



**Kauno technologijos universitetas**

Informatikos fakultetas

# **EKG signalų tyrimas hipertenzijai prognozuoti**

Baigiamasis magistro studijų projektas

---

**Kristupas Trakšelis**

Projekto autorius

**Dr. Eglė Butkevičiūtė**

Vadovė

---

**Kaunas, 2024**



**Kauno technologijos universitetas**

Informatikos fakultetas

## **EKG signalų tyrimas hipertenzijai prognozuoti**

Baigiamasis magistro studijų projektas

Dirbtinio intelekto informatika (6211BX007)

---

**Kristupas Trakšelis**

Projekto autorius

**Dr. Eglė Butkevičiūtė**

Vadovė

**Dr. Gintaras Palubeckis**

Recenzentas

---

**Kaunas, 2024**



**Kauno technologijos universitetas**

Informatikos fakultetas

Kristupas Trakšelis

## **EKG signalų tyrimas hipertenzijai prognozuoti**

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) 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 (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Kristupas Trakšelis

*Patvirtinta elektroniniu būdu*

Trakšelis, Kristupas. EKG signalų tyrimas hipertenzijai prognozuoti. Magistro studijų baigiamasis projektas / vadovė dr. Eglė Butkevičiūtė; Kauno technologijos universitetas, Informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Informatikos mokslai, Informatika (B01).

Reikšminiai žodžiai: EKG, hipertenzija, signalų apdorojimas, konvoliuciniai neuroniniai tinklai.

Kaunas, 2024. 67 p.

### **Santrauka**

Šiame tyrime yra apžvelgiama hipertenzijos problema bei atliekama EKG analizė. Jos metu yra analizuojami esami hipertenzijos prognozavimo metodai bei gauti rezultatai. Analizės metu yra išsiginama problema, jog nėra automatizuoto mašininio mokymo metodo, galinčio prognozuoti hipertenziją iš itin trumpų signalų panaudojant tik vieno elektrodo duomenis. Darbe yra pasiūlomas ir įgyvendinamas hipertenzijos prognozavimo algoritmas, kurio pagrindu tapo SVM ir orientuotų histogramų metodu grįstas sprendimas. Pirmasis pasiūlymas – elektokardiogramos signalo filtravimas panaudojant žemo dažnio *Butterworth* filtrą. Tuomet signalas yra segmentuojamas į širdies dūžius panaudojant algoritmą iš *biopeaks* paketo. Trečiasis pasiūlymas – konvoliucinio neuroninio tinklo architektūra *Net*. Atliekant eksperimentus buvo lyginami *Net*, *ResNet50*, *ResNet152* ir *MobileNetV2* neuroniniai tinklai. Taip pat į palyginimus buvo įtrauktas ir SVM algoritmas. Eksperimentų metu nustatyta, kad hipertenzijos prognozavimo tikslumas siekia 92 %.

Trakšelis Kristupas. ECG signal analysis for the prediction of hypertension. Master's Final Degree Project / supervisor dr. Eglė Butkevičiūtė; Informatics Faculty, Kaunas University of Technology.

Study field and area (study field group): Computer science, Informatics (B01).

Keywords: ECG, hypertension, signal processing, convolutional neural networks.

Kaunas, 2024. 67 p.

### **Summary**

This study provides an overview of the problem of hypertension and ECG analysis. It analyses existing methods for the prediction of hypertension and the results obtained. The analysis highlights the problem that there is no automated machine learning method that can predict hypertension from extremely short signals using only data from a single electrode. In this work, a hypertension prediction algorithm is proposed and implemented based on SVM and oriented histogram method. The first proposal is the filtering of the electrocardiogram signal using a low-pass Butterworth filter. An algorithm from the biopeaks package is then used to segment the signal into heartbeats. The third proposal is a convolutional neural network architecture called *Net*. The experiments compared *Net*, *ResNet50*, *ResNet152* and *MobileNetV2* neural networks. The SVM algorithm was also included in the comparisons. The experiments showed a prediction accuracy of 92 % for hypertension.

