir patikimai identifikuoja normalų sinusinį ritmą.

3.3 Paveldimos aritmijos

Ilgo QT sindromas (IQTS)

QT intervalas atspindi skilvelių miocitų depoliarizacijos ir repoliarizacijos fazių bendrą trukmę, kuri įprastai siekia apie 450 ms. Ilgo QT intervalo sindromas (IQTS) pasireiškia kaip pirminis elektrokardiografinis nukrypimas, kai QT intervalas viršija 450 ms dėl įgimtų jonų kanalų mutacijų arba įgytų veiksnių. Šis sindromas siejamas su grėsmingomis skilvelinėmis tachiaritmijomis, galinčiomis sukelti staigią širdinę mirtį. (25)

QT intervalo įvertinimas yra esminė IQTS diagnostikos dalis, tačiau tradicinis ekspertinis QT matavimas reikalauja didelių laiko sąnaudų, finansinių resursų bei neišvengiamai susiduria su žmogiškosiomis klaidomis. Mously Dior Diaw su komanda sukūrė konvoliuciniu neuroniniu tinklu (KNT) pagrįstą dirbtinio mokymosi algoritmą, kuris pademonstravo aukštą koreliaciją su ekspertų atliktais matavimais (QT intervalo įvertinimo tikslumas siekė 71 %).

Mokslininkai pritaikė U-Net architektūrą, kuri įprastai naudojama vaizdams segmentuoti, QT intervalo išskyrimui, taip patobulindami automatinių matavimų interpretavimą ir ekspertinį vertinimą. (26)

Ben J M Hermans ir kolegos išplėtė tyrimus už QT intervalo ribų, analizuodami T bangos morfologijos žymenų diagnostinę vertę IQTS nustatyti. Jų tyrimai atskleidė nemažą diagnostinio tikslumo šuolį – jautrumas padidėjo nuo 69,4 % iki 82,0 %, o specifiškumas – nuo 82,9 % iki 86,1 %. Remdamiesi šiais rezultatais, jie sukūrė patobulintą atraminių vektorių mašinos modelį, integruojantį T bangos morfologijos charakteristikas su demografiniais veiksniais (amžiumi, lytimi) bei QTc reikšmėmis. (27)

Nors DI technologijos QT intervalo matavimui ir IQTS diagnostikai yra santykinai išvystytos, maždaug 40 % pacientų, kuriems genetiškai patvirtintas IQTS, turi normalų koreguotą QT

ramybės metu, todėl sunku priimti sprendimą dėl prevencinių priemonių, jei jų reikia. Martijn Bos ir bendraautorai atliko diagnostinį atvejo-kontrolės tyrimą, kuriame konvoliucinis neuroninis tinklas buvo apmokytas įvertinti elektrografiskai paslėptą IQTS iš paviršinės 12 derivacijų EKG. Be to, modelis beveik 80 % tikslumu prognozuoja trijų pagrindinių genotipinių pogrupių (LQT1, LQT2 ir LQT3) pasiskirstymą. (28)

IQTS didina paveiktų asmenų riziką spontaninei skilvelinei tachikardijai / skilvelių virpėjimui (ST / SV) ir staigiai širdinei mirčiai, todėl būtina tinkamai įvertinti riziką ir taikyti tinkamas terapines priemones. Gary Tse ir bendraautorai pritaikė atsitiktinio išgyvenimo miško (RSF) algoritmą ir pirmą kartą pademonstravo, kad RSF modelis gali pagerinti IQTS ST / SV prognozinę vertę, lyginant su tradiciniais Cox regresijos modeliais. (29)

Brugados sindromas

Brugados sindromas išsiskiria kaip viena iš pagrindinių staigos kardiologinės mirties priežasčių jauname amžiuje. Šis sindromas pasižymi specifiniais elektrokardiografiniais (EKG) požymiais, atsirandančiais dėl elektrinių ir struktūrinių pakitimų, daugiausiai dešiniojo skilvelio išstūmimo trakte. Liu et al. sukūrė pirmąjį dirbtinio intelekto EKG modelį pritaikytą Brugados sindromui identifikuoti. Šis modelis buvo tikslesnis, (kappa koeficientas siekė 0,78) lyginant su kardiologų rezultatais (kappa koeficientas 0,63). (30)

Vienas esminių diagnostinių iššūkių yra 1-ojo tipo Brugado sindromo požymių laikinumas. Šią problemą sprendė Shun Liao ir bendradarbiai, sukurdami konvoliucinį neuroninį tinklą, gebantį identifikuoti 1-ojo tipo požymius, analizuojant ištisinio 24 valandų 12-kos derivacijų ambulatorinio EKG (Holterio) monitoravimo duomenis. Mokslininkai sukūrė giliojo mokymosi algoritmą, kuris klasifikuoja 1-ojo tipo Brugados sindromą taip pat gerai kaip kardiologai. Algoritmas pasiekė 0,975 plotą po ROC kreive ir parodė didelį pritaikomumo potencialą bei gerą interpretavimo galimybę. (31)

Moksliniai duomenys rodo, kad metinis ligos pasireiškimas siekia maždaug 0,3–0,9 % tarp asimptominių pacientų, turinčių Brugados sindromui būdingus EKG pokyčius. Šiems pacientams implantuojamas kardioverteris-defibriliatorius (IKD) išlieka vienintelė įrodyta staigos širdinės mirties prevencijos priemonė. Atsižvelgiant į svarų IKD poveikį pacientų gyvenimo kokybei, kritinę svarbą įgyja gebėjimas identifikuoti asmenis, turinčius didžiausią staigos kardiologinės mirties riziką, kuriems IKD implantavimas būtų naudingiausias. (25) Nakamura su komanda sukūrė dirbtinio intelekto algoritmą, analizuojantį 12 derivacijų EKG per konvoliucinį neuroninį tinklą, skirtą prognozuoti ankstesnę ar ateityje galimą mirtinos aritmijos atsiradimą Brugados sindromo pacientams. Šis algoritmas pademonstravo įspūdingą

prognostinį potencialą su vidutiniu $0,81 \pm 0,09$ plotu po ROC kreive ir sugebėjo aptikti subtilias EKG anomalijas, kurios dažnai lieka nepastebėtos atliekant įprastą vizualinę EKG analizę. (32)

3.4 Kitų aritmijų identifikavimas

Yra sukurti DI modeliai įvairioms kitoms aritmijoms ir širdies būklėms aptikti.

Skilvelinės aritmijos

DI algoritmai pasiekė labai aukštą tikslumą (99,2-98,8 %), aptinkant skilvelių virpėjimą ir skilvelinę tachikardiją. (15) Joon-Myoung Kwon ir kolegės atliko tyrimą, publikuotą „Journal of American Heart Association” žurnale. Mokslininkai sukūrė ir išbandė dirbtinio intelekto sistemą, skirtą prognozuoti staigų širdies sustojimą ligoninėje. Tyrėjai sukūrė gilųjį neuroninį tinklą, pavadintą *ankstyvo išpėjimo sistema*, kuri analizavo keturis pagrindinius gyvybinius rodiklius: sistolinį kraujospūdį, širdies ritmą, kvėpavimo dažnį ir kūno temperatūrą.

Pirminiame tyrime buvo analizuoti 52 131 paciento duomenys iš dviejų ligoninių, iš kurių 419 patyrė širdies sustojimą. Modelis pasiekė įspūdingus rezultatus – 0,850 plotą po ROC kreive (AUC), kas žymiai pralenkė standartinį modifikuotą ankstyvojo išpėjimo balą (MEWS), kurio AUC siekė tik 0,603. (33)

Hipertrofinė kardiomiopatija (HKM)

Daugiau nei 90 % pacientų, sergančių hipertrofine kardiomiopatija, turi elektrokardiografinius pakitimus, tačiau šie pakitimai nėra specifiniai ir dažnai neatskiriami nuo kairiojo skilvelio hipertrofijos. Įprastai EKG patikra remiasi rankiniu arba automatizuotu tam tikrų požymių, tokių kaip kairiojo skilvelio hipertrofija, kairės ašies nuokrypis, ryškios Q bangos ir T bangu inversijos, nustatymu. Vis dėlto, šių metodų diagnostinis efektyvumas yra nepakankamas. (3) Wei-Yin Ko et al. konvoliucinis neuroninis tinklas išanalizavo daugiau nei 67 000 pacientų elektrokardiogramas ir pademonstravo puikius rezultatus atpažįstant ankstyvąją hipertrofinę kardiomiopatiją. Modelis parodė puikų diagnostinį efektyvumą, ypač jaunesniems pacientams (jaunesniems nei 40 metų). Vienodai gerai veikė tiek pacientams su EKG nustatyta kairiojo skilvelio hipertrofija, tiek be jos. Sistema buvo efektyvi net ir tiems 10 % HKM pacientų, kurių EKG buvo normali pagal standartinius kriterijus. (34)

Priešlaikiniai skilvelių susitraukimai (ekstrasistolės)

DI gali tiksliai klasifikuoti šiuos nenormalius širdies susitraukimus. Tai ypač naudinga ilgalaikėje EKG stebėsenoje. Tyrimas, atliktas Rambam sveikatos priežiūros centre Izraelyje, atskleidžia įdomų ryšį tarp priešlaikinių skilvelinių susitraukimų ir skilvelinės tachikardijos (ST). Išanalizuoti 1 773 Holterio įrašai (24 h) iš 1 570 pacientų be ST. Modelis, naudojantis

širdies ritmo kintamumo ir morfologinius požymius, pasiekė 0.76 ± 0.07 plotą po ROC kreive. Rezultatai rodo, kad ekstrasistolų analizė sinusinio ritmo metu gali padėti identifikuoti pacientus su didesne ST rizika. (35)

Kairiojo skilvelio disfunkcija

Buvo sukurti DI modeliai besimptomei kairiojo skilvelio disfunkcijai aptikti iš standartinių EKG. Zachi Attia ir bendraautoriai sukūrė ir validavo dirbtinio intelekto algoritmą, skirtą nustatyti kairiojo skilvelio išstūmimo frakciją (IF) ≤ 35 % iš įprasto 12 derivacijų EKG. Algoritmas pasiekė AUC 0.918 (95 % CI: 0.902-0.934), 82.5 % jautrumą, 86.8 % specifiškumą. Tyrimas parodė, kad DI algoritmas gali būti naudojamas kaip nebrangus ir neinvazinis metodas ankstyvai kairiojo skilvelio disfunkcijos diagnostikai. Svarbu paminėti, kad sistema gali identifikuoti besimptomius pacientus, kuriems reikalingas detalesnis ištyrimas. NT-proBNP žymens panaudojimas gali padėti sumažinti klaidingai teigiamų rezultatų skaičių. (36)

Aritmijų lokalizacija

DI gali padėti analizuoti paviršinę (įprastą) EKG ir nustatyti idiopatinių skilvelinių aritmijų vietą, taip padėdamas optimizuoti abliacijos strategiją.

Ting-Yung Chang su kolegomis atlikto tyrimo metu buvo sukurtas konvoliucins neuroninis tinklas (KNT) paviršinės 12 derivacijų elektrokardiogramos analizei. Dvisluksnė KNT modelio struktūra buvo sukurta specialiai šiam tikslui – pirmoji KNT sluoksnių grupė buvo skirta požymių išskyrimui išilgai laiko ašies, o antroji grupė – erdvinės informacijos išskyrimui tarp skirtingų derivacijų.

Autoriai sukūrė du skirtingus modelius. Pirmasis modelis buvo skirtas dvejetainei klasifikacijai, leidžiančiai nustatyti, ar aritmijos kilmės šaltinis yra kairiojoje ar dešiniojoje širdies pusėje. Šio modelio plotas po ROC kreive (AUC) siekė 0,963, o jautrumas ir specifiškumas buvo atitinkamai 90,7 % ir 92,3 %. Antrasis modelis buvo sukurtas specifiškai kairiojo skilvelio viršūnės aritmijų identifikavimui ir pasižymėjo itin aukštu tikslumu – AUC siekė 0,998, jautrumas 100 %, o specifiškumas 98 %.

Tyrimas atskleidė, kad dirbtinio intelekto algoritmai gali efektyviai lokalizuoti skilvelinių aritmijų kilmės vietą, ypač didelį tikslumą pasiekiant kairiojo skilvelio viršūnės aritmijų atpažinimui. Autoriai pabrėžia, kad tikslus aritmijos kilmės vietos nustatymas prieš procedūrą yra ypač vertingas klinikiname kontekste, kadangi leidžia optimizuoti abliacijos strategiją, sumažinti procedūros trukmę ir su ja susijusių komplikacijų riziką. (37)

3.5 Elektrodo padėties klaidų nustatymas

Elektrodo uždėjimo klaidos ar elektrodo sukeitimas vietomis yra viena iš dažniausių klaidų atliekant EKG. Daugelis šių klaidų yra lengvai identifikuojamos ir ištaisomos, bet kai kurios jų yra aptinkamos sunkiau. Dėl savo pranašumo atpažįstant subtilius EKG pokyčius, dirbtinis intelektas gali būti pritaikytas EKG įrašuose atpažinti netinkamai uždėtus ar sukeistus elektrodus. Tai gali pagerinti aritmijų diagnostikos kokybę. (25)

2020 metų meta-analizėje, apėmusioje 14 tyrimų, buvo analizuojami ir lyginami esami dirbtiniu intelektu pagrįsti elektrodo padėties klaidų ir elektrodo sukeitimo aptikimo metodai. Tyrimas parodė, kad kairiųjų viršutinių ir apatinių galūnių elektrodo sukeitimo aptikimo efektyvumas yra santykinai prastas (jautrumas 53,6–57,6 %, specifiškumas 95,6–99,97 %). Kitų tipų elektrodo sukeitimo aptikimo efektyvumas buvo geresnis (vidutinis galūnių elektrodo sukeitimo jautrumas buvo 81,7 %, vidutinis specifiškumas – 99,2 %). Vidutinis krūtinės elektrodo transponavimo aptikimo jautrumas ir specifiškumas buvo atitinkamai 85,6 % ir 98,5 %, o vidutinis krūtinės elektrodo vertikalaus padėties netinkamo uždėjimo aptikimo jautrumas ir specifiškumas buvo atitinkamai 80,5 % ir 82,8 %. (38)

Šie taikymai demonstruoja DI potencialą pagerinti aritmijų aptikimą ir įvairių būklių diagnostiką, potencialiai vedant prie ankstyvesnių intervencijų ir geresnių pacientų išiečių. DI gebėjimas greitai analizuoti didelius duomenų kiekius ir identifikuoti subtilius modelius, neatpažįstamus žmogaus interpretuotojams, daro jį galingu įrankiu aritmologijos srityje. Tačiau svarbu pažymėti, kad daugeliui šių modelių vis dar reikia tolesnio patvirtinimo įvairiose, realaus pasaulio klinikinėse situacijose, prieš juos plačiai diegiant į klinikinę praktiką.

4. Dirbtinis intelektas prognozuojant aritmijų riziką ir nustatant paciento prognozę

4.1 Aritmijų pradžios prognozavimas

DI parodė daug žadančių rezultatų prognozuojant įvairių aritmijų pradžią ar pasikartojimą.

Naujai atsiradęs prieširdžių virpėjimas (PV)

Buvo sukurti dirbtinio intelekto modeliai pacientams, turintiems didelę riziką naujai atsiradusiam prieširdžių virpėjimui, identifikuoti.

Ji-Hoon Choi ir bendraautorių 2024 metais atliktas tyrimas sukūrė metodą, pagrįstą nuoseklia elektrokardiogramų analize naudojant dirbtinį intelektą, kuris galėtų padėti numatyti PV vystymąsi dar iki klinikinės aritmijos išraiškos. Tyrimo metodologija apėmė 415 964 EKG įrašų iš 176 090 pacientų analizę. Mokslininkai sukūrė du skirtingus modelius – vieną,

pagrįstą pavienių EKG analize, ir kitą, analizuojantį kelis EKG įrašus, atliktus su tam tikru laiko tarpu. Modelis parodė ženkliai geresnę prognostinę tikslumą (plotas po ROC kreive 0,960, lyginant su 0,910 pavienių EKG modelyje). Svarbu paminėti, kad tyrimas atskleidė P bangos morfologijos pokyčių svarbą prognozuojant PV. P bangos trukmė ir amplitudė buvo tarp svarbiausių prognostinių veiksnių, kas patvirtina elektrinio ir struktūrinio prieširdžių remodeliavimosi reikšmę ligos patogenezėje. Mažesnė P bangos amplitudė ($<0,1$ mV I-oje derivacijoje) buvo susijusi su didesne PV progresavimo rizika. Optimalus intervalas tarp dviejų EKG įrašų buvo 8-14 mėnesių. Per šį laikotarpį modelis pasiekė geriausią prognostinę tikslumą (AUC 0,968). Trumpesni intervalai (<1 mėn.) parodė prastesnius rezultatus, kas rodo, kad prieširdžių remodeliacijai reikia pakankamo laiko išsivystyti. (39)

Gilbert Jabbour ir bendraautoriai sukūrė DI modelį, analizuojantį 12 derivacijų elektrokardiogramas, užrašytas sinusinio ritmo metu. Modelis buvo apmokytas naudojant didelį duomenų rinkinį iš Monrealio širdies instituto – 669 782 elektrokardiogramas iš 145 323 pacientų. Tiriamųjų amžiaus vidurkis siekė 61 ± 15 metų, o vyrų dalis sudarė 58 % visos kohortos. Šis EKG DI modelis buvo išskirtinai efektyvus prognozuojant 5-erių metų prieširdžių virpėjimo atsiradimo tikimybę, pasiekdamas 0,78 plotą po ROC kreive (AUC-ROC). Tai žymiai pranoko tradicinius klinikinius rizikos vertinimo metodus, tokius kaip CHARGE-AF (AUC-ROC 0,62) ir poligeninį rizikos balą (AUC-ROC 0,59). Taikant šį DI modelį, galima identifikuoti 26 % populiacijos, turinčios 4,3 karto padidėjusią prieširdžių virpėjimo riziką. Svarbu paminėti, kad modelio efektyvumas buvo patvirtintas nepriklausomoje išorinėje kohortoje (MIMIC-IV), kur AUC-ROC išliko stabiliai aukštas – 0,77.

