



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus elektrokardiogramoje, galimybių tyrimas

Baigiamasis magistro projektas

Deividas Palubinskas

Projekto autorius

Dr. Andrius Petrėnas

Vadovas

Kaunas, 2022



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus elektrokardiogramoje, galimybių tyrimas

Baigiamasis magistro projektas

Biomedicininė inžinerija (6211EX002)

Deividas Palubinskas

Projekto autorius

Dr. Andrius Petrėnas

Vadovas

Prof. Vaidotas Marozas

Recenzentas

Kaunas, 2022



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Deividas Palubinskas

Miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus elektrokardiogramoje, galimybių tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdamas kitų asmenų autoriaus ar kitų teisių, laikydamasis Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs;
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalintas iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Deividas Palubinskas

Patvirtinta elektroniniu būdu

Palubinskas, Deividas. Miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus elektrokardiogramoje, galimybių tyrimas. Magistro baigiamasis projektas / vadovas lekt. dr. Andrius Petrėnas; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Bioinžinerija, inžinerijos mokslai.

Reikšminiai žodžiai: miokardo infarktas, elektrokardiograma, derivacija, atpažinimas, dirbtinis neuroninis tinklas, algoritmas.

Kaunas, 2022. 56 p.

Santrauka

Miokardo infarktas yra pagrindinė mirties priežastis pasaulyje. Sparčiai tobulėjant išmaniesiems, dėvimiems elektrokardiogramos registratoriams, atsiranda vis daugiau galimybių atpažinti miokardo infarktą ankstyvoje stadijoje. Užregistruoti 12 standartinių derivacijų elektrokardiogramą (EKG), naudojant ant riešo dėvimą elektrokardiogramos registratorių, deja, neįmanoma. Šiame tyrime buvo sukurtas ir ištirtas miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus ambulatoriniuose elektrokardiogramos signaluose, algoritmas. Pasiūlytas algoritmas buvo išbandytas panaudojant įvairias derivacijas bei derivacijų rinkinius. Algoritme, miokardo infarkto atpažinimui, buvo naudojamas hibridinis neuroninis tinklas, susidedantis iš konvoliucinio neuroninio tinklo (*Convolutional Neural Network* - CNN) bei rekurentinio ilgalaikės trumpalaikės atminties neuroninio tinklo (*Long Short Time Memory* - LSTM). Tyrimui atlikti buvo panaudota PTB ambulatoriškai užregistruotų elektrokardiogramos signalų duomenų bazė iš „Physionet“ duomenų banko. Buvo panaudoti 347-iais ūmaus miokardo infarkto atvejais užregistruoti EKG įrašai bei 80 sveikų savanorių EKG įrašų. Duomenų bazė paskirstyta į apmokymo, validacijos ir testavimo duomenų bazes pagal pacientą. Algoritmo apmokymui ir testavimui buvo naudojami 10s trukmės EKG segmentai. Geriausias rezultatas buvo pasiektas panaudojant trijų derivacijų (I, II, III) EKG signalus, gautas 92,3 % tikslumas, 93 % jautrumas ir 91,7 % specifiškumas. Atsižvelgiant į tai, kad registruojant EKG signalus, su ant riešo dėvimais elektrokardiogramos registratoriais, EKG signalų kokybė priklauso nuo elektrodo pridėjimo vietos, šiame darbe buvo tiriama elektrodo pataikymo įtaka algoritmo tikslumui. Šis tyrimas parodė, jog registruojant krūtinines derivacijas, nukrypus nuo standartinės vietos per apytiksliai 10 cm, algoritmo tikslumas sumažėja per 27,28 %. Pataikius elektrodą su apytiksliai 6,2 cm paklaida algoritmo tikslumas sumažėja per 13,3 %. Taip pat buvo tiriama triukšmų įtaka algoritmo veikimui, atsižvelgiant į tai, kokie triukšmai gali daryti įtaką naudojant ant riešo dėvimus elektrokardiogramos registratorius. Buvo panaudota „MIT-BIH Noise Stress Test Database“. Prie EKG signalų buvo pridėti bazinės linijos varijavimo triukšmai, elektrodų judėjimo artefaktai bei raumenų susitraukimų artefaktai. Šis tyrimas parodė, kad didžiausią įtaką algoritmo tikslumui daro raumenų susitraukimų bei elektrodų judėjimo artefaktai. Eliptiniai aukštų dažnių NIR filtrai nebuvo efektyvūs, bandant išfiltruoti šiuos artefaktus, kai jų amplitudė buvo padidinta. Atsižvelgiant į tai, registruojant EKG signalus pacientas turėtų būti ramybės būsenoje, kad elektrodų judėjimo bei raumenų susitraukimų artefaktai būtų kuo silpnesni.

Palubinskas, Deividas. Feasibility Study of Myocardial Infarction Detection in Electrocardiogram With Reduced Number of Leads. Master's Final Degree Project / supervisor Lect. Dr. Andrius Petrėnas; Faculty of Electricity and Electronics, Kaunas University of Technology.

Study field and area (study field group): Bioengineering, engineering sciences.

Keywords: myocardial infarction, electrocardiogram, lead, detection, artificial neural network, algorithm.

Kaunas, 2022. Number of pages 56.

Summary

Myocardial infarction is the leading cause of death in the world. With the rapid development of smart, worn electrocardiogram recorders, there are more and more opportunities to recognize myocardial infarction at an early stage. Record a 12-standard lead electrocardiogram (ECG) using a wrist-worn electrocardiogram recorder, unfortunately, is impossible. In this study, an algorithm for the detection of myocardial infarction in ambulatory electrocardiogram signals with reduced number of leads was developed and investigated. The proposed algorithm was tested using various single leads and combinations of leads. To detect myocardial infarction the algorithm used a hybrid neural network consisting of a convolutional neural network (CNN) and a recursive long-term memory neural network (LSTM). PTB Diagnostic ECG Database from the Physionet was used for the study. ECG recordings from 347 cases of acute myocardial infarction and 80 ECG recordings from healthy volunteers were used. The database is divided into training, validation and testing databases by patient. 10s ECG segments were used to train and test the algorithm. The best results were obtained using three-lead (I, II, III) ECG signals with 92.3 % accuracy, 93 % sensitivity, and 91.7 % specificity. Given that the quality of ECG signals, when recording ECG signals with wrist-worn electrocardiogram recorders, depends on electrode attachment site, electrode attachment site impact on algorithm accuracy was also investigated in this work. This study shows that while recording chest leads the accuracy of the algorithm decreases by 27.28 % when electrode attachment site deviating from the standard location by approximately 10 cm. When electrode attachment site deviating from the standard location by approximately 6.2 cm, the accuracy of the algorithm decreases by 13.3%. The influence of noise on the performance of the algorithm was also investigated, taking into account noises that may occur when using wrist-worn electrocardiogram recorder. The MIT-BIH Noise Stress Test Database was used for this study. Baseline variation noises, electrode movement artifacts, and muscle contraction artifacts were added to the ECG signals. This study shows that the algorithm is most affected by the artifacts of muscle contractions and electrode movement. Elliptic high-frequency IIR filters were not effective in attempting to filter out these artifacts when their amplitude was increased. In this regard, when recording ECG signals, the patient should be at rest to minimize the artifacts of electrode movement and muscle contractions.

Turinys

Santrumpų sąrašas	7
Įvadas.....	8
1. Miokardo infarktas ir jo atpažinimo būdų analizė	10
1.1. Miokardo infarkto klinikinė reikšmė.....	10
1.2. Miokardo infarkto atpažinimo iš elektrokardiogramos analizė.....	12
1.2.1. Miokardo infarkto rūšys ir jų atpažinimas.....	14
1.2.2. Automatiniai miokardo infarkto atpažinimo iš elektrokardiogramos metodai.....	16
1.2.3. Miokardo infarkto atpažinimui skirta, giliojo neuroninio tinklo analizė	18
1.3. Elektrokardiogramos signalų pirminis apdorojimas.....	21
1.4. Ant riešo dėvimi elektrokardiogramos registratoriai bei jų galimybių analizė	23
2. Miokardo infarkto atpažinimo algoritmo metodika ir duomenys	28
2.1. Duomenų bazė	28
2.2. Miokardo infarkto atpažinimo algoritmas	29
2.2.1. Elektrokardiogramos signalų pirminio apdorojimo įgyvendinimas	30
2.2.2. Dirbtinio neuroninio tinklo realizacija	32
2.3. Algoritmo patikimumo vertinimo metodika.....	33
3. Miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus elektrokardiogramoje, algoritmo tyrimas ir rezultatai	35
3.1. Dirbtinio neuroninio tinklo parametrų įtakos tyrimas	35
3.2. Miokardo infarkto atpažinimo algoritmo klasifikavimo slenksčio parinkimas.....	39
3.3. Ambulatorinių signalų simuliacija su parinktu slenksčiu, panaudojant testavimo duomenų bazę	41
Išvados	51
Literatūros sąrašas	51

Santrumpų sąrašas

Santrumpos:

MI – miokardo infarktas;

PSO – Pasaulio sveikatos organizacija;

DNT – dirbtinis neuroninis tinklas;

IŠL – Išeminė širdies liga;

DNN – gilusis neuroninis tinklas;

CNN – konvoliucinis neuroninis tinklas;

LSTM – ilgalaikės trumpalaikės atminties tinklas;

RNN – rekurentinis neuroninis tinklas;

SGD – stochastinis gradientinis nusileidimas;

SGDM – stochastinis gradientinis nusileidimas tam tikru momentu;

AdaGrad – adaptyvaus gradiento apmokymo algoritmas;

RMSProp – sklidimo vidutinės kvadratinės šaknies apmokymo algoritmas;

ADAM – adaptyvaus momento įvertinimo apmokymo algoritmas;

BW – bazinės linijos varijavimas;

PLI – maitinimo linijos trukdžiai;

AD – aukštų dažnių;

ŽD – žemų dažnių;

RIR – ribotos impulsinės reakcijos;

NIR – neribotos impulsinės reakcijos;

FDCH – fazės dažninė charakteristika;

ADCH – amplitudinė dažninė charakteristika;

Acc – tikslumas;

Se – jautrumas;

Sp – specifiškumas.

Įvadas

Remiantis 2021 m. Pasaulio sveikatos organizacijos (PSO) ataskaita, koronarinė širdies liga, dar vadinama išemine širdies liga, yra pagrindinė mirties priežastis pasaulyje. PSO tyrimas rodo, kad per metus nuo širdies ir kraujagyslių ligų miršta daugiau kaip 17,9 milijono žmonių (tai sudaro 32 % visų mirčių pasaulyje), 85 % šių mirčių sukelia miokardo infarktas (MI). penktadalis šių mirčių ištinka žmones jaunesnius nei 50 metų [1]. Eurostat atliktas tyrimas rodo, kad Europos žmonėms jaunesniems nei 75 m. dvi iš trijų mirčių gali būti išvengtos, kadangi jos nutinka per anksti ir tik dėl nesuteiktos tinkamos pagalbos laiku. Pagal šia statistiką, Europoje, net 15 % mirčių ištikusių dėl miokardo infarkto, būtų galima išvengti, laiku suteikus pagalbą žmonėms [2].

Širdies priepuolis, dar vadinamas miokardo infarktu, yra tylus, greitas ir negrįžtamas širdies raumens pažeidimas po vainikinių arterijų dalinės ar visiškos okliuzijos. Kraujo blokavimą sukelia arterijose susikaupusios aterosklerozinės plokštelės, kurias sudaro nuosėdos, cholesterolis ir kitos medžiagos. Kai plokštelė plyšta, toje vietoje greitai susidaro kraujo krešulys. Nutrūkus kraujo ir deguonies tiekimui, širdies raumeninės ląstelės pradeda žūti. Negrįžtama žala prasideda per 30 minučių nuo užsikimšimo. Dėl to širdies raumuo, paveiktas deguonies trūkumo, nebeveikia taip, kaip turėtų. Pagrindinė MI priežastis yra koronarinė širdies liga, o rizikos veiksniai yra nutukimas, diabetas, judėjimo trūkumas, didelis cholesterolio kiekis kraujyje, stresas, rūkymas, per didelis alkoholio vartojimas ir netinkama mityba [3]. Pacientai, kenčiantys nuo šios būklės, skundžiasi oro trūkumu, dideliu nuovargiu, krūtinės skausmu, kojų tinimu, negali atlikti sunkios veiklos. Lengvais atvejais rekomenduojama keisti gyvenimo būdą, sveikai mitintis ir mankštintis, o ūmiais atvejais gali prireikti neatidėliotinos medicininės pagalbos [4]. Pagal skubios pagalbos gaires, MI turi būti nedelsiant nustatytas ir lokalizuotas. Neatidėliotinas MI įvertinimas ir terapinio prioriteto nustatymas gali ne tik sumažinti subjekto mirties riziką, bet ir padėti laiku atlikti reperfuziją, kuri užkerta kelią nekrozei (širdies miocitų mirčiai) [5].

Didėjantys mirtingumo rodikliai, nuo miokardo infarkto, visame pasaulyje, suteikia svarią priežastį tirti ir plėtoti širdies ligų stebėjimo technologijas, teikiant prognostinę sveikatos priežiūrą. Mokslinių tyrimų, susijusių su automatiniu miokardo infarkto atpažinimu, naudojant kompiuterinius algoritmus, vis daugėja. Klinikinėje aplinkoje, MI diagnozuojami naudojant elektrokardiogramos (EKG) įrašus, taip pat medicininį kontekstą, įskaitant paciento simptomus, ligos istoriją ir rizikos veiksnius [6]. EKG yra kliniškai patvirtinta neinvazinė diagnostika, naudojama pacientams, su MI simptomais, tirti. EKG bangų formų pokyčiai gali veiksmingai apibūdinti miokardo išemijos ar nekrozės vietą realiuoju laiku, taip galima atpažinti užsikimšusią vainikinę arteriją ankstyvos MI diagnostikos metu. Kasdieninis EKG stebėjimas ir savalaikis MI atpažinimas yra pagrindiniai veiksniai, mažinantys mirtingumą nuo MI [7].

Pastaraisiais metais buvo padaryta pažanga diagnostikos ir medicinos srityse, tačiau širdies ligos ir toliau yra pagrindinė mirčių, apie kurias pranešama visame pasaulyje, priežastis. Populiarijant nešiojamiems / dėvimiems elektrokardiogramos registratoriams, išmaniosioms apyrankėms ar laikrodžiams, prieiga prie vieno ar daugiau kanalų EKG signalų galima asmenims ir namuose. Yra svarbu aptikti ir užkirsti kelią miokardo infarktui tiriant sumažinto derivacijų skaičiaus EKG signalus. Nešiojamas ar dėvimas elektrokardiogramos registratorius su tikslia ir pripažinta MI atpažinimo sistema, naudojant sumažinto derivacijų skaičiaus EKG signalus, dar nėra publikuotas.

Šiame darbe bus bandoma sukurti ir ištirti miokardo infarkto atpažinimo algoritmą, panaudojant sumažinto derivacijų skaičiaus EKG signalus. Algoritmo realizacijai bus naudojamas dirbtinis neuroninis tinklas (DNT). DNT apmokymui bei testavimui bus panaudota PTB diagnostinė EKG duomenų bazė, kurioje yra pateikta: sveikų savanorių EKG įrašai bei miokardo infarkto atvejais užregistruoti ambulatoriniai EKG signalai [8]. Taip pat, simuliuojant ambulatorinius EKG signalus, bus bandoma imituoti realias situacijas, galinčias pasireikšti registruojant EKG signalus su dėvimais elektrokardiogramos registratoriais, pavyzdžiui, išmaniaja apyranke.

Tikslas – sukurti ir ištirti miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus ambulatoriniuose elektrokardiogramos signaluose, algoritmą.

Darbo tikslui įgyvendinti keliami šie uždaviniai:

1. sukurti miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus elektrokardiogramoje, algoritmą;
2. ištirti sukurto algoritmo parametrų įtaką miokardo infarkto atpažinimo patikimumui;
3. ištirti elektrokardiogramos signalo charakteristikų įtaką miokardo infarkto atpažinimo patikimumui.


1. Miokardo infarktas ir jo atpažinimo būdų analizė

Šiame skyriuje aprašomas miokardo infarktas, jo klinikinė reikšmė. Analizuojama, kaip yra atpažįstamas šis sindromas. Aprašoma EKG signalų reikšmė, bei kas yra svarbiausia tokiuose signaluose, norint atpažinti miokardo infarktą. Taip pat analizuojami būdai, kaip galima tinkamai apdoroti signalus prieš bandant atpažinti MI, ir priemonės, kurios galėtų būti naudojamos MI atpažinimui.

1.1. Miokardo infarkto klinikinė reikšmė

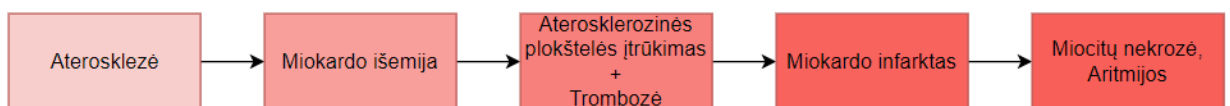
Išeminė širdies liga (IŠL) – tai ūminė ar lėtinė miokardo disfunkcija dėl reliatyviai ar absoliučiai sumažėjusio miokardo aprūpinimo arteriniu krauju. IŠL sinonimas yra koronarinė širdies liga. Šios ligos priežastis – arterijų susiaurėjimas, dalinis arba visiškas užsikimšimas dėl krešulio (trombo), arterijos susispaudimas dėl naviko, rando, kraujo išsiliejimo ir kt., šie veiksniai sukelia įvairios trukmės, laipsnio ir lokalizacijos miokardo išemiją. Miokardo išeminis pažeidimas sukelia klinikinių sindromų spektrą. Dešimtmečius trunkančių intensyvių tyrimų dėka, susidarė aiškus suvokimas apie miokardo atsaką į išeminį pažeidimą. Miokardo išemija sukelia būdingą medžiagų apykaitos ir ultrastruktūrinių pokyčių modelį, dėl kurio atsiranda negrįžtamas sužalojimas. Miokardo išeminis pažeidimas yra susijęs su pagrindiniais ląstelių mirties būdais, būtent su onkoze ir apoptoze. Įrodymai rodo, kad išeminiuose miocituose apoptotiniai ir onkotiniai mechanizmai gali vykti kartu, onkotiniai mechanizmai ir morfologija dominuoja negrįžtamo pažeidimo galutinėje stadijoje. Miokardo išemijos pažeidimo raidą įtakoja daugybė procesų. Laiku atlikta reperfuzija sukelia stiprų poveikį išeminiam miokardui, įskaitant tai, kad gali išgelbėti didelį miokardo dalelių kiekį. Išeminė širdies liga gali pasireikšti įvairiomis klinikinėmis būklėmis: staigia koronarine mirtimi, miokardo infarktu, krūtinės angina, širdies ritmo, laidumo sutrikimais ar širdies nepakankamumu [9].

Miokardo infarkto terminas atspindi miokardo nekrozę, kurią sukelia išemija, dėl perfuzijos disbalanso tarp tiekimo ir paklausos. Išemija klinikinėje aplinkoje dažniausiai gali būti nustatyta iš paciento anamnezės, taip pat, iš EKG. Prasidėjus miokardo išemijai ląstelių mirtis neįvyksta akimirksniu, tačiau užtrunka per tam tikrą ribotą laiką. Pilna, visų rizikoje esančių miokardo ląstelių, nekrozė įvyksta per apytiksliai 2–4 valandas, kartais ir ilgiau. Šis laikas priklauso nuo to ar vainikinių arterijų okliuzija yra nuolatinė ar protarpinė, nuo miocitų jautrumo išemijai, ir nuo individualaus miokardo deguonies ir maistinių medžiagų poreikio [10].



1 pav. Miokardo infarkto iliustracija [11]

Paveiksle apačioje pavaizduota supaprastinta miokardo infarkto eiga:



2 pav. Miokardo infarkto eiga

Miokardo infarkto diagnozė:

Jei yra matomi simptomai ar parodymai susiję su miokardo nekroze, atsiradusia dėl išemijos, bet kuris iš sekančių kriterijų patvirtina miokardo infarkto diagnozę [10]:

- Širdies biomarkerių pakilimo ir/arba kritimo nustatymas, kai bent viena vertė viršija viršutinės atskaitos ribos 99-ąjį procentilį, kartu su miokardo išemijos požymiais ir bent vienu iš šių požymių:
 - Išemijos simptomai;
 - EKG pasikeitimai, kurie parodo išemijos buvimą (nauji ST segmento pokyčiai, patologinių Q bangų raida);
 - Vaizdiniai įrodymai apie naują gyvybingo miokardo praradimą.
- Staigi, netikėta širdies mirtis, kai buvo miokardo išemijos simptomų, kartu su galimais ST segmento pakilimais, kairiojo pluošto šakos bloku (*Left Bundle Branch Block*) ir / arba įrodymais apie trombą vainikinėje arterijoje, kuris gali būti užfiksuotas koronarine angiografija ar autopsija.
- Ūminio miokardo infarkto pataloginiai radiniai.

Miokardo infarktą diagnozuoti dažniausiai reikia ne vieno tyrimo ar įrodymo. Kartu su pacientų anamneze ir klinikinėmis išvadomis, 12 derivacijų EKG vis dar yra lengviausiai prieinamas ir geriausias ankstyvos MI diagnozės metodas [7]. Naudojant dėvimą elektrokardiogramos registratorių


ir sumažinto derivacijų skaičiaus EKG signalus, diagnozuoti MI tikrai nėra galimybių, tačiau šiame projekte yra siekiama išbandyti galimybes atpažinti MI ankstyvoje stadijoje, kad pacientas galėtų atlikti klinikinius tyrimus laiku.

1.2. Miokardo infarkto atpažinimo iš elektrokardiogramos analizė

EKG signalas yra širdies raumenų elektrofiziologinio proceso poliarizacijos ir depoliarizacijos vaizdas. Jame pateikiama informacija apie širdies struktūrą ir jos elektrinio laidumo sistemos funkcionavimą. Tai yra gyvybiškai svarbi neinvazinė diagnostikos priemonė skirta širdies ritmo variabilumui matuoti, širdies raumens ląstelių pažeidimams ar bet kokiems širdies sutrikimams, tokiems kaip miokardo išemija ar infarktas, priešlaikiniai susitraukimai, prieširdžių anomalijos, skilvelių hipertrofija, perikarditas ir kt., nustatyti [12].


