

VILNIAUS UNIVERSITETAS

MEDICINOS FAKULTETAS

Baigiamasis darbas

**IŠMANIOSIOS TECHNOLOGIJOS ŠIRDIES RITMO SUTRIKIMŲ DIAGNOSTIKOJE IR
GYDYME**

**SMART TECHNOLOGIES IN CARDIAC ARRHYTHMIA DIAGNOSIS AND
TREATMENT**

Donatas Povilaitis, VI kursas, 6gr.

Vilniaus Universiteto Medicinos fakulteto Sveikatos mokslų institutas

Širdies ir kraujagyslių ligų klinika

Darbo vadovas

dr. Germanas Marinskis

Katedros vadovė

dr. Sigita Glaveckaitė

2024-03-25

donatas.povilaitis@mf.stud.vu.lt

TURINYS

1	SANTRAUKA.....	1
2	SUMMARY.....	2
3	SANTRUMPOS	2
4	ĮVADAS.....	3
5	DARBO METODIKA.....	5
6	LITERATŪROS APŽVALGA	6
6.1	Jutiklių veikimo principai.....	6
6.1.1	Fotopletizmografija	6
6.1.1.1	Istorinis kontekstas	6
6.1.1.2	Veikimo principas.....	7
6.1.1.3	Rodmenų interpretavimas.....	8
6.1.2	Širdies elektrinis aktyvumas	10
6.1.2.1	Istorinis kontekstas	10
6.1.2.2	Veikimo principas.....	11
6.2	Rodiklių interpretavimas naudojant automatizuotas priemones.....	12
6.2.1	Širdies ritmo klasifikavimo strategijos	14
6.2.2	Širdies ritmo klasifikavimo iššūkiai	17
7	IŠVADOS.....	18
8	LITERATŪROS SĄRAŠAS.....	20

1 SANTRAUKA

Darbo tikslas: apžvelgti strategijas, naudojamas širdies ritmo sutrikimų atpažinimui informacinių technologijų pagalba.

Vienas iš svarbiausių visuomenės sveikatos uždavinių yra ankstyvos širdies ritmo sutrikimų diagnostikos užtikrinimas, norint mažinti būsimą gyvenimo trukmę, įvertinus neįgalumą, (angl. "Disability Adjusted Life Years") rodiklį (1). „Nereguliariu ritmu“ vadinami sutrikimai Europos Širdies Asociacijos duomenimis sukelia 282 mlrd. eurų nuostolių visoje Europoje, iš jų kiekvienam Lietuvos gyventojui tenka 745 eurai kasmet (2). Išmaniųjų technologijų sistemos atveria naujas galimybes širdies sutrikimų diagnostikos ir pacientų būklės stebėjimo srityje, suteikdamos būdą nuotoliniu būdu užrašyti paciento gyvybinius rodiklius ir automatizuotomis priemonėmis pateikti sveikatingumą skatinančias rekomendacijas. Širdies veiklos rodiklių užrašymas išmaniais nešiojamais įrenginiais yra paremtas fotopletizmografijos ir elektrokardiografijos jutikliais.

Aptariamas šių sensorių veikimo principas, pranašumai ir apribojimai. Atlikus literatūros apžvalgą naudojantis „PubMed“, „Scopus“, „Web of Science“ duomenų bazėmis atrinkta 17 pilnos prieigos publikacijų, vertinančių širdies aritmijų klasifikavimo metodikas naudojant dirbtiniu intelektu pagrįstus algoritmus. Remiantis publikacijose aprašytais duomenų apdorojimo būdais bei algoritmų struktūros ypatumais, pateikiamas palyginimas su industrijos naujovėmis; suformuluojamos išvados ir rekomendacijos, susijusios su širdies aritmijų klasifikacijos, naudojant išmaniąsias technologijas, pažangą.

Raktažodžiai: širdies ritmo sutrikimai, fotopletizmografija, elektrokardiografija, klasifikavimo algoritmai, dirbtinis intelektas.

2 SUMMARY

Thesis objective: To review strategies used for the recognition of irregular heart rhythms with the aid of information technology.

One of the most important public health tasks is to ensure early diagnosis of heart rhythm disorders to reduce the Disability Adjusted Life Years (DALY) index (1). Disorders known as "irregular rhythms," according to the European Heart Association, account for 282 billion euros across Europe, with each Lithuanian resident incurring a cost of 745 euros annually (2). Smart technology systems unlock new possibilities in the field of heart disorder diagnostics and patient condition monitoring, providing a way to remotely record vital signs and offer health-promoting recommendations through automated means. The recording of heart activity indicators using smart wearable devices is based on photoplethysmography and electrocardiography sensors. This thesis discusses the operating principles of these sensors, their advantages, and limitations. After conducting a literature review using databases such as PubMed, Scopus, and Web of Science, 17 open-access publications were selected that evaluate classification methodologies for heart arrhythmias using artificial intelligence-based algorithms. Based on the data processing methods and algorithm structures described in these publications, a comparison is made with industry innovations; conclusions and recommendations related to the progress in heart arrhythmia classification using smart technologies are formulated.

Keywords: heart rhythm disorders, photoplethysmography, electrocardiography, classification algorithms, artificial intelligence.

3 SANTRUMPOS

EKG – elektrokardiografija

FPG – fotopletizmografija

ŠRV – širdies ritmo variabilumas

DALY - būsimą gyvenimo trukmę, įvertinus neįgalumą

4 ĮVADAS

Širdies ir kraujagyslių ligų sritis paskutinį dešimtmetį yra aktyvus tyrimų objektas IT technologijų srityje. Bandoma integruoti paskutines technologijų naujienas į kasdienį žmonių gyvenimą, tokiu būdu didinant savo sveikatos suvokimo lygį ir mažinant visuotinę kardiovaskulinių sutrikimų sukeltą naštą. „Nereguliariu ritmu“ vadinami sutrikimai, tokie kaip prieširdžių virpėjimas, skilvelinė tachikardija bei kiti ritmo sutrikimai prisideda prie bendros širdies ir kraujagyslių ligų sukeltos naštos. Šie sutrikimai gali sukelti rimtų komplikacijų, pavyzdžiui, širdies nepakankamumą arba insultą, todėl ankstyva diagnostika ir prevencija yra vienas iš svarbiausių visuomenės sveikatos palaikymo uždavinių. Europos institucijos identifikuoja šios problemos svarbą ir įvardija tikslą mažinti būsimojo gyvenimo trukmę, įvertinus neįgalumą (angl. „Disability Adjusted Life Years“) (1) bei širdies ritmo sutrikimų naštą, kuri Europos Širdies Asociacijos duomenimis apima 282 mlrd. eurų visoje Europoje, iš jų kiekvienam Lietuvos gyventojui tenka 745 eurai kasmet (2).

Tradiciskai, aritmijų diagnostika ir stebėjimas buvo parentas diagnostinėmis priemonėmis ir metodais taikomais gydymo įstaigose. Šie metodai, nors ir yra efektyvūs, tačiau dažniausiai suteikia tik momentinius duomenis apie paciento būklę ir tokiu būdu gali atidėti diagnozės nustatymo laiką ir gydymo skyrimo pradžią. Retrospektyviais skaičiavimais, Jungtinėse Amerikos Valstijose nediagnozuoto prieširdžių virpėjimo atvejai sudarė 11 proc. visų prieširdžių virpėjimo atvejų, 93 proc. kurių atitiko prevencinės terapijos skyrimo reikalavimus (3). Išmaniųjų technologijų, tokių kaip išmanieji nešiojami laikrodžiai, mobiliosios sveikatos programėlės, nuotolinio stebėjimo sistemos, bei naujų dirbtinio intelekto algoritmų atsiradimas iš pagrindų keičia širdies sutrikimų diagnostikos paradigmą suteikiant naujus būdus užtikrinti nepertraukiamą bei neinvazyvų sveikatos būklės stebėjimą, kas gali padėti sumažinti nediagnozuotų prieširdžių virpėjimo atvejų skaičių. Išmanūs nešiojami įrenginiai, aprūpinti jutikliais, gebančiais aptikti širdies elektrinį aktyvumą, širdies susitraukimų dažnį bei kitus gyvybinius rodiklius, yra šių permainų priešakyje. Šios technologijos ne tik leidžia įvertinti rodmenis nedelsiant, bet ir įgalina žmones aktyviai domėtis ir stebėti savo sveikatos būklę, kas gali lemti geresnius sveikatos priežiūros rezultatus bei geresnę gyvenimo kokybę. Dirbtinio intelekto panaudojimas dar labiau didina išmaniųjų įrenginių potencialą, siūlydamas algoritmus, leidžiančius tiksliai aptikti ir klasifikuoti aritmijas, pateikti ligos eigos prognozę ir personalizuotas gydymo rekomendacijas.

Šioje literatūros apžvalgoje analizuojama esama išmaniųjų technologijų, naudojamų širdies ritmo atpažinimui ir klasifikacijai, būklė bei ateities potencialas užtikrinant ankstyvą diagnostiką ir gydymą. Įvertinant konvencinių algoritmų bei dirbtiniu intelektu pagrįstų algoritmų pajėgumus

analizuojant nešiojamų įrenginių užrašytus biologinius rodmenis, pateikiamas jų efektyvumo vertinimas, susiję iššūkiai bei tolimesnės tobulėjimo galimybės.

Darbo tikslas: Apžvelgti išmaniąsias nešiojamas technologijas, naudojamas širdies ritmo sutrikimų diagnostikoje ir gydyme.