Šis tyrimas vertingas tuo, kad leidžia nustatyti prieširdžių virpėjimo riziką iš įprastų EKG, užrašytų sinusinio ritmo metu, dar prieš pasireiškiant aritmijai. Kadangi prieširdžių virpėjimas dažnai yra besimptomis arba pasireiškia paroksizminėmis formomis, ankstyvoji diagnostika gali žymiai pagerinti pacientų gydymo efektyvumą, sumažinti insulto tikimybę ir kitas su šia aritmija susijusias komplikacijas.

Itin svarbi tyrimo naujovė – autorių sprendimas padaryti EKG DI modelį viešai prieinamą, dalijantis atviru kodu. Tai skatina mokslinę bendruomenę toliau tobulinti prognostinius modelius ir atveria galimybes platesniam dirbtinio intelekto taikymui kardiologijoje. (74)

Fan Lin ir bendraautoriai 2024 metais sukūrė paaiškinamo dirbtinio intelekto modelį, pavadintą HBBI-AI (Heart Beat-to-Beat Intervals AI), kuris geba numatyti PV riziką tik iš širdies susitraukimų intervalų (RR intervalų) duomenų sinusinio ritmo metu. Tyrimo metu analizuoti 23 763 24-ių valandų Holterio monitoravimo įrašai iš 22 714 asmenų. Dirbtinio

intelekto modelis pasiekė gerus rezultatus: ambulatorinėje aplinkoje modelio jautrumas buvo 0,836, specifiškumas 0,906, o plotas po ROC kreive (AUC) siekė 0,945; stacionare – jautrumas 0,786, specifiškumas 0,799, AUC 0,867. Ypač svarbus aspektas – modelio „paaiškinamumas“, leidžiantis gydytojams suprasti, kaip DI priima sprendimus. Šis DI modelis leidžia nustatyti rizikos grupes dar prieš pasireiškiant aritmijos simptomams, naudojant tik iš nešiojamų įrenginių ar išmaniųjų laikrodžių gaunamus duomenis. (75)

PV progresavimas

DI algoritmai, naudojantys EKG duomenis iš implantuojamų įrenginių, gali tiksliai prognozuoti elektrinę remodeliaciją, numatydami prieširdžių virpėjimo progresavimą nuo paroksizminio iki nuolatinio.

Je-Wook Park ir bendraautorių 2022 metais publikuotas tyrimas žurnale „Frontiers in Cardiovascular Medicine" pristatė dirbtinio intelekto metodą, skirtą prognozuoti prieširdžių virpėjimo (PV) progresavimą į nuolatinę formą po kateterinės abliacijos procedūros.

Tyrėjai analizavo dvi kohortas: pirmąją, kurią sudarė 1 214 pacientų, ir antrąją, kurią sudarė 658 pacientai, kuriems visiems buvo atlikta PV kateterinė abliacija. Prieširdžių virpėjimo progresavimas į nuolatinę formą buvo apibrėžtas kaip nuolat išlikęs PV, nepaisant pakartotinių abliacijos procedūrų ar kardioversijos taikant antiaritminius vaistus.

Tyrėjai sukūrė rizikos stratifikacijos modelį, pavadintą STAAR balu, kuris apėmė penkis pagrindinius rizikos veiksnius: insultą (2 taškai), persistuojantį PV (1 taškas), kairiojo prieširdžio dydį ≥ 43 mm (1 taškas), kairiojo prieširdžio įtampą $< 1,109$ mV (2 taškai) ir PR intervalą ≥ 196 ms (1 taškas). Šis rizikos vertinimo modelis pasižymėjo gera diskriminacine galia prognozuojant progresavimą į nuolatinį PV, plotas po ROC kreive (AUC) siekė 0,796. (77)

Galimybė anksti identifikuoti pacientus su didele PV pasikartojimo rizika leistų gydytojams priimti tikslesnius klinikinius sprendimus, pavyzdžiui, parinkti papildomą abliacijos taktiką ar intensyvesnį stebėjimą.

Skilvelinių aritmijų prognozavimas

DI modeliai, naudojantys EKG duomenis, tokius kaip širdies ritmo kintamumas, parodė gerą diskriminaciją prognozuojant skilvelinę tachikardiją. Mokslinis tyrimas, pristatytas 2023 metų „Heart Rhythm" žurnale, nagrinėja inovatyvų dirbtinio intelekto metodą, skirtą prognozuoti pavojingas skilvelinės tachikardijos (ST) epizodus, naudojant vienos derivacijos ambulatorinę EKG. Mokslininkai sukūrė gilaus mokymosi modelį, analizuojantį pirmųjų 24 valandų

Holterio monitoravimo įrašus, siekdami numatyti ilgalaikės (≥ 30 sekundžių) ST riziką per artimiausias dvi savaites. Modelis buvo išbandytas su 78 294 Holterio įrašų duomenų baze, surinkta įvairiose šalyse, įskaitant JAV, Jungtinę Karalystę, Prancūziją, Čekijos Respubliką, Pietų Afrikos Respubliką ir Indiją.

Rezultatai yra daug žadantys: vidinio validavimo rinkinyje modelis pasiekė 0,939 plotą po ROC kreive su 83,3 % jautrumu ir 88,7 % specifiškumu. Išorinio validavimo rezultatai taip pat buvo labai geri – 0,911 plotas po ROC kreive, 78,9 % jautrumas ir 81,4 % specifiškumas. Ypač svarbu paminėti, kad modelis teisingai prognozavo 88 % greitos ST (≥ 180 k./min.) atvejų.

Lyginant su tradiciniu referenciniu modeliu, kuris naudojo priešlaikinių skilvelių susitraukimų dažnį, širdies ritmo kintamumą ir demografinius duomenis, dirbtinio intelekto sprendimas parodė geresnius rezultatus (0,939 prieš 0,833 AUC). (40)

Hipertenzijos prognozavimas

Ye et al. sukurtas XGBoost modelis sėkmingai prognozavo pirminės hipertenzijos atsiradimo riziką per ateinančius metus, pasiekdamas C-statistikas 0,917 ir 0,870 atitinkamai kūrimo ir validavimo kohortose. (18)

4.2 Rizikos stratifikacija nepalankiems rezultatams

Buvo sukurti DI įgalinti EKG ir ritmo įrankiai įvairių nepalankių rezultatų rizikos stratifikacijai:

Insulto rizika sergant prieširdžių virpėjimu

Trys skirtingi prižiūravimo mašininio mokymosi modeliai buvo sukurti insulto rizikai prognozuoti, naudojant duomenis iš implantuotų širdies prietaisų daugiau nei 3 000 prieširdžių virpėjimo (PV) pacientų. (3) Tyrimas, atliktas JAV Veteranų administracijos sveikatos priežiūros sistemoje, analizavo 3 114 pacientų be insulto ir 71 paciento su insultu duomenis, gautus iš implantuojamų širdies prietaisų nuotolinio stebėjimo sistemos. Autoriai sukūrė tris skirtingus dirbtinio intelekto modelius: konvoliucinį neuroninį tinklą, atsitiktinių miškų metodą ir L1 regularizuotą logistinę regresiją. Šie modeliai analizavo PV epizodų pasiskirstymą per 30 dienų laikotarpį prieš insultą, lyginant su kontroline grupe. Tyrimas parodė, kad dirbtinio intelekto metodai gerokai pranoko įprastinę CHA2DS2-VASc skalę – geriausias modelis pasiekė 0,702 plotą po ROC kreive, tuo tarpu CHA2DS2-VASc rezultatas buvo tik 0,5. Nors tyrimas turi tam tikrų apribojimų (nedidelis insulto atvejų skaičius, vyriška veteranų populiacija), jis parodo dirbtinio intelekto potencialą pagerinti insulto rizikos vertinimą pacientams, sergantiems PV. Ateityje, validavus šiuos rezultatus didesnėse

kohortose, toks metodas galėtų padėti dinamiškai vertinti insulto riziką ir optimizuoti antikoagulantų terapiją.

Staigi širdinė mirtis

DI potencialas prognozuoti staigią širdinę mirtį yra svarbi tyrimų sritis aritmologijoje.

Maarten Z H Kolk ir bendraautorai (2024) pristatė daugiamodalinį požiūrį į staigos širdies mirties prognozavimą. Tyrimas, paskelbtas „Scientific Reports” žurnale, pristato revoliucinį požiūrį į širdies aritmijų prognozavimą pacientams su neišemine kardiomiopatija. Tyrėjai sukūrė daugiamodalinį dirbtinio intelekto modelį, pavadintą DEEP RISK, kuris integruoja vėlyvojo gadolinio kontrastavimo magnetinio rezonanso tomografijos (LGE-MRI) vaizdus, EKG duomenis ir klinikinę informaciją, siekiant numatyti pavojingas skilvelių aritmijas, vedančias prie staigos širdinės mirties. DEEP RISK modelio efektyvumas išorinio validavimo kohortoje (103 pacientai) modelis pasiekė 0,84 plotą po ROC kreive (95 % PI 0,71-0,96), 98,1 % jautrumą ir 72,6 % specifiškumą. Ypač svarbu paminėti, kad modelis, naudojantis tik MRT duomenis, pasiekė geresnių rezultatų (AUC-ROC 0,80) nei klinikiniais (AUC-ROC 0,64) ar EKG (AUC-ROC 0,54) duomenimis pagrįsti modeliai. (41)

Bendrasis mirtingumas

DI gali tiksliai prognozuoti bendrąjį mirtingumą. Perspektyvus tyrimas, paskelbtas „Lancet Digital Health” žurnale, pristatė inovatyvią dirbtinio intelekto sistemą, pavadintą AIRE (AI-ECG Risk Estimator), skirtą prognozuoti mirties riziką ir širdies bei kraujagyslių ligas pagal EKG duomenis. Šis daugiamodalinis modelis buvo išvystytas analizuojant 1,16 milijono EKG įrašų iš 189 539 pacientų Beth Israel Deaconess medicinos centre. AIRE platforma integruoja giliojo mokymosi metodus su diskrečiuoju išgyvenamumo modeliu, kad sukurtų individualią išgyvenamumo kreivę kiekvienam pacientui remiantis viena EKG. Sistema ne tik prognozuoja mirties riziką, bet ir numato laiką iki mirties. Modelio validavimas buvo atliktas penkiose skirtingose tarptautinėse kohortose iš JAV, Brazilijos ir Jungtinės Karalystės, įtraukiant tiek savanorius, tiek pirminės ir antrinės sveikatos priežiūros pacientus. Rezultatai parodė įspūdingą tikslumą: bendro mirtingumo prognozavimo C-indeksas siekė 0,775 (95 % PI 0,773-0,776), o išoriniuose validavimo rinkiniuose – nuo 0,638 iki 0,773. AIRE sistema taip pat pasižymėjo aukštu tikslumu prognozuojant: skilvelines aritmijas (C-indeksas 0,760, 95 % PI 0,756-0,763), aterosklerozinę širdies ir kraujagyslių ligą (0,696, 0,694-0,698), širdies nepakankamumą (0,787, 0,785-0,789). (43)

4.3 Rezultatų prognozavimas po intervencijų

Buvo sukurti DI modeliai prognozuoti rezultatus po įvairių intervencijų.

Pasikartojimas po abliacijos

DI algoritmai buvo naudojami prognozuoti prieširdžių virpėjimo pasikartojimą po medikamentinio gydymo ir abliacijos. Julie K. Shade ir bendraautoriai sukūrė metodiką, sujungiančią mechanistinį modeliavimą ir dirbtinį intelektą. Kiekvienam pacientui buvo sukurtas individualus kairiojo prieširdžio kompiuterinis modelis, paremtas magnetinio rezonanso tomografijos vaizdais. Šis modelis leido simuliuoti PV dinamiką ir įvertinti aritmijos palaikymo mechanizmus. Dirbtinio intelekto algoritmas analizavo tiek šias simuliacijas, tiek originalius MRT vaizdus, ieškodamas požymių, galinčių numatyti PV pasikartojimą po abliacijos. Algoritmas pasiekė 82 % jautrumą ir 89 % specifiškumą prognozuojant PV pasikartojimą. Įdomu tai, kad vien simuliacijų analizė leido pasiekti beveik tokį patį tikslumą (plotas po ROC kreive 0,81), tuo tarpu MRT vaizdų analizė be simuliacijų buvo žymiai mažiau efektyvi (AUC 0,47). Tai patvirtina mechanistinio modeliavimo svarbą suprantant PV dinamiką. (44)

Atsakas į širdies resinchronizacijos terapiją

Dirbtinis intelektas gali optimizuoti pacientų atranką, išskiriant pacientus, kuriems labiausiai tikėtina nauda iš širdies resinchronizacijos terapijos. (18) Viena tyrimo autorai pristato naują metodologiją, skirtą prognozuoti širdies resinchronizacijos terapijos (ŠRT) efektyvumą, apjungiant klinikinius duomenis su personalizuotais kompiuteriniais širdies modeliais. Tyrimo metu buvo analizuojami 57 pacientų, kuriems buvo atlikta ŠRT implantacija, duomenys. Autoriai sukūrė personalizuotus širdies elektrofiziologijos modelius, paremtus magnetinio rezonanso ir kompiuterinės tomografijos vaizdais. Šie modeliai buvo naudojami simuliuoti skilvelių aktyvaciją ir elektrokardiogramos signalus tiek kairiosios širdies pluošto kojų blokados atveju, tiek biventrikulinės stimuliacijos metu.

Tyrėjai sėkmingai apjungė klinikinius duomenis su modeliavimo rezultatais, sukurdami hibridinį duomenų rinkinį mašininio mokymosi algoritmams. Geriausias sukurtas klasifikatorius, paremtas atraminių vektorių metodu, pasiekė 82 % tikslumą, 85 % jautrumą ir 78 % specifiškumą prognozuojant ŠRT efektyvumą. Šie rezultatai ženkliai pranoko klasifikatorius, sukurtus naudojant vien tik klinikinius duomenis. (45)

Pakartotina hospitalizacija dėl širdies nepakankamumo

Tyrimas, paskelbtas „Journal of Nuclear Medicine” žurnale, pristato dirbtinio intelekto modelį, skirtą numatyti širdies nepakankamumo (ŠN) paūmėjimo ir hospitalizacijos riziką. Šiame novatoriškame tyrime dalyvavo daug pacientų – 4 766 pacientų duomenys buvo naudojami modelio vystymui (vidinis kohortinis tyrimas) ir 2 912 pacientų duomenys – išoriniam validavimui. Modelis integravo klinikinius rizikos faktorius, streso testo duomenis,

SPECT vaizdavimo parametrus ir automatiškai apskaičiuotus kalcio indeksus iš kompiuterinės tomografijos vaizdų.

Tyrimo rezultatai parodė neabejotiną modelio tikslumą: vidiniame kohortiniame tyrime plotas po ROC kreive (AUC) siekė $0,87 \pm 0,03$, kas buvo žymiai geriau nei naudojant tik streso metu nustatytą kairiojo skilvelio išstūmimo frakciją ($0,73 \pm 0,05$) ar modelį su vien klinikiniais parametrais ($0,81 \pm 0,04$). Šie rezultatai buvo patvirtinti ir išoriniame validavimo tyrime, kur galutinio modelio AUC buvo $0,80 \pm 0,04$.

Svarbu pažymėti, kad modelis parodė aukštą prognostinę vertę tiek pacientams su sumažėjusia kairiojo skilvelio išstūmimo frakcija (HFrEF), tiek tiems, kurių išstūmimo frakcija buvo išsaugota (HFpEF). Vidinio kohortinio tyrimo metu per 1,9 metų stebėjimo laikotarpį 103 pacientai buvo hospitalizuoti dėl HFrEF ir 194 – dėl HFpEF paūmėjimo. (46)

Implantuojamo kardioverterio-defibriliatoriaus (IKD) terapija

Pacientų su implantuojamais kardioverteriais-defibriliatoriais (IKD) individualios klinikinės eigos prognozavimas yra esminis faktorius, siekiant užtikrinti tinkamą priežiūrą. Rosman et al. atliktas tyrimas siekė sukurti ir validuoti naują mašininio mokymosi algoritmą, skirtą prognozuoti bendrąjį mirtingumą ir / arba hospitalizaciją pacientams su IKD. Dirbtinio intelekto analizė buvo pritaikyta prognozuoti 3 mėnesių ir 1 metų riziką bendrajam mirtingumui ir hospitalizacijai prognozuoti per pirmuosius 5 metus po prietaiso implantacijos. RF-SLAM algoritmas tiksliai prognozavo bendrąjį mirtingumą ir mirtį ar hospitalizaciją dėl ŠN per 3 mėnesius ir 1 metus pirmaisiais 5 metais po prietaiso implantacijos, parodė gerą vidinį ir išorinį validumą. (47)

4.4 Individualizuotas rizikos vertinimas ir gydymo parinkimas

DI prisideda prie labiau individualizuotų metodų aritmijų valdyme.