## Turinys

Lentelių sąrašas .....	8
Paveikslų sąrašas .....	9
Santrumpų ir terminų sąrašas .....	10
Įvadas.....	11
<b>1. Hipertenzijos prognozavimo metodų ir priemonių analizė .....</b>	<b>12</b>
1.1. Hipertenzija .....	12
1.2. Fiziologiniai signalai hipertenzijai nustatyti .....	12
1.2.1. EKG.....	12
1.2.2. Širdies ritmo variabilumas hipertenzijai prognozuoti .....	13
1.3. Duomenų rinkinių analizė hipertenzijai prognozuoti .....	15
1.3.1. <i>SHAREE</i> .....	15
1.3.2. <i>PTB</i> .....	15
1.3.3. RR intervalai iš sveikų žmonių.....	15
1.3.4. <i>MIMIC-III Waveform</i> .....	16
1.3.5. Duomenų rinkinių apibendrinimas .....	16
1.4. Egzistuojančių sprendimų analizė hipertenzijai nustatyti .....	16
1.4.1. Ortogonalinių bangelių filtrų rinkinio sistema hipertenzijos lygio nustatymui.....	16
1.4.2. Mašininio mokymo metodų taikymas hipertenzijai prognozuoti .....	18
1.4.3. Statistinė ŠRV analizė hipertenzijai nustatyti .....	19
1.4.4. Hipertenzijos nustatymo metodų apibendrinimas .....	20
1.5. EKG signalo filtravimo metodų analizė .....	21
1.5.1. <i>Butterworth</i> filtras .....	21
1.5.2. <i>Wiener</i> filtras .....	21
1.5.3. <i>Kalman</i> filtras .....	22
1.6. Išmanieji įrenginiai, skirti registruoti EKG bei ŠRV signalus .....	23
1.6.1. <i>Polar H10</i> .....	24
1.6.2. <i>Apple Watch 4</i> .....	24
1.6.3. Kiti išmanieji įrenginiai fiziologiniams signalams analizuoti .....	25
1.7. Mobiliosios programėlės fiziologiniams signalams analizuoti .....	25
1.8. Hipertenzijos prognozavimo metodų ir priemonių analizės išvados.....	26
<b>2. EKG signalų tyrimo hipertenzijai prognozuoti projekto specifikacija .....</b>	<b>27</b>
2.1. Reikalavimai.....	27
2.2. EKG signalo filtravimas .....	29
2.3. Signalų skirstymas į širdies dūžius.....	29
2.4. Hipertenzijos prognozavimas .....	31
<b>3. EKG signalų tyrimo hipertenzijai prognozuoti eiga ir rezultatai.....</b>	<b>34</b>
3.1. Eksperimentų aplinka .....	34
3.2. EKG analizė hipertenzijai prognozuoti .....	34
3.3. Duomenų rinkinio sudarymas.....	41
3.4. Konvoliucinių neuroninių tinklų tyrimas hipertenzijai nustatyti.....	42
3.4.1. <i>ResNet</i> tyrimas.....	42
3.4.2. <i>Net</i> tyrimas.....	44
3.4.3. SVM modelio tyrimas .....	47
3.4.4. Modelių apibendrinimas .....	48
3.5. Spektrogramų klasifikavimo tyrimas .....	49
3.6. EKG klasifikatorių tyrimas.....	51
3.7. Prognozavimo modelių greitaveikos tyrimas .....	60
3.8. Diskusija ir hipertenzijos prognozavimo metodo apribojimai .....	62
<b>Išvados .....</b>	<b>63</b>
<b>Literatūros sąrašas .....</b>	<b>64</b>
<b>Priedai.....</b>	<b>67</b>

1	Priedas. <i>DAMMS</i> 2023 konferencijas plakats .....	67
2	Priedas. Straipsnis <i>Computers in Biology and Medicine</i> žurnale.....	67