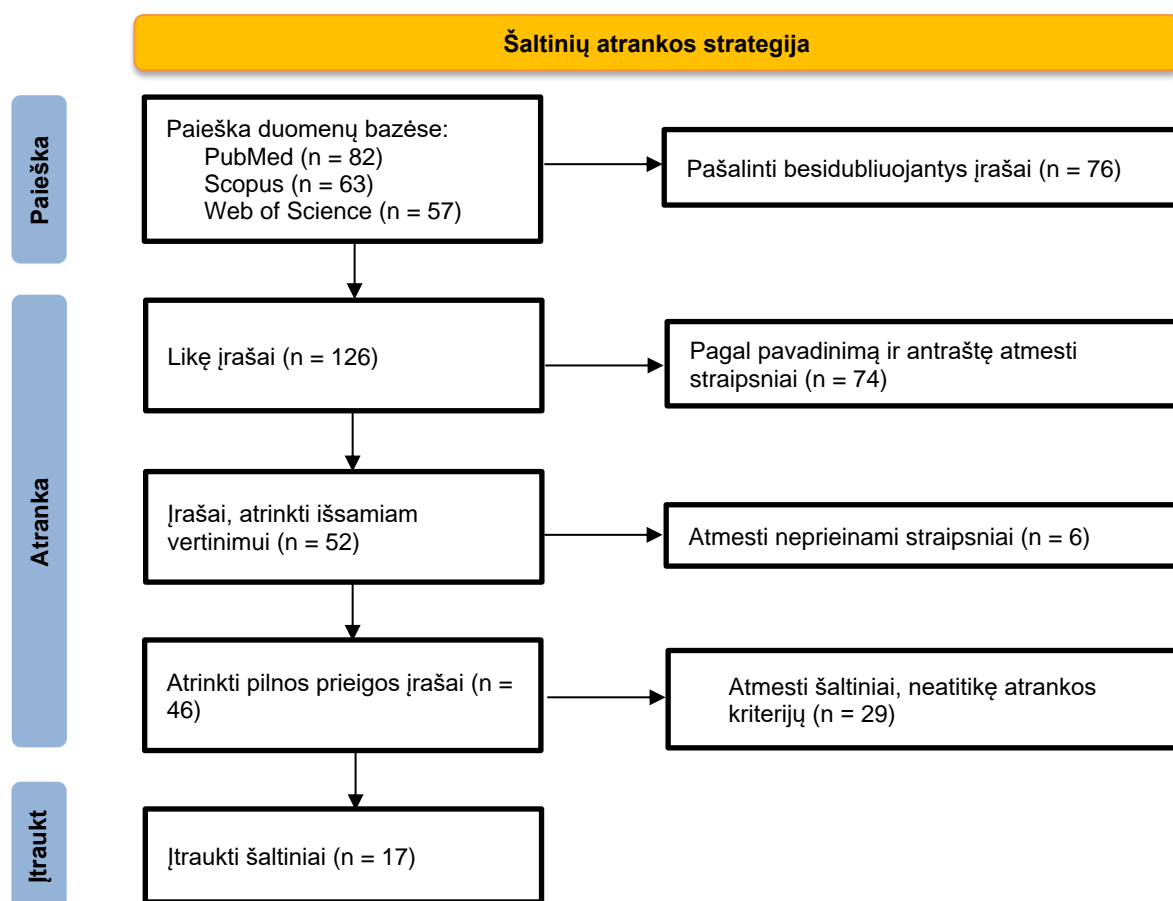
Uždaviniai:

- Identifikuoti išmaniąsias nešiojamas technologijas, naudojamas širdies ritmo sutrikimų diagnostikoje ir gydyme
- Įvertinti išmaniųjų technologijų efektyvumą, diagnozuojant širdies ritmo sutrikimus, bei įvardinti iššūkius, su kuriais susiduriama.
- Išnagrinti išmaniųjų technologijų prieinamumą tikslinės grupės populiacijoje.

5 DARBO METODIKA

Nuo 2024 metų sausio iki 2024 metų kovo mėnesio buvo atlikta tikslinė paieška populiariausiose duomenų bazėse – „PubMed“, „Scopus“, „Web of Science“. Elektroniniai paieškos įrašai sutvarkyti naudojantis Zotero programine įranga. Tarp papildomai pritaikomų filtrų pasirinkta turinio kalba – Anglų, bei darbų naujumas – ne senesni nei 5 metai. Naudojantis raktažodžių kombinacija „(Smart Technologies) AND (Cardiac arrhythmia)“ buvo rasti 202 rezultatai.

Straipsnių įtraukimo į literatūros apžvalgą kriterijai: vertinamas kompiuterinių algoritmų panaudojimas apdorojant fotopletizmografijos ir elektrokardiografijos jutiklių duomenis; pilnos prieigos straipsniai; straipsniai anglų kalba. Išsami atrankos schema pavaizduota 1 pav.



Pav. 1 Šaltinių atrankos strategija

Šaltinių atranka atlikta keturiais etapais. Pirmo etapo metu automatizuotomis priemonėmis pašalinti 76 besidubliuojantys įrašai. Likusiems 126 atlikta pirminė antro etapo peržiūra: remiantis informacija, pateikta antraštėje, atmesti 74 straipsniai dėl neatitikimo atrankos kriterijams. Tarp likusių 52 rezultatų, 5 šaltiniai atmesti dėl apribotos prieigos. Atlikus išsamią šaltinių peržiūrą 17 darbų įtraukt į literatūros apžvalgą.

6 LITERATŪROS APŽVALGA

6.1 Jutiklių veikimo principai

6.1.1 Fotopletizmografija

Fotopletizmografija (FPG) yra neinvazyvus, optiniais principais pagrįstas būdas išmatuoti kraujo tūrio pokyčius žmogaus audiniuose. Fotopletizmografijos įrenginiai dažniausiai sudaryti iš paprastų ir nebrangių komponentų – šviesos šaltinio ir fotodetektoriaus – kad išmatuotų šviesos laidumo kitimus, sukeltus pulsuojančio kraujo tūrio kintamumo metu. Ši technologija naudojama tiek medicininėje, tiek vartotojams prieinamoje įrangoje, tokioje kaip pulsoksimetrai, nešiojami laikrodžiai, aktyvumo matuokliai. Pagrindinė technologijos funkcija yra širdies susitraukimų dažnio, oksigenacijos ir kitų širdies veiklos parametrų matavimas. FPG metodo paprastumas ir prieinamumas leidžia jį naudoti nepertraukiamam realaus laiko širdies funkcijos rodiklių stebėjimui ir pateikti įžvalgas apie širdies dažnio kintamumą, kraujospūdį ir periferinės kraujotakos būklę. Šio sensoriaus panaudojimų sritis plečiasi už klinikinės praktikos ribų – pritaikymai randami sporto medicinoje ir netgi miego kokybės analizei.

6.1.1.1 Istorinis kontekstas

Fotopletizmografijos tyrimo ištakos prasideda nuo bandymų užfiksuoti žmogaus biologinius rodiklius naudojant optinius duomenis. Pirmieji FPG technologijos tyrimai buvo pagrįsti pamatinėmis žiniomis apie cirkuliuojančio kraujo tūrio kraujagyslėse pokyčius kiekvieno širdies susitraukimo metu. Volumetriniai pokyčiai keičia audinių savybes ir šį pokytį galima užregistruoti naudojantis optiniais įrenginiais taip gaunant FPG signalą.

1937 metais Alrick Hertzman tyrimais įrodė, kad įmanoma įvertinti kraujo tūrio audiniuose pokyčius matuojant šviesos laidumo per nosies pertvarą skirtumus laike. Tyrėjo įvardintas fotoelektrinės pletizmografijos metodas pagrįstas tuo, kad audinių šviesinis laidumas keičiasi pro audinius tekant skirtingam kraujo kiekiui, kas leidžia fotoelektrinio sensoriaus pagalba aptikti šviesos laidumo pokyčius (4). Ši demonstracija įrodė, kad fotoelektrinė pletizmograma yra efektyvus būdas matuoti kraujo tūrio, tekančio pro įvairius audinius, pokyčius dinamikoje.

Vėlyvaisiais 1960 metais John A. Pollard savo darbuose pristatė pagerintą jutiklio dizainą, kuris teikė labiau informatyvius duomenis ir buvo pritaikytas nuolatiniam stebėjimui (5). Pollardo sukurtas sensorius pasižymėjo aukštu jautrumu ir mažesniu triukšmu, kas leido tiksliau fiksuoti kraujo tūrio pokyčius audiniuose realiu laiku. Ši inovacija davė pradžią naujoms galimybėms stebėti paciento būklę. Šiais laikais, FPG monitoravimas yra pagrįstas sudėtingais šviesos laidumo matavimais, moderniais jutikliais ir skaitmeniniais apdorojimo būdais, kurie didina tikslumą ir

patikimumą. Modernūs FPG įrenginiai yra kompaktiški, kas leidžia juos integruoti į išmaniuosius įrenginius ir įgalina nuolatinį stebėjimą.

Kitas FPG principų pritaikymas – pulsoksimetrija – gavo pradžią 1935 metais, kai vokiečių mokslininkas Karl Matthes aprašė metodą, kaip naudojant dviejų dažnių šviesos bangas galima išmatuoti kraujo prisotinimą deguonimi (6). Tačiau šie pirmieji įrenginiai reikalavo sudėtingos kalibracijos ir jų rodmenys turėjo daugelį artefaktų dėl pulsacijų, keliamų širdies veiklos. 1972 Japonų klinicisto Takuo Aoyagi darbai sukėlė perversmą šioje srityje – vietoj bandymų pašalinti širdies veiklos sukeltus artefaktus, jis atrado būdą apsakaičiuoti kraujo oksigenaciją matuojant šviesos absorbcijos rodmenų santykį skirtingų pulsuojančių arterinio kraujo tūrio pokyčių metu (7). Šiuo metu pulsoksimetrija yra vienas iš labiausiai naudojamų diagnostinių tyrimų, paplitimu prilyginamų EKG. Jo panaudojimo sritys apima nuolatinį pacientų stebėjimą ligoninėse, intensyviosios terapijos skyriuose, bei bendros būklės vertinimą pacientų namų aplinkoje, įvairių susirgimų metu, taip pat ir su širdies funkcija susijusių būklių vertinimui.

6.1.1.2 Veikimo principas

Dauguma FPG įrenginių naudoja keletą dažnių šviesos bangas, dažniausiai naudojamos yra matomojo ir infraraudonojo spektro šviesos bangos. Šviesa yra skleidžiama iš šviesos diodo ir absorbuojama fotodetektoriaus. Šviesą skleidžiančio diodo ir fotodetektoriaus konfigūracija gali būti dvejopa: pralaidumo ir atspindžio. Šviesos pralaidumą matuojantis jutiklis yra priešais šviesos diodą, kitoje audinio pusėje, ir dažniausiai naudojamas matuoti šviesos laidumui pro rankos piršto galiuką arba ausies spenelį. Atspindžio FPG sensoriai turi abu komponentus išdėstyti šalia vienas kito, toje pačioje audinio pusėje ir naudojami matuoti atspindėtos šviesos intensyvumą ant riešo, kaktos ar liemens. Pastarieji yra labiau paplitę tarp nešiojamų išmaniųjų įrenginių, tokių kaip laikrodžiai ar apyrankės, o pralaidumą matuojantys įrenginiai naudojami klinikinėje praktikoje (8,9).