Atsako į gydymą prognozavimas

DI modeliai buvo naudojami prognozuoti atsaką į antiaritminius vaistus ar širdies implantuojamų prietaisų terapijas. Andrew E. Levy ir bendraautorai atliko tyrimą, nagrinėjantį dirbtinio intelekto taikymą valdant dofetilido dozavimą.

Dofetilidas yra antiaritminis vaistas, kuriam reikalinga FDA nustatyta trijų dienų stebėsena ligoninėje dėl padidėjusios toksiškumo rizikos pradinio gydymo laikotarpiu. Nors yra rekomenduojamas dozės valdymo algoritmas, realybėje gydytojai taiko įvairius metodus vaistui dozuoti.

Tyrėjai analizavo 354 pacientų, pradedančių vartoti dofetilidą, duomenis iš kelių medicinos centrų antiaritminio vaisto (AADGEN) tyrimo. Vienmatė logistinė regresija parodė, kad pradinė 500 mcg dofetilido dozė (OR 5,0, 95 % PI 2,5-10,0, $p < 0,001$) ir sinusinis ritmas gydymo pradžioje (OR 2,8, 95 % PI 1,8-4,2, $p < 0,001$) buvo stiprūs sėkmingos gydymo pradžios prediktoriai. Bet koks dozės koregavimas gydymo metu (OR 0,19, 95 % PI 0,12-0,31, $p < 0,001$) ir koronarinė širdies liga anamnezėje (OR 0,33, 95 % PI 0,19-0,59, $p < 0,001$) buvo stiprūs neigiami prediktoriai.

Remiantis pastebėjimu, kad bet koks dozės koregavimas buvo reikšmingas neigiamas sėkmingos pradžios prediktorius, mokslininkai pritaikė kelis prižiūravimo mokymosi metodus, bandydami prognozuoti dozės koregavimo sprendimus. Tačiau nė vienas iš šių metodų neidentifikavo dozės koregavimų geriau nei tikimybinis spėjimas. Pagrindinių komponentų analizė ir klasterinė analizė identifikavo 8 klasterius kaip tinkamą duomenų redukcijos metodą. Šie 8 klasteriai buvo naudojami apibūdinti pacientų būsenas skatinamojo mokymosi modelyje, apmokytame su 80 % dozavimo sprendimų. Modelio testavimas su likusiais 20 % dozavimo sprendimų parodė gerą tikslumą – tik 16 iš 410 (3,9 %) atvejų nesutapo. (78)

Nors minėtas vaistas nėra registruotas Europos Sąjungoje, tačiau atlikti tyrimai parodo kad panašūs DI metodai galėtų būti pritaikyti ir kitų vaistų atsako į gydymą prognozavimui.

Fenotipu pagrįstas gydymas

Neprižiūrimas mašininis mokymasis buvo panaudotas fenotipų žemėlapiui analizei, siekiant identifiкуoti pacientų pogrupius su skirtingomis klinikinėmis charakteristikomis, kurie galėtų gauti naudos iš skirtingų gydymo būdų. (18)

Yu Horiuchi et al. atliktame tyrime mokslininkai nagrinėjo klasterinės analizės pritaikymą ūminio širdies nepakankamumo (UŠN) pacientų fenotipavime. Tyrimo metodologija apėmė 345 pacientų, hospitalizuotų dėl UŠN, klinikinių duomenų analizę. Buvo naudojama nehierarchinė klasterinė analizė, įtraukiant 77 kintamuosius, tokius kaip amžius, lytis, ŠN etiologija, gretutinės ligos, fizinio ištyrimo duomenys, laboratoriniai tyrimai, elektrokardiograma, echokardiograma ir gydymas hospitalizacijos metu. Cox proporcinės rizikos regresijos analizė buvo atlikta įvertinti ryšį tarp klasterių ir klinikinių išiečių. Tyrėjai identifikavo tris skirtingus klasterius (kraujagyslių nepakankamumas, širdies ir inkstų nepakankamumas, vyresnio amžiaus pacientai su didžiausiu prieširdžių virpėjimo paplitimu ir išsaugota išstūmimo frakcija). Šis tyrimas demonstruoja, kad klasterinė analizė gali būti efektyvi identifiкуojant kliniškai svarbias UŠN kategorijas ir gali padėti suprasti pagrindines patofiziologijos, prognozės ypatybes bei numatyti gydymo strategijas. (48)

Kitame tyrime mokslininkai pritaikė dirbtinio intelekto metodą, vadinamą „phenomapping“, hipertenzijos potipiams identifikuoti. Tyrimo tikslas buvo išsiaiškinti, ar nešališkas mašininis mokymasis, analizuojant išsamius fenotipinius duomenis, galėtų identifikuoti skirtingas hipertenzijos pacientų grupes, susijusias su miokardo substrato pokyčiais, vedančiais į širdies nepakankamumą su išsaugota išstūmimo frakcija (HFpEF). Tyrime buvo analizuoti 1 273 hipertenzija sergančių pacientų duomenys iš HyperGEN studijos. Mokslininkai naudojo 47 klinikinius, laboratorinius ir echokardiografinius kintamuosius. Taikant mašininio mokymosi metodus, ypač modelių pagrįstą klasterizavimą, pacientai buvo suskirstyti į dvi skirtingas fenogrupes (kraujagyslinį nepakankamumo ir širdies ir inkstų nepakankamumo grupes). Tyrimas parodė, kad fenogrupės ženkliai skyrėsi širdies mechanikos rodikliais. Rezultatai parodė, kad dirbtinis intelektas gali padėti identifikuoti kliniškai reikšmingus hipertenzijos potipius, kurie gali turėti skirtingą progresavimą į širdies nepakankamumą ir reikalauti skirtingų gydymo strategijų. (49)

„Tabletės kišenėje“ antikoaguliacija

DI leidžia nuolat stebėti pacientus ir galėtų padėti įdiegti naujus gydymo būdus, pavyzdžiui, skirti antikoagulantus tik tam tikrą laiką, kai aptinkami prieširdžių virpėjimo (PV) epizodai. Šį inovatyvų metodą leistų taikyti trys svarbūs pasiekimai: 1) augantys įrodymai, kad prieširdžių virpėjimas nėra dichotominis kintamasis, ir kad PV trukmė vaidina svarbų vaidmenį insulto rizikai; 2) implantuojami prietaisai ir vartotojams skirtos skaitmeninės sveikatos technologijos, augmentuotos DI ir galinčios aptikti PV; 3) tiesioginiai geriamieji antikoagulantai, suteikiantys greitą antikoaguliacijos pradžią per kelias valandas po vienos dozės. (18) Pilotinis tyrimas TACTIC-AF jau parodė šio metodo perspektyvumą – tyrime antikoagulantų vartojimas sumažėjo 94 %, naudojant 1 valandos trukmės ribą antikoaguliacijos atnaujinimui. (50)

DI pritaikymas prognozuojant riziką ir pacientų išeitis gali žymiai pagerinti pacientų priežiūrą, nes leistų gydytojams anksčiau įsikišti ir pritaikyti individualias gydymo strategijas kiekvienam pacientui. Tačiau svarbu pažymėti, kad, prieš plačiai diegiant, daugeliui šių modelių vis dar reikia perspektyvinio patvirtinimo realaus pasaulio klinikinėse situacijose ir aplinkose. (18) Integruojant papildomą informaciją iš paciento ligos istorijos, vaizdinių tyrimų ir cirkuliuojančių biomarkerių, galima dar labiau patobulinti rizikos vertinimą, tačiau dabartiniai DI modeliai dar neįstengia efektyviai apdoroti tokio sudėtingo duomenų derinio. (3)

5. Dirbtinis intelektas aritmijų stebėsenai ir valdymui

5.1 Nešiojamieji įrenginiai ir nuolatinė stebėseną

DI algoritmai buvo sėkmingai pritaikyti nešiojamoms technologijoms, įgalinant greitą, vietoje atliekamą diagnostiką pacientams. Šis DI integravimas su nešiojamaisiais įrenginiais atvėrė naujas galimybes nuolatinėi širdies stebėsenai ir ankstyvam aritmijų aptikimui.

Aptikimas išmaniuoju laikrodžiu

Health eHeart tyrimas parodė sėkmingą prieširdžių virpėjimo aptikimą naudojant Apple Watch ir Cardiogram mobiliąją programėlę, pasiekiant 0,97 C-statistiką (95 % CI, 0,94-1,00, su 98,0 % jautrumu ir 90,2 % specifiškumu) validacijos kohortoje. (18) Buvo sukurtas gilusis neuroninis tinklas aptikti pasyvų PV iš fotopletizmografijos signalų, gautų iš Apple Watch. Šis tyrimas demonstruoja dirbtinio intelekto potencialą panaudojant plačiai prieinamas technologijas širdies ritmo sutrikimų stebėsenai. Šis tyrimas demonstruoja, kad dirbtinis intelektas gali efektyviai stebėti širdies ritmo sutrikimus, naudodamas plačiai prieinamas technologijas. Nors ambulatorinėje aplinkoje rezultatai buvo kuklesni, tyrimas įrodo koncepciją, kad išmanieji laikrodžiai, kartu su pažangiais algoritmais, gali būti naudojami pasyviai PV diagnostikai be papildomų invazinių priemonių. (24)

KardiaBand

Šis EKG jutiklis, skirtas Apple Watch, kartu su SmartRhythm programine įranga, parodė 93 % jautrumą ir 84 % specifiškumą prieširdžių virpėjimui aptikti (aptartas ankstesniame skyriuje).


TeltoHeart

TeltoHeart laikrodis yra inovatyvus nešiojamas įrenginys, skirtas prieširdžių virpėjimo aptikimui. Šis nešiojamas įrenginys naudoja fotopletizmografinį daviklį ir šešių derivacijų EKG. Įrenginys yra kompaktiškas ir lengvas, leidžiantis jį dėvėti visą dieną be laidų, todėl yra patogus ir pritaikomas kasdieniam naudojimui. Bacevičiaus su bendraautoriais 2022 metais atlikta DoubleCheck-AF studija tyrė dvigubo fotopletizmografijos ir šešių derivacijų EKG prieširdžių virpėjimo ritmo nustatymo tikslumą. Šio perspektyvinio tyrimo metu buvo ištirti 344 dalyviai, įskaitant 121 pacientą su PV bei kontrolines grupes su stabiliu sinusiniu ritmu ir dažnomis ekstrasistolėmis. Tyrimas parodė, kad fotopletizmografijos algoritmas pasižymi 94,2 % jautrumu ir 96,9 % specifiškumu, o įrenginio EKG – atitinkamai 99,2 % ir 99,1 %. Svarbu pažymėti, kad apjungta abiejų metodų sistema išlaikė aukštą tikslumą nustatant prieširdžių virpėjimą (94,2 % jautrumas ir 99,6 % specifiškumas) net ir sudėtingose situacijose, kuomet pacientams pasireikšdavo dažnos ekstrasistolės.

DI įgalintas elektroninis stetoskopas

Tyrėjai jau anksčiau buvo įrodė, kad galima naudoti dirbtinį intelektą kairiojo skilvelio

išstūmimo frakcijos ($IF \leq 40\%$) nustatymui naudojant standartinę 12 derivacijų EKG su 0,91 plotu po ROC kreive (AUC). Attia et al. tyrime siekė įvertinti, ar panašaus tikslumo galima pasiekti naudojant tik vieną derivaciją, užrašytą EKG funkcionalumą turinčiu stetoskopu, įprastinio fizinio ištyrimo metu. Tyrime dalyvavo 100 pacientų, kuriems buvo kliniškai indikuotas echokardiografinis tyrimas. Pacientams buvo atliekamos EKG registracijos su skaitmeniniu stetoskopu (Eko DUO) įvairiose krūtinės ląstos vietose, pacientui esant tiek sėdimoje, tiek gulimoje padėtyje, tuo pačiu metu atliekant echokardiografiją. DI algoritmas, anksčiau apmokytas naudojant 12 derivacijų EKG, buvo pritaikytas naudoti su viena derivacija ir validuotas su EKG įgalintu stetoskopu, siekiant nustatyti tikslumą aptinkant sumažėjusią IF ($\leq 35\%$, $\leq 40\%$ arba $< 50\%$).



Pav. 5: Eko DUO skaitmeninio stetoskopo naudojimas ir galimos pozicijos

Geriausia pavienė registravimo pozicija buvo V2 pacientui gulint [AUC: 0,88 (CI: 0,80–0,97), esant $IF \leq 35\%$, 0,85 (CI: 0,75–0,95), esant $IF \leq 40\%$, ir 0,81 (CI: 0,71–0,90), esant $IF < 50\%$]. Naudojant DI modelį automatiniam įrašo pasirinkimui, AUC buvo 0,91 (CI: 0,84–0,97), esant $IF \leq 35\%$, 0,89 (CI: 0,83–0,96), esant $IF \leq 40\%$, ir 0,84 (CI: 0,73–0,94), esant $IF < 50\%$. Autoriai daro išvadą, kad dirbtinio intelekto algoritmas, pritaikytas EKG įgalintam stetoskopui, patikimai nustato sumažėjusią išstūmimo frakciją prospektyviniame tyrime su pacientais, kuriems buvo atlikta echokardiografija. Galimybė aptikti pacientus su galimai

sumažėjusia EF įprastinio fizinio ištyrimo metu gali paspartinti kairiojo skilvelio disfunkcijos diagnostiką. (51)

5.2 Skubi kardiologinė pagalba ir realaus laiko stebėseną

Skubi kardiologinė pagalba ir realaus laiko stebėseną yra sritys, kuriose dirbtinis intelektas demonstruoja ypatingą potencialą. Vienas tyrimas parodė, kaip dirbtinio intelekto algoritmai gali analizuoti garso įrašus, gautus per išmaniuosius namų garsiakalbius ir telefonus, kad aptiktų agoninį kvėpavimą – tipiską požymį širdies sustojimo metu. Ši technologija galėtų leisti aptikti širdies sustojimą ir aktyvuoti skubią pagalbą tais atvejais, kai pacientas yra vienas namuose, kas sudaro didelę dalį visų širdies sustojimo atvejų. (11)

Išmaniųjų įrenginių srityje AliveCor KardiaMobile sistema, naudojanti dirbtinį intelektą interpretuoti EKG, parodė įspūdingus rezultatus. (8) Kardia Mobile Cardiac Monitor (KMCM) – nešiojamas su išmaniuoju telefonu susietas širdies ritmo registravimo įrenginys. KMCM naudoja dirbtinio intelekto algoritmą, kuris analizuoja 30 sekundžių EKG įrašą (atitinkantį I derivaciją) ir pateikia tris galimas išvadas: „normalus ritmas“, „galimas prieširdžių virpėjimas“ arba „neklasifikuotas ritmas“. KMCM automatinis algoritmas parodė 96,6 % jautrumą ir 94,1 % specifiškumą aptinkant PV, lyginant su standartine 12 derivacijų EKG. (52)

Marcus Dörr ir bendraautorių atliktame WATCH AF tyrime išmaniojo telefono fotopletizmografija pagrįstas algoritmas pasiekė 93,7 % jautrumą, 98,2 % specifiškumą ir 96,1 % tikslumą prieširdžių virpėjimui aptikti. Šis tyrimas parodė, kad net ir paprastos, plačiai prieinamos technologijos, papildytos dirbtinio intelekto algoritmais, gali pasiekti aukštą diagnostinį tikslumą. (79)

Yutao Guo ir bendradarbių Huawei išmaniųjų įrenginių tyrime, atliktame Kinijoje su 187 912 asmenų, 262 dalyviai gavo pranešimus apie galimą prieširdžių virpėjimą ir buvo nukreipti tolimesniam klinikiniam vertinimui su EKG stebėseną. 87 % šių asmenų buvo patvirtintas prieširdžių virpėjimas, o fotopletizmografijos signalų teigiama prognostinė vertė siekė 92 %. (80)

5.3 Integracija su elektroniniais sveikatos įrašais

DI valdomo aritmijų stebėjimo integravimas su elektroniniais sveikatos įrašais (ESI) suteikia galimybių pagerinti pacientų priežiūrą ir klinikinius sprendimus.