## Lentelių sąrašas

<b>1.1 lentelė.</b> Klasifikavimas pagal kraujo spaudimą.....	12
<b>1.2 lentelė.</b> ŠRV laiko srities matavimai [7] .....	13
<b>1.3 lentelė.</b> ŠRV dažnio srities matavimai [7] .....	14
<b>1.4 lentelė.</b> ŠRV netiesiniai matavimai [7] .....	14
<b>1.5 lentelė.</b> Duomenų rinkinių palyginimas .....	16
<b>1.6 lentelė.</b> Egzistuojančių sprendimų palyginimas.....	20
<b>1.7 lentelė.</b> matavimų palyginimas prieš fizinį krūvį.....	24
<b>1.8 lentelė.</b> matavimų palyginimas po fizinio krūvio.....	24
<b>1.9 lentelė.</b> <i>Polar H7</i> ir <i>Apple Watch</i> palyginimas .....	25
<b>1.10 lentelė.</b> Mobilųjų aplikacijų palyginimas.....	25
<b>2.1 lentelė.</b> Filtruoti EKG signalą panaudos atvejo specifikacija .....	27
<b>2.2 lentelė.</b> Segmentuoti EKG signalą į širdies dūžius panaudos atvejo specifikacija .....	28
<b>2.3 lentelė.</b> Sudaryti EKG signalo nuotrauką panaudos atvejo specifikacija.....	28
<b>2.4 lentelė.</b> Prognozuoti hipertenziją panaudos atvejo specifikacija.....	28
<b>3.1 lentelė.</b> Eksperimentų metu naudotos įrangos specifikacijos.....	34
<b>3.2 lentelė.</b> Duomenų rinkinio pasiskirstymas .....	43
<b>3.3 lentelė.</b> Modelių palyginimas .....	48
<b>3.4 lentelė.</b> Treniravimo hiperparametrai.....	52
<b>3.5 lentelė.</b> EKG filtravimo tyrimo metu naudoto kompiuterio specifikacija.....	52
<b>3.6 lentelė.</b> Atliktų eksperimentų pavadinimai .....	53
<b>3.7 lentelė.</b> Eksperimentų treniravimo ir testavimo tikslumai .....	57
<b>3.8 lentelė.</b> <i>ResNet152</i> , <i>ResNet50</i> , <i>MobileNetV2</i> bei <i>Net</i> testavimo metrikos .....	59
<b>3.9 lentelė.</b> Modelių greitaveikos rezultatai vieną epochą .....	61
<b>3.10 lentelė.</b> Modelių operatyviosios atminties sunaudojimas .....	61



## Paveikslų sąrašas

1.1 pav. Elektrokardiogramoje esantys segmentai ir intervalai [6].....	13
1.2 pav. Dviejų kanalų <i>OWFB</i> [8].....	17
1.3 pav. Tyrime pasiūlyta konvoliucinio tinklo architektūra hipertenzijai klasifikuoti [17] .....	19
2.1 pav. Hipertenzijos prognozavimo metodo panaudos atvejų diagrama .....	27
2.2 pav. Eksperto segmentuotas EKG signalas .....	30
2.3 pav. Segmentacijos algoritmo pseudokodas (sudarytas autoriaus remiantis <i>biopeaks</i> ir <i>Neurokit2</i> ).....	31
2.4 pav. Algoritmo žingsniai.....	32
2.5 pav. Dviejų sveikų (a), b)) ir hipertenzinių (c), d)) širdies dūžių EKG signalų pavyzdžiai .....	32
3.1 pav. EKG iš visų trijų derivacijų.....	34
3.2 pav. EKG III-os derivacijos signalų pavyzdžiai: a) sveikas, b) hipertenzinis .....	35
3.3 pav. Hipertenzinio EKG signalo spektrograma .....	36
3.4 pav. Sveiko žmogaus EKG signal spektrograma .....	36
3.5 pav. Sveiko žmogaus signalas su originaliu (a)) ir sumažintu (b)) diskretizavimo dažniu .....	37
3.6 pav. Standartizuoti EKG signalai: a) sveikas, b) hipertenzinis .....	38
3.7 pav. Standartizuoti ir filtruoti (žemo dažnio) EKG signalai: a) sveikas, b) hipertenzinis .....	39
3.8 pav. Sveiko žmogaus signalo spektrogramos .....	40
3.9 pav. Hipertenzinio signalo spektrogramos.....	40
3.10 pav. Segmentuoti EKG signalai: a) sveiko žmogaus; b) hipertenzija sergančio žmogaus .....	41
3.11 pav. Išskirtas širdies dūžio EKG signalas .....	42
3.12 pav. Duomenų rinkinio pasiskirstymas .....	42
3.13 pav. <i>ResNet50</i> modelio treniravimosi metrikos .....	43
3.14 pav. <i>ResNet50</i> modelio validacijos reikšmės .....	44
3.15 pav. <i>ResNet50</i> modelio klasifikavimo rezultatų maišaties matrica.....	44
3.16 pav. Sudaryto <i>Net</i> modelio architektūra.....	45
3.17 pav. <i>Net</i> neuroninio tinklo <i>PyTorch</i> programinis kodas .....	45
3.18 pav. <i>Net</i> modelio treniravimosi metrikos .....	46
3.19 pav. <i>Net</i> modelio validacijos reikšmės.....	46
3.20 pav. <i>Net</i> modelio maišaties matrica .....	47
3.21 pav. SVM modelio treniravimosi metrikos .....	48
3.22 pav. SVM modelio maišaties matrica .....	48
3.23 pav. Modelių testavimo tikslumai .....	49
3.24 pav. Hipertenzinio (kairėje) ir sveiko (dešinėje) signalų spektrogramos iš 5000 reikšmių .....	49
3.25 pav. Treniravimosi ir validacijos tikslumų grafikas klasifikuojant spektrogramas .....	50
3.26 pav. Filtruotų hipertenzinio (kairėje) ir sveiko (dešinėje) signalų spektrogramos.....	50
3.27 pav. Treniravimosi ir validacijos tikslumų grafikas klasifikuojant filtruotų signalų spektrogramas .....	51
3.28 pav. Skirtingų filtravimų palyginimas sveiko žmogaus EKG signalui .....	51
3.29 pav. Skirtingų filtravimų palyginimas hipertenziniam EKG signalui.....	52
3.30 pav. <i>ResNet152</i> eksperimentų treniravimosi tikslumai .....	53
3.31 pav. <i>ResNet152</i> eksperimentų testavimo tikslumai.....	54
3.32 pav. <i>Net</i> eksperimentų treniravimosi tikslumai.....	54
3.33 pav. <i>Net</i> eksperimentų testavimo tikslumai .....	55
3.34 pav. <i>MobileNetV2</i> eksperimentų treniravimosi tikslumai.....	55
3.35 pav. <i>MobileNetV2</i> eksperimentų testavimo tikslumai.....	56
3.36 pav. <i>ResNet50</i> eksperimentų treniravimosi tikslumai .....	56
3.37 pav. <i>ResNet50</i> eksperimentų testavimo tikslumai.....	57
3.38 pav. <i>ResNet152</i> , <i>ResNet50</i> , <i>MobileNetV2</i> ir <i>Net</i> ROC kreivės .....	59
3.39 pav. Modelių greitaveika kiekvieną epochą.....	61