Fotodetektoriaus absorbuotos šviesos intensyvumas, priklausomai nuo šviesos dažnio ir kraujo tūrio audiniuose, skiriasi. Šviesos bangos dažnio pasirinkimas priklauso nuo kraujo komponentų – vandens, melanino ir hemoglobino – gebėjimo absorbuoti tam tikras bangas. Vanduo geriausiai absorbuoja infraraudonojo spektro šviesą, bet yra pralaidus matomojo spektro šviesai (10).

Melaninas pasižymi trumpųjų bangų absorbcija, tokių kaip ultravioletinio spektro bangos (11).

Matomojo spektro šviesos absorbcijai labiausiai daro įtaką oksihemoglobino ir deoksihemoglobino santykis kraujyje, todėl šio spektro šviesa naudojama deguonies prisotinimui vertinti (12).

Infraraudonojo spektro šviesa naudojama kaip stabilus atskaitos taškas pulso bangai vertinti, kadangi jos absorbcija kinta nuo vandens kiekio audiniuose ir audinių tūrinių pokyčių (13).

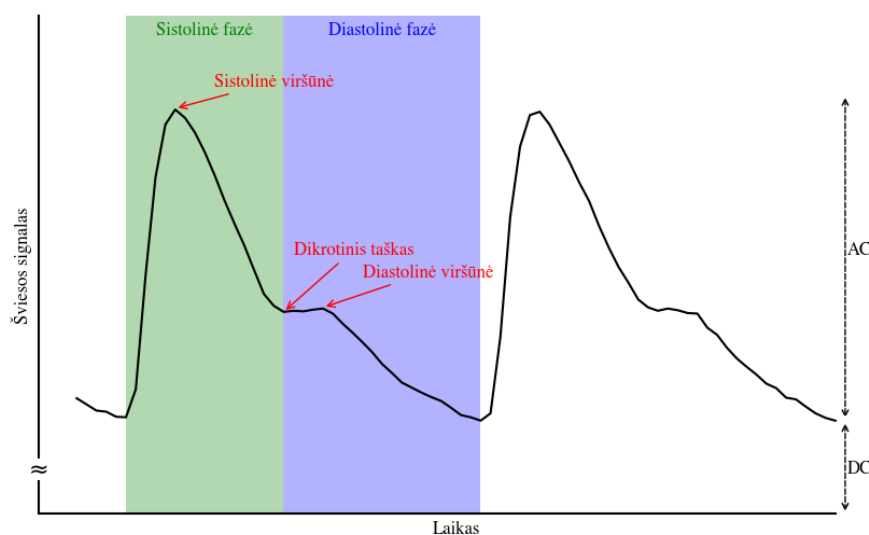
Nors ir literatūroje nėra vienareikšmiškai sutinkama, kokios yra FPG signalo sudėtinės dalys, tačiau pulsinė banga, prasidedanti širdyje ir plintanti pro visą kraujagyslių sistemą, teoriškai turi savyje informacijos apie nervinį, širdinį ir respiracinį kraujagyslių sistemos reguliavimą. Širdies pulso signalo apdorojimui ir išvadų pateikimui yra svarbus kokybiškas signalo užrašymas. FPG kokybė gali priklausyti nuo tam tikrų faktorių, tokių kaip melanino kiekis odoje (14,15), KMI (16), audinių perfuzija, amžiaus sukkelto arterijų sienelių sustorėjimo, lyties (17), ar net prakaito liaukų tankio odoje. Vienas iš netiesiogiai FPG signalą veikiančių veiksnių yra odos temperatūra. Žemėjant odos temperatūrai, dėl autonominės nervų sistemos aktyvumo, susitraukia odos kraujagyslės, kas mažina bendrą audinių perfuziją. Šis efektas labiau stebimas matuojant pirštų galų perfuziją, kadangi šios kūno dalys pasižymi tankesniu alfa-adrenoreceptorių išsidėstymu (18,19).

Kitas veiksnys, darantis įtaką FPG signalo kokybei yra šviesos išsisklaidymas dėl sąveikos su odos komponentais, tokiais kaip melaninas, kolageno skaidulos, lipidų sankaupos. Aukštas šviesos bangų išsisklaidymo lygis kelia sunkumus išgaunant pastovius duomenis tarp skirtingų odos tipų, dėl ko apsunkėja rodmenų vertinimas. Regimosios šviesos bangos – mėlyna (450–495 nm), žalia (495–570 nm), raudona (620–750 nm), infraraudonoji (nuo 750 nm) – vertinamos pagal jų skvarbos savybes ir gebėjimą būti absorbuotoms hemoglobino. Trumpesnės bangos pasižymi didesniu hemoglobino absorbcijos lygiu, tačiau jos taip pat linkusios sparčiau išsisklaidyti, dėl ko turi blogesnes audinių skvarbos savybes ir blogesnę signalo raišką. Stebima, jog didžiausia raiška, nepriklausomai nuo odos tipo, išgaunama naudojant žalios spalvos šviesos diodus. Mėlyna šviesa – teoriškai pranašesnė registruojant hemoglobino koncentracijos pokyčius – pasižymi žemesne raiška dėl signalo artefaktų ir blogos skvarbos pro audinius (20,21).

6.1.1.3 Rodmenų interpretavimas

FPG fotoelektrinis signalas gaunamas išmatuojant pro audinį prasiskverbusios šviesos kiekį. Šis signalas yra sudarytas iš dviejų komponentų – dinaminio (AC), atitinkančio šviesos skvarbą pro kintančią arterinio kraujo dalį, ir statinio (DC), atitinkančio šviesos skvarbą pro audinius, veninį kraują bei nekintančią arterinio kraujo dalį. Klinikinėje praktikoje pateikiami FPG rodmenys atitinka infraraudonojo spektro bangų signalą ir, dažniausiai, yra invertuoti, kad atrodytų kaip arterinio spaudimo banga. Širdies kairiojo skilvelio susitraukimo metu, kraujas išstumiamas iš širdies ir teka pro kraujagyslių sistemą – tai vadinama sistoline faze. FPG signalo schemeje (2 pav.) šią fazę galima matyti nuo teigiamo nuolydžio pradžios iki „Dikrotinio taško“, kuris žymi aortos vožtuvo užsidarymą ir ribą tarp sistolinės ir diastolinės fazės. Diastolinės fazės metu kraujo tūris, arterijų spindis ir hemoglobino koncentracija mažėja, dėl ko didėja šviesos laidumas ir fotodetektorius aptinka stipresnį signalą. Antras pikas, pažymėtas kaip „Diastolinė viršūnė“

apibūdina mažiausią šviesos laidumo momentą po dikrotinio taško. Šis laidumo pokytis stebimas dėl kraujo tūrio padidėjimo po aortos vožtuvo užsidarymo (22,23).



2 pav. FPG signalo schema (24)

Nors ir pagrindinis FPG panaudojimas klinikinėje praktikoje šiuo metu yra pulsoksimetrija, tačiau šis būdas puikiai tinka vertinti širdies ritmo taisyklingumą ir pastebėti aritmijas (25). Sattar nustatė, kad bendras FPG specifškumas diagnozuojant prieširdžių virpėjimą lyginant su elektrokardiograma sudaro 93 proc. (26). Tai rodo, kad fotopletizmografija gali būti patogesnė alternatyva tradicinei elektrokardiografijai ankstyvai prieširdžių virpėjimo diagnostikai.

Kitas FPG išvestinis matas, teikiantis įžvalgų apie asmens sveikatą yra širdies ritmo variabilumas (ŠRV). ŠRV apibūdina laiko intervalų tarp širdies susitraukimų kintamumą. Auksinis standartas ŠRV nustatymui yra aukštos raiškos EKG. FPG metodas yra paremtas širdies sukeltos pulso bangos matavimu. Lyginant su EKG, šis metodas širdies ritmą atspindi netiesiogiai, o vertinant širdies sukeltos pulso bangos savybes. Natūralu, kad pulso banga, priklausomai nuo vietos, kur ji yra matuojama, bus atitinkamai uždelsta, ir, galimai, paveikta kitų faktorių, tokių kaip periferinių kraujagyslių pasipriešinimas ar obstrukcijos. Įvertinus šiuos faktorius, aptikta, kad, vis dėlto, FPG ir EKG metodų ŠRV nustatyti sutapimo lygis yra pakankamai didelis (27,28), dėl ko šis būdas gali būti naudojamas kaip alternatyva EKG.

ŠRV rodmuo yra netiesioginis autonominės nervų sistemos veiklos rodiklis ir gali būti koreliuojamas su organizmo gebėjimu palaikyti homeostazę, fiziniu aktyvumu, žmogaus emocine būkle bei streso lygiu. Ženkliai mažesnis širdies ritmo variabilumas ramybėje yra susijęs su nerimo sutrikimais, potrauminio streso sutrikimu, panikos sutrikimu, generalizuoto nerimo sutrikimu ir socialinio nerimo sutrikimu (29,30). Nepaisant šių radinių, faktoriai, darantys įtaką ŠRV nėra iki galo suprasti. Norint pateikti išvadas apie žmogaus sveikatą remiantis ŠRV analizės duomenimis, yra svarbu įvertinti daugelį veiksnių, susijusių tiek su fiziologiniais žmogaus parametrais, tiek su emocine būkle. ŠRV duomenų interpretavimas turi būti atliktas holistiškai, integruojant visapusišką

žmogaus organizmo rodmenų analizę, kas sudaro iššūkius, norint pritaikyti šį rodiklį naudojimui nekomerciniuose įrenginiuose.

FPG signalas gali būti naudojamas ne tik širdies veiklos monitoravimui, bet, potencialiai, ir visos kardiovaskulinės sistemos būklei vertinti, taip pat ir arterinio kraujo spaudimo matavimui. Tyrimai nurodo, kad FPG gali tapti alternatyva tradiciniams AKS vertinimo metodams ir užtikrinti nuolatinį, realaus laiko bei neinvazyvų kraujospūdžio stebėjimą (31). Tačiau kraujospūdžio matavimas naudojant FPG technologija kelia didelius iššūkius, tokius kaip judesio artefaktų šalinimas, rodmenų standartizavimas, poreikis kalibruoti sensoriaus rodmenis, kurie riboja šio metodo efektyvumą (32).