Automatizuotas rizikos vertinimas

Visiškai automatizuota, į elektroninius sveikatos įrašus integruota platforma, aprūpinta DI-

EKG galimybėmis ir kitais pažangiais mašininio mokymosi metodais, įskaitant natūralios kalbos apdorojimą, galėtų būti apmokyta rinkti duomenis iš EKG, PV modelių ir kitų diagnostinių tyrimų ar net klinikinių užrašų, kad nuolat vertintų insulto riziką. (5)

Realaus laiko įspėjimai

Tokia integracija galėtų leisti atlikti realaus laiko rizikos vertinimą ir įspėti gydytojus klinikistus, kai aptinkama didelė insulto rizika, potencialiai įgalinant laiku pradėti antikoaguliaciją nepageidaujamų klinikinių reiškinių prevencijai. (4)

Išsamūs pacientų profiliai

DI, integruotas į elektroninių sveikatos įrašų sistemą (ESI), leistų sujungti EKG duomenis su kita klinicine informacija, sukurti išsamesnius pacientų profilius ir tiksliau nustatyti riziką bei parengti tinkamesnius gydymo planus. (9)

5.4 Bekontaktės stebėjimo technologijos

Šiuo metu yra atliekama nemažai tyrimų su bekontaktėmis gyvybinių funkcijų stebėjimo technologijomis. Yu-Chiao Tsai ir bendraautorių tyrime buvo pademonstruota 24 GHz Doplerio radaro sistema, skirta bekontakčiam širdies ritmo ir kvėpavimo dažnio stebėjimui, naudojant regresinę analizę su KNT + LSTM neuroniniu tinklu, leidžiančiu pasiekti itin tikslas prognozes. Širdies ritmo ir kvėpavimo dažnio nustatymo tikslumas atitinkamai siekė 99 % ir 98 %. Šis tyrimas teigia, kad bekontaktė radaro sistema gali būti naudojama kaip širdies ritmo kintamumo įspėjimo sistema. Sistema taip pat galėtų būti pritaikyta ilgalaikiam širdies ritmo stebėjimui lovoje gulintiems pacientams ar kitose situacijose, kai pacientai nejudrūs. (53)

Bekontaktiai dirbtinio intelekto stebėjimo įrenginiai taip pat gali būti naudojami širdies ritmo analizei. Sun et al. tyrimas sujungė kamera pagrįstą nuotolinę fotopletizmografiją (rPPG) su gilaus konvoliucinio neuroninio tinklo mokymosi modeliu prieširdžių virpėjimui aptikti. Rezultatai parodė, kad rPPG, naudojantis DI modelį, atskyrė 90,0 % ir 97,1 % prieširdžių virpėjimo ir kitų širdies ritmo anomalijų atvejų nuo normalaus sinusinio ritmo atitinkamai 30 sekundžių ir 10 minučių įrašuose. Šis tyrimas parodė, kad DI modeliai paverčia rPPG perspektyvia, ekonomiška ir veiksminga bekontakte priemone, leidžiančia masiškai tikrinti ir ilgai stebėti pacientus, naudojant tik įprastą kamerą ar išmaniojo telefono kamerą. (54)

Remiantis šiuo pasiekimu, artimiausiu metu galima tikėtis pažangos insulto prevencijoje, tačiau reikalingi tolesni tyrimai, kuriais būtų įvertintas modelio veikimas ligoninėse gydomiems pacientams, didelio masto bendruomenės patikroje ir ilgalaikėje namų priežiūroje.

5.5 Iššūkiai ir ateities kryptys

Nors DI įgalinti stebėsenos ir valdymo įrankiai rodo didelį potencialą, jie taip pat kelia nemažai iššūkių.

Duomenų kokybė

Duomenų kokybės ir nuoseklumo užtikrinimas iš įvairių nešiojamųjų įrenginių ir mobiliųjų programėlių yra ypač svarbus patikimai DI analizei. (3) Kadangi modeliai dažnai kuriami naudojant aukštos kokybės duomenų bazines su kruopščiai gautomis EKG ir fenotipuotais pacientais, jų taikymas įprastinėje klinikinėje praktikoje realiomis sąlygomis gautoms EKG gali būti prastas. Prastos kokybės duomenys gali kliudyti efektyviam DI-EKG technologijų kūrimui ir taikymui.

Pacientų privatumas

Asmeninių sveikatos duomenų rinkimas ir perdavimas kelia svarbius privatumo ir saugumo klausimus. (12) Kai tyrimų komandos visame pasaulyje validuoja DI-EKG modelius ir keičiasi didžiuliais pacientų duomenų kiekiais, iškyla reali grėsmė jautrios pacientų informacijos saugumui – šie duomenys gali tapti kibernetinių atakų ar kitų saugumo pažeidimų taikiniu. Tradicinių šifravimo metodų naudojimas gali būti nepakankamas šiam susirūpinimui sumažinti.

Klinikinis patvirtinimas

Būtinai griežtas klinikinis šių DI įrankių patvirtinimas, siekiant įrodyti jų poveikį pacientų gydymo rezultatams. (3) Norint įrodyti DI-EKG įrankių vertę, juos reikia kruopščiai išbandyti randomizuotuose tyrimuose – lygiai taip pat, kaip tikrinama bet kokia kita klinikinė intervencija.

Integracija su sveikatos priežiūros sistemomis

Šių įrenginių duomenų integravimas į elektroninių sveikatos įrašų sistemas ir klinikines darbo eigas kelia nemažai iššūkių. (14) Dar nėra plačiai išvystyta infrastruktūra, kuri leistų DI-EKG rezultatus įtraukti į elektroninius sveikatos įrašus ir suteiktų gydytojams patogią prieigą prie šių rezultatų paciento gydymo metu.

Modelių interpretavimas ir paaiškinamumas

Daugelis DI modelių, ypač giliojo mokymosi modeliai, veikia kaip „juodosios dėžės“ (jų veikimas nėra pilnai suprantamas net patiems sistemų sukūrusiems tyrėjams), todėl sunku suprasti, kaip priimami jų sprendimai. Šis interpretavimo trūkumas gali pakenkti pasitikėjimui DI modeliais, ypač sveikatos priežiūroje, kur sprendimai gali turėti gyvybiškai svarbių pasekmių.

Reguliaciniai aspektai

DI-EKG gautų diagnozių įtraukimo į tiesioginę klinikinę priežiūrą reguliaciniai aspektai dabar tik pradedami formuluoti. Reguliacinio institucijos DI-EKG įrankius tvirtina kitaip nei medicinos prietaisus ar vaistus. Šis tvirtinimo procesas dar labiau komplikuojasi priklausomai nuo to, ar gydytojai gali patys peržiūrėti ir įvertinti DI algoritmų pateiktus rezultatus. Teisinė sistema, palaikanti DI pagrįstą klinikinį sprendimų priėmimą, dar nėra sukurta.

Šališkumo problemos

Egzistuoja rizika, kad DI gali įtvirtinti esamą šališkumą. Algoritmai, sukurti naudojant dabartinius klinikinės praktikos modelius ir rezultatus, atspindės esamą nelygybę ir kels riziką ją sustiprinti ir įtvirtinti. Tyrėjai ir algoritmų vartotojai turi apsvarstyti, kaip renkami duomenys, kaip veikia modeliai ir kaip jie geriausiai turėtų būti taikomi.

Ateityje šioje srityje gali būti kuriami sudėtingesni DI modeliai, gebantys apjungti duomenis iš įvairių šaltinių – nešiojamųjų įrenginių, elektroninių sveikatos įrašų (ESI) ir vaizdinių tyrimų. Tokiu būdu gydytojai galės taikyti išsamesnes ir kiekvienam pacientui pritaikytas aritmijų gydymo strategijas. Be to, svarbu tobulinti DI modelių interpretavimo galimybes ir kurti aiškias gaires, kaip juos naudoti klinikinėje praktikoje – tai padės gydytojams plačiau taikyti šias technologijas kasdieniame darbe.

6. Dirbtinis intelektas antiaritminių vaistų valdyme

DI taikymas antiaritminių vaistų valdyme yra daug žadanti sritis pacientų priežiūros gerinimui per individualizuotos medicinos metodus. DI parodė potencialą įvairiuose vaistų terapijos aspektuose, nuo dozės optimizavimo iki vaistų efektyvumo ir toksiškumo stebėjimo.

6.1 Vaistų dozavimo optimizavimas

DI metodai, įskaitant prižiūrimą, neprižiūrimą ir skatinamąjį mokymąsi, buvo naudojami optimaliems antiaritminių vaistų dozavimo režimams nustatyti.

Dofetilido dozavimas

DI metodai buvo pritaikyti optimizuoti dofetilido, III klasės antiaritminio vaisto, dozavimą.

(3) Šie DI valdomi metodai siekia pagerinti vaistų terapijos saugumą ir efektyvumą, naudodami labiau individualizuotas dozavimo strategijas. Attia et al. išbandė giliojo mokymosi metodą, analizuojantį EKG. Šis metodas pranoko tradicinį QT/QTc intervalo matavimą, kai stebėjo dofetilido koncentracijas plazmoje. Tai padėjo gydytojams tiksliau koreguoti vaistų dozes trijų dienų stebėjimo laikotarpiu. (55) Sanchez et al. nustatė, kad vaistas veikė skirtingai, priklausomai nuo specifinės srovių išraiškos, ir sukūrė algoritmą,

gebantį prognozuoti antiaritminių vaistų poveikį PV pacientams su heterogeniškumu, identifikuojant kanalų laidumų modelį, vedantį į aritmiją. (56) Šis vaistas nėra registruotas Europoje, tačiau tyrimas parodo kad panašūs DI metodai gali būti pritaikyti ir kitų vaistų, reikalaujančių intensyvios priežiūros, dozavimo optimizavimui.

Skatinamasis mokymasis

Skatinamasis mokymasis (angl. reinforcement learning) yra dirbtinio intelekto metodas, kuris remiasi principu, kad algoritmas mokosi iš sąveikos su aplinka, gaudamas atlygio ar nuobaudos signalus už savo veiksmus. Šis metodas grindžiamas bandymų ir klaidų strategija, kur sistema ilgainiui išmoksta maksimizuoti teigiamą atsaką.

Jeremy Petch ir bendraautorių publikuotoje studijoje nagrinėjamas inovatyvus gilusis skatinamasis mokymasis (angl. deep reinforcement learning) varfarino dozės nustatymui prieširdžių virpėjimu sergantiems pacientams. Tyrime buvo sukurtas ir įvertintas naujas pusiau Markovo sprendimų procesą naudojantis gilusis pastiprinamasis mokymosi algoritmas, galintis dinamiškai rekomenduoti optimalią varfarino dozę, siekiant išlaikyti terapinį INR rodiklį 2,0–3,0 intervale. Tyrimo rezultatai parodė, kad mašininio mokymosi algoritmas gali optimizuoti terapinį INR diapazoną pacientams, vartojantiems varfariną, ir tai galėtų pagerinti klinikines baigtis prieširdžių virpėjimu sergantiems pacientams. (57)

Populiacinė farmakokinetika

DI galėtų potencialiai pagerinti populiacinius farmakokinetinius modelius, naudojamus vaistų dozavimui, leisdamas tiksliau koreguoti dozes pagal individualias paciento charakteristikas. Populiacinė farmakokinetika yra metodas, kuris naudojamas analizuoti vaisto kinetikos (absorbcijos, distribucijos, metabolizmo ir ekskrecijos) variabilumą tarp skirtingų pacientų. Tradiciniai populiacinės farmakokinetikos modeliai dažniausiai remiasi netiesiogine regresine analize ir priežastinių veiksnių (amžiaus, svorio, inkstų funkcijos ir kitų) įtakos vaisto farmakokinetikai įvertinimu. Pritaikant dirbtinio intelekto technologijas antiaritminių vaistų dozavimui, DI sistemos galėtų naudoti ne tik tradicinius klinikinius parametrus (amžius, lytis, svoris, inkstų funkcija), bet ir įtraukti genetinius žymenis (pvz., CYP2D6 polimorfizmus sotalolį vartojantiems pacientams), maistą ir gėrimus (kurie gali paveikti vaisto absorbciją), kitus vartojamus vaistus (potencialias sąveikas) ir net gyvensenos faktorius (fizinį aktyvumą, miego režimą), kurie gali paveikti vaisto farmakokinetiką ir farmakodinamiką. (58)

6.2 Dirbtinis intelektas vaistų saugumo tyrimuose

Vaistų proaritminės rizikos vertinimas yra svarbi dalis nustatant vaisto saugumą. Dėl etinių priežasčių ir praktinių apribojimų, vaistų tyrimai negali būti atliekami tiesiogiai su žmonėmis, tačiau žmogaus indukuotos pluriotentinės kamieninės ląstelės, iš kurių išvystyti

kardiomiocitai (hiPSC-CMs), leido patobulinti in vitro žmogaus miokardo modelį vaistų atrankai. Dirbtinio intelekto technologija buvo sujungta su hiPSC-CMs, siekiant įvertinti vaistų saugumą ir prognozuoti vaistų sukeltų aritmijų tikimybę.

Ricardo Serrano ir bendraautorių atliktoje studijoje aštuoni skirtingi hiPSC-CMs buvo modeliuojami pagal genotipo-fenotipo savybes ir buvo gydomi skirtingomis didelės proaritminės rizikos vaistų dozėmis. Taip buvo sukurta KNT platforma, skirta prognozuoti in vitro vaistų sukeltų aritmijų atsiradimą hiPSC-CMs ląstelėse. Ši platforma padeda nustatyti in vitro vaistų saugumo ribas, prognozuoti klinikinę vaistų proaritmijos riziką ir suteikti naujus įrankius kiekybiniam saugumo vertinimui vaistų kūrimo procese. (59)

Panaudodami daugiau nei 3 000 kardiomiocitų su skirtingomis aritmijomis, kilusių iš pliuripotentinių kamieninių ląstelių in vitro, Jeremy KS Pang ir bendra autoriai apmokė mašininio mokymosi programą suprasti specifinį širdies raumens plakimo elgesį, naudojant intraląstelinės kalcio koncentracijos pokyčius kaip indikatorių. Sistema sugebėjo numatyti vaistų ar genų sukeltų aritmijų atsiradimą daugiau nei 90 % tikslumu ir galėjo identifikuoti skirtingas aritmijas. (60)

Ši mokslinių tyrimų kryptis yra ypač svarbi dėl kelių priežasčių.

Ankstyvesnis rizikos įvertinimas. DI modeliai, integruoti su hiPSC-CMs, leidžia anksti nustatyti potencialiai pavojingus vaistus dar ikiklinikinių tyrimų etape, taip sumažinant nesėkmių riziką vėlesniuose klinikiniuose bandymuose.

Pacientų specifiniai modeliai. Skirtingų genetinių profilių hiPSC-CMs naudojimas leidžia įvertinti, kaip skirtingi vaistai veikia pacientus su skirtingomis genetiškai predisponuotomis aritmijomis.

Mechanistinis supratimas. DI algoritmai gali padėti identifikuoti subtilias elgesio koreliacijų struktūras, kurios atskleidžia pagrindinius aritmijų mechanizmus, ir taip pagerinti mūsų fundamentalų supratimą apie širdies elektrofiziologiją.

Alternatyva gyvūnų modeliams. Šis metodas gali sumažinti poreikį naudoti gyvūnų modelius vaistų saugumo tyrimuose, kas atitinka etinių tyrimų principus ir 3R (pakeitimo, sumažinimo ir patobulinimo) gaires.

Tikslesnis aritmogeninio vaistų potencialo prognozavimas taip pat gali padėti išvengti dviejų tipų klaidų: potencialiai naudingų vaistų atmetimo dėl klaidingai nustatytos aritmijų rizikos ir potencialiai pavojingų vaistų patvirtinimo dėl neaptiktos aritmijų rizikos. Tai gali teigiamai paveikti tiek pacientų saugumą, tiek naujų vaistų kūrimo efektyvumą.

7. Dirbtinis intelektas elektrofiziologijos procedūrose

7.1 Žemėlapių sudarymas ir abliacijos gairės

DI potencialiai galėtų pagerinti širdies žemėlapių sudarymo tikslumą ir efektyvumą elektrofiziologijos procedūrų metu.

DI algoritmai gali padėti analizuoti intrakardines elektrogramas ir greičiau bei tiksliau nei tradiciniais metodais nustatyti optimalias abliacijos vietas. Viename tyrime prižiūrimas konvoliucinis neuroninis tinklas (KNT) buvo apmokytas klasifikuoti 175 000 PV duomenų taškų iš 35 pacientų su persistuojančiu PV, siekiant nustatyti potencialias rotacines vietas, kur abliacija efektyviai nutrauktų PV. Modelis pasiekė 95,0 % (PI 94,8 %–95,2 %) klasifikavimo tikslumą, viršydamas tradicinę tiesinę diskriminantinę analizę, k artimiausių kaimynų metodą (k-NN) ir atraminių vektorių metodą. Be to, KNT rezultatai atitiko ekspertinio lygio vertinimą su 0,961 plotu po ROC kreive (AUC). (61)

Taikydami panašią metodiką, Alexander M Zolotarev ir kolegos analizavo optinio žemėlapių sudarymo ir kateterio signalus iš žmogaus prieširdžių, siekdami diskriminuoti PV židinius arba ne židinius pagal dažnio charakteristikas. Buvo testuojami penki skirtingi prižiūrimo mokymosi algoritmai (k-NN, AVM, XGBoost, atsitiktinis miškas ir logistinė regresija). Naudojant didelio tankio kateterį, sistema pademonstravo 86 % tikslumą geriausiam metodui. Optimalūs rezultatai buvo gauti taikant centro ir periferijos židinio žymėjimą. Visi penki algoritmų tipai veikė panašiai efektyviai ir padėjo nustatyti vertingiausias dažnių spektro savybes, reikalingas klasifikavimui, pavyzdžiui, santykinę aukštą arba dominuojančio dažnio ryškumą. (62)

Nepaisant šių technologinių proveržių, vis dar egzistuoja didelė kontroversija dėl DI sukurtų rezultatų interpretavimo iš neapdorotų PV elektrogramų klinikiniam kontekste. Tai daugiausia lemia didelis kintamumo šaltinių skaičius, įskaitant įrašymo konfigūracijos skirtumus, bangos fronto susidūrimus ir rotorių meandrinio judėjimo efektus. Taigi, dabartinis dirbtinio intelekto taikymas šioje srityje vis dar yra pradinėse vystymosi stadijose.