EKG signalas fiksuojamas uždėjus elektrodus ant žmogaus odos iš anksto žinomose vietose, paprastai matuojamas naudojant dešimt elektrodų, dedamų ant paciento krūtinės ir galūnių. Tokiu būdu yra gaunamas EKG signalas susidedantis iš dvylikos derivacijų [13]. 12 derivacijų EKG užfiksuoja visą širdies elektrinės veiklos vaizdą, informacija įrašoma iš 12 skirtingų perspektyvų. Apie tai galima galvoti kaip apie objektą į kurį buvo pažvelgta iš 12 skirtingų požiūrio kampų, kad būtų sukurtas vientisas vaizdas [14].

V. Einthoveno bipolinės galūnių derivacijos (I, II, III) yra trys dažniausiai naudojamos derivacijos. Kad būtų galima įsivaizduoti, kaip jos yra registruojamos galima pažvelgti į 3 pav.. Žmogaus kūną galima įsivaizduoti, kaip lygiakraštį trikampį, taip suformuojamas trikampis žinomas, kaip Einthoveno trikampis. Elektrodai yra tvirtinami prie kiekvienos trikampio viršūnės ir yra registruojama viena derivacija (I, II arba III) išilgai atitinkamos trikampio kraštinės. Iliustracijoje pavaizduoti pliuso ir minuso ženklais vaizduoja atitinkamo elektrodo poliariškumą. Elektrodai gali būti tvirtinami prie riešų ir kairės kojos čiurnos, taip pat gali būti tvirtinami prie pečių ir apatinės kairiosios pilvo dalies [15].



3 pav. Galūnių EKG derivacijų registravimo iliustracija [14]

Sustiprintos galūnių derivacijos (aVR, aVL ir aVF), kaip ir kitos derivacijos, yra gaunamos matuojant įtampą tarp elektrodų, tačiau šiuo atveju jos yra unipolinės. Tiriamosios galūnės elektrodas (diferentinis) sujungiamas su teigiamu galvanometro poliumi, o indiferentinis (kitų dviejų, netiriamųjų, galūnių elektrodai) su neigiamu galvanometro poliumi, taip kaip pavaizduota 4 pav.. Šiuo atveju kiekvienos derivacijos teigiamas polius yra prie atitinkamos galūnės, o neigiamas polius yra lokalizuotas tarp kitų dviejų galūnių. Taip registruojamo signalo kryptis eina per širdį tiesiai link tiriamosios galūnės [16, 15].



4 pav. Sustiprintų galūniinių EKG derivacijų registravimo iliustracija [14]

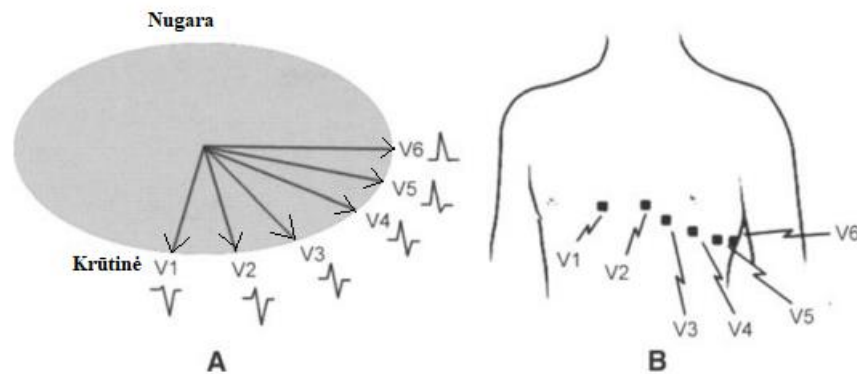
Taip pat *aVR*, *aVL* ir *aVF* derivacijos gali būti tiesiog išskaičiuojamos iš standartinių bipolinių derivacijų (*I*, *II*, *III*) pagal 1, 2, 3 formules [16, 15]:

$$-aVR = (I + II)/2 \quad (1)$$

$$aVL = (I - III)/2 \quad (2)$$

$$aVF = (II + III)/2 \quad (3)$$

Iš tradiciškai registruojamų 12 derivacijų liko dar šešios, jos vadinamo krūtininėmis derivacijomis. Šios derivacijos taip pat yra unipolinės, panašios į sustiprintas galūnines derivacijas, tačiau projektuojamos į skersinę plokštumą. Taip pat krūtininės derivacijos, kaip neutralų derivacijos atskaitos tašką, naudoja visus tris galūnių elektrodus, kurie jungiasi su neigiamu poliumi. Šis atskaitos taškas gaunamas krūtinės centre. Tuo tarpu 6-i teigiami elektrodai yra išdėstomi ant krūtinės, kaip pavaizduota 5 pav. B dalyje. 5 pav. A dalyje pavaizduota skersinė plokštuma ir krūtininių derivacijų kryptys, kartu su gaunama atitinkama derivacijos forma.



5 pav. (A) santykinė šešių krūtininių derivacijų padėtis ir kryptis skersinėje plokštumoje, kartu su gaunama atitinkama derivacijos forma, (B) Priekinis žmogaus krūtinės vaizdas su pavaizduotomis elektrodų pozicijomis [15]

6 pav. pavaizduota širdis ir gautas EKG signalas. Elektrinis signalas prasideda sinusiniame mazge (1), kuris yra dešiniajame prieširdyje, ir keliauja į dešinįjį ir kairįjį prieširdžius, dėl gauto impulso prieširdžiai susitraukia ir pumpuoja kraują į skilvelius. Šis elektrinis impulsas EKG signale matomas kaip P banga [15].


Elektrinis signalas iš prieširdžių į skilvelius pereina per atrioventrikulinį (AV) mazgą (2). Dėl šio mazgo signalas sulėtėja, todėl skilveliai spėja prisipildyti krauju. Šis sulėtėjęs signalas atrodo kaip plokščia linija EKG signale tarp P bangos pabaigos ir Q bangos pradžios. PR segmentas, kuris yra

vaizduojamas nuo P bangos pradžios iki QRS komplekso pradžios, rodo elektros laidumą per prieširdžius ir elektrinio impulso uždelsimą AV mazge [15].

Po to, kai signalas palieka AV mazgą, jis keliauja keliu, vadinamu Hiso pluoštu (3), į dešinę ir kairę pluošto šakas (4, 5). Signalas sklinda per širdies skilvelius, todėl jie susitraukia ir pumpuoja kraują į plaučius ir kūną. Šis signalas įrašomas kaip Q, R, S bangos, EKG signale. Kadangi šios bangos atsiranda greitai vienas po kito, jos paprastai laikomos QRS kompleksu [15].

Po to skilveliai atsistato į normalią elektrinę būseną, tai parodo T banga. Raumenys atsipalaiduoja, todėl prieširdžiai prisipildo krauju ir visas procesas kartojasi su kiekvienu širdies dūžiu. ST segmentas jungia QRS kompleksą ir T bangą ir reiškia skilvelių elektrinio atsipalaidavimo pradžią [15].

QT intervalas reiškia laiką, per kurį skilveliai stimuliuojami ir atsigauna po stimuliacijos. Šis intervalas sutrumpėja esant greitesniam širdies ritmui ir pailgėja esant lėtesniam [15].



6 pav. Širdies elektrinio impulso kelio iliustracija bei EKG signalas [17]

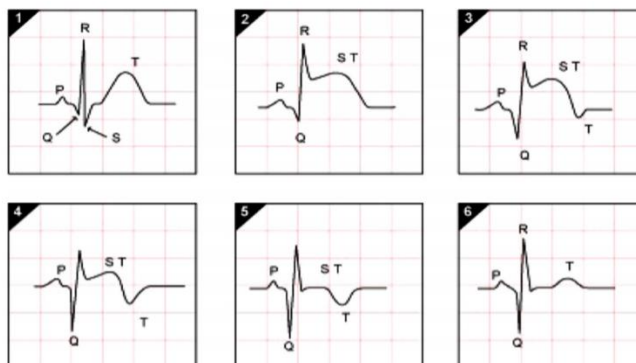
EKG yra neatsiejama diagnostinio darbo dalis, ypač dirbant su pacientais, kuriems įtariamas miokardo infarktas. Elektros srovė normaliai sveikai širdžiai teka nuo teigiamo potencialo iki neigiamo potencialo. Jei, dėl kokios nors priežasties, bus paveiktas elektrinių signalų srautas miokarde, tai atsispindės EKG signale. Pavyzdžiui, MI būklėje, elektrinio signalo srautas per infarkto zoną yra paveiktas dėl audinio mirties toje širdies raumens dalyje. Taigi, jei infarktas sutrikdys srovės srautą, EKG įrašas parodys neįprastas elektrines bangas [7].

Ūmūs ar besivystantys ST segmento formos pokyčiai ir Q bangos pokyčiai, gali leisti gydytojui numatyti su infarktu susijusią arteriją, įvertinti rizikos grupėje esantį miokardo kiekį ar net nustatyti infarkto įvykio dieną. Miokardo išemijos ar infarkto EKG anomalijos gali būti pastebimos PR segmente, QRS komplekse, ST segmente arba T bangoje. Ankstyviausios miokardo išemijos apraiškos yra tipiniai T bangos ir ST segmento pokyčiai. Staigus T bangos amplitudės išaugimas su pastebimomis simetriškomis T bangomis bent dvejose gretimose derivacijose yra išankstinis ženklas prieš prasidedant ST segmento pakilimui [10].

1.2.1. Miokardo infarkto rūšys ir jų atpažinimas

Miokardo infarktas gali pasireikšti su ST segmento pakilimu (*ST Elevation Myocardial Infarctions - STEMI*) ir be jo (*non-ST Elevation Myocardial Infarctions - non-STEMI*). Non-STEMI pasireiškia

per ST segmento sumažėjimą (depresiją) arba T bangos inversiją. STEMI turi kitokius EKG požymius priklausomai nuo laiko, kuris prabėgo prasidėjus miokardo infarktui. Ankščiausias požymis yra aštrus T bangos pakilimas. Vėliau po apytiksliai keleto minučių seka ST segmento pakilimas. Praėjus kelioms valandoms pasireiškia patologinė Q banga ir T banga invertuojasi [6]. Paveiksle apačioje yra pademonstruoti EKG signalo pokyčiai dėl STEMI.




7 pav. EKG signalo pokyčiai dėl STEMI [13]

Širdis yra dalinama į dalis pagal sienas: priekinė (*Anterior*), galinė (*Posterior*), apatinė (*Inferior*), dešinė (*Septal*), kairė (*Lateral*). Miokardo infarktas yra skirstomas pagal vietą širdyje. Priklausomai nuo arterijų, kurioms pasireiškė okliuzija, gali būti pažeista tam tikra širdies raumens, miokardo, dalis. Taigi, miokardo infarktas yra skirstomas pagal pažeisto miokardo vietą, pavyzdžiui apatinis MI, priekinis MI ir kt. Jei miokardo infarktas pasireiškė su ST pakilimu, MI vieta ar koronarinė arterija, kuriai pasireiškė okliuzija, gali būti nustatoma pagal ST segmento pakilimo vietą EKG signale (pagal EKG derivaciją) [7]. Pavyzdžiui, ST pakilimas ir (arba) ūmiai padidėjusios T bangos yra matomos:

1. vienoje ar keliose priešakinėse derivacijose (nuo V1 iki V6) taip pat I ir aVL derivacijose su ūminiu priekinės ar priekinės-kairiosios sienos (*Antero-Lateral*) infarktu;
2. nuo V1 iki V4 derivacijose su priekine-dešinėsios sienos (*Antero-Septal*) infarktu;
3. V5, V6, I, aVL derivacijose su kairiosios sienos (*Lateral*) infarktu;
4. dešiniojo krašto priešakinėse derivacijose su dešiniojo skilvelio infarktu.

Galinės sienos infarktą, kuris sukelia ST pakilimą derivacijose esančiose galinėje širdies dalyje, gali sukelti dešinės vainikinės arterijos arba kairiosios cirkumfleksinės arterijos pažeidimai. Šie pažeidimai gali sukelti tiek apatinės, tiek užpakalinės-šoninės miokardo dalies traumas, kurias netiesiogiai galima atpažinti iš abipusės ST depresijos derivacijose nuo V1 iki V3. Panašūs ST pokyčiai taip pat gali būti pirminės, priekinės subendokardinės išemijos, EKG išraiška [7, 18].



8 pav. EKG derivacijos ir jų kryptys širdies atžvilgiu [14]

Dažniausiai randama susiaurėjusi priekinė nusileidžianti kairiosios koronarinės arterijos (*Left Anterior Descending (LAD)*) šaka. Dėl to ji kartais vadinama „likimo“ arba „našlių“ arterija. Pasireiškus LAD arterijos stenozėi, kuri sparčiai tampa kritinė, miokardas praranda gyvybiškai reikalingas medžiagas. Našlių infarktas – širdies priekinės sienos miokardo infarktas. Šis sindromas yra sunkiai atpažįstamas pagal simptomus, o pasekmės gali būti mirtinos. Patyrus našlių infarktą išgyvenimo tikimybė yra maža, jei laiku nesuteikiama profesionali pagalba. EKG anomalijų atpažinimas yra svarbus, nes parodo prieš infarktine širdies vainikinių arterijų ligos stadiją, kuri negydoma dažnai pereina į priekinės miokardo sienos infarktą [19].

1.2.2. Automatiniai miokardo infarkto atpažinimo iš elektrokardiogramos metodai

Pastaruju metu daugelis tyrėjų prisidėjo nustatant aritmijas, tokias kaip MI, priešlaikiniai skilvelių susitraukimai, prieširdžių virpėjimas, išemija, naudojant EKG modelius. Taikant automatinio MI atpažinimo metodus, mašininis mokymas yra plačiai tiriamas siekiant analizuoti ir diagnozuoti širdies anomalijas. Kadangi būdingi signalų bruožai yra svarbiausi tradicinių, mašininio mokymu pagrįstų, klasifikatorių parametrai, mokslininkai naudojo įvairių tipų bruožus, kad pagerintų klasifikatorių veikimą. Kai kurie dažniausiai naudojami signalų bruožai yra: bangelių transformacija (*Wavelet Transform – WT*) [7, 20, 21, 22], pagrindinių komponentų analizė (*Principal Component Analysis – PCA*) [23], linijinė diskriminantinė analizė (*Linear Discriminant Analysis – LDA*) [20], empirinis režimo skaidymas (*Empirical Mode Decomposition – EMD*) [24], laiko srities bruožai [25], statistinės savybės [21], laiko ir dažnio srities ypatybės [26], galios spektrinis tankis (*Power Spectral Density – PSD*) ir diskretinė Furjė transformacija (DFT) [27], Hilberto transformacija (HT) [28].

Laiko srities bruožus, tokius kaip T bangos amplitudė, Q banga ir ST segmento lygio nuokrypis, kardiologai paprastai laiko MI rodikliais. Kardiologai sugeba interpretuoti laiko srities ypatybes, tačiau kartais, dėl triukšmų atsirandančių EKG signaluose, tai padaryti yra sudėtinga. Jei laiko domeno bruožai nėra tiksliai išgaunami, tai turės įtakos klasifikavimo tikslumui. Norint, laiko srityje, efektyviai išrinkti bruožus iš EKG, reikia efektyvių signalo apdorojimo būdų ir tam tikro priešlaikinio apdorojimo, kad būtų pašalintas triukšmas [7]. Laiko srities metodai skirti MI atpažinti, pagrįsti specifinės bangos amplitude, T bangos intervalu, Q bangos intervalu ir ST segmentu, rodo gerus rezultatus, tačiau jie priklausomi nuo specifinės bangos išskyrimo tikslumo [13].

Bruožų išskyrimas iš EKG bangų formų yra esminė užduotis, kuri atliekama klasifikuojant EKG aritmijas taikant tradicinius mašininio mokymo metodus. Norint iš EKG duomenų bazės ištraukti signalų bruožus, pagal pacientus ar klinikinius įrašus, tai padaryti reikalauja daug sunkaus darbo ir laiko. Be to, neteisingi ar neadekvatūs ištraukti bruožai gali paveikti klasifikavimo tikslumą, gali iškreipti rezultatus. Didėjant duomenų kiekiui, laikas ir pastangos, kurių reikia norint išgauti signalų bruožus, taip pat didėja. Norėdami išspręsti visas šias problemas, mokslininkai, inžinieriai ir tyrinėtojai sugalvojo pasinaudoti giliuoju neuroniniu tinklu (*Deep Neural Network* – DNN). DNN technologija automatiškai išskiria signalų bruožus be žmogaus įsikišimo arba nenaudodama papildomų įrankių ar metodų. DNN taip pat gerai veikia naudojant dideles duomenų bazes, labai sumažina pastangas ir laiką, kurie buvo skirti išgaunant bruožus iš signalų. Per pastaruosius kelerius metus giliuoju mokymusi pagrįsti DNN metodai tapo plačiai ir dažniausiai naudojamais įrankiais medicinos sveikatos priežiūros srityje, ypač biomedicininį signalų ir vaizdo apdorojimo srityje.

Pastaruosius kelerius metus buvo naudojami skirtingi giliuoju mokymusi pagrįsti DNN metodai MI požymių išskyrimui ir aptikimui iš EKG signalų, tokie kaip: konvoliucinis neuroninis tinklas (*Convolutional Neural Network* – CNN) [29, 30, 31, 32], rekurentinis neuroninis tinklas (*Recurrent Neural Network* – RNN) [33], ilgalaikės trumpalaikės atminties tinklas (*Long Short-Term Memory* – LSTM) [34], liekamasis tinklas (*Residual Network* – ResNet) [35], Generatyvūs priešpriešiniai tinklai (*Generative Adversarial Networks* – GAN) [36], automatiniai kodavimo įrenginiai (*Autoencoders*) [37] ir t.t.

Kora [38] pasiūlė hibridinį „Firefly“ algoritimą miokardo infarktui aptikti pagal EKG bangų formas. Užuo išskyręs signalų charakteristikas naudojant tradicines technologijas, neapdorotas EKG signalas buvo tiesiogiai optimizuotas naudojant hibridinį tinklą sudėtą iš „Firefly“ algortimo ir dalelių spiečiaus optimizavimo (*Particle Swarm Optimization*) (sutrumpintai – FFPSO). Naudojant hibridinį FFPSO algoritimą ir Levenberg‘o Marquardt‘o neuroninį tinklą (LMNN), kaip klasifikatorių, gautas MI aptikimo tikslumas – 99,3 %, specifiškumas – 98,7 % ir jautrumas – 99,97 %. Kora naudojo MIT-BIH ir NSR duomenų bazes, o iš signalų ištraukė širdies dūžio segmentus, kuriuos ir klasifikavo. Acharya ir kt. [29] pasiūlė automatizuotą CNN pagrįstą algoritimą, automatiniam MI aptikimui iš EKG signalų. Tyrimas skirtas numatyti MI pagal triukšmingą ir netriukšmingą EKG bangos formą. Naudojant triukšmingą duomenų bazę MI buvo aptinkamas 93,53 % tikslumu, o naudojant filtruotus EKG signalus gavo 95,22 % tikslumą. Šiuo atveju tyrėjas naudojo PTB duomenų bazę, o klasifikavo širdies dūžio segmentus. Liu ir kt. [30] pristatė miokardo infarkto (MI) aptikimo algoritimą, naudojant CNN ir apdorojant daugiakanalius EKG signalus. Jų daugiakanalis CNN modelis naudoja 2D konvoliuciją, kuri gali panaudoti visų EKG derivacijų charakteristikas, taip pat naudoja 1D filtrą vietiniams optimaliems signalų požymiams išskirti. Algoritmas buvo įvertintas naudojant PTB diagnostinę EKG duomenų bazę, iš kurios buvo naudojami tik priekinio (*Anterior*) miokardo infarkto atveju užregistruoti signalai bei sveikų savanorių signalai. Algoritmas klasifikuodamas širdies dūžio segmentus pasiekė 95,40 % jautrumą, 97,37 % specifiškumą ir 96 % tikslumą. Sharma ir kt. [39] pasiūlė naują MI klasifikavimo metodą, naudojant optimalių biortogonalų filtrų banką. K – artimiausio kaimyno (*K – Nearest Neighbour* – KNN) klasifikatorius buvo naudojamas MI klasifikavimui, tiriant triukšmingus EKG signalus, tikslumas buvo 99,62 %, o kai EKG signalai buvo apdoroti, pasiektas 99,74 % tikslumas. Šiame tyrime buvo naudojami širdies dūžio segmentai, deja tyrėjas neaprašo, kaip buvo paskirstyta duomenų bazė, o tai leidžia suprasti, kad algoritmas buvo apmokytas ir testuotas panaudojant tuos pačius duomenis. Liu ir kt. [40] pristatė naują hibridinį CNN ir LSTM tinklais pagrįstą metodą – „Multiple-Feature-Branch Convolutional Bidirectional Recurrent

Neural Network“ (MFB-CBRNN), skirtą MI atpažinimui pagal 12 derivacijų EKG, ir gavo bendrą 93,08 % tikslumą. Šiame tyrime taip pat buvo klasifikuojami širdies dūžio segmentai. Feng ir kt. [34] naudojo hibridinį CNN-LSTM tinklą MI klasifikavimui, jie taip pat naudojami širdies dūžio segmentais pasiskolintais iš PTB duomenų bazės, deja tyrėjai nemini ar duomenys algoritmo apmokymui bei testavimui buvo paskirstyti atsižvelgiant į pacientus, nes PTB duomenų bazėje pacientams buvo užregistruoti nuo 1 iki 5 EKG signalų. Algoritmas pasiekė 95,4 % tikslumą, 98,2 % jautrumą ir 86,5 % specifiškumą.

1.2.3. Miokardo infarkto atpažinimui skirto, giliojo neuroninio tinklo analizė

Anksčiau, miokardo infarktui atpažinti, buvo naudojami įvairių tipų dirbtiniai neuroniniai tinklai. Tokiai užduočiai spręsti tinkamas neuroninis tinklas yra LSTM. Būtent LSTM tinklai yra plačiai išbandyti ir patikrinti klasifikuojant laikui bėgant kintančius signalus, tokius kaip tekstas, kalba ar vaizdo įrašas [41] [42] [43]. Šiame tyrime yra siekiama atpažinti miokardo infarktą iš elektrokardiogramų, taigi yra reikalingas laike kintančių signalų apdorojimas bei svarbių signalo bruožų atpažinimas. LSTM tinklas yra pranašesnis už kitus rekurentinius neuroninius tinklus, nes išsprendžia dingstančių gradientų problema, gali saugoti svarbią informaciją nepaisant prabėgusio laiko tarp svarbių įvykių. Taip pat, atlikti MI atpažinimo tyrimai, panaudojant LSTM tinklą, rodo gerus rezultatus [34] [42] [44].