6.1.2 Širdies elektrinis aktyvumas

Elektrokardiograma (EKG) yra pirminis diagnostinis metodas, skirtas nustatyti širdies ritmo pokyčius ir analizuoti širdies elektrinį aktyvumą. Klinikinėje praktikoje dažniausiai taikomas momentinis EKG užrašymas, kuris fiksuoja ritmo pakitimus tuo metu, kai jie įvyksta. Tačiau šis metodas yra mažiau jautrus ankstyvose ligos stadijose, kai ritmo sutrikimai yra nepastovūs ir praeina savaime, todėl sunku patvirtinti diagnozę. Norint užfiksuoti šiuos retus ritmo sutrikimus, naudojamas Holterio monitorius arba implantuojamas EKG registravimo prietaisas. Šios technologijos leidžia nuolat registruoti EKG duomenis ir aptikti laikinas aritmijas, kurios gali likti nepastebėtos atliekant standartinę testą. Tačiau šie metodai irgi turi trūkumų – šių prietaisų skyrimas reikalauja pagrįsto specialisto sprendimo, kas apriboja šios technologijos pasiekiamumą; prietaisai nėra pigūs ir patogūs naudoti (33).

Tradiciniai metodai, nors ir laikomi auksiniu standartu širdies aritmijų diagnostikoje, turi trūkumų susijusių su realaus laiko duomenų fiksavimu ir nuolatiniu stebėjimu, kas riboja ankstyvos diagnostikos galimybes. Elektrokardiogramos davikliai gali būti integruojami į išmaniuosius nešiojamus prietaisus, norint padaryti šį tyrimą labiau prieinamą plačiajai visuomenei. Išmaniosios technologijos, tokios kaip išmanieji laikrodžiai su EKG funkcija, demonstruoja didelį potencialą pašalinti šiuos apribojimus ir suteikti žmonėms galimybę nuolat stebėti savo širdies veiklą, padedant tiksliai identifikuoti širdies ritmo sutrikimus. Tačiau, norint užtikrinti šio metodo paplitimą, turi būti įvertintas tokiu būdu pateiktų išvadų tikslumas ir patikimumas.

6.1.2.1 Istorinis kontekstas

Širdies aritmijos diagnostikos ir gydymo evoliucijos šaknys prasideda vėlyvame XIX amžiuje, Londone, Šv. Marijos ligoninėje, kur britų fiziologas Augustas Valeris (angl. August Waller) pirmą kartą užrašė širdies elektrinį aktyvumą naudojant gyvsidabrio kapiliarinį elektrometrą ir pirmą kartą panaudojęs terminą „elektrokardiograma“. Matavimai buvo žemos raiškos ir leido stebėti tik du

iškreiptus įlinkius, o prieširdžių potencialai nebuvo stebimi (34). Dėl pažangos kapiliarinio elektrometro technologijoje, taip pat pritaikius matematinius skaičiavimus elektrinio aktyvumo analizėje, Olandų mokslininkas Vilemas Einthovenas (angl. Willem Einthoven) sugebėjo tiksliai užregistruoti širdies elektrinį aktyvumą. Einthovenas įvedė šiais laikais įprastą P, Q, R, S nomenklatūrą bei yra laikomas moderniosios EKG pradininku (35). 1905 metais Einthovenas pristatė metodą, kuriuo ligoninėje užrašyti EKG duomenys buvo telefono linija persiųsti į jo nutolusią laboratoriją analizei, demonstruojant pirmąsias telemedicinos užuomazgas. Už šiuos atradimus 1924 metais (praėjus dviem metams po Valerio mirties) Vilemas Einthovenas gavo Nobelio premiją fiziologijos ir medicinos srityje.

Nepaisant paties EKG tyrimo atradėjo Augusto Valerio įsitikinimo, jog šis tyrimas neturi pakankamai klinikinės reikšmės ir nėra tinkamas vertinti ar diagnozuoti su širdies elektriniu aktyvumu susijusius sutrikimus, tolesni tyrimai parodė, kad EKG tyrimo metu galima registruoti patologinius pokyčius, tokius kaip ekstrasistolės, prieširdžių virpėjimas, Hiso pluošto kojųčių blokada (36,37). Tolesnė pažanga širdies elektrinio aktyvumo diagnostikoje, tokia kaip modernių EKG jutiklių atsiradimas, signalo stiprintuvai, išmanūs apdorojimo algoritmai nulėmė tai, kad šiuo metu elektrokardiograma yra vienas iš pagrindinių ir labiausiai paplitusių tyrimų širdies sutrikimų diagnostikoje.

6.1.2.2 Veikimo principas

Elektrokardiograma yra medicininis tyrimas, kuris registruoja širdies elektrinį aktyvumą tam tikru metu naudojant prie žmogaus kūno pritvirtinamus elektrodus. Šie elektrodai fiksuoja mažiausius elektrinio potencialo svyravimus odoje, kurie kyla dėl širdies raumens depoliarizacijos kiekvieno susitraukimo metu. Šis susitraukimas yra sukeltas elektrinių impulsų, generuojamų pačioje širdyje esančių struktūrų: normaliu atveju širdies ritmo elektrinis impulsas prasideda sinusiniame mazge, kuris yra išdėstytas dešiniajame prieširdyje. Sinusinio mazgo ląstelių depoliarizacija sukelia prieširdžių raumenų ląstelių depoliarizaciją, kas atitinka „P“ dantelį elektrokardiogramoje. Impulsas keliauja pro atrioventrikulinį mazgą, kur yra uždelsiamas, kad leisti prieširdžiam užbaigti susitraukimą ir išstumti juose esantį kraują į skilvelius. Skilvelių susitraukimas yra sukiamas, kai impulsas pradeda sklisti Hiso pluošto šakomis ir Purkinje skaidulomis. Šis aktyvumas matomas kaip „QRS“ kompleksas EKG. Galiausiai, po sėkmingo susitraukimo, EKG fiksuojama skilvelių repoliarizacija ir pasiruošimas sekančiam susitraukimui – tai matoma kaip „T“ banga.

Klinikinėje praktikoje EKG užrašoma naudojant 10 elektrodų, kad sukurti 12 širdies elektrinio aktyvumo pjūvių: tai apima šešias galūnių derivacijas (I, II, III, aVR, aVL ir aVF), bei šešias krūtinines derivacijas (V1-V6). Taisyklingas elektrodų išdėstymas yra labai svarbus norint teisingai užrašyti EKG – pavyzdžiui, klaidingai išdėstyti V1 ir V2 elektrodai gali būti klaidingos miokardo

infarkto ar kairiosios Hiso pluošto kojų blokados diagnozės priežastimi (38). Nors ir klinikinėje praktikoje klaidingas elektrodų išdėstymas yra sąlyginai retas (39), tačiau tai iliustruoja galimus iššūkius, su kuriais gali susidurti ne ligoninės aplinkoje naudoti skirtų EKG sensorių gamintojai. Vartotojams skirti EKG įrenginiai, kaip antai išmanieji laikrodžiai ar sporto apyrankės dažnai naudojami nekontroliuojamose aplinkose ir gali būti naudojami be profesionalų priežiūros, todėl yra didesnė tikimybė, kad elektrodų išsidėstymas gali būti netinkamas. Tai gali lemti netikslius matavimus ir potencialiai klaidingas savidiagnostikos prielaidas.

Kiekvienas EKG užrašymo prietaisas turi būti kalibruojamas, kad užtikrinti taisyklingą širdies elektrinio aktyvumo mastelį. Standartiškai, vienas milivoltas (mV) turi atitikti dešimt milimetrų (mm) EKG popieriaus aukštyje, kad specialistai galėtų teisingai nustatyti širdies ritmą, laidumą ir kitus svarbius parametrus. Tai yra svarbu norint išvengti klaidingų interpretacijų, kurios gali kilti dėl neteisingo signalo stiprumo arba formos atvaizdavimo. EKG jutiklių integracija su nešiojamais išmaniaisiais įrenginiais, tokiais kaip išmanieji laikrodžiai ir sporto apyrankės, kelia papildomų iššūkių norint užrašyti kokybišką signalą. Šių įrenginių kalibravimas ir tikslumas yra ypač svarbūs, nes jie dažnai naudojami nekontroliuojamose aplinkose dėl ko gali kilti klaidų, susijusių su judesiais ar netinkamu dėvėjimu. Ousaka įvertino į audinių su EKG jutikliais gebėjimą nepertraukiamai fiksuoti atletų, dalyvaujančių maratone, rodmenis – adekvati raiška gauta tik 65% bėgikų (40). Faktoriai, galėję daryti įtaką užrašymui buvo intensyvios fizinės veiklos keliami judesiai, prakaitavimas, EKG jutiklių netaisyklingas priglūdimas prie kūno. Šie atradimai pabrėžia būtinybę tobulinti nešiojamų išmaniųjų technologijų dizainą ir funkcionalumą, kad būtų užtikrintas aukštas duomenų kokybės lygis net ir ekstremalios veiklos sąlygomis.

EKG užrašymą gali paveikti įvairūs išoriniai bei vidiniai veiksniai, kurie iškraipo širdies elektrinį aktyvumą. Tokie veiksniai yra elektromagnetinis triukšmas iš įvairių šalinių, pavyzdžiui, mobiliojo telefono signalai ar medicininė įranga, esanti netoliese. Taip pat svarbus yra paciento judėjimas ar drebinimas, kuris gali sukelti artefaktus, trikdžius registruojant EKG signalą. Vidiniai veiksniai, galintys paveikti EKG signalo kokybę ir interpretavimo taisyklingumą yra paciento širdies ir kraujagyslių sistemos būklė, elektrolitų pusiausvyros sutrikimai, raumenų tremoras. Siekiant sumažinti šių veiksnių įtaką užrašymo kokybei, būtina EKG užrašyti ramioje aplinkoje, užtikrinant tinkamą paciento paruošimą ir elektrodų padėtį.