7.2 Robotų asistuojamos procedūros

Robotų asistuojamos procedūros minimos kaip naujas DI proveržis medicinoje, kuris ateityje galėtų leisti atlikti sudėtingesnes intervencijas. (18)

Kateterio navigacija

DI potencialiai galėtų pagerinti kateterio navigacijos tikslumą ir saugumą abliacijos procedūrų

metu. Integruotas DI ir robotikos sprendimas galėtų suteikti tikslesnę kateterio kontrolę ir stabilumą, ypač sudėtingose anatomicinėse vietose, tokiose kaip plaučių venų jungtys ar kairiojo prieširdžio ausytė. Taikant mašininio mokymosi algoritmus, robotinės sistemos galėtų automatiškai kompensuoti širdies judėjimą kvėpavimo ciklo metu ir širdies susitraukimų metu, užtikrinant stabilesnį kateterio kontaktą su taikinio audiniu.

Realaus laiko gairės

DI algoritmai galėtų teikti realaus laiko gaires procedūrų metu, potencialiai gerinant rezultatus ir trumpinant procedūrų trukmę. Šie algoritmai galėtų analizuoti intrakardinių elektrogramų duomenis kartu su anatomiciniais žemėlapiais, identifikodami optimalias abliacijos vietas prieširdžių virpėjimui, skilvelinėms tachikardijoms ir kitoms sudėtingoms aritmijoms gydyti. DI valdomos sistemos galėtų pateikti dinamines rekomendacijas abliacijos eiliškumui, kateterio kryptčiai ir abliacijos energijos parametrams, atsižvelgiant į unikalias kiekvieno paciento elektrinio substrato charakteristikas.

Nors šie DI taikymai elektrofiziologijos procedūrose skamba kaip daug žadantys, svarbu pažymėti, kad daugelis jų vis dar yra ankstyvose vystymosi stadijose arba yra spekuliatyvūs, remiantis DI pritaikymu susijusiose srityse. Prieš plačiai diegiant bus reikalingi išsamūs tyrimai ir nuoseklus klinikinis patvirtinimas.

8. Dirbtinis intelektas širdies stimuliacijos terapijoje

Širdies stimuliacijos terapija, tokia kaip širdies resinhronizacijos terapija (CRT) ir implantuojami kardioverteriai-defibriliatoriai (IKD), yra svarbi intervencija gydant įvairias širdies ligas, ypač širdies nepakankamumą ir prevencijoje nuo staigios širdinės mirties. Dirbtinio intelekto metodai rodo didelį potencialą optimizuojant pacientų atranką šioms intervencijoms, gerinant prietaisų programavimą ir valdymą bei tiksliau prognozuojant klinikinius rezultatus.

8.1 Dirbtinis intelektas širdies resinchronizacijos terapijoje

Širdies resinchronizacijos terapija yra metodas, skirtas sinchronizuoti širdies susitraukimą ir atsipalaidavimą implantuojant trijų kamerų stimuliatorių. Jos efektyvumas gydant lengvą-vidutinį ir sunkų širdies nepakankamumą buvo įrodytas daugelyje klinikinių tyrimų. Tačiau CRT taip pat pasižymi dideliu neatsako dažniu (25-33 % pacientų), todėl ypač svarbūs geresni pacientų atrankos metodai. (63)

Atsako į CRT prognozavimas

Albert Feeny ir bendraautoriai sukūrė mašininio mokymosi modelius, skirtus prognozuoti atsaką į CRT (apibrėžiamą kaip $\geq 10\%$ kairiojo skilvelio išstūmimo frakcijos padidėjimas), remiantis skirtingais klasifikavimo algoritmų ir klinikinių kintamųjų deriniais. Jų sukurtas DI modelis, įtraukiantis QRS morfologiją, QRS trukmę, NYHA klasifikaciją, kairiojo skilvelio išstūmimo frakciją ir diastolinį skersmenį, lytį, išeminę kardiomiopatiją, prieširdžių virpėjimą ir epikardinį kairiojo skilvelio laidą, pasiekė AUC-ROC 0,70, kas buvo geriau nei tradiciniai gairėmis pagrįsti kriterijai. (64)

Kitas tyrimas, atliktas Márton Tokodi ir bendraautorių, atskleidė specifinius lyčiai būdingus modelius ir atskleidė dinaminį kitimą tęstinio stebėjimo metu nuo 1 iki 3 metų laikotarpiu, naudojant permutacijos požymių svarbos metodą. Širdies ligos etiologija, NYHA klasė, kairiojo skilvelio išstūmimo frakcija ir QRS morfologija buvo stipriausi visų mirties priežasčių prediktoriai, tuo tarpu hemoglobino kiekis kraujyje buvo mažiau svarbus moterims, lyginant su vyrais. Tyrėjai taip pat nustatė, kad prieširdžių virpėjimo ir amžiaus prognostinė vertė didėjo, o serumo kreatinino – mažėjo abiejų lyčių atveju laikui bėgant. (65)

EKG pagrįsti prognozavimo modeliai

Požangą šioje srityje pasiekė Philippe Wouters ir bendraautoriai, kurie nustatė, kad giliojo mokymosi modelis, reikalaujantis tik standartinės 12 derivacijų EKG, galėjo prognozuoti bendrą klinikinę baigtį – mirtį, kairiojo skilvelio pagalbinio prietaiso implantavimą ar širdies transplantaciją CRT pacientams, nereikalaudant papildomų klinikinių kintamųjų. Šis modelis parodė geresnį efektyvumą nei tradiciniai gairėmis grįsti kriterijai. (66)

8.2 Implantuojami kardioverteriai-defibriliatoriai (IKD)

Staigi širdinė mirtis (SŠM) yra viena iš pagrindinių pasaulinių visuomenės sveikatos problemų, sukelianti daugiau nei 4 milijonus mirčių kasmet. Implantuojami kardioverteriai-defibriliatoriai (IKD) gali užkirsti kelią SŠM, kurią sukelia piktybinė skilvelinė aritmija, taikant defibriliaciją ar antitachikardinį stimuliavimą. Visgi sunku nuspręsti, kuriems pacientams tikrai reikia implantuoti IKD, nes maždaug 60 % pacientų, kuriems įdiegia šiuos prietaisus, jie taip ir nesuveikia per visą veikimo laikotarpį. Tuo tarpu net 50 % staigios širdies mirties atvejų nutinka žmonėms, kuriuos pagal įprastus kriterijus priskiria mažos rizikos grupei. (25)

Piktybinių skilvelinių aritmijų prognozavimas

Curtis Ginder ir bendraautoriai sukūrė metodą, skirtą prognozuoti piktybines skilvelines aritmijas, naudodami kasdienes nuotolinio stebėjimo duomenis. Analizuodami duomenis 30 dienų prieš prietaiso implantavimą ir taikydami konvoliucinius neuroninius tinklus, tyrėjai

patobulino įprastus rizikos stratifikavimo metodus ir pasiekė AUC-ROC nuo 0,72 iki 0,90. (67) Šie rezultatai įrodo, kad DI gali pagerinti mūsų gebėjimą numatyti ir užkirsti kelią potencialiai pavojingoms aritmijoms.

Poodinių IKD optimizavimas

Mohamed ElRefai ir bendradarbiai nagrinėjo poodinių IKD (S-IKD) tinkamumą ir nustatė, kad jį lemia didesnis T:R santykis. Jie sukūrė naują konvoliucinio neuroninio tinklo modelį, skirtą atrinkti širdies nepakankamumo pacientus, tinkamus S-IKD implantacijai, siekiant sumažinti T bangos perteklinių signalų riziką ir netinkamų šokų tikimybę. (68) Šis modelis potencialiai gali padėti pagerinti individualaus prietaiso parinkimą pacientams ir sumažinti komplikacijų skaičių.

Nuotolinio stebėjimo optimizavimas

IKD gerina pacientų gydymo rezultatus, nes anksti aptinka technines problemas, todėl daugelyje gairių jis turi I klasės rekomendaciją. Tačiau tradicinis nuotolinio stebėjimo duomenų apdorojimas reikalauja daug žmogiškųjų išteklių. Tai gali didinti išlaidas ir sukelti organizacinių iššūkių. Marc Strik ir bendraautorai sukūrė dirbtinio intelekto algoritmą, skirtą klasifikuoti nestabilios skilvelinės tachikardijos epizodus ir nustatyti perteklinį skilvelinių signalų nustatymą nuotoliniu būdu, perduodamą IKD. Šis algoritmas pasiekė 0,932 F2 įvertinimą. Tai gali padėti sumažinti sveikatos apsaugos specialistų darbo krūvį ir pagerinti pacientų išeitį. (69)

Atsparaus skilvelių virpėjimo prognozavimas

Jason Coult ir bendraautorai sukūrė algoritmą, pagrįstą EKG, kuris padeda atpažinti pacientus, galimai turėsiančius šokui atsparų skilvelių virpėjimą. Šį skilvelių virpėjimą dažnai sukelia ne ligoninėje įvykstantis širdies sustojimas, kuris pasižymi itin maža išgyvenamumo tikimybe. Jų modelis pasiekė 0,85 AUC-ROC, kas galėtų leisti gelbėtojams iš anksto nukreipti intervencijas ir potencialiai pagerinti reanimacijos rezultatus. Galimybė iš anksto prognozuoti atsparų skilvelių virpėjimą (reikalaujantį ≥ 3 šokų) prieš pakartotinį šoko sukeltą nesėkmingą gydymą leistų taikyti tikslines intervencijas: anksčiau skirti antiaritminius vaistus, optimizuoti epinefrino naudojimą ar dozavimą, keisti šoko tiekimo strategijas arba greičiau pradėti taikyti invazinius gydymo būdus. (70)

Dirbtinio intelekto taikymas širdies stimuliacijos terapijoje atveria naujų galimybių pagerinti pacientų priežiūrą individualizuojant gydymą, optimizuojant prietaisų funkcijas ir gerinant klinikinius rezultatus. Tolimesni tyrimai turėtų sutelkti dėmesį į modelių validavimą realiame

pasaulyje, atsižvelgiant į įvairius klinikinius scenarijus ir pacientų populiacijas, siekiant užtikrinti šių technologijų saugumą ir efektyvumą kasdienėje klinikinėje praktikoje.

9. Iššūkiai ir apribojimai

Nors dirbtinis intelektas turi didelį potencialą kardiologijoje ir aritmologijoje, yra keletas iššūkių ir egzistuojančių apribojimų, kuriuos reikia išspręsti norint jį sėkmingai įdiegti klinikinėje praktikoje.

9.1 Duomenų kokybės ir standartizavimo problemos

Dirbtinio intelekto modelių kūrimui reikalingi dideli duomenų rinkiniai mokymui, validavimui ir testavimui. (4) Tačiau užtikrinti aukštos kokybės duomenis gali būti sudėtinga.

Duomenų kintamumas

Medicininį duomenų kokybė ir nuoseklumas gali stipriai skirtis tarp institucijų ir geografinių regionų. Tai gali turėti įtakos DI modelių veikimui ir sprendimų paaiškinamumui. Skirtingi EKG registravimo prietaisai, įvairios elektrodų padėties variacijos ir įstaigų specifiniai protokolai gali lemti duomenų heterogeniškumą, kuris mažina DI modelių, apmokytų viename kontekste, pritaikymą kitose aplinkose. Šis kintamumas taip pat apsunkina daugiainstitucinio bendradarbiavimo galimybes, kai siekiama apmokyti DI modelius naudojant didesnę ir įvairesnę duomenų imtį. Dėl to modeliai, kurie puikiai veikia vienos institucijos aplinkoje, gali prarasti tikslumą taikomi kitose aplinkose, taip apribojant jų platesnį diegimą. (7)

Duomenų žymėjimas

Daugeliui DI modelių reikia didelių kiekių sužymėtų duomenų apmokymui. Medicinos srityje tikslus žymėjimas dažnai reikalauja ekspertinio lygio žinių. Tai gali būti laiko ir didelių lėšų reikalaujantis procesas. Aritmijų identifikavimas ir klasifikavimas EKG įrašuose dažnai reikalauja aukšto specializacijos lygio, net ir tarp ekspertų gali kilti nesutarimų dėl tam tikrų subtilybių interpretacijos. Žymėjimo užduotis tampa dar sudėtingesnė analizuojant ilgalaikį Holterio monitoravimą ar įvairius aritmijų epizodus, kur kiekviena sekundė reikalauja patyrusio klinicisto įvertinimo. (6)

Standartizavimas

Standartizuotų duomenų rinkimo ir ataskaitų teikimo metodų trūkumas sveikatos priežiūros sistemose gali apsunkinti plačiai taikomų DI modelių kūrimą. Elektrofiziologinių diagnostikos tyrimų ir procedūrų protokolai tarp institucijų gali žymiai skirtis, o tai apsunkina lyginamąją duomenų analizę. (7)

Duomenų formato apribojimai

Kai kurie dabartiniai DI įrankiai negali analizuoti EKG, saugomų kaip vaizdai (pavyzdžiui, TIFF ar PDF failų formatai). Daugelyje ligoninių EKG vis dar saugomos skenuotų nuotraukų forma, o ne kaip neapdoroti skaitmeniniai signalai, kurie optimaliausiai tinka DI analizei. Nors egzistuoja metodai skaitmeninti šiuos vaizdų formatus, toks konvertavimas dažnai lemia duomenų praradimą ir artefaktus, kurie gali turėti įtakos DI modelių tikslumui. Klinikinių aplinkų perėjimas prie standartizuotų, skaitmeninių EKG formatų, tokių kaip DICOM-ECG ar HL7 aECG, būtų naudingas, tačiau reikalauja didelių investicijų į infrastruktūrą ir technologijas. (4)

Duomenų kokybė

Prastai organizuoti ir netikslūs duomenų rinkiniai mažina DI algoritmų efektyvumą. Kai duomenys prastos kokybės, su dideliu triukšmu, o jų kiekis nepakankamas mokymui, kyla viena didžiausių DI apmokymo problemų – persimokymas (overfitting). Tai reiškia, kad modelis klaidingai išmoka duomenų triukšmą laikyti tikrais dėsniniais, todėl vėliau nepajėgia tinkamai veikti su naujais ir šiek tiek pakitusiais duomenų rinkiniais.

Duomenų apribojimai

Duomenų bazės, kuriose yra jautri pacientų informacija, dažnai negali būti visiškai anonimizuotos, todėl viešų duomenų bazių skaičius yra ribotas. Dėl griežtų duomenų privatumo įstatymų, tokių kaip BDAR Europoje ir HIPAA JAV, medicininių duomenų dalijimasis tarp institucijų tampa apsunkintas. Tai riboja didelių, įvairių ir reprezentatyvių duomenų rinkinių, būtinų kuriant patikimus DI modelius, sukūrimą. Be to, pacientai su retesnėmis aritmijomis ar neįprastais elektrofiziologiniais radiniais, kurie būtų ypač naudingi mokymui, dažnu atveju yra nepakankamai atstovaujami viešai prieinamuose duomenų rinkiniuose. (18)

9.2 DI modelių interpretavimo ir paaiškinamumo problemos

Daugelis DI modelių, ypač giliojo mokymosi modeliai, veikia kaip „juodosios dėžės“ (t.y. jų veikimo principai nėra iki galo žinomi), todėl sunku suprasti, kaip jie priima sprendimus. (5) Šis interpretavimo trūkumas kelia keletą rimtų problemų:

Klinikinis pasitikėjimas

Interpretavimo trūkumas gali pakenkti pasitikėjimui DI modeliais. Modeliai dažnai pateikia tikslias prognozes nenurodydami, kodėl konkretus sprendimas buvo priimtas. Tai ypač problemiška medicinos srityje, kur būtina užtikrinti atsakomybę ir atsekamumą. (71)

Atitiktis reglamentams

Daugelio DI modelių „juodosios dėžės“ pobūdis gali apsunkinti atitiktį reglamentavimui dėl paaiškinamo sprendimų priėmimo sveikatos priežiūroje. Reguliavimo institucijos – JAV Maisto ir vaistų administracija (FDA) ir Europos Sąjungos Europos vaistų agentūra (EMA) – vis griežčiau reikalauja, kad medicininių sprendimų priėmimo technologijos būtų skaidrios ir paaiškinamos. (71)

Modelio šališkumo aptikimas

Paaškinamumo trūkumas gali apsunkinti šališkumo DI modeliuose nustatymą ir mažinimą. DI modelis, sukurtas naudojant duomenis daugiausia iš vyrų pacientų, gali veikti prasčiau diagnozuojant aritmijas moterims, kurios dažnai pasižymi skirtingomis EKG charakteristikomis ir aritmijų pasireiškimo modeliais. Panašiai modeliai, sukurti naudojant duomenis iš specifinių etninių grupių, gali veikti mažiau patikimai.