## Santrumpų ir terminų sąrašas

### Santrumpos:

EKG – elektrokardiograma.

FPG – fotopletizmografija.

ŠRV (angl. *HRV*) – širdies ritmo kintamumas.

RMSE (angl. *root mean squared error*) – vidutinė kvadratinė paklaida.

MAD (angl. *mean absolute difference*) – vidutinė absoliuti paklaida.

SBP (angl. *systolic blood pressure*) – sistolinis kraujo spaudimas.

DBP (angl. *diastolic blood pressure*) – diastolinis kraujo spaudimas.

LSTM (angl. *long short - term memory*) – ilgalaikės trumpalaikės atminties neuroninis tinklas.

CNN (angl. *convolutional neural network*) – konvoliucinis neuroninis tinklas.

SBP (angl. *systolic blood pressure*) – sistolinis kraujo spaudimas.

DBP (angl. *diastolic blood pressure*) – diastolinis kraujo spaudimas.

### Terminai:

**QRS kompleksas** – trijų grafinių deformacijų, matomų tipinėje elektrokardiogramoje, derinys.

**Sistolinis kraujo spaudimas** – didžiausias kraujo slėgis į kraujagyslių sieneles.

**Diastolinis kraujo spaudimas** – mažiausias kraujo slėgis į kraujagyslių sieneles.

**Spektrograma** – vizualiai pavaizduotas signalo dažnių spektras, kintantis priklausomai nuo laiko.

**ROC** (angl. *receiver operating characteristic*) – grafikas, rodantis klasifikatoriaus jautrumo ir specifiškumo sąryšį.

**Sveikų pacientų klasė** – tyrimo metu naudojamas terminas, apibūdinantis žmonių, nesergančių jokiais širdies ligomis, EKG signalus.

**Hipertenzinių pacientų klasė** – tyrimo metu naudojamas terminas, apibūdinantis žmonių, turinčių hipertenziją, EKG signalus.