6.2 Rodiklių interpretavimas naudojant automatizuotas priemones

EKG ir FPG rodiklių interpretavimas rankiniu būdu yra daug laiko ir dėmesio reikalaujantis darbas, todėl siekiama atrasti būdą greitai ir efektyviai įvertinti šiuos rodiklius bei pateikti išvadas. Šių technologijų integravimas į kasdien naudojamus įrenginius, pavyzdžiui, išmaniuosius telefonus ir nešiojamus sveikatos stebėjimo prietaisus, atveria galimybes kiekvienam asmeniui aktyviai

dalyvauti savo sveikatos priežiūroje, tuo pačiu sukuria didelę duomenų bazę, kurią įvertinti rankiniu būdu reikėtų skirti daug žmogiškųjų išteklių. Tai sukelia poreikį automatizuotiems vertinimo algoritmams, kurie turi potencialą įgalinti daugelį sričių: patiems vartotojams padėti suprasti savo sveikatos būklę; pateikti gydytojams informaciją apie paciento sveikatą taip plečiant personalizuotos medicinos galimybes; pateikti visuomenės sveikatos specialistams įžvalgas apie įvairias tendencijas visuomenėje. Norint užtikrinti informacinių technologijų sėkmę sveikatos apsaugos srityje, būtina atrasti tikslią, pagrįstą ir pastovius rezultatus pateikiančią širdies ritmo apdorojimo technologiją. Sekančiose skiltyse pateikiama širdies ritmo klasifikavimo strategijų apžvalga. Nagrinėjamų studijų charakteristikos pateiktos 1 lentelėje.

<i>Autorius</i>	<i>Metai</i>	<i>Naudoti duomenys</i>	<i>Įvestis</i>	<i>Duomenų transformacija</i>	<i>Modelio architektūros ypatumai</i>	<i>Klasijų skaičius</i>	<i>Tikslumas</i>
<i>Yoon GW</i>	2024	MUSE, PTB-XL	EKG	GAN	ResNet	5	82%
<i>Shanmugavadivel K</i>	2022	Kaggle, UCI	EKG	Nuotrauktų Augmentacija	CNN	5	94%
<i>Ullah H</i>	2022	MIT-BIH, IN-CART	EKG	Sekų segmentacija	ResNet-18	1	99,85%
<i>Mantravadi A</i>	2024	MIT-BIH, ICCAD	EKG	Nėra	INN	8	99,92%
<i>Zhou F</i>	2024	MIT-BIH	EKG	DWT	FB	5	99,50%
<i>Din S</i>	2024	MIT-BIH	EKG	Nėra	Ansamblinis mokymasis	11	99,56%
<i>Chopannejad S</i>	2024	Chapman–Shaoxing	EKG	Triukšmo šalinimas	BiLSTM-BiGRU	11	98,57%
<i>Radhakrishnan</i>	2021	MIT-BIH, Physionet	EKG	Dažnių laike analizė	BiLSTM	1	99,18%
<i>Mhamdi</i>	2022	Khan, A.H.	EKG	Nuotrauktų Augmentacija	MobileNetV2, VGG16	4	97,56%
<i>Hui Y</i>	2021	MIT-BIH	EKG	Nėra	1D CNN	6	94%
<i>Ramesh J</i>	2021	MIT-BIH, UMass	EKG, FPG	Triukšmo šalinimas, normalizacija	CNN	1	95,50%
<i>Xie W</i>	2023	Nenurodyta	FPG	Normalizacija, segmentacija	BiLSTM-Attention	1	96,50%
<i>Aldughayfiq B</i>	2023	MIMC PERform	EKG, FPG	Nėra	1D CNN, BiLSTM	1	88%
<i>Kudo S</i>	2023	PhysioNet, MIT-BIH, Lt-AF-DB, UMMC	EKG, FPG	Sekų segmentacija	CNN-Transformeriai	3	79%
<i>Nguyen P</i>	2022	MIMIC, NTU Ligoninė	FPG	Nėra	1D CNN, 2D CNN	1	98,08%
<i>Huang YH</i>	2023	MIMIC-III	FPG	Normalizacija, segmentacija	1D CNN, 2D CNN	1	98,26%

<i>Mohagheghan F</i>	2024	Pulsewatch, Stanford University	FPG	Normalizacija	Automatinis kodavimas	1	91,98%
----------------------	------	---------------------------------	-----	---------------	-----------------------	---	--------

Lentelė 1. Studijų charakteristikos

6.2.1 Širdies ritmo klasifikavimo strategijos

EKG interpretavimas gali būti sudėtingas, todėl specialistai turi atsižvelgti į daugelį su pacientu susijusių veiksnių, tokių kaip amžius, kūno sudėjimas ar kitos fiziologinės būklės, galinčios paveikti EKG bangos užrašymą. Pavyzdžiui, vaikai ir paaugliai dažniausiai turi didesnę širdies susitraukimų dažnį ir skirtingas EKG ypatybes, dėl ko EKG vertinimo kriterijuose turi būti atsižvelgiama į paciento amžių, norint interpretuoti rodmenis teisingai (41). Vyrų ir moterų EKG pasižymi subtiliais skirtumais repoliarizacijos fazėje, kas stebima vertinant T ir QT intervalus (42). Taip pat, širdies elektrinis aktyvumas gali priklausyti nuo žmogaus fizinio parengimo: atletų EKG gali būti panaši į patologinę dėl didesnio kardiovaskulinio efektyvumo ir širdies remodeliavimo procesų, dėl ko gali būti klaidingai diagnozuojamos įvairios būklės (43). Taigi, EKG interpretavimas reikalauja ne tik elektrofiziologinių principų supratimo, bet ir suvokimo, kaip kitos paciento būklės gali keisti EKG signalo struktūrą.

Kompiuterizuoti EKG analizės būdai taip pat kelia iššūkius, pirmiausiai, dėl esminio tradicinių kompiuterinių algoritmų trūkumo – negebėjimo generalizuoti turimos informacijos ir pritaikyti jos sudėtingų ir nestandartinių EKG analizei. Nors ir kompiuterinės sistemos yra ypatingai efektyvios apdorojant didelius duomenų kiekius ir suteikiant greitą vertinimą, jomis pagrįstos išvados gali būti neteisingos, dėl algoritmo apmokymo ypatumų ir nevisaverčio apmokymui naudojamų duomenų rinkinio. Littmann paruošė išsamią populiariausių analizės algoritmų trūkumų analizę, kurioje pažymi, kad neteisinga EKG interpretacija gali būti sukelta neteisingo QRS komplekso ribų atpažinimo; T bangų ir QRS kompleksų painiojimo; prieširdžių plazdėjimo bangų, kurios neteisingai interpretuojamos kaip ST segmento pakilimai; Hiso pluošto kojų blokadų painiojimu su skilveline tachikardija (44–46). Šie pavyzdžiai iliustruoja kompiuterinės EKG analizės sudėtingumą, ypač kai algoritmai susiduria su neįprastais atvejais ar subtiliais požymiais, kurie gali būti nepastebėti net ir apmokyto specialisto.

Sprendžiant šias problemas kyla poreikis atrasti algoritmą, kuris geba generalizuoti anksčiau gautą informaciją ir pateikti atitinkamą išvadą analizuojant naujus duomenis. Šį poreikį atliepia naujosios dirbtinio intelekto pagrįstos technologijos. Skirtingai nuo tradicinių kompiuterinių algoritmų, kurie veikia remdamiesi iš anksto nustatytais taisyklių rinkiniais ir duomenų šablonais, dirbtinio intelekto algoritmai, paremti neuronų tinklais, geba „išmokti“ atskirti skirtingas būkles net ir labai sudėtingose situacijose, kur tradiciniai metodai gali nepasiteisinti (47). Dirbtinio intelekto algoritmai, naudodami tą patį duomenų rinkinį, kaip ir konvenciniai algoritmai, potencialiai gali

atsižvelgti į didesnę informacijos kiekį bei geba patys atpažinti ir sumodeliuoti EKG bangos struktūras būdingas tam tikrai būklei. Kompiuterinės simuliacijos leidžia manyti, kad vienos derivacijos teikiama informacija yra panašios vertės kaip ir 12 derivacijų EKG klasifikuojant širdies aritmijas naudojant neuroninius tinklus (48). Tai rodo, kad kompiuterinių algoritmų teikiama EKG analizė gali būti pranašesnė netgi už žmogaus analizę.

Naujausi atradimai dirbtinio intelekto srityje, keičiantys mūsų suvokimą apie žmonių sąveiką su kompiuteriais, yra susiję su transformerių neuroninių tinklų architektūra, „perdavimo mokymosi“ (angl. „transfer learning“) metodu, bei dideliais kalbų modeliais (angl. „large language models“). Vaswani darbas apie transformerių architektūrą davė pradžią šiam perversmui: jame pateikiami įrodymai, kad šios architektūros pagalba apmokyti algoritmai geba generalizuoti ir pateikti išvadas apie anksčiau nematytą informaciją (49). Originaliai sukurti natūralios kalbos suvokimo užduočių nagrinėjimui, dideli kalbų modeliai taip pat yra pagrįsti transformerių principu (50,51). Šie modeliai demonstruoja nepaprastai didelį efektyvumą analizuojant logines duomenų sekas, tokias kaip kalba (52). EKG signalai, panašiai kaip sakiniai kalboje, yra nuoseklūs ir perduoda informaciją intervaluose bei pasikartojančiose sekose. Transformeriai gali fiksuoti šias sekas ir pastebėti smulkiausias signalo ypatumus taip gebėdami interpretuoti sudėtingus EKG atvejus efektyviau nei konvenciniai analizės metodai.