9.3 Reglamentavimo ir etiniai aspektai

DI įgyvendinimas klinikinėje praktikoje kelia keletą reglamentavimo ir etinių klausimų.

Reglamentavimo patvirtinimas

Reguliaciniai aspektai, susiję su DI pagrįstų diagnozių įtraukimu į tiesioginę klinikinę praktiką, šiuo metu tik pradedami formuluoti. Reguliacinių institucijų patvirtinimo barjeras gali būti visiškai kitoks nei įprastiems įrenginiams ar vaistams, ir gali skirtis priklausomai nuo klinicisto galimybės „peržiūrėti“ DI išvadas ir išvadų pagrindimus. Algoritmams, kurie optimizuoja darbo eigą, bet atlieka užduotį, kurią paprastai atlieka žmonės (pavyzdžiui, ritmo nustatymą), algoritmas gali būti patvirtintas kaip priemonė, padedanti optimizuoti klinicisto darbą. (3)

Tačiau jei modeliai atlieka analizę, kurios negali atlikti ekspertai klinicistai (pavyzdžiui, paciento amžiaus iš EKG nustatymas ar galimo prieširdžių virpėjimo rizikos nustatymas), gali atsirasti papildomų reguliacinių patvirtinimo iššūkių. Lietuvoje teisinė sistema, apibrėžianti DI grįstą klinikinių sprendimų priėmimą, dar nėra sukurta. (4)

Duomenų privatumas

Didelio masto pacientų duomenų naudojimas, kuriant DI modelius, kelia klausimų dėl pacientų privatumo ir duomenų saugumo. Tai ypač svarbu Europos Sąjungoje, kur BDAR nustato griežtus reikalavimus pacientų duomenų apdorojimui ir algoritminiam sprendimų priėmimui. (4)

Informuotas sutikimas

DI naudojimas klinikinuose sprendimuose kelia fundamentalių klausimų, kaip gauti informuotą pacientų sutikimą ir kaip paaiškinti su DI pagalba nustatytas diagnozes ir gydymo rekomendacijas. (6) Tradicinėje medicinoje informuoto sutikimo principas remiasi prielaida, kad pacientui bus pateikta suprantama informacija apie diagnostikos ar gydymo metodų esmę, rizikas, naudą ir alternatyvas. Tačiau DI sistemų atveju šis procesas tampa sudėtingesnis.

Lygybė ir šališkumas

Yra pagrįstų susirūpinimų, kad DI algoritmai, sukurti naudojant dabartinę klinikinę praktiką ir rezultatus, gali atspindėti ir įtvirtinti esamus sveikatos priežiūros skirtumus. (3) Sveikatos priežiūros sistemose egzistuojantys netolygumai, susiję su socialinėmis determinantėmis, ekonominiu statusu, rase, lytimi ar geografinė padėtimi, neišvengiamai atsispindi duomenyse, kuriais apmokomi DI modeliai. Kardiologijoje šis reiškinys ypač pastebimas, nes širdies ligų simptomatika ir diagnostika skiriasi tarp vyrų ir moterų. (3)

Atsakomybės klausimai

DI naudojimas klinikinuose sprendimuose kelia sudėtingus klausimus dėl atsakomybės klaidų ar neigiamų rezultatų atvejais. (6) Tradicinėje medicinoje atsakomybės paskirstymas yra pakankamai aiškus – gydytojas priima klinikinį sprendimą ir prisiima atsakomybę už jų pasekmes. Tačiau DI eroje atsiranda nauja „atsakomybės spraga“, kai sprendimų grandinėje dalyvauja algoritmai. (6)

9.4 Klinikinis patvirtinimas ir įgyvendinimas

Nors daugelis DI modelių rodo daug žadančius rezultatus tyrimų metu, jų veikimas realioje klinikinėje praktikoje gali skirtis.

Išorinis validumas

Modeliai, kurie gerai veikia vienoje populiacijoje, gali rodyti prastesnius rezultatus kitose. (3) Šis reiškinys ypač pastebimas, kai modeliai apmokomi specifinėse demografinėse grupėse, bet vėliau taikomi platesnėje ir heterogeniškesnėje populiacijoje.

Integracijos iššūkiai

Infrastruktūra DI-EKG rezultatams integruoti į elektroninius sveikatos įrašus ir padaryti juos prieinamus paciento apžiūros vietoje nėra plačiai prieinama. (3)

Nusistovėjusios darbo eigos sutrikdymas

DI įrankių integravimas į esamas kliniškes darbo eigas gali būti sudėtingas ir gali reikalausti

nusistovėjusios praktikos pakeitimų. (7) Tokia transformacija reikalauja ne tik technologinių pokyčių, bet ir adaptuoti organizacinę kultūrą bei įveikti personalo pasipriešinimą.

Mokymas ir švietimas

Sveikatos priežiūros specialistus reikia apmokyti efektyviai naudoti ir interpretuoti DI valdomus įrankius, o tam reikia nuolatinio mokymosi. (6) Medicinos studijų programos dar nėra pakankamai pritaikiusios savo mokymo programų, kad būtų įtraukti DI raštingumo ir skaitmeninių kompetencijų moduliai. Tarpdisciplininiai mokymai, apimantys technologijų, medicinos ir etikos aspektus, tampa esminiu veiksniu, užtikrinančiu tinkamą DI įrankių naudojimą ir kritinį gautų rezultatų vertinimą klinikinėje praktikoje.

Ekonominis efektyvumas

DI technologijų įdiegimą sveikatos priežiūroje reikia įvertinti jų ekonominio efektyvumo požiūriu. (18)

9.5 Technologiniai apribojimai

Dabartinės DI technologijos taip pat susiduria su kai kuriais technologiniais apribojimais:

Skaičiavimo pajėgumų reikalavimai

Kai kuriems pažangiems DI modeliams reikia didelių skaičiavimo pajėgumų (galingų grafinių procesorių), kurie gali būti prieinami ne visose klinikinėse aplinkose. Ši problema ypač aktuali kardiologijos srityje, kur sudėtingi modeliai, tokie kaip gilieji neuroniniai tinklai, reikalauja specializuotų grafinių procesorių (GPU) ar net specializuotų skaičiavimo akceleratorių (TPU), norint efektyviai apdoroti aukštos raiškos ir didelės apimties duomenis. Pavyzdžiui, pažangūs elektrokardiogramų interpretavimo modeliai gali turėti dešimtis milijonų parametrų, kurių apdorojimui reikalinga specializuota skaičiavimo įranga. Lietuvos sveikatos priežiūros sistemoje, ypač regioninėse ligoninėse ar poliklinikose, tokios įrangos prieinamumas yra ribotas, o investicijos į infrastruktūros atnaujinimą dažnai nėra prioritetinės. Šis atotrūkis tarp reikalingų ir prieinamų skaičiavimo išteklių gali lemti „skaitmeninę atskirtį“ tarp didžiųjų akademinių centrų ir periferinių sveikatos priežiūros įstaigų. Be to, aukštų skaičiavimo pajėgumų reikalavimai susiję ne tik su pradinėmis investicijomis, bet ir su nuolatinėmis infrastruktūros palaikymo išlaidomis – elektros energijos sąnaudomis, vėsinimo sistemomis, techninės priežiūros kaštais.

Realaus laiko duomenų apdorojimas

Tam tikroms taikomosioms programoms, pavyzdžiui, nuolatinei stebėsenai, DI modeliai turi apdoroti duomenis realiu laiku, o tai gali būti komplikauta dirbant su sudėtingais modeliais. Aritmijos stebėsenos kontekste ypač svarbu, kad algoritmai galėtų analizuoti EKG signalus be

vėlavimo, kadangi laiku nepastebėti gyvybei pavojingi ritmo sutrikimai gali turėti negrįžtamų pasekmių.

Realaus laiko apdorojimo iššūkiai apima ne tik paties algoritmo vykdymo greitį, bet ir visą duomenų apdorojimo grandinę: signalų gavimą iš jutiklių, pirminį apdorojimą, triukšmo pašalinimą, požymių išskyrimą ir galutinę analizę. Ši grandinė turi veikti su minimaliu vėlavimu, ypač nešiojamuose įrenginiuose ar implantuojamuose prietaisuose, kurie dažnai turi ribotus energijos išteklius ir procesorių galią. Praktikoje tai reiškia, kad tenka ieškoti kompromiso tarp modelio sudėtingumo (tikslumo) ir apdorojimo greičio. Nors giliai konvoliuciniai neuroniniai tinklai (KNT) gali pasiekti aukštesnį tikslumą analizuojant EKG signalus, nešiojamuose įrenginiuose tenka naudoti supaprastintus modelius, galinčius veikti su ribotais ištekliais. Tokio kompromiso pasekmė gali būti sumažėjęs diagnostinis tikslumas, o tai kelia papildomų klausimų dėl tokių sistemų klinikinio naudingumo ir patikimumo.

Sąveikumas

Užtikrinti, kad DI sistemos galėtų sklandžiai veikti su esama sveikatos priežiūros IT infrastruktūra ir skirtingose platformose, išlieka nemažu iššūkiu. Sveikatos priežiūros įstaigose dažnai naudojama heterogeninė IT infrastruktūra, apimanti įvairias elektroninių sveikatos įrašų (ESI) sistemas, vaizdinimo archyvavimo ir komunikavimo sistemas (PACS), laboratorinės informacijos valdymo sistemas (LIS) ir kitas specializuotas platformas. DI sprendimų integravimas į šią sudėtingą ekosistemą reikalauja ne tik techninės sąveikos tarp sistemų, bet ir semantinio suderinamumo – užtikrinimo, kad duomenys būtų interpretuojami vienodai skirtingose sistemose. Tai ypač svarbu kardiologijoje, kur duomenys gaunami iš įvairių šaltinių: EKG aparatų, echokardiografijos įrenginių, Holterio stebėjimo sistemų, invazinių elektrofiziologinių tyrimų, KT ir MRT vaizdinimo tyrimų.

Nors egzistuoja standartai, skirti medicininių duomenų keitimuisi (DICOM, HL7 FHIR), jų įgyvendinimas praktikoje dažnai yra nepilnas ar nesuderintas tarp skirtingų gamintojų. Šis standartizacijos trūkumas gali lemti situacijas, kai DI modelis, sukurtas ir išbandytas vienoje aplinkoje, negalės būti efektyviai pritaikytas kitoje dėl duomenų formatų, kodavimo ar protokolų skirtumų. Šie iššūkiai pabrėžia tolesnių tyrimų ir plėtros poreikį DI srityje kardiologijoje-aritmologijoje.

Norint išnaudoti visą DI potencialą, kad būtų geriau aptinkamos, diagnozuojamos ir gydomos aritmijos, būtina išspręsti šias problemas. Ateityje mokslininkai turėtų sutelkti dėmesį į duomenų kokybės gerinimą ir standartizavimą, kurti lengviau suprantamus DI modelius,

nustatyti aiškias reglamentavimo sistemas ir atlikti griežtus klinikinius tyrimus, kad įrodytų realią DI technologijų naudą kardiologijoje.

9.6 Dirbtinio intelekto įgyvendinimas klinikinėje praktikoje

Dirbtinio intelekto įgyvendinimas klinikinėje kardiologijos praktikoje reikalauja sisteminio požiūrio ir infrastruktūros pritaikymo. Vienas iš sėkmingų pavyzdžių yra CardioCube balso technologijos pritaikymas Los Andželo kardiologijos klinikoje. Ši sistema automatizavo pacientų medicininės istorijos surinkimą, leisdama pacientams žodžiu atsakyti į iš anksto paruoštus klausimus ir automatiškai generuodama tikslias ataskaitas elektroninėje sveikatos sistemoje. Sistema buvo pritaikyta ir nuotolinei pacientų stebėsenai per FCNcare platformą, kur širdies nepakankamumo ir diabeto pacientai galėjo atnaujinti savo sveikatos būklės stebėjimus iš namų. (8)

Mayo klinikoje buvo įdiegta pažangi dirbtinio intelekto sistema interpretuoti elektrokardiogramas. Sistema, apmokyta naudojant daugiau nei 44 000 pacientų duomenis, sugebėjo identifikuoti asimptominę kairiojo skilvelio disfunkciją su 86,3 % jautrumu ir 85,7 % specifiškumu. Kai sistema buvo išbandyta nepriklausomoje 52 870 pacientų grupėje, ji išlaikė aukštą efektyvumą, pasiekdama 0,93 plotą po ROC kreive. Šis įgyvendinimas parodė, kad dirbtinio intelekto sistemas galima sėkmingai integruoti į kasdienę klinikinę praktiką ir naudoti kaip patikimą atrankos įrankį. (11)

10. Ateities kryptys

10.1 Didžiųjų kalbos modelių potencialas aritmologijoje

Per pastaruosius kelerius metus dirbtinio intelekto srityje įvyko proveržis kuriant didžiuosius kalbos modelius (LLM), o Chat Generative Pre-trained Transformer (ChatGPT) platformos atsiradimas sulaukė didelio visuomenės susidomėjimo. ChatGPT yra interaktyvus didysis kalbos modelis, kuris naudoja giliojo mokymosi metodus žmogaus kalbai apdoroti ir generuoti atsakymus, panašius į žmogaus atsakymus. Jo puikūs rezultatai JAV medicinos licencijavimo egzamine (USMLE) parodė šios technologijos potencialią vertę medicinos srityje.

Mokslininkai pradėjo tirti ChatGPT pritaikymą diagnozuojant ir gydant aritmijas. Ralf E. Harskamp ir bendraautorių tyrime buvo vertinamas ChatGPT gebėjimas atsakyti į medicininius klausimus. Šis tyrimas nustatė, kad jo tikslumas prieširdžių virpėjimo srityje siekia 70 %. Šis DI modelis pateikia atsakymus remdamasis naujausiais moksliniais tyrimais bei gairėmis ir gali „išversti“ medicininius užrašus į pacientams suprantamą kalbą, taip

padėdamas klinikiniam darbe gerinant pacientų švietimą ir paciento-gydytojo komunikaciją. (72)

Chunyu Liu ir kolegos sukūrė SignalGPT – bendradarbiaujančią sistemą, apjungiančią generatyvinį DI biomedicininį signalų apdorojimą ir ChatGPT. SignalGPT interpretavo EKG signalus į natūralią kalbą 100 % tikslumu diagnozuojant dešinės Hiso pluošto kojytės ir kairės Hiso pluošto kojytės blokadą bei daugiau nei 90 % tikslumu nustatant I laipsnio AV blokadą ir prieširdžių virpėjimą, taip pagerinant klinikinę diagnostiką. (73)

Vis dėlto dabartiniuose kalbos modeliuose išlieka tam tikrų ribojimų. Nustatyta, kad tipiniai ligos požymiai, simptomai ir ištyrimų radiniai yra būtini, kad ChatGPT galėtų pateikti teisingą diagnozę, kas rodo jo nepakaks sudėtingose klinikinėse situacijose. Be to, apmokytą dideliu teksto kiekiu, kuris nėra specialiai atrinktas, ChatGPT gali nepateikti patikimų informacijos šaltinių ir gali turėti gan nemažą lyties bei rasinį šališkumą. (25)

10.2 Naujos DI technologijos aritmologijoje

Ateities moksliniai tyrimai aritmologijos srityje gali koncentruotis ties sudėtingesnių DI modelių kūrimu, gebančių apdoroti ir sujungti įvairių tipų duomenis. Pavyzdžiui, visiškai automatizuotos, į elektroninius sveikatos įrašus įdiegtos platformos su DI-EKG galimybėmis ir kitais pažangiais mašininio mokymosi metodais, įskaitant natūralios kalbos apdorojimą, galėtų būti apmokytos rinkti duomenis iš įvairių šaltinių nuolatiniam paciento rizikos vertinimui. (3) Šios integruotos sistemos galėtų pateikti išsamesnį paciento širdies sveikatos būklės vaizdą ir padėti tiksliau įvertinti riziką bei suplanuoti tinkamesnį gydymą.

Taip pat yra galimybė kurti pažangesnius DI modelius kitoms širdies būklėms aptikti. Pavyzdžiui, aktyviai kuriami DI modeliai aortos vožtuvo stenozei ir amiloidinei širdies ligai aptikti. (3) Šiems modeliams tampant sudėtingesniems, jie galėtų potencialiai aptikti subtilias širdies anomalijas, kurias žmogui interpretuotojui sunku nuosekliai identifikuoti.