## Įvadas

Širdies ligos yra viena iš pagrindinių mirties priežasčių visame pasaulyje. Hipertenzija yra itin rimta liga, kurios pagrindinis simptomas yra padidėjęs kraujo spaudimas. Laiku nediagnozuoti širdies sutrikimai gali pažeisti svarbius organus, tokius kaip plaučiai, smegenys, širdis ir inkstai. Šios ligos prevencijai bei požymiams stebėti yra naudojami elektrokardiografai, kraujospūdžio matuokliai. Tačiau duomenims rinkti ir interpretuoti reikalingi šios srities ekspertai. Šių dienų technologijos, įskaitant išmaniuosius įrenginius, pateikia naujų galimybių šioje srityje. Pavyzdžiui, išmanieji laikrodžiai ar širdies ritmo matuokliai gali atlikti EKG matavimus, tačiau neretai nepateikia pakankamai išsamių duomenų apie galimą hipertenziją. Šiuo tyrimu yra stengiamasi prisidėti prie problemos sprendimo, ieškant ar kuriant būdus, kurie leistų aptikti galimą hipertenziją panaudojant EKG signalus.

**Darbo tikslas** – sukurti hipertenzijos nustatymo ir klasifikavimo metodą, panaudojant vieno širdies dūžio trukmės EKG signalus bei konvoliucinius neuroninius tinklus.

**Tyrimo objektas** – elektrokardiogramos tyrimo metu gauti signalai iš sveikų ir hipertenzija sergančių žmonių.

### Uždaviniai:

1. apžvelgti literatūrą, kurioje tyrimai yra atliekami naudojant elektrokardiogramos signalus, hipertenzijos charakteristikas bei šios ligos prognozavimo algoritmus;
2. identifikuoti esamų algoritmų privalumus ir trūkumus bei pasiūlyti metodus hipertenzijai prognozuoti;
3. išbandyti pasiūlytą hipertenzijos prognozavimo algoritmą su laisvai prieinamomis EKG signalų duomenų bazėmis bei palyginti su kitais klasifikavimo metodais;
4. atlikti EKG signalų apdorojimo bei spektro analizės tyrimą siekiant išsiaiškinti tinkamiausius metodus tiksliausiems prognozavimo rezultatams pasiekti;
5. atlikti hipertenzijos prognozavimo algoritmų greitaveikos tyrimą.

### Darbo struktūra:

1. **Hipertenzijos prognozavimo metodų ir priemonių analizė.** Apžvelgiama literatūra, kurioje analizuojama hipertenzija ir fiziologiniai signalai. Taip pat yra atliekama hipertenzijos prognozavimo bei signalų filtravimo metodų analizė. Yra apžvelgiami išmanieji įrenginiai galintys išmatuoti širdies elektrinę veiklą.
2. **EKG signalų tyrimo hipertenzijai prognozuoti projekto specifikacija.** Sudaroma hipertenzijos prognozavimo projekto specifikacija, iškeliami funkciniai ir nefunkciniai reikalavimai.
3. **EKG signalų tyrimo hipertenzijai prognozuoti eiga ir rezultatai.** Aprašomi tyrimų metu gauti rezultatai. Atliekami EKG filtravimo eksperimentai. Apžvelgiami skirtingi konvoliuciniai neuroniniai tinklai, palyginami tikslumai, greitaveika.

## 1. Hipertenzijos prognozavimo metodų ir priemonių analizė

Šiame skyriuje yra aprašomi elektrokardiogramos signalai, RR intervalai bei iš jų apskaičiuotas širdies ritmo variabilumas (ŠRV, angl. *heart rate variability*). Taip pat yra apžvelgiami kitų mokslininkų atlikti tyrimai bei gauti rezultatai. Pateikiama duomenų rinkinių bei egzistuojančių mobiliųjų programėlių analizė.