Shanmugavadivel pademonstravo konvoliuciniais neuronų tinklais pagrįstą modelį, gebantį klasifikuoti įvairius širdies ritmo sutrikimus 94 procentų tikslumu (53). Pademonstruoto modelio architektūra naudoja išankstinio duomenų apdorojimo technikas, kurios atpažįsta ir klasifikuoja tam tikras EKG sekas, panašiai kaip ir konvenciniai analizės metodai. Ulahh pritaikytas perdavimo mokymosi metodas priešlaikinės skilvelių depoliarizacijos epizodams atpažinti pademonstravo 99,77–99,93 proc. tikslumą (54). Ulahh pademonstruota architektūra buvo paremta išankstine EKG sekų segmentacija naudojantis Pan-Tompkins algoritmu, kas galėjo nulemti šio modelio pranašumą. Šis pavyzdys taip pat parodė, kad ši technologija tinka nesubalansuotiems duomenų rinkiniams, kai tiriamojo požymio galia yra maža. Kitos neuronų tinklais pagrįstos dirbtinio intelekto modelių architektūros rodo panašų efektyvumo lygį: Mantravadi aprašytas algoritmas naudoja involiucinius neuronų tinklus (angl. „Involucional Neural Network“, „INN“), kurie geriau fiksuoja ilgo nuotolio erdvinę informaciją ir veikia kaip savaiminio dėmesio mechanizmas, taip gaudamas 99,92 proc. klasifikacijos tikslumą (55); Zhou klasifikacijai pasitelkė sintezės bloką (angl. „Fusion Block“), kuriuo apjungė konvoliucinio neuronų tinklo ir transformerio modelių pateiktus klasifikacijos rezultatus išgaudamas 99,5 proc. tikslumą (56); Din panaudojo ansamblinio mokymosi (angl. „Ensemble learning“) techniką, kad balsų daugumos principu išrinkti tiksliausią klasę pagal trijų klasifikatorių rezultatus, gaudama 99,56 proc. tikslumą (57); Chopannejad įvertino dvikrypčio ilgos

trumpalaikės atminties ir dvikrypčio sklendžių rekurentinių vienetų modelio efektyvumą (angl. „BILSTM-BiGRU), pasiekdama 98,57 proc. tikslumą (58) .

Nemažiau svarbu nei paties dirbtinio intelekto modelio sluoksnių architektūra yra ir duomenų paruošimas klasifikavimui. Duomenų paruošimas apima keletą žingsnių, kurie gali turėti didelę įtaką modelio mokymo efektyvumui ir galutinės klasifikacijos tikslumui. Pirmiausia, duomenys turi būti išvalyti nuo triukšmo ir netikslumų. Antra, svarbu atlikti duomenų normalizavimą ir standartizavimą, kad visų savybių masteliai būtų suderinami. Toliau gali būti taikomi įvairūs informatyviųjų požymių ištraukimo metodai – ši strategija yra naudojama, kad kuo labiau išgryninti informaciją, išlaikant tuos požymius, kurie yra labiausiai reikšmingi sprendžiamai užduočiai. Natūralu, kad šio metodo trūkumas yra duomenų, kurie, tyrėjo subjektyvia nuomone, yra mažiau svarbūs, praradimas. Nepaisant to, šis būdas ypač naudingas turint mažesnę įvesties duomenų kiekį, bei leidžia apmokėti mažesnius, greitesnius ir labiau specializuotus modelius.

Literatūroje tiriamos įvairios duomenų apdorojimo strategijos, tokios kaip dažnių laike analizė ar įvesties transformacijos į dvimatę išraišką. Radhakrishan tyrė kaip EKG signalo apdorojimas naudojant dažnių laike analizę (angl. „time-frequency analysis“), kad geriau užfiksuoti EKG signalo kitimą laike (59). Taip apdoroti duomenys vėliau buvo panaudoti apmokėti neuroniniais tinklais pagrįstą modelį. Šis metodas pademonstravo 99,18 proc. tikslumą klasifikuojant prieširdžių virpėjimo epizodus. Ullah ir Radhakrishan naudojami duomenų paruošimo metodai buvo paremti vienos dimensijos EKG signalo konvertavimu į dviejų dimensijų išraišką, iš esmės paverčiant linijinį EKG signalą paveiksliuku – tai leido klasifikavimui panaudoti vaizdų apdorojimui skirtą modelį (54,59). Daugelis kitų tyrimų, naudojančių neuronų tinklus, klasifikavo EKG signalą naudojant jo vienmatę išraišką (48,60,61). Pastarasis klasifikacijos būdas naudoja mažiau kompiuterinių resursų, tačiau, vertinant rezultatus, yra prastesnis, nei dvimatės išraiškos klasifikavimas.

Fotopletizmografijos signalo analizė yra paremta panašiais principais kaip ir EKG signalo analizė. Statistinės analizės algoritmai dažniausiai yra paremti RR intervalų ir ritmo variabilumo vertinimu – normalios širdies veiklos rodmenys analizuojami, kad atpažinti slenkstines šių rodikliu reikšmes. Šios reikšmės naudojamos kad sukurti nukrypimų nuo normos atpažinimo taisyklės. Analogiškai EKG signalo analizei, konvenciniai, taisyklėmis pagrįsti metodai turi pagrindinį trūkumą, jog jie negeba generalizuoti ir prisitaikyti prie anksčiau nematytų duomenų variacijų. Todėl šiuolaikiniai tyrimai vis dažniau prieina išvadą, jog dirbtiniu intelektu pagrįsti metodai yra pranašesni klasifikuoti FPG signalo variacijas.

Sutrikusio širdies ritmo atpažinimui nagrinėjamos įvairios dirbtinio intelekto modelių architektūros bei duomenų išankstinio apdorojimo metodai. Xie teigia, kad FPG signalo informacija gali būti apdorojama dvejopai - laiko srities (angl. „time domain“) ir dažnio srities (angl. „frequency

domain“) apdorojimu, pastarajam būnant labiau informatyviai klasifikuojant duomenis dirbtinio intelekto pagalba, tačiau sunkiau interpretuojamam žmogaus (62). Svarstant tarp vienmatės ir dvimatės įvesties duomenų reprezentacijos, Aldughayfiq nurodo, kad dvimatę įvestį turintys vaizdų klasifikavimo modeliai, specifiskai „ResNet“, gali būti prastesni nei modeliai, naudojantys vienmatę įvestį (63). Taip pat, Kudo pažymi, kad binarinė, dviejų klasių – „prieširdžių virpėjimas“ ir „ne prieširdžių virpėjimas“ – yra nepakankama, kadangi modeliai neteisingai klasifikuos ektopinius širdies susitraukimus, tokius kaip priešlaikinis skilvelių ar prieširdžių susitraukimas (64). Stebima, kad optimalus įvesties signalo struktūros ir klasifikavimo išeičių parinkimas yra pagrindinis įvairių darbų tyrimų objektas.

Aldughayfiq nagrinėjo galimybę integruoti EKG ir FPG rodmenis ir sudaryti kombinuotą šių signalų įvestį širdies aritmijų klasifikavimui. Šių bandymų rezultatai nurodo, kad šio būdo klasifikacijos tikslumas gali būti nuo 88 iki 95 proc. (63). Šis pavyzdys parodo, kad išsamaus, apimančio kuo daugiau paciento rodiklių, įvesties signalo konstravimas, gali būti pranašesnis metodas klasifikuojant širdies ritmo anomalijas, nei izoliuotai analizuojant tik vieną iš signalų. Ramesh darbai parodė, kad EKG ir PPG signalai yra labai panašūs morfologiškai – apmokytas modelis, gebantis klasifikuoti širdies aritmiją nepriklausomai naudodamasis tiek EKG, tiek FPG signalu, parodė panašų klasifikavimo tikslumą – 95,5 proc. ir 95.1 proc. atitinkamai EKG ir FPG įvestimi (65). Tai nurodo, kad EKG ir FPG signalo kombinavimas galimai nesuteikia pakankamai papildomos informacijos, kad padidintų širdies aritmijų klasifikavimo tikslumą.

6.2.2 Širdies ritmo klasifikavimo iššūkiai

Sprendžiant signalo kokybės dėl įvairių trikdžių, tokių kaip judesio artefaktai, problemą, kai kurie tyrimai pateikia papildomų signalų, tokių kaip akselerometras, įvedimą, papildant įprastą FPG signalą (66,67). Huang pateikia kitą sprendimo būdą ir teigia, kad naudojant vienmatį konvoliucinį neuronų tinklą duomenų išankstiniam apdorojimui, kaip siūloma Nguyen darbuose (68), galima išvengti papildomų sensorių naudojimo aptikti judesio artefaktams, o aptiktus artefaktų epizodus siūloma atmesti (69). Alternatyvus pasiūlymas Mohagheghian darbuose yra naudoti automatinio užkodavimo (angl. „autoencoder“) technologiją, kad rekonstruoti taisyklingą FPG signalą iš „triukšmingo“ signalo (70). Šie darbai nagrinėja galimus metodus apeiti šiuolaikinių jutiklių technologijų trūkumus.

Vienas iš iššūkių, su kuriuo susiduria transformerių architektūros modelių kūrėjai yra modelių dydis, efektyvumas bei sparta. Didieji kalbų modeliai, tokie kaip Mistral 7B savyje saugo septynis milijardus parametrų (51), kas kelia technologinius apribojimus naudoti šiuos modelius nešiojamuosiuose įrenginiuose. Paskutiniųjų tyrimų objektas šiuo metu yra EKG modelių greitaveikos optimizavimas pritaikant juos naudojimui ribotų resursų aplinkoje išlaikant tokią pačią

arba panašią klasifikavimo kokybę (60,61,71). Mhamdi pademonstravo neuronų tinklu pagrįstą EKG analizės modelį, gebantį veikti mažose sistemose, tokiose kaip Raspberry Pi (60). Didelių kalbos modelių pavyzdys rodo, kad algoritmo gebėjimas atsižvelgti į kuo daugiau įvesties signalo parametrų yra vienas iš svarbiausių sėkmės faktorių, norint, kad algoritmas gebėtų įvertinti kuo daugiau veiksnių. Paskutiniai pademonstruoti aritmijų klasifikacijos modeliai fokusuojasi į aukso viduriuko atradimą tarp parametrų skaičiaus ir greitaiveikos, pavyzdžiui, Mantravadi modelio parametrų skaičius sudarė 297 tūkstančius (55). Tačiau šie skaičiai neprilygsta dideliems kalbos modeliams, kas leidžia manyti, jog dirbtinio intelekto potencialas sveikatos apsaugos industrijoje nėra iki galo išnaudotas.