Vienas iš svarbiausių pasiekimų yra virtualaus vėlyvojo gadolinio kontrastavimo (VNE) technologija magnetinio rezonanso tyrimuose. Šis metodas, išbandytas 1 348 pacientų su hipertrofine kardiomiopatija tyrime, sugeba generuoti vaizdus, identiškus standartiniam vėlyvajam gadolinio kontrastavimui, tačiau nenaudojant kontrastinės medžiagos. Sistema naudoja tris lygiagrečius konvoliucinius neuroninius tinklus, kurie apdoroja ir sustiprina signalus iš vietinių T1 žemėlapių ir vaizdo gavimo. Šis metodas ne tik išvengė kontrastinės medžiagos naudojimo rizikų, bet ir sutrumpino tyrimo laiką iki 15 minučių. (8)

Robotikos srityje svarbus žingsnis buvo žengtas su CEREBRIA-1 tyrimu, kuris patvirtino dirbtinio intelekto gebėjimą nustatyti vainikinių arterijų pažeidimų fiziologinę reikšmę ir poreikį revaskuliarizacijai. Ši technologija, derinama su magnetinės navigacijos sistemomis ir robotika, atveria kelią tikslesnėms ir mažiau invazinėms intervencijoms. Jau kuriamos nanodalelės, gebančios savarankiškai naviguoti į aterosklerozės pažeistas sritis ir tiekti tikslinį gydymą, naudojant tiek vidinį, tiek išorinį magnetinį valdymą. (8)

Individualizuotas gydymas ir rizikos vertinimas tampa vis svarbesne kardiologijos dalimi, kur dirbtinis intelektas atveria naujas galimybes. Mayo klinikoje atliktas tyrimas su 1 606 pacientais, kuriems buvo taikoma širdies resinchronizacijos terapija (ŠRT), atskleidė, kaip dirbtinis intelektas gali pagerinti pacientų atranką. Dirbtinio intelekto algoritmai, analizuodami 33 klinikinius kintamuosius, sugebėjo prognozuoti 1-5 metų mirštamumą nuo visų priežasčių gerokai tiksliau nei tradiciniai vertinimo metodai. Šis algoritmas, pavadintas SEMMELWEIS-CRT, parodė geresnį atsaką į gydymą prognozavimą ir patobulintą mirštamumo diskriminaciją. (8)

Svarbus žingsnis buvo žengtas ir širdies nepakankamumo srityje. Tyrėjai, naudodami neprižiūrimo mokymosi metodus ir dimensijų mažinimo algoritmus, išanalizavo 1 106 pacientų duomenis ir identifikavo keturias skirtingas fenotipų grupes. Dvi iš šių grupių turėjo didesnę dalį žinomų klinikinių charakteristikų, prognozuojančių geresnį atsaką į CRT, ir buvo susietos su geresniu gydymo efektu. Ši sistema leido geriau suprasti, kurie pacientai turės didžiausią naudą iš CRT implantacijos. (11)

Naują perspektyvą atvėrė ir dirbtinio intelekto taikymas vertinant vainikinių arterijų ligų riziką. Kinijos mokslininkai sukūrė 50 sluoksnių konvoliucinį neuroninį tinklą, gebantį aptikti vainikinių arterijų ligą (stenozę >50 %, patvirtinta angiografija), analizuodami paciento veido nuotrauką. Tyrimas, atliktas su 5 796 pacientais, parodė, kad algoritmo plotas po ROC kreive siekė 0,730, su 80 % jautrumu ir 54 % specifiškumu. Nors tyrimas turėjo tam tikrų apribojimų, įskaitant geografinį populiacijos specifiškumą, jis parodė naujas galimybes neinvazinei diagnostikai. (8)

Svarbus vystymasis pastebimas ir naujųjų biosignalų analizės technologijų srityje. Cardio-HART™ technologija demonstruoja inovatyvų požiūrį į širdies būklės vertinimą, apjungdama tris skirtingus biosignalų tipus: EKG elektrofiziologiniams nukrypimams aptikti, PCG hemodinaminėms ligoms nustatyti ir MCG mechano-fiziologiniams sutrikimams identifikuoti. Ši technologija leidžia įvertinti struktūrinius, funkcinis ir hemodinaminius sutrikimus

neinvaziniu būdu, kas ypač svarbu pirminėje sveikatos priežiūros grandyje, kur echokardiografijos tyrimas nėra lengvai prieinamas. (17)

10.3 Daugiamodalinių duomenų integracija

Ateities DI modeliai gali sugebėti integruoti duomenis iš kelių šaltinių, įskaitant EKG, vaizdinimo tyrimus, genetinius duomenis ir klinikinę istoriją, kad pateiktų išsamesnį rizikos vertinimą ir gydymo rekomendacijas. Nors dabartinės DI galimybės šiuo atžvilgiu gali būti ribotos, papildomos informacijos iš klinikinės istorijos, vaizdinimo tyrimų ir cirkuliuojančių biomarkerių integracija ateityje gali dar labiau pagerinti rizikos stratifikavimą. (4)

DI modelių, gebančių efektyviai apdoroti ir sujungti informaciją iš skirtingų duomenų šaltinių, kūrimas ir toliau išlieka aktyviai tyrinėjama sritis. (3) Šios daugiamodalinės DI sistemos potencialiai galėtų suteikti holistiškesnį paciento kardiovaskulinės sveikatos vaizdą, lemiantį tikslesnes diagnozes ir individualizuotus gydymo planus.

10.4 Pažangios klinikinių sprendimų palaikymo sistemos

Realaus laiko sprendimų palaikymo sistemos, valdomos DI, galėtų tapti labiau paplitusios klinikinėje praktikoje. Šios sistemos galėtų teikti neatidėliotiną pagalbą procedūrų metu, pavyzdžiui, kateterinės abliacijos ar širdies prietaiso implantavimo metu. (6)

Adaptyvios terapijos sistemos, galinčios nuolat stebėti paciento duomenis ir siūlyti terapijos korekcijas realiu laiku, pavyzdžiui, širdies stimulatoriaus nustatymams ar vaistų dozavimui, galėtų tapti realybe. (6) Šios sistemos potencialiai galėtų pagerinti gydymo efektyvumą ir sumažinti dažnų individualių koregavimų poreikį.

Pažangūs DI modeliai, galintys prognozuoti ir įspėti klinikus apie artėjančius aritminius įvykius ar klinikinę būklės pablogėjimą, galėtų įsikišti anksčiau. (10) Šis prognozavimo gebėjimas potencialiai galėtų užkirsti kelią nepageidaujamiems įvykiams ir pagerinti pacientų rezultatus.

10.5 Naujos technologijos ir metodai

Virtualios ir papildytos realybės technologijos galėtų įgalinti holografinį vaizdavimą ir pagerinti procedūrų planavimą elektrofiziologijoje. (18) Šios technologijos, kartu su DI, galėtų pagerinti sudėtingų aritmijos gydymo procedūrų tikslumą ir efektyvumą.

Balsu valdomi virtualūs asistentai galėtų realiu laiku padėti gydytojams procedūrų metu ar priimant klinikinius sprendimus. (18) Šie DI valdomi asistentai galėtų akimirksniu suteikti prieigą prie svarbių paciento duomenų, gairių ir gydymo rekomendacijų.

Robotų padedami prietaisai galėtų leisti atlikti sudėtingesnes intervencijas elektrofiziologijoje. (18) DI potencialiai galėtų valdyti šias robotines sistemas, toliau gerinant aritmijos gydymo procedūrų tikslumą ir saugumą.

10.6 Etiškas DI ir reguliavimo sistemos

Kadangi DI tampa labiau integruotas į klinikinę praktiką, augs poreikis tvirtoms etikos gairėms ir reguliavimo sistemoms. Etikos gairių, užtikrinančių teisingumą DI taikymuose sveikatos priežiūroje, kūrimas bus itin svarbus. (12) Šios gairės turėtų spręsti tokius klausimus kaip algoritminis šališkumas, duomenų privatumas ir atsakingas DI naudojimas klinikiniuose sprendimuose.

Reguliacinės institucijos turės toliau kurti ir tobulinti DI pagrįstų medicinos prietaisų patvirtinimo ir stebėsenos sistemas. (12) Šios sistemos turės subalansuoti inovacijų poreikį su pacientų saugumu ir etiniais aspektais.

Apibendrinant, DI ateitis kardiologijoje-aritmologijoje yra šviesi ir kupina potencialo. Toliau besivystydamos technologijos žada pagerinti mūsų gebėjimą aptikti, diagnozuoti ir valdyti širdies aritmijas tiksliau ir efektyviau. Tačiau šio potencialo realizavimui reikės tęstinių tyrimų, atidaus patvirtinimo ir apgalvoto įgyvendinimo, siekiant užtikrinti, kad DI tikrai būtų naudingas pacientų priežiūrai, kartu sprendžiant svarbius etinius ir reguliacinius klausimus.

11. Išvados ir praktinės rekomendacijos

11.1 Dirbtinio intelekto vaidmuo kardiologijoje

DI technologijos, ypač giliojo mokymosi modeliai, jau dabar rodo aukštą tikslumą EKG interpretacijoje ir aritmijų aptikime, o ateityje gali ženkliai pakeisti kardiologinių patologijų diagnostiką ir gydymą.

11.2 Rizikos vertinimas ir gydymo prognozavimas

DI geba prognozuoti aritmijų riziką, paciento būklės dinamiką ir gydymo efektyvumą, leidžiant labiau individualizuoti gydymo strategijas.

11.3 Nuolatinė stebėseną ir nuotolinę priežiūrą

Integracija su nešiojamaisiais įrenginiais ir mobiliomis programėlėmis atveria galimybes nuolatinę stebėseną bei ankstyvam aritmijų aptikimui, sustiprina nuotolinės priežiūros galimybes.

11.4 DI taikymas procedūrose ir vaistų valdyje

DI gali pagerinti elektrofiziologinių procedūrų rezultatus, prietaisų programavimą ir optimizuoti antiaritminių vaistų vartojimą.

11.5 Poveikis klinikinei praktikai

DI įrankiai potencialiai didina diagnostikos tikslumą, mažina sveikatos priežiūros specialistų darbo krūvį ir didina darbo proceso efektyvumą.

11.6 Iššūkiai ir tyrimų poreikiai

Siekiant patikimo DI taikymo klinikinėje praktikoje, būtini aukštos kokybės duomenys, standartizacija, modelių paaiškinamumas ir klinikinis patvirtinimas įvairiose klinikinėse aplinkose.

11.7 Etinės, teisinės ir integracijos problemos

Reikalingos aiškos gairės dėl duomenų apsaugos, atsakomybės ir DI integravimo į esamas kliniines darbo eigas, taip pat dėl daugiamodalinės analizės galimybių.

Apibendrinant, nors DI kardiologijoje-aritmologijoje rodo didelį potencialą, jis dar nei iš dalies nėra įgyvendintas. Tyrimams progresuojant ir sprendžiant kylančius iššūkius, DI-EKG technologijos turi potencialą transformuoti klinikinę priežiūrą, pagerinti mūsų gebėjimą aptikti, diagnozuoti ir gydyti aritmijas. Tačiau, kaip ir bet kuris medicinos įrankis, DI turi būti kruopščiai patikrintas prieš platų klinikinį įdiegimą. DI ateitis aritmologijoje yra šviesi, tačiau jai reikės nuolatinio bendradarbiavimo tarp klinikistų, duomenų mokslininkų, inžinierių ir medicinos etikų, siekiant užtikrinti, kad šie galingi įrankiai būtų kuriami ir naudojami būdais, kurie yra tikrai naudingi pacientų priežiūrai.

Literatūros sąrašas

1. Kiranyaz S, Avci O, Abdeljaber O, Ince T, Gabbouj M, Inman DJ. 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*. 2021 Apr;151:107398.
2. Quer G, Arnaout R, Henne M, Arnaout R. Machine Learning and the Future of Cardiovascular Care. *Journal of the American College of Cardiology*. 2021 Jan;77(3):300–13.
3. Siontis KC, Noseworthy PA, Attia ZI, Friedman PA. Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. *Nat Rev Cardiol*. 2021 Jul;18(7):465–78.

4. Lopez-Jimenez F, Attia Z, Arruda-Olson AM, Carter R, Chareonthaitawee P, Jouni H, et al. Artificial Intelligence in Cardiology: Present and Future. *Mayo Clinic Proceedings*. 2020 May;95(5):1015–39.
5. Somani S, Russak AJ, Richter F, Zhao S, Vaid A, Chaudhry F, et al. Deep learning and the electrocardiogram: review of the current state-of-the-art. *EP Europace*. 2021 Aug 6;23(8):1179–91.
6. Trayanova NA, Popescu DM, Shade JK. Machine Learning in Arrhythmia and Electrophysiology. *Circulation Research*. 2021 Feb 19;128(4):544–66.
7. Ghosh P, Azam S, Jonkman M, Karim A, Shamrat FMJM, Ignatious E, et al. Efficient Prediction of Cardiovascular Disease Using Machine Learning Algorithms With Relief and LASSO Feature Selection Techniques. *IEEE Access*. 2021;9:19304–26.
8. Nagarajan VD, Lee SL, Robertus JL, Nienaber CA, Trayanova NA, Ernst S. Artificial intelligence in the diagnosis and management of arrhythmias. *European Heart Journal*. 2021 Oct 7;42(38):3904–16.
9. Hayiroğlu Mİ, Altay S. The Role of Artificial Intelligence in Coronary Artery Disease and Atrial Fibrillation. *Balkan Med J*. 2023 May 10;40(3):151–2.
10. Hammad M, Ilyasu AM, Subasi A, Ho ESL, El-Latif AAA. A Multitier Deep Learning Model for Arrhythmia Detection. *IEEE Trans Instrum Meas*. 2021;70:1–9.
11. Karatzia L, Aung N, Aksentijevic D. Artificial intelligence in cardiology: Hope for the future and power for the present. *Front Cardiovasc Med*. 2022 Oct 13;9:945726.
12. Ahsan MM, Siddique Z. Machine learning-based heart disease diagnosis: A systematic literature review. *Artificial Intelligence in Medicine*. 2022 Jun;128:102289.
13. Seckanovic A, Sehovac M, Spahic L, Ramic I, Mamatnazarova N, Pokvic LG, et al. Review of Artificial Intelligence Application in Cardiology. In: 2020 9th Mediterranean Conference on Embedded Computing (MECO) [Internet]. Budva, Montenegro: IEEE; 2020 [cited 2025 Mar 11]. p. 1–5. Available from: <https://ieeexplore.ieee.org/document/9134333/>
14. Somani S, Russak AJ, Richter F, Zhao S, Vaid A, Chaudhry F, et al. Deep learning and the electrocardiogram: review of the current state-of-the-art. *EP Europace*. 2021 Aug 6;23(8):1179–91. SAME AS 2.2!!!!

15. Sánchez De La Nava AM, Atienza F, Bermejo J, Fernández-Avilés F. Artificial intelligence for a personalized diagnosis and treatment of atrial fibrillation. *American Journal of Physiology-Heart and Circulatory Physiology*. 2021 Apr 1;320(4):H1337–47.
16. Usha Kumari Ch, Sampath Dakshina Murthy A, Lakshmi Prasanna B, Pala Prasad Reddy M, Kumar Panigrahy A. An automated detection of heart arrhythmias using machine learning technique: SVM. *Materials Today: Proceedings*. 2021;45:1393–8.
17. Martínez-Sellés M, Marina-Breyse M. Current and Future Use of Artificial Intelligence in Electrocardiography. *JCDD*. 2023 Apr 17;10(4):175.
18. Van Den Eynde J, Lachmann M, Laugwitz KL, Manlhiot C, Kutty S. Successfully implemented artificial intelligence and machine learning applications in cardiology: State-of-the-art review. *Trends in Cardiovascular Medicine*. 2023 Jul;33(5):265–71.
19. Linas Petkevičius, PhD, Mašininio ir giliojo mokymosi sąvokų žodynas, <https://github.com/linas-p/ML-AI-2-LT>
20. Zhu H, Cheng C, Yin H, Li X, Zuo P, Ding J, et al. Automatic multilabel electrocardiogram diagnosis of heart rhythm or conduction abnormalities with deep learning: a cohort study. *The Lancet Digital Health*. 2020 Jul;2(7):e348–57.
21. Kashou AH, Ko WY, Attia ZI, Cohen MS, Friedman PA, Noseworthy PA. A comprehensive artificial intelligence-enabled electrocardiogram interpretation program. *Cardiovascular Digital Health Journal*. 2020 Sep;1(2):62–70.
22. Fiorina L, Maupain C, Gardella C, Manenti V, Salerno F, Socie P, et al. Evaluation of an Ambulatory ECG Analysis Platform Using Deep Neural Networks in Routine Clinical Practice. *JAHA*. 2022 Sep 20;11(18):e026196.
23. Attia ZI, Noseworthy PA, Lopez-Jimenez F, Asirvatham SJ, Deshmukh AJ, Gersh BJ, et al. An artificial intelligence-enabled ECG algorithm for the identification of patients with atrial fibrillation during sinus rhythm: a retrospective analysis of outcome prediction. *The Lancet*. 2019 Sep;394(10201):861–7.
24. Tison GH, Sanchez JM, Ballinger B, Singh A, Olgin JE, Pletcher MJ, et al. Passive Detection of Atrial Fibrillation Using a Commercially Available Smartwatch. *JAMA Cardiol*. 2018 May 1;3(5):409.