Naudojant tik LSTM neuroninį tinklą, apmokymas trunka ilgai, kadangi tinklas saugo visą svarbią informaciją apmokymo metu. Martin ir kt. [42] savo tyrime naudojo 3 sluoksnių LSTM tinklą, paslėptųjų neuronų (*Hidden Units*) skaičius sluoksniuose atitinkamai – 100;100;1, apmokymo spartos konstanta (*Learning Rate*) – 0,1. Apmokymui jie naudojo 64-bit Windows 10 PC su AMD FX-8350 8 branduolių procesoriumi, 32 GB RAM atmintimi ir NVIDIA GeForce GTX1070 vaizdo plokšte. Apmokant tokį tinklą, kiekviena apmokymo epocha truko apytiksliai 5 h.

Atliekant šį tyrimą, kad būtų sumažinta apmokymo trukmė bei saugomų duomenų kiekis, buvo panaudotas CNN-LSTM hibridinis gilusis neuroninis tinklas. CNN tinklo pagalba buvo ištrauktos svarbiausios signalų charakteristikos ir sumažintas duomenų kiekis, dėl to LSTM tinklui nebereikia apdoroti perteklinės informacijos.

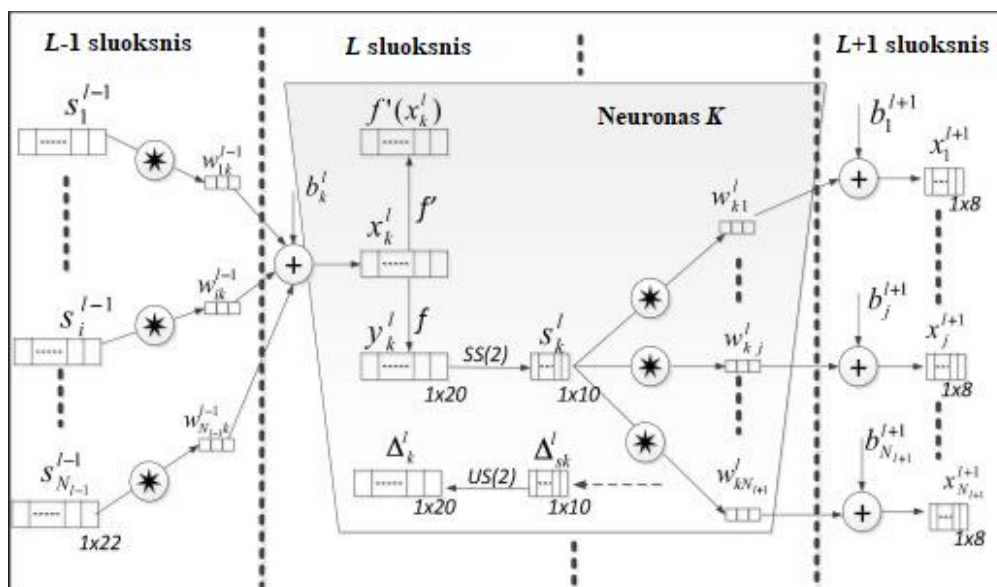
Konvoliucinis neuroninis tinklas:

Iš pradžių CNN buvo sukurtas kraštų aptikimo, segmentavimo ir objektų aptikimo užduotims atlikti, kompiuterinio matymo srityje. Tačiau dėl savo paprastos architektūros ir plataus pritaikomumo, jis dabar naudojamas beveik visose mašininio mokymo srityse, tokiose kaip kompiuterinis matymas, teksto atpažinimas, duomenų gavyba, kalbos ir signalų apdorojimas, vaizdo ir objektų aptikimas ir daugelyje kitų sričių. CNN taip pat žinomas ir dėl jo gebėjimo generuoti būdingas charakteristikas be žmogaus įsikišimo iš 1D, 2D ar 3D duomenų [44].

Gilieji 2D CNN, su dideliu skaičiumi paslėptųjų sluoksnių bei milijonais parametru, turi galimybę išmokti atpažinti sudėtingus objektus ar modelius, jie gali būti apmokomi su didelėmis vizualinių duomenų bazėmis. Dėl šių unikalių gebėjimų jie tampa pagrindiniu įrankiu įvairioms 2D signalų, pavyzdžiui, vaizdų ir vaizdo kadru, inžinerinėms programoms. Tuo tarpu neseniai buvo pasiūlytas 1D CNN, kuris pasiekė aukštą našumo lygį keliuose pritaikymo srityse, tokiose kaip: individualizuotas biomedicininis duomenų klasifikavimas, ankstyvos diagnostikos nustatymas, sveikatos būklės stebėjimas, anomalijų aptikimas, elektros variklių gedimų aptikimas. Kitas svarbus privalumas yra

tai, kad tinklas gali būti realizuotas naudojant nebrangią įrangą, o duomenys apdorojami realiu laiku dėl paprastos ir kompaktiškos 1D CNN konfigūracijos, atliekančios tik 1D konvoliucijas (skaliarines daugybas ir sudėtis) [45].

Trijų sluoksnių 1D CNN pavaizduotas apačioje (9 pav.). Kaip parodyta paveiksle, naudojamo 1D filtro dydis yra 3, o telkimo faktorius (SS) yra 2. Neuronas K , paslėptajame CNN sluoksnyje L , pirmiausiai atlieka duomenų sekų kovoliucijas, kurių suma yra praleidžiama per aktyvacijos funkciją (f), vėliau atliekama telkimo operacija. Kitame žingsnyje, CNN sluoksnis apdoroja 1D duomenis ir mokinasi ištraukti tokias charakteristikas, kurios yra naudojamos klasifikavime. Tiek charakteristikų ištraukimo, tiek klasifikavimo operacijos yra sujungtos į vieną procesą, kurį galima optimizuoti, kad būtų maksimaliai padidintas klasifikavimo našumas [45].



9 pav. Trijų sluoksnių 1D konvoliucinio neuroninio tinklo pavyzdys [45]

Ilgalaikės trumpalaikės atminties tinklas:

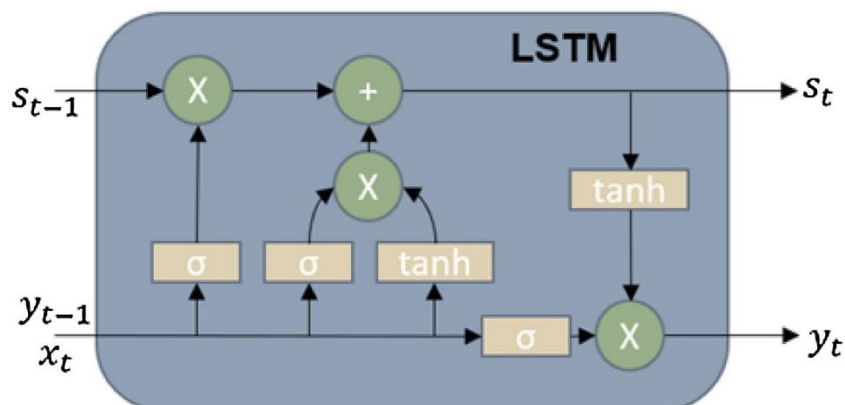
LSTM yra dirbtinio, rekurentinio neuroninio tinklo (RNN) architektūra, naudojama giliojo mokymo srityje. Skirtingai nuo standartinių tiesioginio sklidimo neuroninių tinklų, tokių kaip CNN, LSTM tinklas turi grįžtamąjį ryšį. Jis gali apdoroti ne tik atskirus duomenų taškus (pvz., vaizdus), bet ir išsias duomenų sekas (pvz., kalbą ar vaizdo įrašą) [44].

LSTM tinklai puikiai tinka klasifikuoti, apdoroti ir prognozuoti remiantis laike kintančiais duomenimis, nes tarp svarbių įvykių laiko eilutėje gali būti nežinomos vėlavimų trukmės. LSTM buvo sukurti siekiant išspręsti nykstančių gradientų problemą, su kuria galima susidurti apmokant tradicinius RNN. Tradiciniuose RNN tinkluose, seniai įvykę reikšmingi įvykiai turi mažėjančią įtaką dabartiniams sprendimams. Santykinis neįtakumas vėlavimo tarp svarbių įvykių trukmei yra LSTM pranašumas prieš tradicinius RNN ir kitus duomenų sekos mokymosi metodus, daugelyje pritaikymo sričių [42].

LSTM tinklo neurono struktūros pavyzdys pavaizduotas žemiau (10 pav.). LSTM neurono įėjime turi būti paduodama praeities celės būseną (s_{t-1}), žinoma kaip ilgalaikė tinklo atmintis, prieš tai buvęs išėjimo vektorius (y_{t-1}), žinomas kaip praeities paslėptoji būseną, ir dabartinis įėjimo vektorius (x_t), kad būtų suformuota nauja celės būseną (s_t) ir naujas išėjimo vektorius (y_t). LSTM naudoja „vartus“, kurie kontroliuoja informaciją, patenkančią į tinklą, saugomą arba išeinančią iš tinklo. LSTM neurone

yra trys vartai: užmiršimo, įėjimo ir išėjimo. Šiuos vartus galima prilyginti filtrams. Užmiršimo vartai nusprendžia kurie celės būsenos bitai yra svarbūs, atsižvelgiant į praeities vektorių ir naują įėjimo vektorių. Šie vartai yra sigmoidinė funkcija (σ), kuri generuoja vektorių $[0,1]$. Reikšmingus duomenis praleidžia (filtro vertė artėja link 1), o nereikšmingus duomenis pašalina (filtro vertė artėja link 0). Užmiršimo vartų vektorius yra dauginamas su praeities celės būseną, taip nustatydamas kurį ilgalaikės atmintis turėtų būti užmiršta. Kitame žingsnyje dalyvauja naujos atminties tinklas ir įėjimo vartai, kurie sprendžia kokia informacija turi būti pridėta prie tinklo ilgalaikės atminties (celės būsenos), atsižvelgiant į praeities vektorių ir naują įėjimo vektorių. Naujos atminties tinklas nusako, kaip stipriai turi būti keičiamas ilgalaikės atminties bitas, priklausomai nuo įėjimo duomenų. Šiuo atveju tai yra filtras naudojantis hiperbolinio tangento funkciją (\tanh), kurio vektorius yra tarp $[-1, 1]$. Tuo tarpu įėjimo vartai nusako, kurie naujos atminties vektoriaus komponentai yra reikšmingi ir juos reikia įsiminti (šiuo atveju tai yra sigmoidinės funkcijos filtras $[0, 1]$). Pabaigoje, kai ilgalaikė atmintis yra atnaujinta, dalyvauja išėjimo vartai, kurie generuoja išėjimo vektorių, atsižvelgiant į atnaujintą ilgalaikę atmintį (kuri pagal reikšmingumą apdorojama \tanh filtru $[-1, 1]$), praeities vektorių ir dabarties vektorių (kurie relizuoja išėjimo vartus, sigmoidinį filtrą $[0, 1]$) [42, 46].

LSTM neuronas gali sudaryti klasifikavimo prognozę kiekvienam įvesties laiko žingsniui ir taip generuoti laikui bėgant besikeičiančias klasifikacijas, kurios tampa tikslesnės ir galutinės, kai apdorojama daugiau signalo imčių [42].



10 pav. Ilgalaikės trumpalaikės atminties tinklo neuroso struktūros pavyzdys [42]

Pastaruojų metu galima pastebėti, kad gilieji neuroniniai tinklai yra naudojami vis dažniau ir plačiau, įvairiose srityse. Tokių tinklų optimizavimas darosi vis sudėtingesnis, nes kuriami neuroniniai tinklai darosi vis gilesni, o apdorojamų duomenų kiekiai vis didėja. Taigi, per pastaruosius metus DNN optimizavimo algoritmai taip pat patobulėjo [47].

stochastinio gradientinio nusileidimo (Stochastic Gradient Descent– SGD) apmokymo algoritmas seka neigiamą gradientą, kad nustatytų praradimų funkcijos minimumą. Naudojant stochastinį gradientinį nusileidimą, praradimo funkcijos išvestinė nėra apskaičiuojama. Vietoj to, ji įvertinama panaudojant mažą duomenų paketą. Tai reiškia, kad ne visada einama optimalia kryptimi, nes funkcijos duomenys gali būti triukšmingi. Stochastinio gradientinio priartėjimo tam tikru momentu (Stochastic Gradient Descent With Momentum – SGDM) apmokymo algoritmas yra toks pat SGD algoritmas, tik šiuo atveju praradimų funkcija yra apskaičiuojama eksponentiškai įvertintus vidurkius. Taip yra gaunama tikslesnė praradimų funkcija, net ir esant triukšmingiems duomenims. Tai yra viena iš priežasčių, kodėl SGDM gali veikti geriau nei klasikinis SGD apmokymo algoritmas [47].

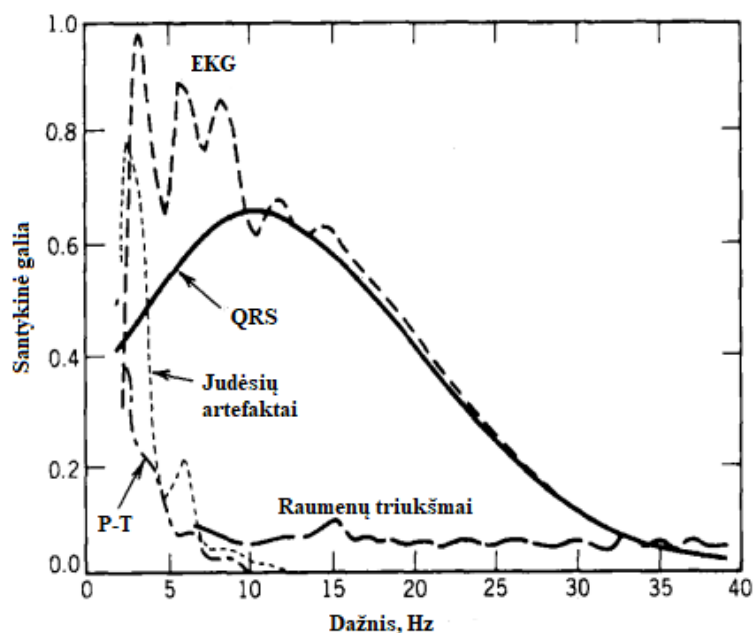
Adaptyvaus gradiento (*Adaptive Gradient* – AdaGrad) apmokymo algoritmas individualiai adaptuoja mokymosi spartą pagal modelio parametrus, panaudojant žinias apie ankstesnių gradientų kvadratinės vertes. Parametrų, turinčių didžiausią dalinę praradimų išvestinę, mokymosi sparta greitai mažėja, o parametrų, kurių dalinės praradimų išvestinės yra mažos, mokymosi sparta mažėja santykinai. AdaGrad naudoja papildomą kintamąjį gradientų kaupimui. Šio algoritmo pradžioje gradientų kaupimo kintamasis inicijuojamas kaip nulis, o gradientas apskaičiuojamas iš mažo duomenų paketo. Tačiau AdaGrad turi trūkumų, mokymosi sparta gali būti sumažinta iki tokio lygio, kad algoritmas tiesiog sustoja, nepasiekęs globalaus optimumo [47].

Sklidimo vidutinės kvadratinės šaknies (Root Mean Square Propagation – RMSProp) apmokymo algoritmas yra modifikuota AdaGrad versija. Tik šiuo atveju gradiento kaupimas yra pakeičiamas į eksponentinių svorių slenkantį vidurkį. AdaGrad sumažina mokymosi spartą pagal visą kvadratinio gradiento istoriją, tuo tarpu, RMSProp naudoja eksponentiškai mažėjantį vidurkį tam, kad vertės iš tolimos praeities būtų panaikintos. Tai leidžia algoritmui konverguoti greičiau [47].

Adaptyvaus momento įvertinimo (*Adaptive Moment Estimation* – ADAM) apmokymo algoritmas yra plačiai naudojamas giliųjų neuroninių tinklų apmokymui. Šis algoritmas adaptuoja mokymo spartą, atsižvelgdamas į skirtingus parametrus, iš pirmuoju ir antruoju momentu apskaičiuotų gradientų. ADAM apjungia privalumus iš AdaGrad, kuris gerai veikia su retais gradientais, ir RMSProp, kuris gerai veikia su nestacionariais parametrais. Algoritmas atnaujina eksponentiškai slenkančius gradientų vidurkius ir kvadratinis gradientus, kur hiperparametrai kontroliuoja šių slankiųjų vidurkių eksponentinį mažėjimo greitį. Patys slenkantys vidurkiai yra gradiento pirmojo momento vertės (vidurkiai) ir antrojo momento vertės (necentruota dispersija) [47].

1.3. Elektrokardiogramos signalų pirminis apdorojimas

Mašininis mokymusi pagrįstas klasifikatoriaus veikimas priklauso nuo išankstinio EKG signalo apdorojimo. Įvairiais elektrokardiogramos registratoriais gauti EKG signalai yra užteršti triukšmais tokiais kaip: bazinės linijos varijavimas (*Baseline Wander* – BW), maitinimo linijos trukdžiai (*Power Line Interference* – PLI), triukšmai dėl elektrodų kontakto, judėjimo artefaktai ar raumenų susitraukimų artefaktai. Dėl šių triukšmų bei artefaktų automatiniai diagnostiniai įrankiai gali tapti nepatikimi. PLI yra 50 arba 60 Hz triukšmas, kurį daugiausia sukelia elektromagnetiniai elektros linijos trikdžiai, elektromagnetinis laukas dėl netoliese esančių prietaisų, netinkamas paciento ar elektrokardiografo įžeminimas. BW yra žemo dažnio triukšmas (0,05-0,7Hz), esantis neapdorotame EKG signale, dėl bet kokio elektrodų judėjimo, raumenų judėjimo ar kvėpavimo. BW triukšmas persidengia su ST segmento dažnių juosta (0,05Hz-60Hz) ir jį iškraipo, taip pat gali sukelti R smailių nukirpimą. Tuo tarpu PLI daro įtaką P ir T bangų bei kitų EKG bruožų atpažinimui, didelės galios PLI gali visiškai užgožti EKG signalą. Taigi, prieš kuriant klasifikavimo modelį BW ir PLI turi būti nuslopinami nepašalinant jokių reikšmingų EKG atributų [48, 49].



11 pav. Tipinis EKG signalo galios spektras [50]

Bėgant metams buvo ištirti įvairūs metodai, kaip pašalinti BW ir PLI iš EKG signalų. Tarp jų standartinis BW pašalinimo būdas yra aukštų dažnių filtras [51], o PLI įprastai šalinamas naudojant užtvarinį filtrą [52]. Įdiegus ribotos impulsinės reakcijos filtras [51], dėl didelės filtro eilės ir ilgo impulsinio atsako, skaičiavimai užtrunka ilgiau ir pasireiškia virpesių „ripples“ efektai. Tuo tarpu neribotos impulsinės reakcijos filurai išsprendžia prieš tai minėtas problemas, tačiau jie gali sukelti netiesinį fazės iškraipymą [50]. Ši problema sprendžiama naudojant nulinės fazės dvikrypčius filtras, tačiau naudoti aukštos eilės neribotos impulsinės reakcijos filtras yra nepatartina, kadangi tokiu atveju fazės charakteristika yra per daug netiesiška.

Atlikti tyrimai su skirtingais neribotos impulsinės reakcijos (NIR) filtrais, norint apdoroti EKG signalus ir pašalinti bazinės linijos varijavimą bei maitinimo linijos trukdžius, parodė, kad iš visų standartinių NIR filtrų, eliptiniai yra tinkamiausi šiam darbui. Tyrimų autoriai teigia, kad eliptiniai filurai pašalina triukšmus iš EKG signalų geriau nei Chebyshev'o I, Chebyshev'o II ar Butterworth'o NIR filurai [50, 53].

Kaip buvo minėta 1.2 poskyryje, MI gali būti atpažįstamas iš ST segmento EKG signale. MI yra svarbus veiksnys, lemiantis ST segmento pokyčius. ST segmento padidėjimas per 0,1 mV arba sumažėjimas per 0,05 mV, palyginti su pradiniu lygiu, paprastai laikomas nenormalia ST morfologija [54]. Atsižvelgiant į tai galima suprasti, kaip svarbu išsaugoti ST segmentą nepažeistą, norint nufiltruoti BW triukšmą.

Aukštų dažnių (AD) filtro, skirto BW pašalinimui iš EKG signalo, pjūvio dažnio pasirinkimas yra lemtingas faktorius, norint užtikrinti, kad nebūtų pažeidžiami EKG signalo žemų dažnių komponentai, tokie kaip ST segmentas, QT segmentas. Pagal Amerikos širdies asociacijos rekomendacijas, įprastai, tokio AD filtro pjūvio dažnis turėtų būti parenkamas – 0,05 Hz, bet jeigu yra naudojamas tiesinis filtras su vienu poliumi ir fazės vėlavimas pakankamai trumpas, sąlygos gali būti sušvelnintos ir pjūvio dažnis parenkamas iki 0,67 Hz [55]


Afsar ir kt. [56] bandydami nustatyti ST segmento pakitimus EKG signaluose, bazinės linijos varijavimą šalino naudodami 6 eilės Butterworth NIR AD filtrą su pralaidumo juostos dažniu $f_{pass} =$

0.6 Hz ir slopinimo juostos dažniu $f_{stop} = 0,4$ Hz panaudojant nulinės fazės dvikryptį filtravimą, pirmyn ir atgal. Aukštų dažnių triukšmus šalino panaudodami 12 eilės Butterworth NIR žemų dažnių (ŽD) filtrą su pjūvio dažniu $f_p = 45$ Hz. Xu ir kiti [54] klasifikuodami ST segmentus pagal morfologinius pakitimus, kiekvieną EKG įrašą filtravo juostiniu filtru, kurio pjūvio dažniai atitinkamai 0,05–45 Hz. Tokį patį juostinį filtrą (0,05–45 Hz) naudojo ir Guo ir kiti [57] tirdami savo EKG stebėjimo sistemą. Tuo tarpu Liu ir kiti [58] norėdami pašalinti žemo dažnio trikdžius ir išlaikyti EKG aktyviausias dedamasias, aukštų dažnių filtro pjūvio dažnį pasirinko – 0,5 Hz.