Kitas iššūkis taikant dirbtinį intelektą automatinei susirgimų diagnostikai yra sunkumai aiškinant dirbtinio intelekto sprendimus – modelių aptiktos sekos ir sąlygos tampa neuronų tinklo dalis, kurią interpretuoti yra žymiai sunkiau, nei konvencinių metodų taisyklėmis pagrįstą modelį. Tai reiškia, kad nors neuroniniai tinklai gali pasiūlyti aukštesnį sprendimų tikslumą, jų „mąstymo“ procesas dažnai lieka neaiškus, o tai sukelia iššūkių, kai reikia garantuoti sistemos skaidrumą ir pasitikėjimą ja. Dėl šios priežasties, dirbtinio intelekto sektoriuje vis labiau populiarėja tyrimai ir metodologijos, skirtos pagerinti modelių paaiškinamumą. Vadinamosios „Paaiškinamojo dirbtinio intelekto“ (angl. „Explainable AI“, „XAI“) iniciatyvos siekia sukurti technologijas, kurios galėtų paaiškinti, kaip būtent dirbtinio intelekto modeliai priima sprendimus (72). Tai yra ypač svarbu sveikatos apsaugos sektoriuje, kuris reikalauja ypatingai aukšto pasitikėjimo ir sprendimų priėmimo skaidrumo lygio. Tikimasi, kad paaiškinamasis dirbtinis intelektas padės įgalinti atsakingą ir efektyvų sprendimų priėmimą kompiuterinių algoritmų pagalba.

7 IŠVADOS

Ši literatūros apžvalga atskleidžia, kad EKG ir FPG signalų analizė yra sudėtinga ir reikalauja gilaus supratimo apie širdies veiklos elektrinį aktyvumą bei apie įvairias su pacientu susijusias būkles. Biologinių signalų analizės sudėtingumas, ypač susijęs su nestandartiniais atvejais ir subtiliais signalo požymiais, yra iššūkis net ir labiausiai kvalifikuotiems specialistams. Dirbtinio intelekto algoritmai, mokomi, naudojant didžiulius duomenų rinkinius, rodo potencialą atsižvelgti į didesnę su paciento sveikata susijusios informacijos spektrą ir taip įgalinti išmaniųjų technologijų vartotojus greitai ir patogiai gauti įžvalgų apie savo sveikatos būklę; pateikti gydytojams informaciją apie paciento sveikatą, taip plečiant personalizuotos medicinos galimybes; pateikti visuomenės sveikatos specialistams įžvalgas apie įvairias tendencijas visuomenėje. Naujausi išradimai dirbtinio intelekto srityje, tokie kaip transformeriai ir „perdavimo mokymasis“, leidžia efektyviau interpretuoti EKG ir FPG signalų duomenis, dėl jų pranašumo efektyviai apdorojant

nesubalansuotus duomenų rinkinius ir atpažįstant sudėtingas signalų variacijas. Didžiausias tyrimų objektas dirbtinio intelekto algoritmų srityje yra optimalios modelių architektūros ir įvesties duomenų apdorojimų metodų parinkimas. Dirbtinio intelekto modeliai, taikomi sveikatos priežiūroje, kol kas nepasiekė to paties galimybių lygio, kurį demonstruoja dideli kalbos modeliai, todėl ši panaudojimo sritis reikalauja didesnio dėmesio ir tolimesnių tyrimų. Norint užtikrinti dirbtinio intelekto technologijų prieinamumą vartotojams, būtina atsižvelgti į pasitikėjimo ir sprendimo priėmimo skaidrumo reikalavimus. Tikimasi, kad paaiškinamo dirbtinio intelekto iniciatyva padės įgyvendinti atsakingą ir efektyvų sprendimų priėmimą, suteikiant gydytojams įrankius, kurie padeda aiškiai ir tiksliai interpretuoti sudėtingus biologinius signalus.

8 LITERATŪROS SĄRAŠAS

1. Beating cardiovascular disease — the role of Europe’s environment — European Environment Agency [Internet]. [cited 2024 Apr 13]. Available from: <https://www.eea.europa.eu/publications/beating-cardiovascular-disease/beating-cardiovascular-disease-the/#fn2>
2. Luengo-Fernandez R, Walli-Attaei M, Gray A, Torbica A, Maggioni AP, Huculeci R, et al. Economic burden of cardiovascular diseases in the European Union: a population-based cost study. *European Heart Journal*. 2023 Dec 1;44(45):4752–67.
3. Turakhia MP, Guo JD, Keshishian A, Delinger R, Sun X, Ferri M, et al. Contemporary prevalence estimates of undiagnosed and diagnosed atrial fibrillation in the United States. *Clinical Cardiology*. 2023;46(5):484–93.
4. Hertzman AB. Photoelectric Plethysmography of the Nasal Septum in Man. *Proceedings of the Society for Experimental Biology and Medicine*. 1937 Nov 1;37(2):290–2.
5. Pollard JA. A New Photoelectric Plethysmograph. *Anesthesia & Analgesia*. 1968 Jun;47(3):310.
6. Matthes K. Untersuchungen über die Sauerstoffsättigung des menschlichen Arterienblutes. *Archiv f experiment Pathol u Pharmakol*. 1935 Nov 1;179(6):698–711.
7. Severinghaus JW. Takuo Aoyagi: discovery of pulse oximetry. *Anesth Analg*. 2007 Dec;105(6 Suppl):S1–4.
8. Charlton PH, Allen J, Bailón R, Baker S, Behar JA, Chen F, et al. The 2023 wearable photoplethysmography roadmap. *Physiol Meas*. 2023 Nov 1;44(11):111001.
9. Tamura T. Current progress of photoplethysmography and SPO2 for health monitoring. *Biomed Eng Lett*. 2019 Feb 18;9(1):21–36.
10. Allen J. Photoplethysmography and its application in clinical physiological measurement. *Physiol Meas*. 2007 Mar;28(3):R1-39.
11. Yousef H, Alhadj M, Sharma S. Anatomy, Skin (Integument), Epidermis. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2024 [cited 2024 Apr 5]. Available from: <http://www.ncbi.nlm.nih.gov/books/NBK470464/>
12. Nitzan M, Nitzan I, Arieli Y. The Various Oximetric Techniques Used for the Evaluation of Blood Oxygenation. *Sensors (Basel)*. 2020 Aug 27;20(17):4844.
13. Sidorov IS, Romashko RV, Koval VT, Giniatullin R, Kamshilin AA. Origin of Infrared Light Modulation in Reflectance-Mode Photoplethysmography. *PLoS One*. 2016;11(10):e0165413.
14. Bierman A, Benner K, Rea MS. Melanin bias in pulse oximetry explained by light source spectral bandwidth. *Br J Anaesth*. 2024 Mar 4;S0007-0912(24)00060-6.
15. Bermond M, Davies HJ, Occhipinti E, Nassibi A, Mandic DP. Reducing racial bias in SpO2 estimation: The effects of skin pigmentation. *Annu Int Conf IEEE Eng Med Biol Soc*. 2023 Jul;2023:1–5.

16. Rodriguez AJ, Boonya-Ananta MT, Gonzalez M, Le VND, Fine J, Palacios C, et al. Skin optical properties in the obese and their relation to body mass index: a review. *J Biomed Opt.* 2022 Mar;27(3):030902.
17. Fine J, Branan KL, Rodriguez AJ, Boonya-ananta T, Ajmal, Ramella-Roman JC, et al. Sources of Inaccuracy in Photoplethysmography for Continuous Cardiovascular Monitoring. *Biosensors (Basel).* 2021 Apr 16;11(4):126.
18. Alian AA, Shelley KH. Photoplethysmography. *Best Pract Res Clin Anaesthesiol.* 2014 Dec;28(4):395–406.
19. Ray D, Collins T, Woolley SI, Ponnappalli PVS. A Review of Wearable Multi-Wavelength Photoplethysmography. *IEEE Reviews in Biomedical Engineering.* 2023;16:136–51.
20. Fallow BA, Tarumi T, Tanaka H. Influence of skin type and wavelength on light wave reflectance. *J Clin Monit Comput.* 2013 Jun;27(3):313–7.
21. Shchelkanova E, Shchapova L, Shchelkanov A, Shibata T. Blue as an Underrated Alternative to Green: Photoplethysmographic Heartbeat Intervals Estimation under Two Temperature Conditions. *Sensors (Basel).* 2021 Jun 21;21(12):4241.
22. Akl TJ, Wilson MA, Ericson MN, Coté GL. Quantifying tissue mechanical properties using photoplethysmography. *Biomed Opt Express, BOE.* 2014 Jul 1;5(7):2362–75.
23. Caizzone A, Boukhayma A, Enz C. AC/DC Ratio Enhancement in Photoplethysmography Using a Pinned Photodiode. *IEEE Electron Device Lett.* 2019 Nov;40(11):1828–31.
24. Siam A, Abd El-Samie F, Abu Elazm A, El-Bahnasawy N, Elbanby G. Real-World PPG dataset. 2019 Apr 19 [cited 2024 Apr 7];1. Available from: <https://data.mendeley.com/datasets/yynb8t9x3d/1>
25. Shelley KH. Photoplethysmography: Beyond the Calculation of Arterial Oxygen Saturation and Heart Rate. *Anesthesia & Analgesia.* 2007 Dec;105(6):S31.
26. Sattar Y, Song D, Sarvepalli D, Zaidi SR, Ullah W, Arshad J, et al. Accuracy of pulsatile photoplethysmography applications or handheld devices vs. 12-lead ECG for atrial fibrillation screening: a systematic review and meta-analysis. *J Interv Card Electrophysiol.* 2022 Oct;65(1):33–44.
27. Weinschenk SW, Beise RD, Lorenz J. Heart rate variability (HRV) in deep breathing tests and 5-min short-term recordings: agreement of ear photoplethysmography with ECG measurements, in 343 subjects. *Eur J Appl Physiol.* 2016 Aug 1;116(8):1527–35.
28. Theurl F, Schreinlechner M, Sappeler N, Toifl M, Dolejsi T, Hofer F, et al. Smartwatch-derived heart rate variability: a head-to-head comparison with the gold standard in cardiovascular disease. *Eur Heart J Digit Health.* 2023 May;4(3):155–64.
29. Cheng YC, Su MI, Liu CW, Huang YC, Huang WL. Heart rate variability in patients with anxiety disorders: A systematic review and meta-analysis. *Psychiatry Clin Neurosci.* 2022 Jul;76(7):292–302.
30. Schiweck C, Piette D, Berckmans D, Claes S, Vrieze E. Heart rate and high frequency heart rate variability during stress as biomarker for clinical depression. A systematic review. *Psychol Med.* 2019 Jan;49(2):200–11.