25. Guo R, Tian X, Bazoukis G, Tse G, Hong S, Chen K, et al. Application of artificial intelligence in the diagnosis and treatment of cardiac arrhythmia. *Pacing Clinical Electrophis.* 2024 Jun;47(6):789–801.
26. Diaw MD, Papelier S, Durand-Salmon A, et al. AI-assisted QT measurements for highly automated drug safety studies. *IEEE Trans Biomed Eng.* 2023;70:1504-1515. doi:10.1109/tbme.2022.3221339
27. Hermans BJM, Stoks J, Bennis FC, et al. Support vector machinebased assessment of the T-wave morphology improves long QT syndrome diagnosis. *Europace.* 2018;20:iii113-iii119. doi:10.1093/ europace/euy243
28. Bos JM, Attia ZI, Albert DE, et al. Use of artificial intelligence and deep neural networks in evaluation of patients with electrocardiographically concealed long QT syndrome from the surface 12-lead electrocardiogram. *JAMA Cardiol.* 2021
29. Tse G, Lee S, Zhou J, et al. Territory-wide Chinese cohort of long QT syndrome: random survival forest and cox analyses. *Front Cardiovasc Med.* 2021;8:608592
30. Liu CM, Liu CL, Hu KW, et al. A deep learning-enabled electrocardiogram model for the identification of a rare inherited arrhythmia: Brugada syndrome. *Can J Cardiol.* 2022;38:152-159. doi:10.1016/j. cjca.2021.08.014. [published Online First: 20210828]
31. Liao S, Bokhari M, Chakraborty P, et al. Use of wearable technology and deep learning to improve the diagnosis of Brugada syndrome. *JACC Clin Electrophysiol.* 2022;8:1010-1020. doi: 10.1016/j.jacep.2022.05.003
32. Nakamura T, Aiba T, Shimizu W, et al. Prediction of the presence of ventricular fibrillation from a brugada electrocardiogram using artificial intelligence. *Circ J.* 2023;87:1007-1014. doi:10.1253/circj.CJ22-0496. [published Online First: 20221112]
33. Kwon JM, Lee Y, Lee Y, Lee S, Park J. An algorithm based on deep learning for predicting in-hospital cardiac arrest. *J Am Heart Assoc.* 2018;7:e008678
34. Ko WY, Siontis KC, Attia ZI, Carter RE, Kapa S, Ommen SR, et al. Detection of Hypertrophic Cardiomyopathy Using a Convolutional Neural Network-Enabled Electrocardiogram. *J Am Coll Cardiol.* 2020 Feb 25;75(7):722-733. doi: 10.1016/j.jacc.2019.12.030.
35. Gendelman S, Zvuloni E, Oster J, Suleiman M, Derman R, Behar JA. An artificial intelligence-enabled Holter algorithm to identify patients with ventricular tachycardia by

analysing their electrocardiogram during sinus rhythm. *European Heart Journal - Digital Health*. 2024 Jul 29;5(4):409–15.

36. Attia ZI, Kapa S, Yao X, Lopez-Jimenez F, Mohan TL, Pellikka PA, et al. Prospective validation of a deep learning electrocardiogram algorithm for the detection of left ventricular systolic dysfunction. *J Cardiovasc Electrophysiol*. 2019 May;30(5):668-674. doi: 10.1111/jce.13889.
37. Chang TY, Chen KW, Liu CM, Chang SL, Lin YJ, Lo LW, Hu YF, Chung FP, Lin CY, Kuo L, Chen SA. A High-Precision Deep Learning Algorithm to Localize Idiopathic Ventricular Arrhythmias. *J Pers Med*. 2022 May 9;12(5):764. doi: 10.3390/jpm12050764. PMID: 35629186; PMCID: PMC9145898.
38. Rjoob K, Bond R, Finlay D, McGilligan V, Leslie SJ, Rababah A, et al. Machine learning techniques for detecting electrode misplacement and interchanges when recording ECGs: A systematic review and meta-analysis. *J Electrocardiol*. 2020 Sep-Oct;62:116-123. doi: 10.1016/j.jelectrocard.2020.08.013.
39. Choi JH, Song SH, Kim H, Kim J, Park H, Jeon J, et al. Machine Learning Algorithm to Predict Atrial Fibrillation Using Serial 12-Lead ECGs Based on Left Atrial Remodeling. *J Am Heart Assoc*. 2024 Oct;13(19):e034154. doi: 10.1161/JAHA.123.034154.
40. "Late Breaking Clinical Trials: Late Breaking Science: Near-Term Prediction of Life-Threatening Ventricular Arrhythmias using Artificial Intelligence-Enabled Single Lead Ambulatory ECG" [Friday, May 19, 2023, at 3:30 pm CT]
41. Kolk MZH, Ruipérez-Campillo S, Allaart CP, Wilde AAM, Knops RE, Narayan SM, et al. Multimodal explainable artificial intelligence identifies patients with non-ischaemic cardiomyopathy at risk of lethal ventricular arrhythmias. *Sci Rep*. 2024 Jun 27;14(1):14889.
42. Hannun AY, Rajpurkar P, Haghpanahi M, Tison GH, Bourn C, Turakhia MP, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nat Med*. 2019 Jan;25(1):65-69. doi: 10.1038/s41591-018-0268-3.
43. Sau A, Pastika L, Sieliwonczyk E, Patlatzoglou K, Ribeiro AH, McGurk KA, et al. Artificial intelligence-enabled electrocardiogram for mortality and cardiovascular risk estimation: a model development and validation study. *The Lancet Digital Health*. 2024 Nov;6(11):e791–802.

44. Shade JK, Ali RL, Basile D, Popescu D, Akhtar T, Marine JE, et al. Preprocedure Application of Machine Learning and Mechanistic Simulations Predicts Likelihood of Paroxysmal Atrial Fibrillation Recurrence Following Pulmonary Vein Isolation. *Circ: Arrhythmia and Electrophysiology*. 2020 Jul;13(7):e008213.
45. Khamzin S, Dokuchaev A, Bazhutina A, Chumarnaya T, Zubarev S, Lyubimtseva T, et al. Machine Learning Prediction of Cardiac Resynchronisation Therapy Response From Combination of Clinical and Model-Driven Data. *Front Physiol*. 2021 Dec 14;12:753282.
46. Feher A, Bednarski B, Miller RJ, Shanbhag A, Lemley M, Miras L, et al. Artificial Intelligence Predicts Hospitalization for Acute Heart Failure Exacerbation in Patients Undergoing Myocardial Perfusion Imaging. *J Nucl Med*. 2024 May;65(5):768–74.
47. Rosman L, Lampert R, Wang K, Gehi AK, Dziura J, Salmoirago-Blotcher E, et al. Machine Learning-Based Prediction of Death and Hospitalization in Patients With Implantable Cardioverter Defibrillators. *J Am Coll Cardiol*. 2025 Jan 7;85(1):42-55. doi: 10.1016/j.jacc.2024.09.006.
48. Horiuchi Y, Tanimoto S, Latif AHMM, Urayama KY, Aoki J, Yahagi K, et al. Identifying novel phenotypes of acute heart failure using cluster analysis of clinical variables. *International Journal of Cardiology*. 2018 Jul;262:57–63.
49. Katz DH, Deo RC, Aguilar FG, Selvaraj S, Martinez EE, Beussink-Nelson L, et al. Phenomapping for the Identification of Hypertensive Patients with the Myocardial Substrate for Heart Failure with Preserved Ejection Fraction. *J Cardiovasc Transl Res*. 2017 Jun;10(3):275-284. doi: 10.1007/s12265-017-9739-z.
50. Waks JW, Passman RS, Matos J, Reynolds M, Thosani A, Mela T, et al. Intermittent anticoagulation guided by continuous atrial fibrillation burden monitoring using dual-chamber pacemakers and implantable cardioverter-defibrillators: Results from the Tailored Anticoagulation for Non-Continuous Atrial Fibrillation (TACTIC-AF) pilot study. *Heart Rhythm*. 2018 Nov;15(11):1601-1607. doi: 10.1016/j.hrthm.2018.06.027.
51. Attia ZI, Dugan J, Rideout A, Maidens JN, Venkatraman S, Guo L, et al. Automated detection of low ejection fraction from a one-lead electrocardiogram: application of an AI algorithm to an electrocardiogram-enabled Digital Stethoscope. *Eur Heart J Digit Health*. 2022 May 23;3(3):373-379. doi: 10.1093/ehjdh/ztac030.

52. William AD, Kanbour M, Callahan T, Bhargava M, Varma N, Rickard J, et al. Assessing the accuracy of an automated atrial fibrillation detection algorithm using smartphone technology: The iREAD Study. *Heart Rhythm*. 2018 Oct;15(10):1561–5.
53. Tsai YC, Lai SH, Ho CJ, Wu FM, Henrickson L, Wei CC, Chen I, Wu V, Chen J. High Accuracy Respiration and Heart Rate Detection Based on Artificial Neural Network Regression. *Annu Int Conf IEEE Eng Med Biol Soc*. 2020 Jul;2020:232-235. doi: 10.1109/EMBC44109.2020.9175161.
54. Sun, Y., Yang, YY., Wu, BJ. et al. Contactless facial video recording with deep learning models for the detection of atrial fibrillation. *Sci Rep* 12, 281 (2022). <https://doi.org/10.1038/s41598-021-03453-y>
55. Attia ZI, Sugrue A, Asirvatham SJ, Ackerman MJ, Kapa S, Friedman PA, et al. Noninvasive assessment of dofetilide plasma concentration using a deep learning (neural network) analysis of the surface electrocardiogram: A proof of concept study. *PLoS One*. 2018 Aug 22;13(8):e0201059. doi: 10.1371/journal.pone.0201059.
56. Sanchez de la Nava AM, Arenal Á, Fernández-Avilés F, Atienza F. Artificial Intelligence-Driven Algorithm for Drug Effect Prediction on Atrial Fibrillation: An in silico Population of Models Approach. *Front Physiol*. 2021 Dec 6;12:768468. doi: 10.3389/fphys.2021.768468.
57. Petch, J., Nelson, W., Wu, M. et al. Optimizing warfarin dosing for patients with atrial fibrillation using machine learning. *Sci Rep* 14, 4516 (2024). <https://doi.org/10.1038/s41598-024-55110-9>
58. Ghayoor A, Kohan HG. Revolutionizing pharmacokinetics: the dawn of AI-powered analysis. *J Pharm Pharm Sci*. 2024 Feb 16;27:12671. doi: 10.3389/jpps.2024.12671.
59. Serrano R, Feyen DAM, Bruyneel AAN, Hnatiuk AP, Vu MM, Amatya PL, et al. A deep learning platform to assess drug proarrhythmia risk. *Cell Stem Cell*. 2023 Jan 5;30(1):86-95.e4. doi: 10.1016/j.stem.2022.12.002.
60. Pang JKS, Chia S, Zhang J, Szyniarowski P, Stewart C, Yang H, et al. Characterizing arrhythmia using machine learning analysis of Ca²⁺ cycling in human cardiomyocytes. *Stem Cell Reports*. 2022 Aug 9;17(8):1810-1823. doi: 10.1016/j.stemcr.2022.06.005.
61. Aijing Luo, Wei Chen, Hongtao Zhu, Wenzhao Xie, Xi Chen, Zhenjiang Liu, et al. Machine Learning in the Management of Patients Undergoing Catheter Ablation for Atrial

Fibrillation: Scoping Review, Journal of Medical Internet Research, 27, (e60888), (2025).<https://doi.org/10.2196/60888>

62. Zolotarev AM, Hansen BJ, Ivanova EA, Helfrich KM, Li N, Janssen PML, et al. Optical Mapping-Validated Machine Learning Improves Atrial Fibrillation Driver Detection by Multi-Electrode Mapping. *Circ Arrhythm Electrophysiol*. 2020 Oct;13(10):e008249. doi: 10.1161/CIRCEP.119.008249.

63. 2021 ESC Guidelines on cardiac pacing and cardiac resynchronization therapy *Eur Heart J*. 2021; 42:3427-3520

64. Feeny AK, Rickard J, Patel D, Toro S, Trulock KM, Park CJ, et al. Machine Learning Prediction of Response to Cardiac Resynchronization Therapy: Improvement Versus Current Guidelines. *Circ Arrhythm Electrophysiol*. 2019 Jul;12(7):e007316. doi: 10.1161/CIRCEP.119.007316.

65. Tokodi M, Behon A, Merkel ED, Kovács A, Tóser Z, Sárkány A, et al. Sex-Specific Patterns of Mortality Predictors Among Patients Undergoing Cardiac Resynchronization Therapy: A Machine Learning Approach. *Front Cardiovasc Med*. 2021 Feb 25;8:611055. doi: 10.3389/fcvm.2021.611055.

66. Wouters PC, van de Leur RR, Vessies MB, van Stipdonk AMW, Ghossein MA, Hassink RJ, et al. Electrocardiogram-based deep learning improves outcome prediction following cardiac resynchronization therapy. *Eur Heart J*. 2023 Feb 21;44(8):680-692. doi: 10.1093/eurheartj/ehac617.

67. Ginder C, Li J, Halperin JL, Akar JG, Martin DT, Chattopadhyay I, Upadhyay GA. Predicting Malignant Ventricular Arrhythmias Using Real-Time Remote Monitoring. *J Am Coll Cardiol*. 2023 Mar 14;81(10):949-961. doi: 10.1016/j.jacc.2022.12.024.

68. ElRefai M, Abouelasaad M, Wiles BM, Dunn AJ, Coniglio S, Zemkoho AB, et al. Role of deep learning methods in screening for subcutaneous implantable cardioverter defibrillator in heart failure. *Ann Noninvasive Electrocardiol*. 2023 Jan;28(1):e13028. doi: 10.1111/anec.13028.

69. Strik M, Sacristan B, Bordachar P, Duchateau J, Eschalier R, Mondoly P, et al. Artificial intelligence for detection of ventricular oversensing: Machine learning approaches for noise detection within nonsustained ventricular tachycardia episodes remotely transmitted by pacemakers and implantable cardioverter-defibrillators. *Heart Rhythm*. 2023 Oct;20(10):1378-1384. doi: 10.1016/j.hrthm.2023.06.019.

70. Coult J, Yang BY, Kwok H, Kutz JN, Boyle PM, Blackwood J, et al. Prediction of Shock-Refractory Ventricular Fibrillation During Resuscitation of Out-of-Hospital Cardiac Arrest. *Circulation*. 2023 Jul 25;148(4):327-335. doi: 10.1161/CIRCULATIONAHA.122.063651.
71. M U, Sreeja & Philip, Abin & M H, Supriya. (2024). Towards explainability in artificial intelligence frameworks for heartcare: A comprehensive survey. *Journal of King Saud University - Computer and Information Sciences*. 36. 102096. 10.1016/j.jksuci.2024.102096.
72. Harskamp RE, De Clercq L. Performance of ChatGPT as an AI-assisted decision support tool in medicine: a proof-of-concept study for interpreting symptoms and management of common cardiac conditions (AMSTELHEART-2). *Acta Cardiol*. 2024 May;79(3):358-366. doi:10.1080/00015385.2024.2303528.
73. Liu C, Ma Y, Kothur K, et al. BioSignal copilot: leveraging the power of LLMs in drafting reports for biomedical signals. *medRxiv*. 2023.doi:10.1101/2023.06.28.23291916
2023.06.28.23291916
74. Gilbert Jabbour, Alexis Nolin-Lapalme, Olivier Tastet, Denis Corbin, Paloma Jordà, Achille Sowa, et al. Prediction of incident atrial fibrillation using deep learning, clinical models, and polygenic scores, *EurTopean Heart Journal*, Volume 45, Issue 46, 7 December 2024, Pages 4920–4934, <https://doi.org/10.1093/eurheartj/ehae595>
75. Fan Lin, Peng Zhang, Yuting Chen, Yuhang Liu, Dun Li, Lun Tan, et al. Artificial-intelligence-based risk prediction and mechanism discovery for atrial fibrillation using heart beat-to-beat intervals, *Med*, Volume 5, Issue 5, 2024, Pages 414-431.e5, <https://doi.org/10.1016/j.medj.2024.02.006>.
76. Chaddad A, Peng J, Xu J, Bouridane A. Survey of Explainable AI Techniques in Healthcare. *Sensors*. 2023; 23(2):634. <https://doi.org/10.3390/s23020634>
77. Park JW, Kwon OS, Shim J, Hwang I, Kim YG, Yu HT, Kim TH, Uhm JS, Kim JY, Choi JI, Joung B, Lee MH, Kim YH, Pak HN. Machine Learning-Predicted Progression to Permanent Atrial Fibrillation After Catheter Ablation. *Front Cardiovasc Med*. 2022 Feb 16;9:813914. doi: 10.3389/fcvm.2022.813914. PMID: 35252393; PMCID: PMC8890475.
78. Levy AE, Biswas M, Weber R, Tarakji K, Chung M, Noseworthy PA, Newton-Cheh C, Rosenberg MA. Applications of machine learning in decision analysis for dose management for dofetilide. *PLoS One*. 2019 Dec 31;14(12):e0227324. doi: 10.1371/journal.pone.0227324. PMID: 31891645; PMCID: PMC6938356.

79. Dörr M, Nohturfft V, Brasier N, Bosshard E, Djurdjevic A, Gross S, Raichle CJ, Rhinisperger M, Stöckli R, Eckstein J. The WATCH AF trial: SmartWATCHes for detection of atrial fibrillation. *JACC Clin Electrophysiol* 2019;5:199–208.
80. Guo Y, Wang H, Zhang H, Liu T, Liang Z, Xia Y, Yan L, Xing Y, Shi H, Li S, Liu Y, Liu F, Feng M, Chen Y, Lip GYH; MAFA II Investigators. Mobile photoplethysmographic technology to detect atrial fibrillation. *J Am Coll Cardiol* 2019;74:2365–2375.