1.4. Ant riešo dėvimi elektrokardiogramos registratoriai bei jų galimybių analizė

Šiomis dienomis milijonai žmonių naudoja išmaniuosius laikrodžius tokius kaip „Apple Watch“, „Samsung Galaxy Watch“, „Fitbit Sense“ ir kitus, kurie gali registruoti, sumažinto derivacijų skaičiaus, EKG signalus. Avila [59] išbandė išmaniojo laikrodžio galimybes užregistruoti 3 derivacijų EKG signalą, koreguojant laikrodžio padėtį, panaudojant Einthoveno trikampį, kaip orientyrą. Jis naudojo „Apple Watch 4“ laikrodį, kuris turi elektrodus, įmontuotus į skaitmeninę karūnelę (neigiamas elektrodas) ir į vidinę laikrodžio korpuso sieną (teigiamas elektrodas), kad aptiktų širdies elektrinius signalus.


Derivaciją I galima gauti naudojant laikrodį pagal paskirtį, nešiojant laikrodį ant kairiojo riešo ir dešiniu rodomuoju pirštu liečiant skaitmeninę karūnelę. Taip pat šiuo išmaniuoju laikrodžiu galima gauti II-ą bei III-ą derivacijas pridėdant teigiamą elektrodą (laikrodžio galinę dalį) prie pilvo srities ir liečiant neigiamą elektrodą (skaitmeninę karūnelę) dešiniuoju arba kairiuoju rodomuoju pirštu atitinkamai (10 pav.).



12 pav. Išmaniojo laikrodžio pozicijos norint išgauti 3 derivacijų EKG signalą, sustiprintas galūnes derivacijas aVL, aVF ir aVR galima išskaičiuoti iš gautų trijų galūnių derivacijų [59]

Avila [59] naudodamas „Apple Watch 4“ užregistravo keletą MI pacientų EKG signalų ir juos palygino su ambulatoriškai gautais EKG signalais. Atlikęs vizualinį testą, nustatė, kad išmaniuoju laikrodžiu gauti signalai atitinka etaloninį EKG signalą. Kaip ir tradicinis EKG signalas, laikrodžiu užregistruotas signalas parodė ST segmento pakilimą III derivacijoje bei ST depresiją I derivacijoje

(13 pav.). Autorius neįvertino, kaip tiksliai galima atpažinti MI iš gautų EKG signalų, panaudojant laikrodį, taip pat pabrėžė, kad neturint sustiprintų galūninių ir krūtininių derivacijų tam tikrų MI atpažinti nepavyktų.




13 pav. Tradicinio EKG signalo bei signalo gauto panaudojant „Apple Watch“ palyginimas [59]

Cobos Gil [60] savo straipsnyje aprašo būdą, kaip naudojantis „Apple Watch“ galima užregistruoti kvazi-standartinį 12-os derivacijų EKG signalą. Tam tikslui reikia gauti kvazi-standartines krūtinines derivacijas, panaudojant išmanųjį laikrodį su dviem elektrodais. Kaip buvo minėta 1.2 poskyryje, standartinėms unipolinėms krūtininėms derivacijoms gauti yra reikalingas atskaitos taškas, gautas iš trijų galūninių elektrodų. Su „Apple Watch“ išmaniuoju laikrodžiu tokio atskaitos taško gauti neįmanoma. Nepaisant to, prilietus laikrodžio galinę dalį (teigiamą elektrodą) prie standartiškai nustatytų krūtininių derivacijų taškų ir su dešiniu pirštu liečiant laikrodžio karūnelę (14 pav.), galima užregistruoti šešias bipolines krūtinines derivacijas (*Chest-Right Arm – CR*) (nuo CR1 iki CR6). Šios CR derivacijos yra panašios į standartine V1-V6 derivacijas. Tokias derivacijas medicinoje anksčiau naudojo šiaurinė Europa ir buvusi Sovietų sąjunga [60, 61].



14 pav. Galūniųjų bei kvazi-standartinių krūtininių CR EKG derivacijų registravimas, panaudojant išmanųjį laikrodį [61]

15 pav. galima matyti standartinių derivacijų palyginimą su derivacijomis gautomis panaudojant išmanųjį laikrodį. Galima pastebėti, jog pirmosios trys derivacijos beveik nesiskiria nuo standartinių. Tuo tarpu žvelgiant į CR ir V derivacijų palyginimą matosi daugiau skirtumų, tačiau derivacijos išlieka panašios.



15 pav. Standartinių EKG derivacijų palyginimas su gautomis išmaniuoju „Apple Watch“ laikrodžiu [60]

Kauno technologijos universiteto, Biomedicinos instituto, mokslininkai kartu su partneriais sukūrė išmanų ant rankos dėvimą prietaisą, su kuriuo užregistruo 6 derivacijų EKG signalą. Prietaisas turi tris elektrodus: du išoriniame paviršiuje ir vieną vidiniame paviršiuje šalia PPG jutiklio (16 pav.). Ant rankos dėvimo prietaiso pagalba, šešių derivacijų EKG signalas gali būti užregistruotas taip: prietaisas turi būti dėvimas ant kairės rankos, kurią liečia vidinis elektrodas, dešinės rankos rodomuoju pirštu reikia paliesti elektrodą viršutiniame paviršiuje, o trečiąjį elektrodą, esantį apyrankės paviršiuje, reikia liesti prie odos kairiojoje pilvo dalyje, po šonkauliu (pavyzdį galima matyti 16 pav. dešinėje). Tokiu būdu galima užregistruoti I-ąją ir II-ąją Einthoven'o derivacijas. III-oji derivacija apskaičiuojama pagal Kirchhoff'o dėsnį, o Goldberger'io sustiprintos galūninės derivacijos aVR, aVL ir aVF apskaičiuojamos iš užregistruotų galūnių derivacijų I, II, III [62]. Taip pat, panaudojant tokią išmaniąją apyrankę, kaip ir naudojant „Apple Watch“, galima užregistruoti ir 12 derivacijų, gaunant kvazi-standartines krūtinines derivacijas.



16 pav. Ant rankos dėvimo prietaiso su trimis elektrodais prototipas bei 6 derivacijų EKG signalo registravimo demonstracija [62]

Spaccarotella ir kt. [61] vykdė tyrimą, panaudodami daugiakanalius EKG signalus užregistruotus su „Apple Watch“. Jie palygino galimybes atpažinti ST segmento pakitimus iš standartinio EKG signalo ir užregistruoto išmaniuoju laikrodžiu. ST segmento pakitimų atpažinimą vykdė du skirtingi, patyrę kardiologai. Vienas naudojo standartinius EKG signalais, kitas išmaniuoju laikrodžiu užregistruotais EKG signalais. Tyrime dalyvavo 100 tiriamųjų (54 su STEMI infarktu, 27 su non-STEMI infarktu, 19 sveikų savanorių). Įvykdytas galimybių tyrimas parodė, kad išmaniuoju laikrodžiu užregistruoti signalai atitiko standartinius EKG. Užfiksuoti ST pakitimai iš standartinių ir ne standartinių EKG signalų skyrėsi minimaliai, skirtumai buvo pripažinti kliniškai nereikšmingi. Taip pat, panaudojant diagnozes gautas iš standartinių EKG signalų, kaip etalonines, buvo tiriamas diagnozių patikimumas, naudojant signalus iš „Apple Watch“. STEMI infarkto diagnozės jautrumas buvo – 93 %, specifiškumas – 95 %. Non-STEMI infarkto diagnozės jautrumas – 94 %, specifiškumas – 92 %. Bandant atpažinti normalius EKG signalus jautrumas buvo – 84 %, specifiškumas – 100 %. Išvadose teigia, kad potencialiai įmanoma atpažinti MI panaudojant išmaniojo laikrodžio technologiją.

Norint atpažinti ST segmento pakitimus ir MI, ant riešo dėvimo elektrokardiogramos registratoriaus nepakanka tiesiog dėvėti įprastai. Registruojant daugiakanalį EKG signalą, ant riešo dėvimo elektrokardiogramos registratoriaus elektrodus reikia priliesti atitinkamose vietose ant pilvo ir krūtinės, taip kaip pavaizduota 14 pav. ir 16 pav.. Jeigu šį procesą atlikinėtų ne kardiologas, atsiranda galimybė netiksliai pataikyti elektrodą į tam skirtą vietą, ypač registruojant krūtinines derivacijas, kur atitinkami taškai yra arti vienas kito. Tai gali sukelti daug netikslumų užregistruotose derivacijose, o nuo to nukentėtų MI atpažinimo tikslumas.

2. Miokardo infarkto atpažinimo algoritmo metodika ir duomenys

Šiame skyriuje tiksliai aprašyta duomenų bazė naudota algoritmo apmokymui bei tyrimui. Taip pat aprašyta įgyvendinto MI atpažinimo algoritmo metodika: apibūdinti ir pademonstruoti filtrai, naudoti pirminiam signalų apdorojimui, aprašytas, algoritme panaudotas, dirbtinis neuroninis tinklas ir jo sluoksniai, taip pat, aprašyta algoritmo patikimumo vertinimo metodika.

2.1. Duomenų bazė

Mašininio mokymo metodų, naudojamų aritmijų klasifikavimui, veikimui patvirtinti naudojamos įvairios, viešai prieinamos, duomenų bazės. Dažniausiai MI atpažinimui naudojama duomenų bazė yra, „Physionet“ duomenų banke patalpinta, PTB diagnostinė EKG duomenų bazė. Būtent ši duomenų bazė ir buvo panaudota šiame tyrime. PTB duomenų bazėje yra 549 įrašai iš 290 tiriamųjų (kurių amžius yra tarp 17 ir 87 metų, vidurkis – 57,2 m.; 209 vyrai, amžiaus vidurkis – 55,5 m.; 81 moteris, amžiaus vidurkis – 61,6 m.). Kiekvienam tiriamajam buvo užregistruoti nuo 1 iki 5 EKG įrašų. Kiekviename įrašė yra 15 derivacijų (12-a tradicinių derivacijų bei 3 Frank'o derivacijos). Kiekvienas signalas diskretizuotas 1000 Hz dažniu. Šią duomenų bazę sudaro 148-iais miokardo infarkto atvejais užregistruoti EKG signalai (368 įrašai), 52-ų sveikų savanorių EKG signalai (80 įrašų), o likę įrašai yra EKG su kitomis širdies ligomis, kaip miokarditas, angina, įvairūs ritmo sutrikimai ir t.t. [8, 63].

Šiam tyrimui buvo naudojami tik MI pacientų bei sveikų savanorių EKG įrašai, norint tinkamai apmokyti algoritmą MI atpažinimui, signalai su kitokiomis / gretimomis anomalijomis gali pakenkti rezultatui, taigi, šie signalai naudojami nebuvo. Taip pat, signalai su pasireiškusiu MI buvo kruopščiai atrinkti. Šio tyrimo tikslas yra sukurti ir iširti MI atpažinimo algoritmą, atsižvelgiant į dėvimų elektrokardiogramos registratorių galimybes. Dėvimais elektrokardiogramos registratoriais, namų sąlygomis, būtų bandoma atpažinti būtent ūmaus MI signalus, siekiant sumažinti mirties riziką. Taigi šio darbo metu realizuoto algoritmo apmokymui bei tyrimui buvo atrinkti tik ūmaus MI atvejais užregistruoti signalai. PTB duomenų bazėje pacientams 195, 103, 111, 135, 138, 140, 141, 142, 145, 148, 149, 149, 189, 183, 205, 207, 211, 261, 280, 282, 283 nebuvo užfiksuotas ūmus MI, taigi šių pacientų signalai buvo atmesti ir nenaudojami.


Pasirinkta naudojamų signalų trukmė – 10s, naudojant ilgus trukmės signalus dirbtinis neuroninis tinklas būtų ženkliai daugiau apkraunamas. Tačiau naudoti per trumpus signalų segmentus ar net širdies dužius (*Beats*) būtų netinkamas pasirinkimas. MI atsiskleidžia per ST segmento pakitimus, tačiau galima fiksuoti MI tik tada kai ST segmentas išlieka pakitęs tam tikrą ribotą laiką. Tuo tarpu, naudojant tik širdies dūžius, viename iš jų ST segmentas gali būti stipriai pakitęs dėl neaiškių priežasčių ar triukšmų, tokiu atveju MI gali būti užfiksuotas klaidingai.

Iš visų panaudotų signalų, 60% buvo paskirti DNT apmokymui, 20% validacijai, o kiti 20% testavimui. Tyrime naudojamų MI įrašų (347 vnt.) buvo 4,3 kartus daugiau nei sveikų savanorių įrašų (80 vnt.). Tokiu atveju klasifikatorius gali pasiekti didelį tikslumą tiesiog priskirdamas visus signalus prie MI, nes MI įrašai tokiu atveju sudaro 81% visų įrašų. Norint išspręsti nesubalansuoto duomenų rinkinio problemą, kad būtų išvengta šališkumo, iš sveikų savanorių signalų, kurių trukmė 1 min. buvo panaudoti 4 skirtingi segmentai po 10 s. Vėliau, visi sveikų savanorių ir MI atvejais užregistruoti signalai buvo suskirstyti pagal pacientus, taip užtikrinant, kad to paties paciento signalai nepatektų į kelias duomenų bases, pavyzdžiui, į apmokymo ir testavimo duomenų bases.

Panaudotuose MI signaluose (347 vnt.), kurie buvo paimti iš PTB duomenų bazės, buvo užregistruoti tokie ūmaus MI tipai:

- priekinės sienos – 47;
- priekinės dešinėsios sienos – 79;
- priekinis kairiosios sienos – 43;
- apatinės sienos – 90;
- apatinis kairiosios sienos – 56;
- apatinės galinės sienos – 20;
- kairiosios sienos – 3;
- galinės sienos – 4;
- galinės kairiosios sienos – 5.

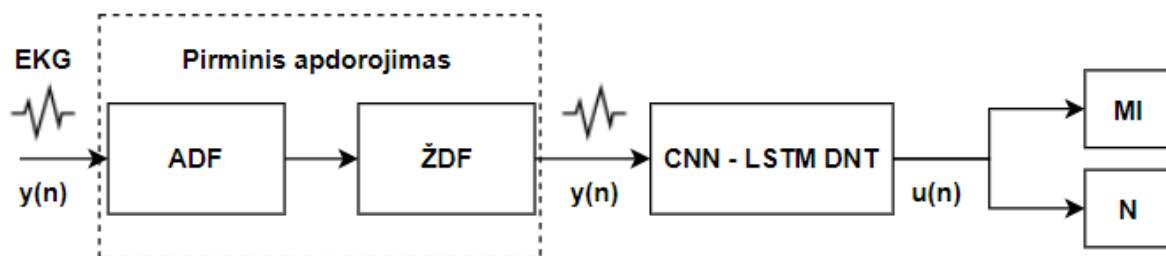
Paveiksluose apačioje pavaizduota keletas signalų gautų iš PTB duomenų bazės. Paanalizavus juos galima pamatyti, jog signalai yra užteršti triukšmais. Pastebimi aukštų dažnių triukšmai bei variacija aplink bazinę liniją.



17 pav. Sveikų savanorių bei miokardo infarkto atvejais užfiksuoti EKG signalai gauti iš PTB duomenų bazės

2.2. Miokardo infarkto atpažinimo algoritmas

Algoritmo struktūrinė schema pateikta apačioje (18 pav.). Pradžioje, EKG signalai turi būti apdoroti, pašalinti žemų bei aukštų dažnių triukšmai. Tuomet signalai paduodami į apmokytą dirbtinį neuroninį tinklą, kuris susideda iš konvoliucinio neuroninio tinklo bei ilgalaikės trumpalaikės atminties tinklo. DNT pagalba gauti įverčiai pateikiami į klasifikatorių, kur yra vertinamas gautas rezultatas ir priimamas sprendimas ar užregistruotame EKG signale galima išvelgti miokardo infarktą, ar ne.



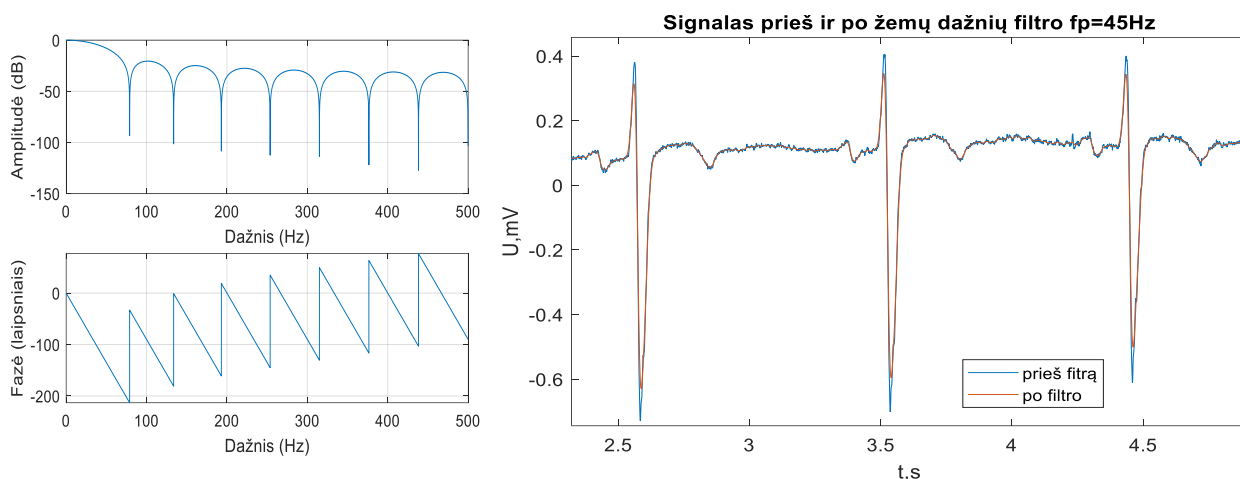
18 pav. Algoritmo struktūrinė schema

2.2.1. Elektrokardiogramos signalų pirminio apdorojimo įgyvendinimas

Prieš paduodant duomenis į DNT yra svarbu atlikti pirminį signalų apdorojimą, kurio metu yra eliminuojami artefaktai ir triukšmai bei siekiama sumažinti įėjimų dimensiškumą. Aukštų dažnių triukšmams šalinti buvo naudojamas 15 eilės ŽD ribotos impulsinės reakcijos (RIR) filtras, pjūvio dažnis parinktas ties 45Hz. Ganėtinai žemas pjūvio dažnis buvo pasirinktas įvertinus, kad analizuojamų ST segmentų didžiausia spektro galia sukoncentruota 0-5 Hz dažnių ruože, todėl aukštesniųjų dažnių EKG signalo informacija sprendžiant MI epizodų atpažinimo uždavinį yra perteklinė ir nereikalinga. Filtruojant EKG signalus, filtrai turi pasižymėti kiek įmanoma labiau tiesine fazės dažnine charakteristika (FDCH), kad visos signalo dedamosios būtų vėlinamos vienodai, taip pat turėtų būti filtruojama dvikrypčiais nulinės fazės filtrais.

19 pav. kairėje pavaizduota ŽD RIR filtro ADCH bei FDCH. Šis filtras skirtas pašalinti aukštesnių dažnių triukšmus bei perteklinę informaciją. Galima pastebėti, jog fazės dažninė charakteristika yra dalinai tiesinė. Pjūvio dažnis šiuo atveju 45Hz.


Paveikslo dešinėje pavaizduotas EKG signalas prieš ir po apdorojimo suprojektuotu ŽD RIR filtru. Po šio filtro matoma, kad aukšto dažnio triukšmai buvo pašalinti, signalas tapo glotnesnis, matomi signalo pakitimai ties R ir S danteliais, panašu, kad R ir S dantelių amplitudė šiek tiek sumažėjo, tačiau šio tyrimo tikslas yra MI atpažinimas ir svarbiausias segmentas šiuo atveju yra ST.



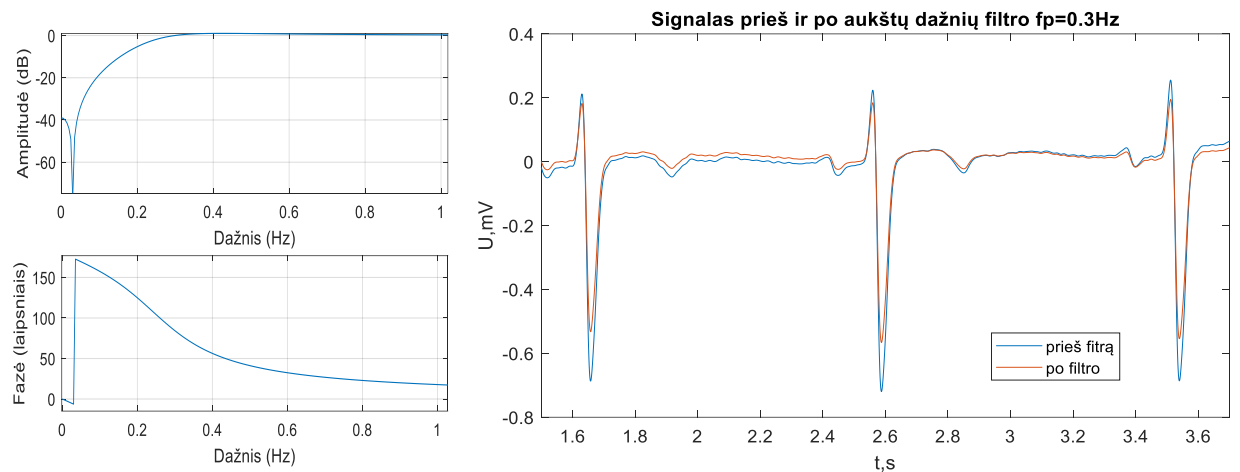
19 pav. 15 eilės ŽD RIR filtro, kurio pjūvio dažnis $f_p = 45\text{Hz}$ ADCH ir FDCH pateiktos kairėje, dešinėje pavaizduotas EKG signalas prieš ir po apdorojimo filtru

Bazinės linijos varijavimas buvo šalinamas panaudojant 2 eilės AD eliptinį NIR filtrą. Pasirinkta žema filtro eilė tam, kad EKG signalas būtų kuo mažiau iškraipomas. Kaip buvo minima 1.3 poskyryje, tokio filtro pjūvio dažnis pagal AHA (American Heart Association) reikalavimus EKG monitoriams turi būti tarp 0,05 ir 0,67 Hz (-3 dB lygyje), daroma prielaida, jog širdies ritmas nebūna retesnis nei 40 kpm. Kadangi ST segmento bei BW triukšmo galios spektrai persidengia yra sudėtinga nuspręsti kokį filtro pjūvio dažnį reikėtų pasirinkti. Yra svarbu, kiek įmanoma daugiau, nufiltruoti triukšmus, tačiau ST segmento iškraipymas lemtų prastą klasifikatoriaus veikimą. Šio tyrimo metu buvo išbandyti trys 2 eilės AD NIR filtrai su skirtingais pjūvio dažniais: 0,05 Hz, 0,3 Hz bei 0,5 Hz. Suprojektuotų filtrų ADCH ir FDCH yra pateiktos paveiksluose apačioje (20 pav., 21 pav., 22 pav.). Taip pat yra pademonstruotas EKG signalas prieš ir po filtravimo, galima pastebėti, kad bazinės linijos varijavimą pašalinti pavyksta su visais filtrais, tačiau labiausiai BW pašalintas buvo su 0,5 Hz


pjūvio dažniu. Signalus filtrai iškraipo minimaliai, galima pastebėti, kad signalo morfologija išlieka beveik nepakitusi, tačiau matosi R ir S dantelių amplitudės sumažėjimas.