### 1.1. Hipertenzija

Širdies ligos yra viena iš pagrindinių mirties priežasčių visame pasaulyje [1]. Hipertenzija yra itin rimta liga, kurios pagrindinė priežastis yra padidėjęs kraujo spaudimas, t. y. jėga, kuria širdis spaudžia arterijų sienelės, išlieka didesnė ilgą laiko tarpą. Būtent tai sukelia padidėjusį širdies krūvį, kuris reikalingas pumpuoti kraują su deguonimi į visą kūną per kairįjį skilvelį. Hipertenzija yra dažnai vadinama „tyliąja žudike“, nes būtent ši liga dažniausiai nesukelia jokių simptomų ir gali būti nedidžiosios ilgą laiką. Pasaulio sveikatos organizacija skaičiuoja, jog 2015 metais 1,3 milijardo žmonių visame pasaulyje sirgo hipertenzija ir tik 20 % pacientų sulaukė gydymo [2]. Kraujo spaudimas yra matuojamas dviem dydžiais: sistolinis ir diastolinis spaudimas ir yra klasifikuojamas į skirtingas kategorijas (žr. **1.1 lentelę**). Šiuos klasifikavimus 2020 metais atliko tarptautinė hipertenzijos draugija [3]. Jie nustatė, kad sveiko žmogaus sistolinis kraujo spaudimas neturėtų viršyti 130 mm Hg, o diastolinis neturėtų būti aukštesnis nei 80 mm Hg. Hipertenzinis kraujo spaudimas yra laikomas, kai sistolinis kraujo spaudimas yra virš 140 mm Hg, o diastolinis viršija 90 mm Hg.

#### 1.1 lentelė. Klasifikavimas pagal kraujo spaudimą

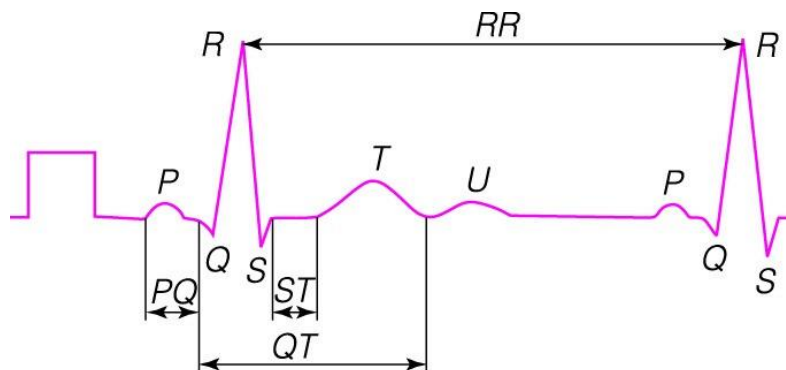
Kraujo spaudimo kategorija	Sistolinis (mm Hg)	Diastolinis (mm Hg)
Normalus	< 130	< 80
Padidėjęs - normalus	130 – 139	85 – 89
Pirmo lygio hipertenzija	140 – 149	90 – 99
Antro lygio hipertenzija	≥ 160	≥ 100

### 1.2. Fiziologiniai signalai hipertenzijai nustatyti

#### 1.2.1. EKG

Vienas iš populiariausių metodų, diagnozuoti širdies ligas, yra elektrokardiograma (EKG). Širdis yra raumuo, kuris pumpuoja kraują visam kūnui. Tam ji turi koordinuotai susitraukti ir atsipalaiduoti. Būtent šį koordinuotą susitraukimą ir atsipalaidavimą kontroliuoja širdies elektrinis aktyvumas. Naudojant specialius elektrodus galima neinvaziniu būdu stebėti širdies veiklą. Ant kūno pritvirtinti elektrodai įrašinėja širdies elektrinį aktyvumą ir aktyvavimo diagrama, gauta šiuo įrašu, vadinama elektrokardiograma (EKG). Įprastiniame EKG signale (žr. **1.1 pav.**) yra trys pagrindinės deformacijos nuo izolinijos (tiesios linijos, kurioje nėra nei teigiamo nei neigiamo elektros krūvio): P banga, QRS kompleksas ir T banga. P banga parodo prieširdžių depoliarizaciją, kurios metu prieširdžiai susitraukia. QRS kompleksas – skilvelių depoliarizaciją ir T banga – skilvelių repoliarizaciją, kurios metu skilveliai atsipalaiduoja [4]. Šių bangų pradžios, maksimumo ir poslinkio taškai nurodo gydytojams kliniškai reikšmingą informaciją diagnozei nustatyti. Analizuojant sveiko žmogaus EKG, šių bangų amplitudės ir trukmės yra žinomos ir pasikartojantys šablonai, kuriems viršijus normas yra interpretuojami kaip širdies sutrikimai.