31. Pandit JA, Lores E, Batlle D. Cuffless Blood Pressure Monitoring: Promises and Challenges. *Clin J Am Soc Nephrol*. 2020 Oct 7;15(10):1531–8.
32. Islam SMS, Chow CK, Daryabeygikhotbehsara R, Subedi N, Rawstorn J, Tegegne T, et al. Wearable cuffless blood pressure monitoring devices: a systematic review and meta-analysis. *Eur Heart J Digit Health*. 2022 Jun;3(2):323–37.
33. Pezawas T. ECG Smart Monitoring versus Implantable Loop Recorders for Atrial Fibrillation Detection after Cryptogenic Stroke—An Overview for Decision Making. *J Cardiovasc Dev Dis*. 2023 Jul 18;10(7):306.
34. Burchell HB. A centennial note on waller and the first human electrocardiogram. *The American Journal of Cardiology*. 1987 Apr 15;59(9):979–83.
35. Barold SS. Willem Einthoven and the birth of clinical electrocardiography a hundred years ago. *Card Electrophysiol Rev*. 2003 Jan;7(1):99–104.
36. Lewis T. SINGLE AND SUCCESSIVE EXTRA-SYSTOLES. *The Lancet*. 1909 Feb 6;173(4458):382–5.
37. The Mechanism and Graphic Registration of the Heart Beat. *Journal of the American Medical Association*. 1925 Dec 5;85(23):1832.
38. Abobaker A, Rana RM. V1 and V2 pericordial leads misplacement and its negative impact on ECG interpretation and clinical care. *Ann Noninvasive Electrocardiol*. 2021 Apr 4;26(4):e12844.
39. Electrocardiographic artifacts due to electrode misplacement and their frequency in different clinical settings – AJEM [Internet]. [cited 2024 Apr 8]. Available from: <https://ajemjournal.com/article/S0735-67570600382-2/fulltext>
40. Ousaka D, Hirai K, Sakano N, Morita M, Haruna M, Hirano K, et al. Initial evaluation of a novel electrocardiography sensor-embedded fabric wear during a full marathon. *Heart Vessels*. 2022 Mar;37(3):443–50.
41. Dickinson DF. The normal ECG in childhood and adolescence. *Heart*. 2005 Dec;91(12):1626–30.
42. Moss AJ. Gender Differences in ECG Parameters and Their Clinical Implications. *Ann Noninvasive Electrocardiol*. 2010 Jan 20;15(1):1–2.
43. Basu J, Malhotra A. Interpreting the Athlete’s ECG: Current State and Future Perspectives. *Curr Treat Options Cardiovasc Med*. 2018;20(12):104.
44. Littmann L. Common ECG interpretation software mistakes. Part I: False reporting of myocardial infarction. *Journal of Electrocardiology*. 2023 Nov 1;81:32–5.
45. Littmann L. Common ECG interpretation software mistakes Part II: Computer errors that hide diagnostic clues. *Journal of Electrocardiology*. 2023 Nov 1;81:277–80.
46. Littmann L. Common ECG interpretation software mistakes Part III: Computer errors that should never be missed. *Journal of Electrocardiology*. 2023 Nov 1;81:281–4.

47. Ardeti V, Kolluru V, Varghese G, Patjoshi R. An overview on state-of-the-art electrocardiogram signal processing methods: Traditional to AI-based approaches. *EXPERT SYSTEMS WITH APPLICATIONS*. 2023;217.
48. Yoon GW, Joo S. Classification feasibility test on multi-lead electrocardiography signals generated from single-lead electrocardiography signals. *Sci Rep*. 2024 Jan 22;14(1):1888.
49. Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, et al. Attention Is All You Need [Internet]. *arXiv*; 2023 [cited 2024 Apr 7]. Available from: <http://arxiv.org/abs/1706.03762>
50. OpenAI, Achiam J, Adler S, Agarwal S, Ahmad L, Akkaya I, et al. GPT-4 Technical Report [Internet]. *arXiv*; 2024 [cited 2024 Apr 7]. Available from: <http://arxiv.org/abs/2303.08774>
51. Jiang AQ, Sablayrolles A, Mensch A, Bamford C, Chaplot DS, Casas D de las, et al. Mistral 7B [Internet]. *arXiv*; 2023 [cited 2024 Apr 7]. Available from: <http://arxiv.org/abs/2310.06825>
52. Huang Y, Xu J, Lai J, Jiang Z, Chen T, Li Z, et al. Advancing Transformer Architecture in Long-Context Large Language Models: A Comprehensive Survey [Internet]. *arXiv*; 2024 [cited 2024 Apr 7]. Available from: <http://arxiv.org/abs/2311.12351>
53. Shanmugavadivel K, Sathishkumar VE, Kumar MS, Maheshwari V, Prabhu J, Allayear SM. Investigation of Applying Machine Learning and Hyperparameter Tuned Deep Learning Approaches for Arrhythmia Detection in ECG Images. *Comput Math Methods Med*. 2022;2022:8571970.
54. Ullah H, Heyat M, Akhtar F, Muaad A, Ukwuoma C, Bilal M, et al. An Automatic Premature Ventricular Contraction Recognition System Based on Imbalanced Dataset and Pre-Trained Residual Network Using Transfer Learning on ECG Signal. *DIAGNOSTICS*. 2023;13(1).
55. Mantravadi A, Saini S, R. SCT, Mittal S, Shah S, R. SD, et al. CLINet: A novel deep learning network for ECG signal classification. *Journal of Electrocardiology*. 2024 Mar 1;83:41–8.
56. Zhou F, Wang J. Heartbeat classification method combining multi-branch convolutional neural networks and transformer. *iScience*. 2024 Mar 15;27(3):109307.
57. Din S, Qaraqe M, Mourad O, Qaraqe K, Serpedin E. ECG-based cardiac arrhythmias detection through ensemble learning and fusion of deep spatial-temporal and long-range dependency features. *Artif Intell Med*. 2024 Apr;150:102818.
58. Chopannejad S, Roshanpoor A, Sadoughi F. Attention-assisted hybrid CNN-BILSTM-BiGRU model with SMOTE-Tomek method to detect cardiac arrhythmia based on 12-lead electrocardiogram signals. *Digit Health*. 2024;10:20552076241234624.
59. Radhakrishnan T, Karhade J, Ghosh SK, Muduli PR, Tripathy RK, Acharya UR. AFCNNNet: Automated detection of AF using chirplet transform and deep convolutional bidirectional long short term memory network with ECG signals. *Comput Biol Med*. 2021 Oct;137:104783.
60. Mhamdi L, Dammak O, Cottin F, Dhaou IB. Artificial Intelligence for Cardiac Diseases Diagnosis and Prediction Using ECG Images on Embedded Systems. *Biomedicines*. 2022 Aug 19;10(8).

61. Hui Y, Yin Z, Wu M, Li D. Wearable Devices Acquired ECG Signals Detection Method Using 1D Convolutional Neural Network. In Harbin Inst Technol, Sch Elect & Informat Engn, Harbin 150006, Peoples R China; 2021. p. 81–5.
62. Xie W, Chen C, Zhao R, Lu Y. Detection of Atrial Fibrillation based on Feature Fusion using Attention-based BiLSTM. In: 2023 45th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC) [Internet]. 2023 [cited 2024 Apr 9]. p. 1–4. Available from: <https://ieeexplore.ieee.org/document/10340023>
63. Aldughayfiq B, Ashfaq F, Jhanjhi NZ, Humayun M. A Deep Learning Approach for Atrial Fibrillation Classification Using Multi-Feature Time Series Data from ECG and PPG. *Diagnostics*. 2023 Jul;13(14):2442.
64. Kudo S, Chen Z, Zhou X, Izu LT, Chen-Izu Y, Zhu X, et al. A training pipeline of an arrhythmia classifier for atrial fibrillation detection using Photoplethysmography signal. *Front Physiol* [Internet]. 2023 Jan 19 [cited 2024 Apr 9];14. Available from: <https://www.frontiersin.org/journals/physiology/articles/10.3389/fphys.2023.1084837/full>
65. Ramesh J, Solatidehkordi Z, Aburukba R, Sagahyroon A. Atrial Fibrillation Classification with Smart Wearables Using Short-Term Heart Rate Variability and Deep Convolutional Neural Networks. *SENSORS*. 2021;21(21).
66. Reiss A, Indlekofer I, Schmidt P, Van Laerhoven K. Deep PPG: Large-Scale Heart Rate Estimation with Convolutional Neural Networks. *Sensors*. 2019 Jan;19(14):3079.
67. Mehrgardt P, Khushi M, Poon S, Withana A. Deep Learning Fused Wearable Pressure and PPG Data for Accurate Heart Rate Monitoring. *IEEE Sensors Journal*. 2021 Dec;21(23):27106–15.
68. D. H. Nguyen, P. C. . -P. Chao, C. -C. Chung, R. -H. Horng, B. Choubey. Detecting Atrial Fibrillation in Real Time Based on PPG via Two CNNs for Quality Assessment and Detection. *IEEE Sensors Journal*. 2022;22(24):24102–11.
69. C. -H. Huang, D. H. Nguyen, P. C. . -P. Chao. Novel Robust-to-Motion-Artifact Detection of Atrial Fibrillation Based on PPG Only. In: 2023 IEEE SENSORS. 2023. p. 01–4.
70. Mohagheghian F, Han D, Ghetia O, Chen D, Peitzsch A, Nishita N, et al. Atrial fibrillation detection on reconstructed photoplethysmography signals collected from a smartwatch using a denoising autoencoder. *EXPERT SYSTEMS WITH APPLICATIONS*. 2024;237.
71. A. Catalani, I. Chatzigiannakis, A. Anagnostopoulos, G. Akrivopoulou, D. Amaxilatis, A. Antoniou. Hardware-assisted and Deep-Learning techniques for Low-Power Detection of Cardiovascular Abnormalities in Smart Wearables. In: 2021 IEEE International Conference on Smart Internet of Things (SmartIoT). 2021. p. 144–51.
72. A. S, R. S. A systematic review of Explainable Artificial Intelligence models and applications: Recent developments and future trends. *Decision Analytics Journal*. 2023 Jun 1;7:100230.