20 pav. 2 eilės AD FIR filtro, kurio pjūvio dažnis $f_p = 0,05\text{Hz}$ ADCH ir FDCH pateiktos kairėje, dešinėje pavaizduotas EKG signalas prieš ir po apdorojimo filtru



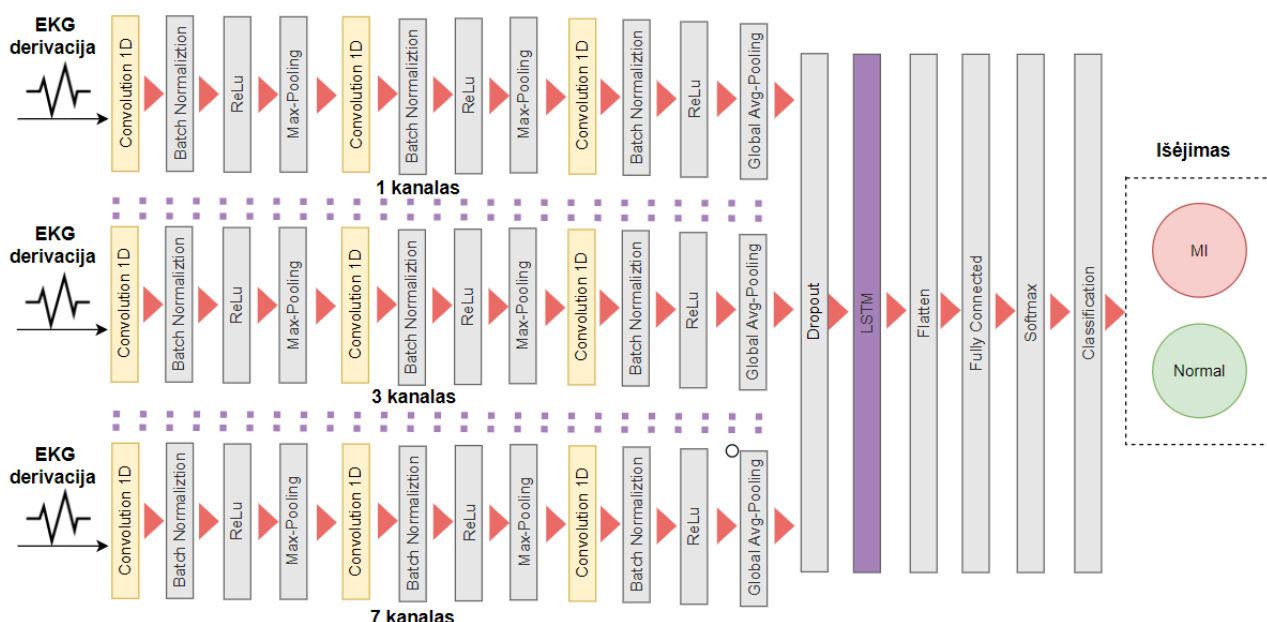
21 pav. 2 eilės AD FIR filtro, kurio pjūvio dažnis $f_p = 0,3\text{Hz}$ ADCH ir FDCH pateiktos kairėje, dešinėje pavaizduotas EKG signalas prieš ir po apdorojimo filtru



22 pav. 2 eilės AD FIR filtro, kurio pjūvio dažnis $f_p = 0,5\text{Hz}$ ADCH ir FDCH pateiktos kairėje, dešinėje pavaizduotas EKG signalas prieš ir po apdorojimo filtru

2.2.2. Dirbtinio neuroninio tinklo realizacija

Miokardo infarkto atpažinimo, panaudojant sumažinto derivacijų skaičiaus EKG, galimybių tyrimui buvo sudarytas neuroninis tinklas pagal pateiktą struktūrinę diagramą apačioje (23 pav.). Tinklas buvo sudarytas iš trijų CNN bloků bei LSTM sluoksnio. Priklausomai nuo to kiek EKG derivacijų yra naudojama, sudaromas dirbtinis neuroninis tinklas su atitinkamu kanalų skaičiumi, pvz., jei naudojama tik V1 derivacija, buvo panaudotas tinklas tik su vienu įėjimo kanalu, jei naudojamos I, II, III derivacijos, buvo panaudotas trijų kanalų tinklas ir t.t.



23 pav. Tinklo struktūros diagrama

Konvoliucinis sluoksnis yra pirmasis ir svarbiausias CNN architektūros sluoksnis, kuris iš jai pateiktos įvesties išskiria charakteristikas pagal parametrus, tokius kaip filtro dydis ir žingsnio dydis [44]. Įvesties EKG signalai buvo vienmačiai (1D) signalai, taigi, buvo pasirinkta naudoti vienmačius konvoliucinius sluoksnius, kurių filtrų skaičiai buvo atitinkamai 4, 8 ir 16, konvoliucijos filtro dydis buvo 5 visuose trijuose blokuose, o žingsnis (*Stride*) - 1.

Paketų normalizavimo sluoksnis (*Batch Normalization Layers*): normalizuoja mažą duomenų paketą kiekvienam kanalui atskirai. Paketų normalizavimo sluoksniai buvo naudojami tarp konvoliucinių sluoksnių ir ReLU sluoksnių, kad būtų pagreitintas konvoliucinio neuroninio tinklo mokymas ir sumažintas jautrumas tinklo inicializavimui.

ReLU sluoksniai: vadinamoji „lygintuvo“ funkcija – ReLU (*Rectified Linear Unit*) buvo pritaikyta kaip aktyvacijos funkcija. ReLU aktyvacijos funkcija gali būti išreikšta 4 lygtimi. Palyginti su sigmoidine (gali būti išreikšta pagal 5 lygtį) ir hiperbolinio tangento (gali būti išreikšta pagal 6 lygtį) funkcijomis, ReLU funkcija konverguoja greičiau ir palengvina persimokymo (*Over-Fitting*) problemą [64].

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (4)$$

$$f(x) = \frac{1}{1+e^{-x}} \quad (5)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

Telkimo sluoksniai (*Pooling Layers*): paprastai šie sluoksniai yra naudojami po konvoliucinio sluoksnio, jie sumažina būdingų charakteristikų dydį bei tinklo parametrų skaičių, dėl ko sumažėja skaičiavimo kaštai [44]. Šiame darbe buvo naudojamas maksimalus telkimas (filtro dydis buvo 5), kurio dėka buvo sumažintas apskaičiuotų charakteringų parametrų dimensiškumas ir išsaugotos svarbiausios savybės, taip paspartinant skaičiavimus. Po trečiojo CNN bloko buvo panaudotas globalus vidutinis telkimas, kad būtų sumažintas galimų charakteringų savybių / koeficientų skaičius, išvedant įvesties laiko reikšmių vidurkį.

Atmetimo sluoksnis (*Dropout Layer*) buvo pritaikytas tarp globalaus vidutinio telkimo sluoksnio ir LSTM sluoksnio, kad būtų pasiekta stipresnė apibendrinimo galimybė atsitiktinai panaikinant kai kuriuos tinklo mazgus.

LSTM sluoksnis: po konvoliucinio tinklo buvo prijungtas LSTM tinklo sluoksnis, kad būtų gautos ilgalaikės priklausomybės tarp laiko eilučių žingsnių ir sekos duomenų. Sluoksnis atlieka papildomas sąveikas, kurios gali padėti pagerinti gradiento srautą ilgomis sekomis apmokymo metu [34]. Apdoroti laiko seką naudojant LSTM sluoksnį galima kryptimi tik pirmyn, o dvikryptis LSTM sluoksnis gali išmokyti dvikryptes ilgalaikes priklausomybes tarp laiko eilučių žingsnių ar sekos duomenų. Šios priklausomybės gali būti naudingos, kai norima, kad tinklas mokytųsi iš visos laiko eilutės kiekviename laiko žingsnyje. Šiame tyrime naudojamas dvikryptis LSTM sluoksnis – BiLSTM. Paslėptųjų neuronų skaičius (*Hidden Units*) yra pagrindinis LSTM sluoksnio parametras ir atitinka tarp laiko žingsnių įsimenamos informacijos kiekį. Paslėptųjų neuronų skaičius gali būti informacija iš visų ankstesnių laiko etapų, neatsižvelgiant į laikinės sekos ilgį. Šiame tyrime pasirinkta naudoti 100 paslėptųjų neuronų.

Išlyginamasis sluoksnis (*Flatten Layer*): daugiamatė LSTM tinklo išvestis buvo konvertuota į vienmatę išvestį.

Pilnai apjungtas sluoksnis (*Fully Connected Layer*): gautos charakteristikos po visų procesų buvo įvestos į visiškai apjungtą sluoksnį klasifikavimui.

Minkštojo maksimumo sluoksnis (*Softmax Layer*) – aktyvacijos funkcija, kuri paverčia visas išėjimo komponentes / charakteristikas į tikimybes, sunormuoja išėjimo vektorius.

Klasifikavimo sluoksnis (*Classification Layer*) atlieka klasifikavimą pagal gautas tikimybes.

Neuroninio tinklo apmokymui buvo naudojamas ADAM optimizavimo algoritmas. ADAM yra tinkamas problemoms, kurios yra didelės apimties duomenų ir (arba) parametrų požiūriu. Taip pat tinka nestacionariems signalams apdoroti ar problemoms, susijusioms su triukšmingais gradientais spręsti [65].

2.3. Algoritmo patikimumo vertinimo metodika

Algoritmo veikimas buvo vertinamas pritaikant standartinius vertinimo kriterijus, pateiktus žemiau:

Jautrumas:

$$Se = TP / (TP + FN) \times 100\% \quad (7)$$

Specifiškumas:

$$Sp = TN / (TN + FP) \times 100\% \quad (8)$$

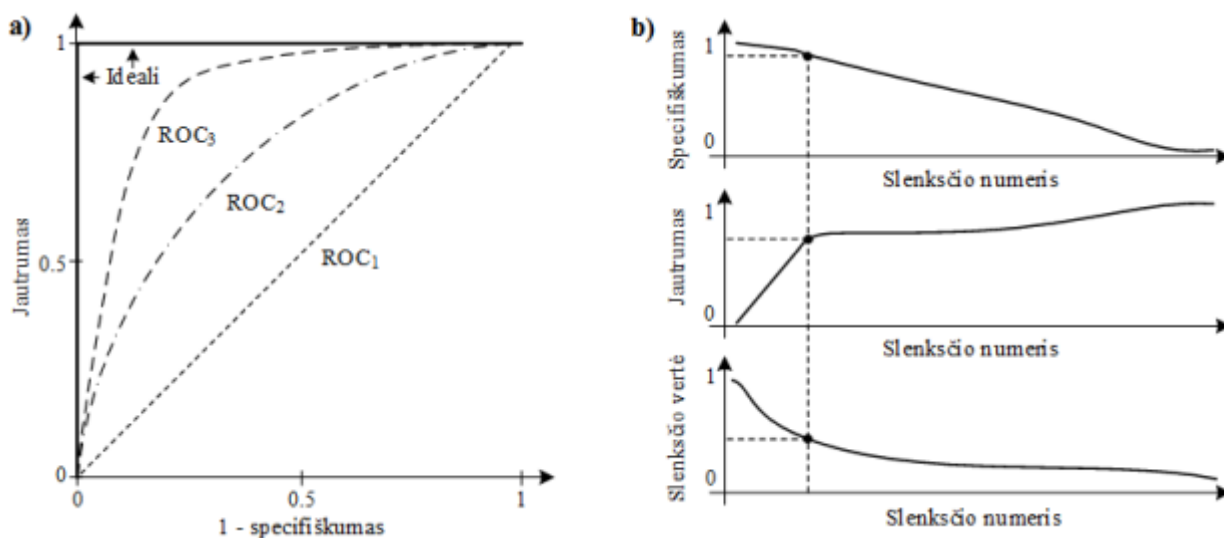
Tikslumas:

$$Acc = (TP + TN) / (TP + FP + FN + TN) \times 100\% \quad (9)$$

čia TP – tikri teigiami rezultatai; FN – klaidingi neigiami rezultatai; TN – tikri neigiami rezultatai; FP – klaidingi teigiami rezultatai.

Jautrumas susijęs su tikrojo MI identifikavimo procedūros galimybe. Specifiškumas nurodo, kaip gerai algoritmas geba nustatyti tikrus neigiamus rezultatus. Tikslumas yra išmatuotos vertės ir tikrosios vertės artumo laipsnis [13].

Taip pat algoritmo vertinimui buvo naudojama sprendimus priimančiojo charakteristikų (*Receiver Operating Characteristic* – ROC) kreivė ir plotas po ROC kreive. Ši kreivė parodo sąryšį tarp klasifikatoriaus jautrumo ir specifiškumo kiekvienai slenksčio vertei. Jei slenkstis parenkamas mažas, tai beveik visi patologiniai įvykiai būna atpažinti ir gaunamas aukštas jautrumas, tačiau padaugėja klaidingų aliarmų. Jei slenkstis parenkamas sąlyginai aukštas, tada sumažėja klaidingų aliarmų ir gaunamas aukštas specifiškumas, tačiau padidėja neatpažintų patologinių įvykių skaičius. Taigi, slenksčių reikia parinkti toki, kad jis optimaliai tenkintų uždavinio sąlygas. Plotas po ROC kreive taip pat kaip ir ROC kreivė nusako jautrumo bei specifiškumo vertes. Maksimalus ploto po ROC kreive dydis yra 1, tokiu atveju jautrumas ir specifiškumas būtų lygūs 100 %. Kuo plotas po ROC kreive didesnis tuo klasifikatoriaus tikslumas yra didesnis [66].



24 pav. ROC kreivės pavyzdys (a) optimalaus slenksčio parinkimas remiantis ROC kreive, jautrumo bei specifiškumo vertėmis (b) [66]

3. Miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus elektrokardiogramoje, algoritmo tyrimas ir rezultatai

Šiame skyriuje aprašomi visi atlikti tyrimai, susiję su sukurtu miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus elektrokardiogramoje, algoritmu. Pradžioje aprašomas dirbtinio neuroninio tinklo veikimo ir jo parametrų įtakos tyrimas. Išsiaiškinus parametrus, su kuriais įgyvendintas algoritmas veikia optimaliai, buvo renkamas algoritmo klasifikavimo slenkstis. Parinkus visus šiuos parametrus algoritmas buvo testuojamas simuliuojant ambulatoriniais signalais. Buvo atliktas derivacijos (elektrodo pridėjimo) paklaidos testas. Vėliau buvo vertinamas sukurtu algoritmo veikimas, panaudojant skirtingas EKG derivacijas ar derivacijų rinkiniu, ir išrinktas aukščiausią tikslumą pademonstravęs algoritmas. Taip pat buvo testuojamas optimalaus algoritmo atsparumas triukšmams. Pabaigoje, buvo įvertintas geriausias gautas rezultatas bei palygintas su kitais publikuotais miokardo infarkto atpažinimo iš EKG algoritmais.

3.1. Dirbtinio neuroninio tinklo parametrų įtakos tyrimas

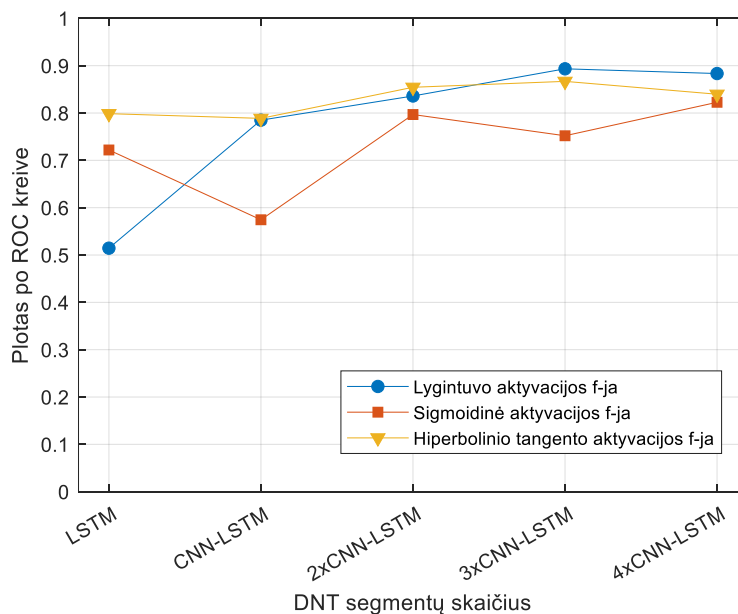
Dirbtinio neuroninio tinklo parametrų įtakos tyrimo metu pradiniai parametrai buvo parinkti tokie:

- aktyvacijos funkcija – lygintuvo;
- LSTM paslėptų vienetų skaičius – 100;
- maksimalus epochų skaičius – 50;
- mokymosi spartos konstanta – 0.001;
- laikinių sekų imties (paketų) dydis – 20;
- laikinių sekų ilgis – 2000.

Tiriant aktyvacijos funkcijų ir dirbtinio neuroninio tinklo sluoksnių skaičiaus įtaką plotui po ROC kreive, buvo palygintos trys skirtingos aktyvacijos funkcijos: lygintuvo funkcija, sigmoidinė funkcija bei hiperbolinio tangento funkcija. Panaudojant skirtingas aktyvinimo funkcijas (tokią pačią aktyvacijos funkcija visuose DNT segmentuose) buvo keičiamas CNN-LSTM tinklo sluoksnių skaičius, CNN segmentai po vieną buvo pridėjami prie LSTM segmento iki pilno tinklo, kuris pavaizduotas 23 pav., viršuje, ir susideda iš trijų CNN segmentų bei LSTM segmento.

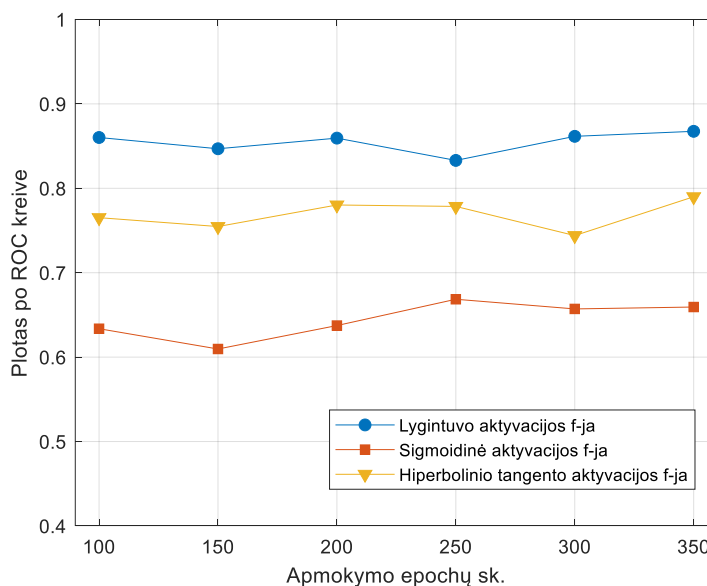
Panaudojant tik LSTM segmentą buvo pastebėta, kad gautas didžiausias plotas po ROC kreive naudojant hiperbolinio tangento aktyvacijos f-ją (25 pav.). Informaciniuose šaltiniuose galima pastebėti, jog naudojant LSTM tinklą, hiperbolinio tangento aktyvinimo funkcija parenkama, kaip numatytoji, LSTM tinklas su hiperbolinio tangento aktyvinimo f-ja veikia patikimiausiai [67]. Žvelgiant į rezultatus 25 paveiksle, taip pat galima pastebėti tendencija, jog panaudojus CNN segmentus, plotas po ROC kreive didėja, nepaisant to kokia aktyvacijos funkcija buvo panaudota. Lyginant aktyvacijos funkcijas, panaudojant hiperbolinio tangento arba lygintuvo funkcijas gaunamas didesnis plotas po ROC kreive, nei panaudojus sigmoidinę aktyvinimo f-ją. Nors panaudojant hiperbolinio tangento ar lygintuvo funkcijas gauti rezultatai yra panašūs, didžiausias plotas po ROC kreive buvo gautas panaudojus 3xCNN-LSTM tinklą ir lygintuvo f-ją.

Iš šių skirtingų dirbtinių neuroninių tinklų palyginimo, galima spręsti, jog 3xCNN-LSTM tinklas yra optimalus pasirinkimas, kadangi matosi ryškus ploto po ROC kreive augimas, didinant CNN segmentų skaičių iki trijų. Tuo tarpu, pridėjant ketvirtą CNN segmentą plotas po ROC kreive nustoja didėti. LSTM tinklui tinkamiausia aktyvacijos funkcija – hiperbolinio tangento. Tolimesniuose algoritmo parametrų įtakos tyrimo etapuose bus naudojami šie optimalūs parametrai.



25 pav. Aktyvacijos funkcijos ir dirbtinio neuroninio tinklo sluoksnių skaičiaus įtaka plotui po ROC kreive

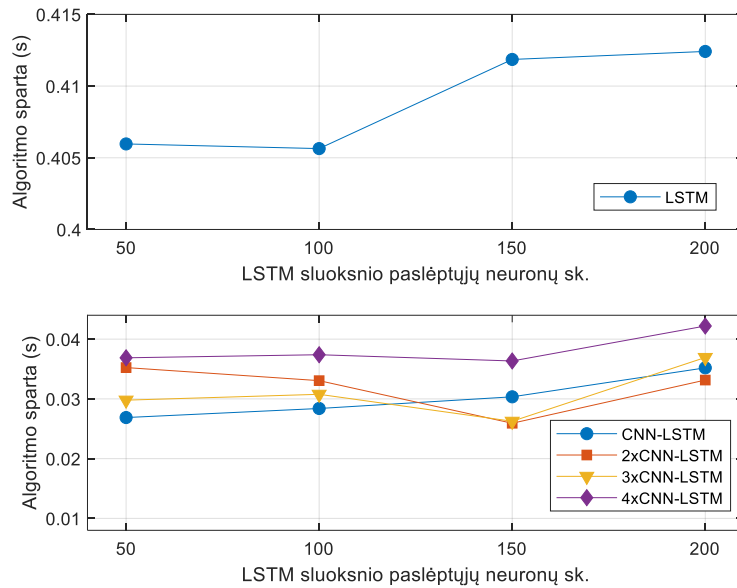
Toliau buvo tiriama aktyvacijos f-jos ir apmokymo epochų skaičiaus įtaka plotui po ROC kreive. Šiuo atveju buvo naudojamas 3xCNN-LSTM tinklas. LSTM segmentui buvo naudojama hiperbolinio tangento aktyvacijos funkcija, tuo tarpu CNN segmentams aktyvacijos funkcija buvo keičiama. Taip pat tinklas buvo apmokomas panaudojant vis didesnę epochų skaičių. Tinklą apmokius daugiau kartų (panaudojus didesnę epochų skaičių) galima aiškiai matyti skirtumus tarp naudojamų aktyvacijos funkcijų (26 pav.). Rezultatai rodo, jog panaudojant lygintuvo aktyvacijos funkciją CNN segmentuose, gaunamas didžiausias plotas po ROC kreive. Taip pat didžiausias plotas po ROC kreive gautas tinklo apmokymui panaudojant 350 epochų, tačiau panašūs rezultatai gaunami ir panaudojant mažesnę epochų skaičių. Toliau tyrime bus naudojama lygintuvo aktyvacijos funkcija CNN segmentuose.



26 pav. Aktyvacijos funkcijos ir apmokymo epochų skaičiaus įtaka plotui po ROC kreive

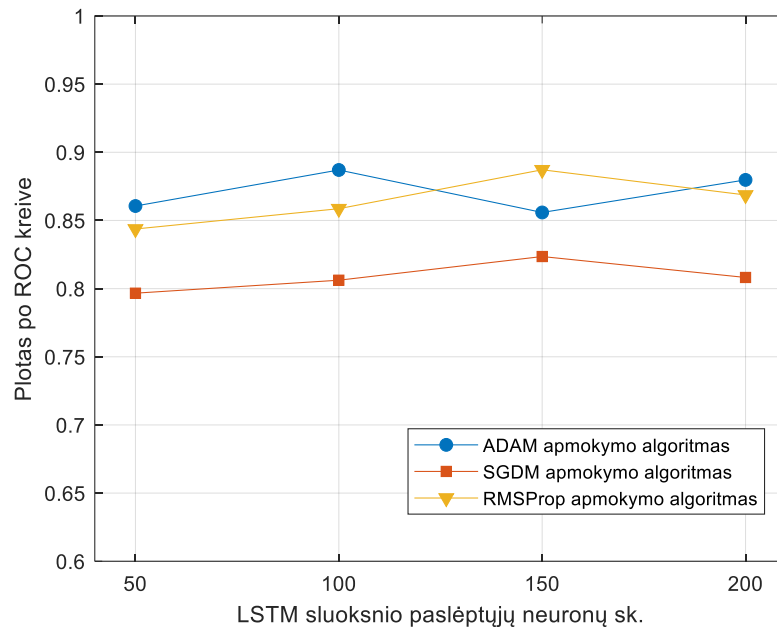
Vėliau buvo tiriama tinklo sluoksnių skaičiaus bei LSTM sluoksnio paslėptųjų neuronų skaičiaus įtaka algoritmo spartai (27 pav.). Buvo matuojamas laikas, kaip sparčiai veikia algoritmas (signalų

pirminis apdorojimas, signalo padavimas į tinklą, svarbiausių charakteristikų išskyrimas ir klasifikavimas) į jį padavus vieną EKG signalą. Buvo pastebėta, jog naudojant tik LSTM segmentą, gautas algoritmas užtrunka ilgiau, apdorojant ir klasifikuojant vieną signalą, lyginant su DNT, kuriuose yra CNN segmentas. Gauti rezultatai atspindi tai, kad CNN sluoksniai sumažina apdorojamų duomenų kiekį, o tai padaro algoritmą spartesniu, jis apdoroja signalus greičiau. Lyginant algoritmų spartą kai panaudojami CNN-LSTM, 2xCNN-LSTM ir 3xCNN-LSTM tinklai, buvo pastebėta, kad didinant sluoksnių skaičių algoritmo sparta blogėja. Tuo tarpu, LSTM paslėptųjų neuronų skaičiaus įtaka spartai varijuoja mažame intervale, bet galima pastebėti tendenciją, jog didinant paslėptųjų neuronų skaičių, algoritmas užtrunka vis ilgiau apdorojant signalą.



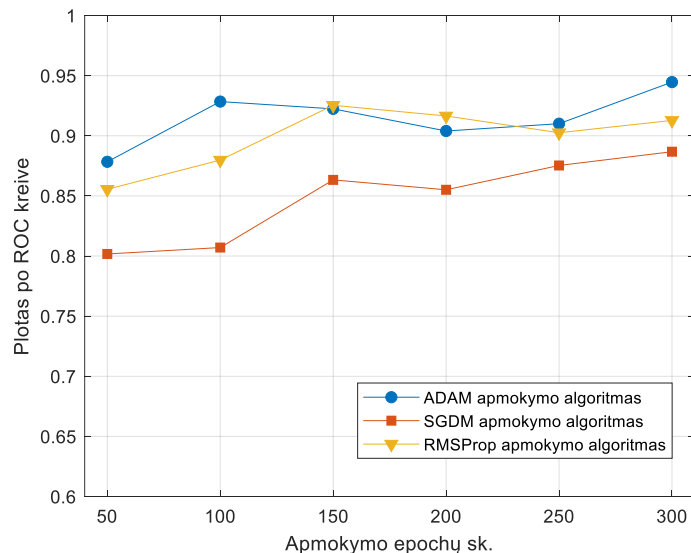
27 pav. Algoritmo spartos priklausomybė nuo dirbtinio neuroninio tinklo sluoksnių skaičiaus bei LSTM sluoksnio paslėptųjų vienetų skaičiaus

28 pav. pateikti DNT apmokymo algoritmo ir LSTM sluoksnio paslėptųjų neuronų skaičiaus įtakos plotui po ROC kreive tyrimo rezultatai. Galima pastebėti, jog didesnis plotas po ROC kreive gaunamas panaudojant ADAM arba RMSProp apmokymo algoritmus. Panaudojant SGDM apmokymo algoritmą tokių rezultatų pasiekti nepavyksta. Didžiausias plotas po ROC kreive buvo naudojant 100 paslėptųjų neuronų. Taip pat, iš algoritmo spartos tyrimo galima suprasti, jog didinant LSTM sluoksnio paslėptųjų neuronų skaičių, sparta vis blogėja, taigi, daugiau didinti paslėptųjų neuronų skaičių nereikia. Optimalus LSTM sluoksnio paslėptųjų neuronų sk. – 100.



28 pav. Apmokymo algoritmo bei LSTM sluoksnio paslėptųjų neuronų skaičiaus įtaka plotui po ROC kreive

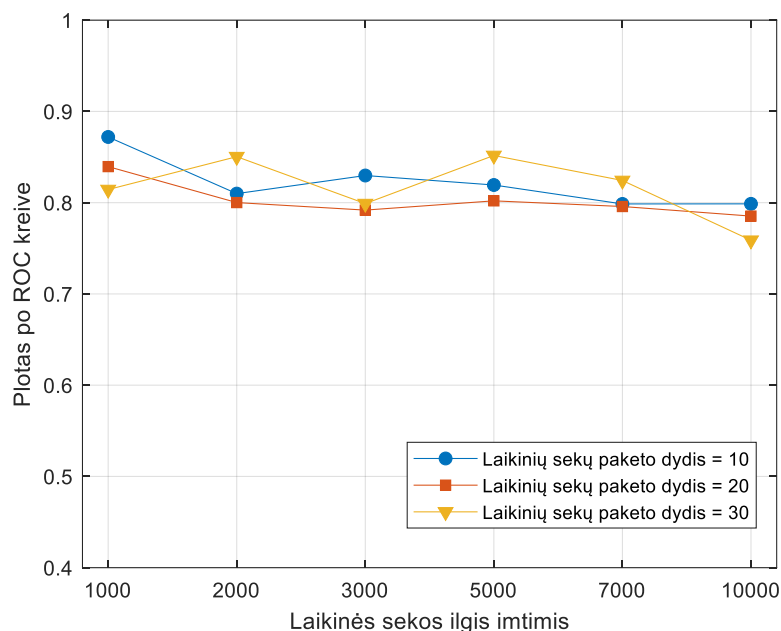
Kitame algoritmo parametrų įtakos tyrimo etape buvo tiriama apmokymo algoritmo ir apmokymo epochų skaičiaus įtaka plotui po ROC kreive (29 pav.). Taip pat ir šiame tyrimo etape buvo pastebėta, jog panaudojus SGDM apmokymo algoritimą, gauti prasčiausi rezultatai. Tuo tarpu apmokymui naudojant ADAM ar RMSProp algoritmus plotas po ROC kreive gaunamas didesnis. Atliekant šį tyrimą ir eksperimentuojant toliau buvo pastebėta, kad naudojant ADAM algoritimą dažniausiai buvo gaunamas didesnis plotas po ROC kreive nei panaudojant RMSProp. Tinklo apmokymui panaudojus ADAM apmokymo algoritimą bei 300 epochų buvo gautas didžiausias plotas po ROC kreive.



29 pav. Apmokymo algoritmo bei apmokymo epochų skaičiaus įtaka plotui po ROC kreive

Paskutiniame algoritmo parametrų įtakos tyrimo etape buvo tiriama ploto po ROC kreive priklausomybė nuo laikinių sekų imties (paketo) dydžio bei laikinių sekų ilgio. Paketo dydis nurodo kiek laikinių sekų bus apdorojama vienu metu apmokant neuroninį tinklą, o laikinės sekos ilgis nurodo kokio ilgio laikinės sekos bus apdorojamos apmokymo metu. Kuo laikinė seka trumpesnė tuo

iteracijų apmokant tinklą bus daugiau, žinoma ilgėja ir apmokymo trukmė. Žvelgiant į gautus rezultatus (30 pav.), galima pastebėti aiškią tendenciją, jog didinant laikinių sekų ilgį, plotas po ROC kreive mažėja. Šio tyrimo metu, didžiausias plotas po ROC kreive gautas apdorojant 10 sekų vienu metu, kurių ilgis 1000 imčių.



30 pav. Apmokymo metu apdorojamos laikinės sekos ilgio bei laikinių sekų paketo dydžio įtaka plotui po ROC kreive

Atlikus algoritmo parametrų įtakos tyrimą buvo parinkti optimalūs parametrai:

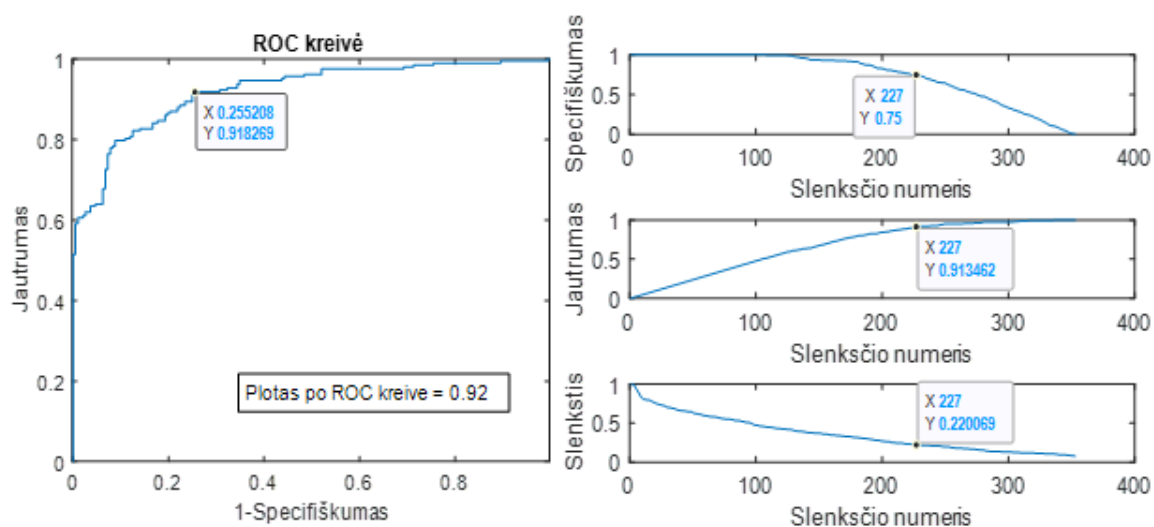
- optimalus dirbtinis neuroninis tinklas – 3xCNN-LSTM;
- aktyvacijos funkcija CNN segmentams – lygintuvo;
- aktyvacijos funkcija LSTM segmentui – hiperbolinio tangento;
- LSTM paslėptų neuronų skaičius – 100;
- apmokymo algoritmas – ADAM;
- maksimalus epochų skaičius – 300;
- mokymosi spartos konstanta – 0.001;
- laikinių sekų imties (paketų) dydis – 10;
- laikinių sekų ilgis – 1000.

Šie parametrai buvo naudojami tolimesniuose miokardo infarkto atpažinimo iš EKG, panaudojant dirbtinį neuroninį tinklą, tyrimuose.

3.2. Miokardo infarkto atpažinimo algoritmo klasifikavimo slenksčio parinkimas

Atlikus dirbtinio neuroninio tinklo parametrų įtakos tyrimą, buvo nustatyti optimalus tinklo sluoksnių skaičius bei tinkamiausi parametrai CNN-LSTM hibridiniam neuroniniam tinklui. Panaudojus šiuos parametrus, neuroninis tinklas buvo apmokytas pasitelkus apmokymo ir validavimo duomenų bazes sudarytas iš EKG signalų, kuriuose pasireiškė ūmus miokardo infarktas arba signalai buvo gauti iš sveikų savanorių (buvo panaudota tik V1 derivacija). Prieš paduodant į dirbtinį neuroninį tinklą, signalai buvo apdoroti panaudojant 15 eilės, žemų dažnių RIR filtrą, kurio pjūvio dažnis – $f_p = 45\text{Hz}$, ir 2 eilės aukštų dažnių eliptinį NIR filtrą, kurio pjūvio dažnis – $f_p = 0,5\text{Hz}$.

Po DNT apmokymo, buvo atliktas algoritmo testavimas panaudojant apmokymo duomenų bazę. Gautas plotas po ROC kreive – 0,92 (31 pav. kairėje).



31 pav. Dirbtinio neuroninio tinklo įvertinimui skirta ROC kreivė bei slenksčio parinkimas

Gavus plotą po ROC kreive buvo renkamas algoritmo slenkstis, pagal jautrumo bei specifiškumo vertes (31 pav. dešinėje). Algoritmo jautrumas nurodo santykį, kiek teigiamų rezultatų buvo atpažinta teisingai, lyginant su visais teigiamais rezultatais, šiuo atveju būtų taip – santykis, kiek miokardo infarkto signalų buvo atpažinta teisingai, lyginant su visais signalais priskirtais prie MI. Tai reiškia, kuo jautrumas yra didesnis, tuo daugiau MI signalų bus atpažinti teisingai. Tuo tarpu specifiškumas nurodo tikrų neigiamų rezultatų santykį su visais rezultatais priskirtais prie neigiamų. Šiuo atveju tai reikštų, kiek sveikų savanorių signalų buvo teisingai priskirta prie sveikų klasės, lyginant su visais signalais priskirtais prie sveikų žmonių klasės.


Renkantis slenkstį reikia apsvarstyti ir pasverti abi puses, didinant jautrumą bus atpažinta daugiau miokardo infarkto atveju, o pagrindinis tikslas ir yra atpažinti miokardo infarktą. Jei algoritmas būtų naudojamas realioje situacijoje, panaudojant išmaniąją apyrankę, jautrumas būtų svarbus. Jeigu jautrumas aukštas, dauguma ar net visi MI būtų atpažinti, tačiau jei jautrumas būtų sumažintas, tam tikrais atvejais MI būtų neatpažinti. Jeigu prietaiso kūrėjais teigtų, kad apyrankė gali atpažinti MI, tačiau to nepadarėtų, žmogus dėl to gali nesikreipti į gydymo įstaigą, o taip galima sukelti komplikacijas ar net įtakoti mirtį tam žmogui. Tuo tarpu specifiškumas taip pat yra svarbus, jeigu specifiškumas būtų mažas, tokiu atveju būtų daug klaidingų aliarmų. Realioje situacijoje, toks prietaisas dažnai priskirtų sveikų žmonių EKG signalus prie MI, taip pranešdamas sveikam žmogui, kad jam prasidėjo miokardo infarktas. Tai sukeltų stresą žmogui, taip pat sudarytų nepalankias sąlygas gydymo įstaigose, kur dažnai žmonės pasirodytų be tikrų simptomų. Taigi, abu parametrai yra svarbūs šioje situacijoje, tačiau nevienodai, algoritmas turintis atpažinti MI turi ir padaryti, jautrumas turėtų būti kiek įmanoma aukštesnis, kitaip tai gali sukelti komplikacijas žmonėms ar net įtakoti mirtį. Žinoma, per daug numažinti specifiškumą būtų klaidinga. Šiuo atveju slenkstis buvo parinktas toks – 0,22, taip gaunant 91,35 % jautrumą ir 75,00 % specifiškumą. Tikslumas šiuo atveju – 83.50 %.

3.3. Ambulatorinių signalų simuliacija su parinktu slenksčiu, panaudojant testavimo duomenų bazę

Įgyvendinus miokardo infarkto atpažinimo algoritmą ir parinkus slenkstį, toliau buvo bandoma jį testuoti simuliuojant ambulatoriniais signalais ir imituojant įvairias situacijas, kurios gali pasireikšti naudojant ant rankos dėvimą elektrokardiogramos registratorių.

Kaip buvo minėta 1.4 poskyryje, ant rankos dėvimo prietaiso užregistruotų EKG derivacijų tikslumas, lyginant su standartinėmis derivacijomis, priklauso nuo to, kaip bus priličiami elektrodai prie kūno. Jei elektrodas priličiamas tiksliai prie standartų nurodytos vietos, užregistruojama derivacija bus tikslesnė, tuo tarpu, jei elektrodas bus bent šiek tiek pastumiamas į kurią nors pusę, derivacija gali pakisti. Realioje situacijoje, dėl skausmo, streso ar įtampos, dėvimo elektrokardiogramos registratoriaus vartotojas gali pataikyti elektrodą su tam tikra paklaida. Šiame tyrime buvo bandoma imituoti situaciją, kad elektrodas nebuvo pataikytas tiksliai, taip užregistruojant kitokią derivaciją. Tokia situacija buvo imituojama panaudojant algoritmą, kuris buvo apmokytas atpažinti miokardo infarktą iš V1 derivacijos, ir jį testuojant su kitomis EKG derivacijomis (V2, V3, V4, V5, V6) iš testavimo duomenų bazės.

Gauti rezultatai pateikti 1 lentelėje, galima pastebėti, kad pakeitus derivaciją algoritmo įėjime, rezultatai suprastėja ženkliai. Panaudojant V2 derivaciją gautas tikslumas – 57,34%, tuo tarpu, panaudojant kitas derivacijas (V3, V4, V5, V6) algoritmas neveikia, tikslumas nukrenta žemiau 50 %. Matant tokius rezultatus, galima suprasti, kad derivacijos pokyčiai turi svarią įtaką algoritmo veikimui, jei elektrodai būtų pridėti netiksliai, algoritmas gali neveikti. Kita vertus, šiame algoritmo testavime, buvo panaudotos derivacijos, kurios kardinaliai skiriasi nuo V1 derivacijos. Realybėje, naudojant išmaniąją apyrankę ir norint užregistruoti V1 derivaciją, galimybė pataikyti elektrodą su tokia didele paklaida yra maža. Norint užregistruoti V1 derivaciją, elektrodas standartiškai statomas dešinėje krūtinės pusėje, tuo tarpu registruojant V2, V3, V4, V5, V6 elektrodai statomi kairėje (32 pav.). Preliminarūs atstumai tarp krūtininių derivacijų, vidutinio sudėjimo vyrui, yra tokie: tarp V1 ir V2 apie 10 cm, tarp V2 ir V4 apie 12,4 cm, tarp V4 ir V6 apie 10,6 cm [68].



32 pav. Elektrodo pozicijos norint užfiksuoti krūtinines derivacijas [14]

Taigi, rezultatai parodo, kad derivacijos pokyčiai daro svarią įtaką algoritmo veikimui, nukrypus nuo standartinės vietos per apytiksliai 10 cm (nuo V1 iki V2) algoritmo tikslumas sumažėja per 27,28 %. Tačiau šis tyrimas neparodo realios situacijos, kadangi elektrodo pataikymo paklaidos turėtų būti mažesnės. Norint tiksliau įvertinti EKG derivacijų paklaidas dėl netinkamai pridėto elektrodo,

algoritmas turėtų būti išbandytas panaudojant realius EKG signalus, užregistruotus su išmaniają apyranke. Nepaisant to, galima susidaryti nuomone apie tai, kad naudojant krūtinines derivacijas, užregistruotas ant riešo dėvimu elektrokardiogramos registratoriumi, gali būti paklaidų dėl elektrodo pataikymo. Taigi, būtų rekomenduojama registruoti ne visas krūtinines derivacijas arba visai jų neregistruoti, taip sumažinant elektrodo pataikymo paklaidų riziką.

1 lentelė. Algoritmo (apmokyto panaudojant V1 derivaciją) testavimas su kitomis krūtininėmis derivacijomis algoritmo įėjime

EKG derivacija tinklo įėjime	Tikslumas	Jautrumas	Specifiškumas
V1	84.62 %	90.14 %	79.17 %
V2	57.34 %	93.0 %	22.2 %
V3	49.65 %	88.7 %	11.1 %
V4	45.45 %	85.9 %	5.6 %
V5	46.15 %	81.7 %	11.1 %
V6	46.85 %	94.4 %	0 %

Atlikus tokį patį testavimą tik panaudojant DNT, apmokytą su V2 derivacija, o algoritmą testuojant su kitomis derivacijomis (V1, V3, V4, V5, V6), galima pamatyti skirtumų (2 lentelė). Šiuo atveju, prie V2 derivacijos yra artimesnių derivacijų tokių kaip V3 (kuri nutolusi nuo V2 per apytiksliai 6,2 cm). Galim pastebėti, kad rezultatas pakito ne taip smarkiai į algoritmo įėjimą padavus V3 derivaciją. Pataikius elektrodą su apytiksliai 6,2 cm paklaida algoritmo tikslumas sumažėja per 13,3 %. Iš to galima spręsti, kad mažesnės elektrodo pataikymo paklaidos nedarytų tokios didelės įtakos algoritmo tikslumui.

2 lentelė. Algoritmo (apmokyto panaudojant V2 derivaciją) testavimas su kitomis krūtininėmis derivacijomis algoritmo įėjime

EKG derivacija tinklo įėjime	Tikslumas	Jautrumas	Specifiškumas
V2	84.62 %	91.5 %	77.8 %
V1	69.93 %	93.0 %	47.2 %
V3	71.32 %	91.5 %	51.4 %
V4	58.04 %	63.4 %	52.8 %
V5	58.74 %	60.6 %	56.9 %
V6	50.35 %	45.1 %	55.6 %

Kito tyrimo metu buvo bandoma išsiaiškinti, kaip veikia algoritmas panaudojant skirtingas EKG signalų derivacijas arba jų rinkinius. Derivacijos ir jų rinkiniai buvo parinkti atsižvelgiant į tai, kokias derivacijas būtų galima užregistruoti išmaniuoju dėvimu prietaisu. Šio tyrimo metu dirbtinis neuroninis tinklas buvo apmokomas kiekvienu atveju skirtingai, panaudojant mokymo ir validacijos duomenų bazes su atitinkamomis EKG derivacijomis. Algoritmo slenkstis buvo parankamas kiekvienu atveju individualiai. Vėliau algoritmas su apmokytu dirbtiniu neuroniniu tinklu buvo testuojamas panaudojant testavimo duomenų bazę su atitinkamomis EKG derivacijomis. Testavimo metu buvo registruojami rezultatai: algoritmo tikslumas, jautrumas ir specifiškumas, taip pat, buvo tikrinamas neatpažinto miokardo infarkto tipas, pagal tai kokia širdies miokardo dalis buvo pažeista konkrečiam pacientui.

Kaip buvo aprašyta 1.2.1 skyrelyje, širdis yra dalinama į dalis pagal sienas: priekinė (*Anterior*), galinė (*Posterior*), apatinė (*Inferior*), dešinė (*Septal*), kairė (*Lateral*). Taip pat miokardo infarktas yra

skirstomas į tipus pagal tai kurią miokardo dalį pažeidžia, tai priklauso nuo to, kuri arterija užsikemša ir į kurią miokardo dalį kraujas neatiteka. Tyrime naudotoje testavimo duomenų bazėje yra 142 signalai, iš kurių 71 signalas užregistruotas miokardo infarkto atveju. Tarp šių miokardo infarkto EKG signalų yra tokie infarkto tipai:

- priekinės sienos – 8;
- priekinės dešinėsios sienos – 10;
- priekinis kairiosios sienos – 18;
- apatinės sienos – 26;
- apatinis kairiosios sienos – 4;
- apatinės galinės sienos – 5.

Šiuo tyrimu buvo bandoma išsiaiškinti, kaip tiksliai veikia algoritmas panaudojant skirtingas elektrokardiogramos derivacijas, bei kokio tipo miokardo infarkto nepavyksta atpažinti su konkrečia EKG derivacija ar derivacijų rinkiniu. Tyrimo rezultatai yra pateikti apačioje, 3 lentelė

Naudojant Derivaciją I, buvo neatpažinta 11 apatinės sienos infarktų, teoriškai, naudojant šia derivaciją, geriausiai matosi priekinės ar priekinės kairiosios sienos infarktas. Naudojant derivaciją II, galima pastebėti, kad yra sudėtinga atpažinti kairiosios sienos miokardo infarktą, tačiau gautas tikslumas lyginant su kitomis derivacijomis buvo aukštas. Algoritmas su derivaciją III dažniausiai neatpažino priekinės ar priekinės kairiosios sienos miokardo infarkto. Kalbant apie sustiprintas galūnines derivacijas, naudojat aVR derivaciją, algoritmas veikė tiksliai, liko neatpažinti tik 2 apatiniai bei vienas priekinės dešinės sienos MI. Naudojant aVL derivaciją, daugiausiai neatpažintų miokardo infarktų buvo priekinės kairiosios sienos ir apatinės sienos MI. Šis rezultatas atrodo neadekvatus, nes būtent aVL derivacijoje kairiosios bei priekinės kairiosios sienos miokardo infarktas turėtų būti matomas. Panaudojus aVF derivacija, buvo neatpažinta 6 priekiniai kairiosios sienos bei 6 apatinės sienos infarktai. Analizuojant krūtinines derivacijas galima pastebėti aiškia tendenciją, kad naudojant šias derivacijas yra sunkiau atpažinti apatinės sienos miokardo infarktą. Aukštą tikslumą pavyko pasiekti panaudojant V1, V2 ir V5 derivacijas.

Tyrimo pabaigoje, panaudojus daugiakanalį neuroninį tinklą, kuris buvo apmokytas panaudojant keletą atitinkamų derivacijų, pavyko gauti geriausius rezultatus. Panaudojus I, II, III derivacijas, buvo pasiektas aukščiausias tikslumas – 92,3 %, tačiau šiuo atveju jautrumas neprilygo šešių ir septinių kanalų tinklams. Panaudojant galūnines, sustiprintas galūnines ir V1 derivacijas, buvo pasiektas aukščiausias jautrumas – 95,8 %. Nepaisant to, naudojant algoritmą su I, II, III derivacijomis, buvo pasiektas tik šiek tiek žemesnis jautrumas – 93,0 %, o specifiškumas ženkliai aukštesnis – 91,7 %, lyginant su 7 derivacijų algoritmu. Taigi, apibendrinant galima teigti, kad geriausias rezultatas buvo pasiektas naudojant algoritmą su I, II, III derivacijomis.

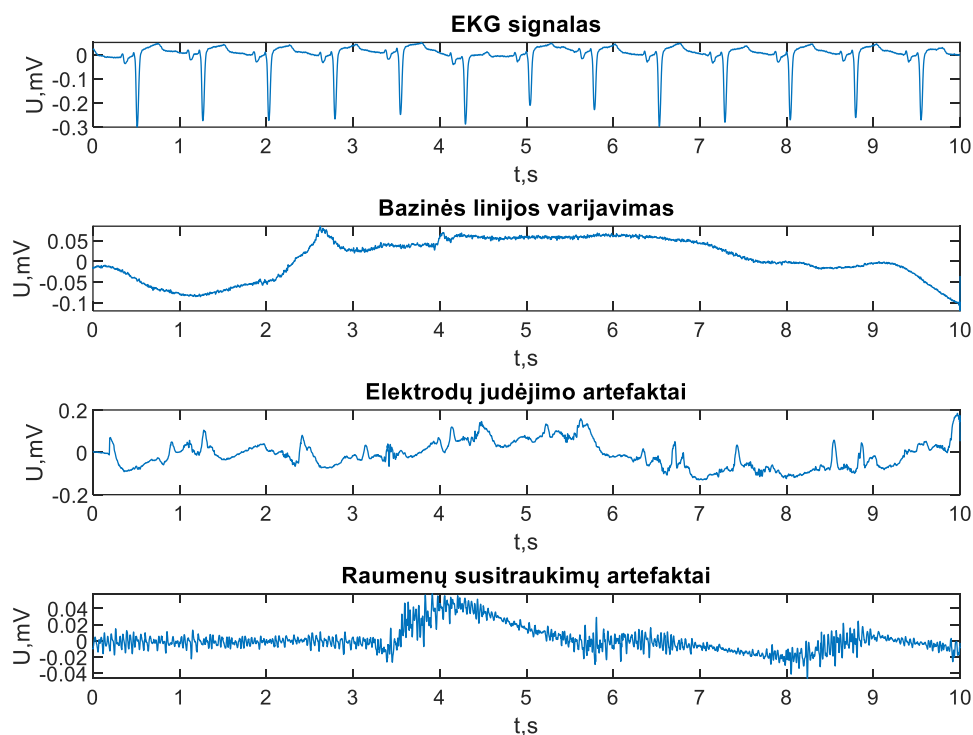
3 lentelė. Miokardo infarkto atpažinimo, sumažinto derivacijų skaičiaus elektrokardiogramoje, galimybių tyrimas

EKG derivacija/-os	Rezultatai	Neatpažinto miokardo infarkto tipas
I	Acc = 81.82 % Se = 84.5 % Sp = 79.2 %	11x apatinės sienos
II	Acc = 84.62 % Se = 93.0 % Sp = 76.4 %	3x priekinis kairiosios sienos 1x priekinės dešinėsios sienos 1x apatinės sienos

III	Acc = 74.13 % Se = 77.5 % Sp = 70.8 %	4x priekinės sienos 5x priekinis kairiosios sienos 4x apatinės sienos 2x apatinis kairiosios sienos 1x apatinės galinės sienos
aVR	Acc = 85.31 % Se = 95.8 % Sp = 75.0 %	1x priekinės dešinėsios sienos 2x apatinės sienos
aVL	Acc = 72.03 % Se = 76.1 % Sp = 68.1 %	1x priekinės sienos 7x priekinis kairiosios sienos 1x priekinės dešinėsios sienos 7x apatinės sienos 1x apatinis kairiosios sienos 1x apatinės galinės sienos
aVF	Acc = 76.92 % Se = 80.3 % Sp = 73.6 %	1x priekinės sienos 6x priekinis kairiosios sienos 6x apatinės sienos 1x apatinis kairiosios sienos
V1	Acc = 84.62 % Se = 90.14 % Sp = 79.17 %	2x priekinės sienos 1x priekinis kairiosios sienos 3x apatinės sienos 1x apatinės galinės sienos
V2	Acc = 84.62 % Se = 91.5 % Sp = 77.8 %	1x priekinės sienos 1x priekinės dešinėsios sienos 3x apatinės sienos 1x apatinis kairiosios sienos
V3	Acc = 79.02 % Se = 87.3 % Sp = 70.8 %	1x priekinis kairiosios sienos 1x priekinės dešinėsios sienos 6x apatinės sienos 1x apatinis kairiosios sienos
V4	Acc = 82.52 % Se = 84.5 % Sp = 80.6 %	10x apatinės sienos 1x apatinis kairiosios sienos
V5	Acc = 85.31 % Se = 94.4 % Sp = 76.4 %	3x apatinės sienos 1x apatinis kairiosios sienos
V6	Acc = 79.02 % Se = 85.9 % Sp = 72.2 %	1x priekinės sienos 2x priekinis kairiosios sienos 2x priekinės dešinėsios sienos 5x apatinės sienos
I, II, III	Acc = 92.3 % Se = 93.0 % Sp = 91.7 %	1x priekinės sienos 3x priekinis kairiosios sienos 1x apatinės sienos
I, II, III, aVR, aVL, aVF	Acc = 85.32 % Se = 95.8 % Sp = 75.0 %	2x priekinis kairiosios sienos 1x apatinės sienos
I, II, III, aVR, aVL, aVF, V1	Acc = 87.41 % Se = 95.8 % Sp = 79.2 %	1x priekinis kairiosios sienos 2x apatinės sienos

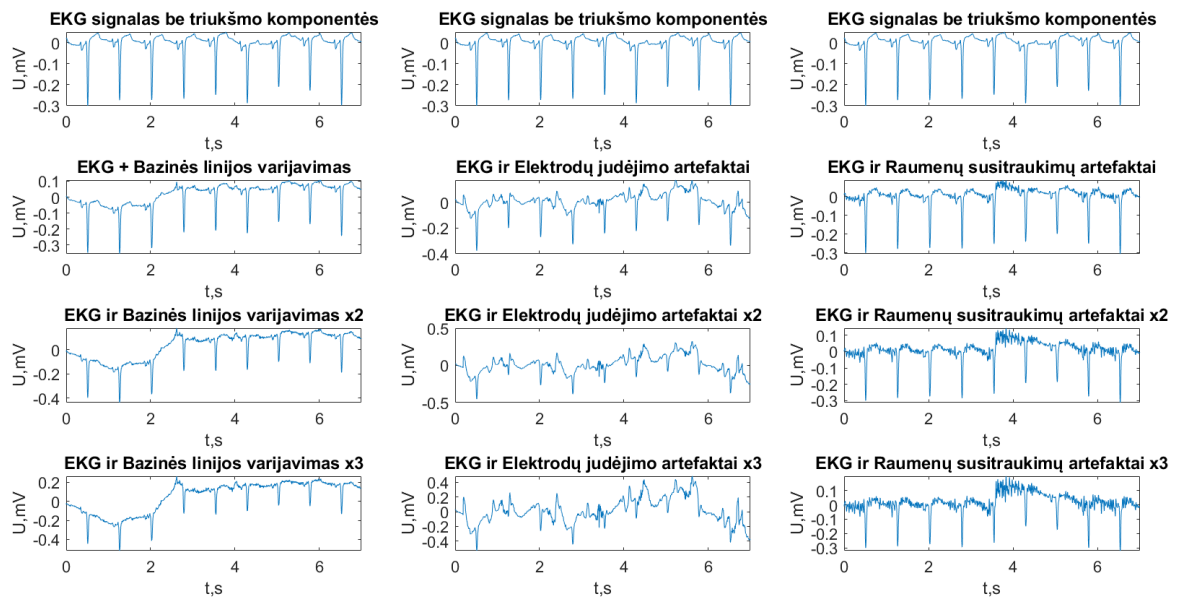
Kitame tyrimo etape buvo tikrinamas algoritmo atsparumas triukšmams, šiame tyrime naudojamas aukščiausią tikslumą parodęs algoritmas su I, II, III derivacijomis. Šiuo testu buvo bandoma imituoti situacija, kad signalai buvo užregistruoti ne ambulatoriškai, o panaudojus išmaniają apyranę. Kaip

galima nuspėti, signalai užregistruoti išmaniuoju dėvimu elektrokardiogramos registratoriumi gali būti labiau užteršti triukšmais, lyginant su ambulatoriškai užregistruotais signalais. Šiam tyrimui vykdyti buvo panaudota „MIT-BIH Noise Stress Test“ duomenų bazė, kurioje yra patalpinti bazinės linijos varijavimo, elektrodų judėjimo bei raumenų susitraukimų triukšmai [69]. 33 pav. pavaizduota, vienas švarus EKG signalas iš testavimo duomenų bazės ir triukšmų signalai gauti iš MIT-BIH duomenų bazės.




33 pav. Testavimo duomenų bazės EKG signalas bei triukšmų segmentai gauti iš „MIT-BIH Noise Stress Test“ duomenų bazės

Algoritmo atsparumas triukšmams buvo tikrinamas panaudojant testavimo duomenų bazę su visais EKG signalais, prie kurių buvo pridėti skirtingų amplitudžių triukšmai. Paveiksle žemiau yra pateiktas švarus EKG signalas iš testavimo duomenų bazės bei toks pat EKG signalas su pridėtais skirtingos amplitudės triukšmais. Iš paveikslo galima pamatyti, kad triukšmai yra žalingi EKG signalui ir gali jį iškraipyti neatpažįstamai.



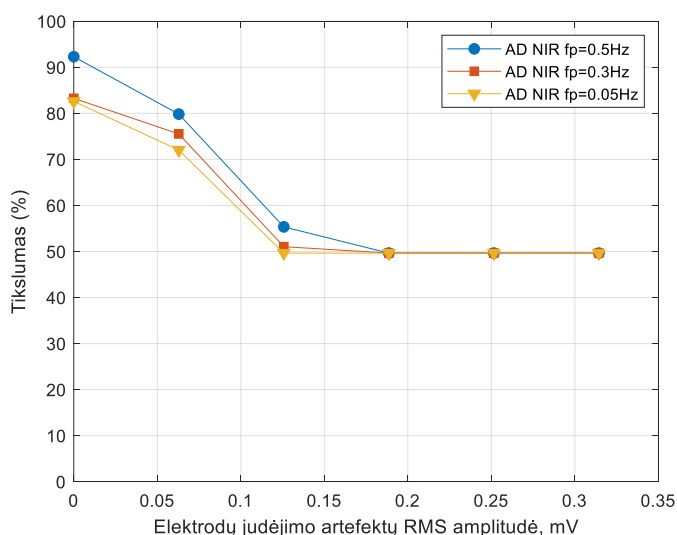
34 pav. Švarus EKG signalas bei EKG signalai su pridėtais skirtingos amplitudės triukšmais

Pirmajame šio testo etape buvo tiriama bazinės linijos varijavimo įtaka algoritmo veikimui. Prie švarių EKG signalų buvo pridėdama vis didesnės amplitudės triukšmas ir kiekvienu atveju buvo vertinamas algoritmo tikslumas. Taip pat žinant, kad bazinės linijos varijavimo bei ST segmento spektrai persidengia ir tai yra problema, kurios išspręsti nepavysta, buvo tiriami trys skirtingi aukštų dažnių filtrai su skirtingais pjūvio dažniais (filtrai plačiau aprašyti 2.2.1 skyrelyje). Šie filtrai buvo panaudoti pirminiam signalų apdorojimui algoritme. Gauti rezultatai pateikti apačioje (35 pav.). Reikėtų pastebėti, kad algoritmo tikslumas panaudojant skirtingus filtrus buvo vis kitoks, net ir testuojant su švariais EKG signalais. Naudojant aukštų dažnių NIR filtrą, kurio pjūvio dažnis – $f_p = 0.5$ Hz, pasiektas aukščiausias tikslumas, testą atlikus su švariais EKG signalais. Taip pat galima matyti, jog naudojant šį filtrą bazinės linijos varijavimo triukšmas nesukelia didelių problemų algoritmui, net kai triukšmas buvo sustiprintas tris kartus. Triukšmą sustiprinus keturis ar penkis kartus tikslumas ženkliai sumažėja. Tuo tarpu panaudojant AD NIR filtrą, kurio pjūvio dažnis – $f_p = 0.3$ Hz, bazinės linijos varijavimo triukšmo įtaka algoritmo tikslumui yra panaši. Triukšmą sustiprinus iki trijų kartų algoritmo tikslumas išlieka gan stabilus, tačiau triukšmą sustiprinus 4 ar 5 kartus tikslumas ženkliai krenta. Panaudojus trečiąjį filtrą, kurio pjūvio dažnis – $f_p = 0.05$ Hz galima pastebėti, kad bazinės linijos varijavimas padaro didesnę įtaką algoritmo tikslumui. Triukšmą sustiprinus 3,4 ar 5 kartus tikslumas ženkliai sumažėja.



35 pav. Bazinės linijos variavimo RMS amplitudės įtaka miokardo infarkto atpažinimo diagnostiniam tikslumui, signalų apdorojimui panaudojant tris aukštų dažnių filtrus, su skirtingais pjūvio dažniais


Toliau testuojant algoritmo atsparumą triukšmams, buvo tiriama elektrodų judėjimo artefaktų įtaka algoritmo tikslumui. Iš rezultatų, kurie pateikti 36 pav., galima pastebėti, kad pridėjus elektrodų judėjimo artefaktus prie signalų, algoritmo tikslumas ženkliai sumažėja. Pridėjus dvigubai didesnės amplitudės triukšmus algoritmo tikslumas nukrenta iki 50%, galima teigti, kad algoritmas tokiu atveju nebeveikia. Taigi, iš šio tyrimo galima pastebėti, jog elektrodų judėjimo artefaktai stipriai įtakoja algoritmo veikimą. Taip pat filtrai, naudojami pirminiam signalų apdorojimui, negali nufiltruoti šių triukšmų. Elektrodų judėjimo artefaktai kelia daug problemų įvairių širdies aritmijų detektoriams, dėl to kad yra sunkiai nufiltruojami panaudojant standartinius filtrus. Šio triukšmo dažnių juosta persidengia su QRS, ST segmentais, taip pat šis triukšmas gali būti panašus į priešlaikinio širdies susitraukimo signalą [69].



36 pav. Elektrodų judėjimo artefaktų RMS amplitudės įtaka miokardo infarkto atpažinimo diagnostiniam tikslumui, signalų apdorojimui panaudojant tris aukštų dažnių filtrus, su skirtingais pjūvio dažniais


Kitame testo etape buvo tiriama raumenų susitraukimų triukšmo įtaka algoritmo tikslumui. Rezultatai pateikti apačioje (37 pav.). Algoritmo tikslumas išlieka beveik nepakitęs, pridėjus šį triukšmą prie EKG signalų, tačiau triukšmą sustiprinus du ar tris kartus, algoritmo tikslumas ženkliai sumažėja. Jei triukšmo amplitudė padidinama keturis kartus, algoritmas nebeveikia. Iš to galima spręsti, kad šiuos

triukšmus yra sunku išfiltruoti įprastais filtrais. Kaip galima matyti 1.3 poskyryje pateiktame 11 pav., raumenų susitraukimų triukšmas yra pasiskirstęs beveik visame EKG signalo spektre, taigi jei šio triukšmo amplitudė išauga per daug, jis tiesiog užgožia EKG signalą.



37 pav. Raumenų susitraukimų artektų RMS amplitudės įtaka miokardo infarkto atpažinimo diagnostiniam tikslumui, signalų apdorojimui panaudojant tris aukštų dažnių filtrus, su skirtingais pjūvio dažniais

Paskutiniame tyrimo etape prie EKG signalų buvo pridėtas sudėtinis triukšmas sudarytas iš visų prieš tai minėtų. Rezultatai pateikti apačioje (38 pav.). Kaip ir buvo galima tikėtis, sudėtinis triukšmas daro didžiausią įtaką algoritmui. Pridėjus tokį triukšmą prie EKG signalų algoritmo tikslumas ženkliai sumažėja, o sustiprinus triukšmą dvigubai algoritmas nebeveikia. Toks triukšmas tiesiog užgožia EKG signalą.



38 pav. Triukšmo, susidedančio iš bazinės linijos varijavimo, elektrodų judėjimo ir raumenų susitraukimų artektų, RMS amplitudės įtaka miokardo infarkto atpažinimo diagnostiniam tikslumui, signalų apdorojimui panaudojant tris aukštų dažnių filtrus, su skirtingais pjūvio dažniais

Atlikus algoritmo atsparumo triukšmams tyrimą galima daryti tokias išvadas:

Bazinės linijos varijavimo bei ST segmento spektrai persidengia, dėl to yra sudėtinga nuspręsti kokio pjūvio dažnio AD filtrą būtų geriausia naudoti, šis testas bei tolimesni eksperimentavimai parodė, jog aukščiausią tikslumą galima gauti panaudojant aukštų dažnių filtrą, kurio pjūvio dažnis $f_p = 0.5\text{Hz}$; Elektrodo judėjimo bei raumenų susitraukimo artefaktai daro didelę įtaką algoritmo tikslumui, šiuos artefaktus yra sudėtinga išfiltruoti nepašalinus svarbių EKG signalo komponentų, taigi, kad būtų sumažinta šių triukšmų įtaka, atliekant EKG signalų registravimą reikia būti ramybės būsenoje.

Šiame tyrime pasiūlytas algoritmas pasiekė 92,3 % tikslumą, 93,0 % jautrumą bei 91,7 % specifiškumą, apmokymui ir testavimui buvo panaudoti 10 s trukmės EKG segmentai iš PTB duomenų bazės. Lyginant su kitais publikuotais algoritmais (4 lentelė), aukščiausias tikslumas nebuvo pasiektas, tačiau buvo pastebėti tam tikri trūkumai kitų algoritmų tyrimuose. Kaip buvo minėta 1.2.2 skyrelyje, kai kurie tyrėjai tinkamai neatskyrė apmokymo ir testavimo duomenų. Tam tikruose tyrimuose, naudojant duomenų bazę nebuvo atsižvelgta, kad tam pačiam pacientui galėjo būti užregistruotas daugiau nei vienas signalas, taigi, to paties paciento signalai galėjo patekti į apmokymo bei testavimo duomenų bases. Taip pat buvo pastebėta, kad visuose analizuotuose straipsniuose buvo naudojami širdies dūžio segmentai. Lyginant širdies anomalijų detektorius klasifikuojančius širdies dūžio segmentus ir trumpus EKG segmentus (pvz., 10 s), rezultatai gali skirtis. Klasifikuojant širdies dūžio segmentus, gali būti pasiektas dirbtinai didesnis tikslumas, dėl kelių priežasčių. Gali atsirasti didesnis disbalansas tarp duomenų, kai širdies dūžių su anomalijomis yra žymiai daugiau nei normalių širdies dūžių. Tuo tarpu, naudojant trumpus EKG segmentus gali pasitaikyti MI būdingų bruožų, tokių kaip ST segmentas, pokyčių, kas gali lemti mažesnę klasifikavimo tikslumą, tačiau ST segmento pakilimas turi matytis ne viename širdies dūžyje, kad būtų teisingai atpažintas miokardo infarktas.

4 lentelė. Šiame darbe siūlomo algoritmo ir kitų, publikuotų miokardo infarkto klasifikavimo algoritmų palyginimas

Autorius	Derivacijos	Duomenų bazė	Metodas	Rezultatai
Reasat ir kt. [70]	II, III, avF	PTB	Negilus konvoliucinis neuroninis tinklas	Acc = 85 % Se = 85 % Sp = 84 %
Strothoff ir kt. [71]	standartinės 12 derivacijų	PTB	Pilnai konvoliucinis neuroninis tinklas	Acc = 93.6 %; Se = 93.3 %; Sp = 89.2 %
Acharya ir kt. [29]	II	PTB	11 sluoksnių konvoliucinis neuroninis tinklas	Acc = 95.2 % Se = 95.5 % Sp = 94.2 %
Feng ir kt. [34]	I	PTB	CNN-LSTM	Acc = 95.4 % Se = 98.2 % Sp = 86.5 %
Kora [38]	II	MIT-BIH NSR	Naudojo hibridinį tinklą FFPSO	Acc = 99.3 % Se = 99.97 % Sp = 98.7 %
Liu ir kt. [30]	V2, V3, V5, aVL	PTB	ML-CNN modelis	Acc = 96 % Se = 95.4 % Sp = 97.37 %
Sharma ir kt. [39]	-	PTB	Naudojant optimalių biortogonalinių filtrų banką ir KNN klasifikatorius	Acc = 99.74 % Se = 99.84 % Sp = 99.35 %

Liu ir kt. [40]	standartinēs 12 derivacijū	PTB	MFB-CBRNN	Acc = 93.08 % Se = 94.42 % Sp = 86.29 %
Rai ir kt. [44]	II	PTB MIT-BIH	CNN-LSTM	Acc = 99.88 %
Martin ir kt. [42]	II	PTB	LSTM	Acc = 89.56 % Se = 91.88 % Sp = 80.81 %
Pasiūlytas	I, II, III	PTB	CNN-LSTM	Acc = 92.3 % Se = 93.0 % Sp = 91.7 %

Išvados

1. Sukurtas giliojo mokymosi neuroniniu tinklu pagrįstas miokardo infarkto atpažinimo algoritmas, skirtas atpažinti infarktą sumažinto derivacijų skaičiaus elektrokardiogramoje.
2. Ištyrus algoritmo parametrų įtaką miokardo infarkto atpažinimo patikimumui nustatyta, kad optimali dirbtinio neuroninio tinklo struktūra – 3xCNN-LSTM, optimali aktyvacijos funkcija LSTM segmentui – hiperbolinio tangento, o CNN segmentams – lygintuvo funkcija.
3. Tiriant elektrokardiogramos signalo charakteristikų įtaką miokardo infarkto atpažinimo patikimumui, fokusuotasi į ant riešo dėvimų elektrokardiogramos registratorių galimybes. Tyrimai parodė, kad:
 - netinkamoje vietoje priliestas elektrodas daro ženkliai įtaką miokardo infarkto atpažinimo tikslumui. T.y., registruojant krūtinines derivacijas ir nukrypęs nuo reikiamos vietos (pvz., V1 registravimo taško) apytiksliai 6 cm algoritmo tikslumas sumažėja 13,3 %.
 - naudojant skirtingus elektrokardiogramos derivacijų derinius, geriausias rezultatas gautas panaudojant I, II ir III derivacijas, t.y., tikslumas – 92,3 %, jautrumas – 93,0 %, specifiškumas – 91,7 %.
 - didžiausią įtaką algoritmo patikimumui daro elektrodų judėjimo bei raumenų susitraukimų artefaktai. Miokardo infarkto atpažinimo patikimumas nepatenkinamas esant 0,05 mV RMS amplitudės raumenų susitraukimų triukšmams bei 0,15 mV RMS amplitudės elektrodų judėjimo artefaktams.

Galimos tolimesnių tyrimų kryptys

1. Algoritmo tyrimas panaudojant EKG signalus užregistruotus su ant riešo dėvimo EKG registratoriumi.
2. Pažangių signalų apdorojimo metodų taikymas siekiant sumažinti elektrodų judėjimo bei raumenų susitraukimų artefaktų įtaką algoritmo tikslumui.
3. CNN-LSTM dirbtinio neuroninio tinklo efektyvumo didinimas, optimizuojant skaičiavimams vykdyti reikalingus resursus.

Literatūros sąrašas

1. World Health Organization, „Cardiovascular diseases (CVDs),“ 2021, [žiūrėtas 2022-05-20]. Prieiga per: [https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/en/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
2. Eurostat, „For people under 75, two deaths out of three in the EU could have been avoided,“ 2019 [žiūrėtas 2022-05-23]. Prieiga per: https://ec.europa.eu/commission/presscorner/detail/it/STAT_19_5526
3. YUSUF, Salim, et al., „Effect of potentially modifiable risk factors associated with myocardial infarction in 52 countries (the INTERHEART study): case-control study,“ *The Lancet*, t. 364, nr. 9438, pp. 937-952, 2004.
4. BAX, Jeroen J., et al., „Third universal definition of myocardial infarction,“ *Journal of the American College of Cardiology*, t. 60, nr. 60, pp. 1581-1598, 2012.
5. JAFARIAN, Kamal, et al., „Automating detection and localization of myocardial infarction using shallow and end-to-end deep neural networks,“ *Applied Soft Computing*, t. 93, 2020.
6. ANTMAN, Elliott, et al., „Myocardial infarction redefined—a consensus document of The Joint European Society of Cardiology/American College of Cardiology committee for the redefinition of myocardial infarction: The Joint European Society of Cardiology/ American College of Cardiology,“ *Journal of the American College of Cardiology*, t. 36, nr. 3, pp. 959-969, 2000.
7. ACHARYA, U. Rajendra, et al., „Automated detection and localization of myocardial infarction using electrocardiogram: a comparative study of different leads,“ *Knowledge-Based Systems*, t. 99, pp. 146-156, 2016.
8. BOUSSELJOT, R., D. Kreisler, A. Schnabel, „Nutzung der EKG-Signaldatenbank CARDIODAT der PTB über das Internet,“ *Biomedizinische Technik*, t. 40, nr. 1, p. 317, 1995.
9. BUJA, L. Maximilian, „Myocardial ischemia and reperfusion injury,“ *Cardiovascular Pathology*, t. 14, nr. 4, pp. 170-175, 2005.
10. THYGESEN, Kristian, et al., "Universal definition of myocardial infarction," *European Heart Journal*, vol. 28, no. 20, pp. 2525-2538, 2007.
11. VERMA, Manish Kumar, et al., „Current and futuristic scope of biomarkers in acute myocardial infarction,“ *Indian Journal of Medical Science*, t. 70, nr. 2, pp. 4-10, 2018.
12. DE LUNA, Antoni Bayés, *Basic electrocardiography: normal and abnormal ECG patterns*, Barcelona: Blackwell Futura, 2008.
13. SWAIN, Sushree Satvatee, Dipti Patra and Yengkhom Omesh Singh, „Automated detection of myocardial infarction in ECG using modified Stockwell transform and phase distribution pattern from time-frequency analysis,“ *Biocybernetics and Biomedical Engineering*, t. 40, nr. 3, pp. 1174-1189, 2020.
14. Cables and Sensors, LLC, „12-Lead ECG Placement Guide with Illustrations,“ 2022, [žiūrėtas 2022-05-20]. Prieiga per: <https://www.cablesandsensors.com/pages/12-lead-ecg-placement-guide-with-illustrations>.
15. DUPRE, Anthony, Sarah Vincent and Paul A. Iaizzo, „Basic ECG theory, recordings, and interpretation,“ *Handbook of cardiac anatomy, physiology, and devices*. Humana Press, pp. 191-201, 2005.

16. SOVILJ, S., et al., „A Simplified 3D Model of Whole Heart Electrical Activity and 12-Lead ECG Generation,“ *Computational and Mathematical Methods in Medicine*, t. 2013, nr. 134208, p. 10, 2013.
17. KLABUNDE, Richard E., „Electrocardiogram (EKG, ECG),“ *Cardiovascular Physiology Concepts*, 2019.
18. NEWMAN, Jonathan D., et al., „Trends in Myocardial Infarction Rates and Case Fatality by Anatomical Location in Four United States Communities, 1987 to 2008 (from the Atherosclerosis Risk in Communities Study),“ *The American Journal of Cardiology*, t. 112, nr. 11, pp. 1714-1719, 2013.
19. MUHARAM, M. Yusuf, R. Ahmad, M. Y. Harny, „The ‘widow maker’: Electrocardiogram features that should not be missed,“ *Malays Fam Physician*, t. 8, nr. 1, pp. 45-47, 2013.
20. HAN, Chuang and Li Shi, „Automated interpretable detection of myocardial infarction fusing energy entropy and morphological features,“ *Computer methods and programs in biomedicine*, t. 175, pp. 9-23, 2019.
21. TRIPATHY, Rajesh Kumar, Abhijit Bhattacharyya and Ram Bilas Pachori, „A novel approach for detection of myocardial infarction from ECG signals of multiple electrodes,“ *IEEE Sensors Journal*, t. 19, nr. 12, pp. 4509-4517, 2019.
22. JAYACHANDRAN, E. S., Paul Joseph K. and R. Acharya U., „Analysis of myocardial infarction using discrete wavelet transform,“ *Journal of medical systems*, t. 34, nr. 6, pp. 985-992, 2010.
23. FU, Jie, et al., „Deep learning approaches using 2D and 3D convolutional neural networks for generating male pelvic synthetic computed tomography from magnetic resonance imaging,“ *Medical physics*, t. 46, nr. 9, pp. 3788-3798, 2019.
24. ACHARYA, U. Rajendra, et al., „Automated characterization and classification of coronary artery disease and myocardial infarction by decomposition of ECG signals,“ *A comparative study. Information Sciences*, t. 377, pp. 17-29, 2017.
25. DOHARE, Ashok Kumar, Vinod Kumar and Ritesh Kumar, „Detection of myocardial infarction in 12 lead ECG using support vector machine,“ *Applied Soft Computing*, t. 64, pp. 138-147, 2018.
26. ACHARYA, U. Rajendra, et al., „Study of heart rate variability signals at sitting and lying postures,“ *Journal of bodywork and Movement Therapies*, t. 9, nr. 2, pp. 134-141, 2005.
27. PŁAWIAK, Paweł, U. Rajendra Acharya, „Novel deep genetic ensemble of classifiers for arrhythmia detection using ECG signals,“ *Neural Computing and Applications*, t. 32, nr. 15, pp. 11137-11161, 2020.
28. GUPTA, Varun and Monika Mittal, „Efficient R-peak detection in electrocardiogram signal based on features extracted using Hilbert transform and Burg method,“ *Journal of the Institution of Engineers (India)*, t. 101, nr. 1, pp. 23-34, 2020.
29. ACHARYA, U. Rajendra, et al., „Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals,“ *Information Sciences*, pp. 190-198, 2017.

30. LIU, Wenhan, et al., „Real-time multilead convolutional neural network for myocardial infarction detection,“ *IEEE journal of biomedical and health informatics*, t. 22, nr. 5, pp. 1434-1444, 2017.
31. BALOGLU, Ulas Baran, et al., „Classification of myocardial infarction with multi-lead ECG signals and deep CNN,“ *Pattern Recognition Letters*, t. 122, pp. 23-30, 2019.
32. ACHARYA, U. Rajendra, et al., „Deep convolutional neural network for the automated diagnosis of congestive heart failure using ECG signals,“ *Applied Intelligence*, t. 41, nr. 9, pp. 16-27, 2019.
33. LUI, Hin Wai, King Lau Chow, „Multiclass classification of myocardial infarction with convolutional and recurrent neural networks for portable ECG devices,“ *Informatics in Medicine Unlocked*, t. 13, pp. 26-33, 2018.
34. FENG, Kai, et al., „Myocardial Infarction Classification Based on Convolutional Neural Network and Recurrent Neural Network,“ *Applied Sciences*, t. 9, nr. 9, p. 1879, 2019.
35. Han, Chuang, Li Shi, „ML-ResNet: A novel network to detect and locate myocardial infarction using 12 leads ECG,“ *Computer methods and programs in biomedicine*, t. 185, p. 105138, 2020.
36. XU, Chenchu, et al., „MuTGAN: Simultaneous segmentation and quantification of myocardial infarction without contrast agents via joint adversarial learning,“ *Lecture Notes in Computer Science*, t. 11071, p. 525-534, 2019.
37. ZHANG, Jieshuo, et al., „Automated detection and localization of myocardial infarction with staked sparse autoencoder and treebagger,“ *IEEE Access*, t. 7, pp. 70634-70642, 2019.
38. KORA, Padmavathi, „ECG based myocardial infarction detection using hybrid firefly algorithm,“ *Computer methods and programs in biomedicine*, t. 152, pp. 141-148, 2017.
39. SHARMA, Manish, Ru San Tan and U. Rajendra Acharya, „A novel automated diagnostic system for classification of myocardial infarction ECG signals using an optimal biorthogonal filter bank,“ *Computers in biology and medicine*, t. 102, pp. 341-356, 2018.
40. LIU, Wenhan, et al., „MFB-CBRNN: A hybrid network for MI detection using 12-lead ECGs,“ *IEEE journal of biomedical and health informatics*, t. 24, nr. 2, pp. 503-514, 2019.
41. ULLAH, Amin, et al., „Action recognition in video sequences using deep bi-directional LSTM with CNN features,“ *IEEE*, t. 6, pp. 1155-1166, 2017.
42. MARTIN, Harold, et al., „Near real-time single-beat myocardial infarction detection from single-lead electrocardiogram using Long Short-Term Memory Neural Network,“ *Biomedical Signal Processing and Control*, t. 68, nr. 102683, pp. 1746-8094, 2021.
43. BREUEL, Thomas M., et al., „High-performance OCR for printed English and Fraktur using LSTM networks,“ *12th international conference on document analysis and recognition. IEEE*, pp. 683-687, 2013.
44. RAI, Hari Mohan, Kalyan Chatterjee, „Hybrid CNN-LSTM deep learning model and ensemble technique for automatic detection of myocardial infarction using big ECG data,“ *Appl Intell*, t. 52, p. 5366-5384, 2022.
45. KIRANYAZ, Serkan, et al., „1D convolutional neural networks and applications: A survey,“ *Mechanical systems and signal processing*, t. 151, p. 107398, 2021.

46. DOLPHIN, Rian, „LSTM Networks | A Detailed Explanation,“ Towards Data Science, 2020.
47. SOYDANER, Derya, „A Comparison of Optimization Algorithms for Deep Learning,“ International Journal of Pattern Recognition and Artificial Intelligence, t. 34, nr. 13, p. 2052013, 2020.
48. FATIMAH, Binish, et al., „Efficient detection of myocardial infarction from single lead ECG signal,“ Biomedical Signal Processing and Control, t. 68, nr. 102678, pp. 1746-8094, 2021.
49. SINGHAL, Amit, et al., „An efficient removal of power-line interference and baseline wander from ECG signals by employing Fourier decomposition technique,“ Biomedical Signal Processing and Control, t. 57, nr. 101741, pp. 1746-8094, 2020.
50. CHAVAN, Mahesh S., R. A. Agarwala, M. D. Uplane, „Suppression of baseline wander and power line interference in ECG using digital IIR filter,“ International journal of circuits, systems and signal processing, t. 2, nr. 2, pp. 356-365, 2008.
51. VAN Alste, Jan A., T. S. Schilder., „Removal of base-line wander and power-line interference from the ECG by an efficient FIR filter with a reduced number of taps,“ IEEE transactions on biomedical engineering, t. 12, pp. 1052-1060, 1985.
52. PISKOROWSKI, Jacek, „Powerline interference removal from ECG signal using notch filter with non-zero initial conditions,“ 2012 IEEE International Symposium on Medical Measurements and Applications Proceedings, pp. 1-3, 2012.
53. BHOGESHWAR, Sande Seema, M. K. Soni and Dipali Bansal, „Design of Simulink Model to denoise ECG signal using various IIR & FIR filters,“ In: 2014 International Conference on Reliability Optimization and Information Technology (ICROIT). IEEE, pp. 477-483, 2014.
54. XU, Mingfang, et al., „Rule-based method for morphological classification of ST segment in ECG signals,“ Journal of Medical and Biological Engineering, t. 35, nr. 6, pp. 816-823, 2015.
55. KLIGFIELD, Paul, et al., „Recommendations for the Standardization and Interpretation of the Electrocardiogram Part I,“ Journal of the American College of Cardiology, t. 49, nr. 10, pp. 1109-1127, 2007.
56. AFSAR, Fayyaz A., M. Arif and J. Yang, „Detection of ST segment deviation episodes in ECG using KLT with an ensemble neural classifier,“ Physiological measurement, t. 29, nr. 7, p. 747, 2008.
57. GUO, Shu-Li, et al., „The future of remote ECG monitoring systems,“ Journal of geriatric cardiology, t. 13, nr. 6, p. 528, 2016.
58. LIU, Jun and Yaqi Zhou., „Design of a novel portable ECG monitor for heart health,“ In: 2013 Sixth International Symposium on Computational Intelligence and Design. IEEE, pp. 257-260, 2013.
59. AVILA, Cesar O., „Novel Use of Apple Watch 4 to Obtain 3-Lead Electrocardiogram and Detect Cardiac Ischemia,“ The Permanente Journal, <https://doi.org/10.7812/TPP/19-025>, 2019.
60. COBOS GIL, M. Á., „Standard and precordial leads obtained with an Apple Watch,“ Annals of internal medicine, t. 173, nr. 3, pp. 249-250, 2020.
61. SPACCAROTELLA, Carmen Anna Maria, et al., „Multichannel electrocardiograms obtained by a smartwatch for the diagnosis of ST-segment changes,“ JAMA cardiology, t. 5, nr. 10, pp. 1176-1180, 2020.

62. BACEVIČIUS, J., et al., „High Specificity Wearable Device With Photoplethysmography and Six-Lead Electrocardiography for Atrial Fibrillation Detection Challenged by Frequent Premature Contractions: DoubleCheck-AF,“ *Frontier in Cardiovascular Medicine*, t. 9, nr. 869730, 2022.
63. GOLDBERGER, Ary L., et al, „PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex,“ 2000.
64. BROWNLEE, Jason, „A Gentle Introduction to the Rectified Linear Unit (ReLU),“ *Machine Learning Mastery*, 2020.
65. HOSEINI, Farnaz, Asadollah Shahbahrami, Peyman Bayat, „Gentle Introduction to the Adam Optimization Algorithm for Deep Learning,“ *Deep Learning Performance*, 2019.
66. KUMAR, Rajeev, Abhaya Indrayan, „Receiver operating characteristic (ROC) curve for medical researchers,“ *Indian pediatrics*, t. 48, nr. 4, pp. 277-287, 2011.
67. YADAV, Anita, C. K. Jha, Aditi Sharan, „Optimizing LSTM for time series prediction in Indian stock market,“ *International Conference on Computational Intelligence and Data Science (ICCIDS 2019)*, 2019.
68. LATEEF, F., A. Annathurai, T. T. Loh, „The V-Quick patch versus the standard 12-lead ECG system: time is the essence,“ *International journal of emergency medicine*, t. 1, nr. 1, pp. 43-48, 2008.
69. MOODY, George B., W. Muldrow, and Roger G. Mark, „A noise stress test for arrhythmia detectors,“ *Computers in Cardiology*, t. 11, pp. 381-384, 1984.
70. REASAT, Tahsin and Celia Shahnaz, „Detection of inferior myocardial infarction using shallow convolutional neural networks,“ *IEEE region 10 humanitarian technology conference (R10-HTC)*, pp. 718-721, 2017.
71. STRODTHOFF, Nils and Claas Strodthoff, „Detecting and interpreting myocardial infarction using fully convolutional neural networks,“ *Physiological measurement*, t. 40, nr. 1, p. 015001, 2019.