Elektrokardiograma taip pat gali būti naudojama prognozuoti kraujo spaudimą. Apskritai, trys veiksniai lemia kraujospūdžio svyravimus: širdies kontraktiškumas (gebėjimas susitraukti), kraujo tūris ir periferinis pasipriešinimas. Naujausi tyrimai parodė, kad EKG signalai gali būti naudojami įvertinti širdies kontraktiškumą [5], todėl galima pagrįstai manyti, kad EKG yra glaudžiai susijęs su kraujospūdžio svyravimais.



1.1 pav. Elektrokardiogramoje esantys segmentai ir intervalai [6]

### 1.2.2. Širdies ritmo variabilumas hipertenzijai prognozuoti

Širdies ritmo variabilumas (toliau ŠRV) – tai paeiliui einančių RR intervalų kitimas. Skirtingai nei širdies ritmas, kuris nurodo širdies dūžių skaičių per minutę, ŠRV yra skirtumas tarp iš eilės einančių širdies dūžių laiko intervalų. Aiškiai atskirti sveikus ir sutrikimą turinčius atvejus tik pagal morfologinius EKG požymius gali būti sudėtinga ir kartais neįmanoma, nes nedideli pokyčiai iš dalies nepastebimi. Todėl tokiais atvejais ŠRV analizė yra itin svarbi norint atrasti pokyčius EKG signale. Širdies ritmo kintamumas yra itin dažnai naudojamas kraujagyslių sistemos veiklai bei autonominei nervų sistemai įvertinti.

ŠRV taip pat naudojamas ir hipertenzijai prognozuoti. Galime išskirti trumpo laiko (angl. *short-term*, ST, ~5 min) ŠRV ir ultra trumpo laiko (angl. *ultra short-term*, UST, <5 min) ŠRV naudodami laiko, dažnio ir netiesinius matavimus. [7]. Ilgesni įrašai geriau atspindi sutrikimus, kurių svyravimai yra lėtesni (pvz. cirkadinius ritmus [10]), todėl hipertenzijai nustatyti yra dažniau naudojami trumpesni įrašai [8, 9, 10].

Laiko srities ŠRV rodikliai (žr. 1.2 lentelę) kiekybiškai įvertina kintamumą matuojant intervalą tarp širdies dūžių (angl. *interbeat interval*) (toliau IBI), t. y. laiko tarpą tarp vienas po kito einančių širdies dūžių. Šios vertės gali būti išreikštos pradiniais vienetais (ms, bpm, % ir t.t.) arba pradinių vienetų natūrinium logaritmu (ln), kad būtų pasiektas duomenų pasiskirstymas artimas normaliajam. Atliekant laiko srities matavimus, galima atskirti RR ir NN intervalus. Abu parodo laiką tarp R pikų, tačiau NN intervalai atsižvelgia tik į normalų sinusinį ritmą, kai tuo tarpu RR intervalai – visus sinusinius ritmus.

1.2 lentelė. ŠRV laiko srities matavimai [7]

Parametras	Matavimo vienetas	Aprašymas
SDNN	ms	NN intervalų standartinis nuokrypis
SDRR	ms	RR intervalų standartinis nuokrypis
SDANN	ms	Vidutinių NN intervalų standartinis nuokrypis kiekviename 24 val. ŠRV įrašo 5 min segmente

Parametras	Matavimo vienetas	Aprašymas
SDNN index (SDNNI)	ms	Visų NN intervalų standartinių nuokrypių vidurkis kiekviename 24 val. ŠRV įrašo 5 min segmente
pNN50	%	Iš eilės einančių RR intervalų, kurie skiriasi daugiau kaip 50 ms, procentinė dalis
HR Max-HR Min	bpm	Vidutinis skirtumas tarp didžiausio ir mažiausio širdies susitraukimų dažnio per kiekvieną kvėpavimo ciklą
RMSSD	ms	Nuoseklių RR intervalų skirtumų vidutinis kvadratinis vidurkis
ŠRV trikampis indeksas		RR intervalo histogramos tankio integralas, padalytas iš jos aukščio
TINN	ms	RR intervalo histogramos izolinijos plotis

Atliekant dažnio srities matavimus įvertinamas absoliučiosios arba santykinės galios pasiskirstymas keturiose dažnių juostose. Europos kardiologų draugijos ir Šiaurės Amerikos širdies ritmo stimuliavimo ir elektrofiziologijos draugijos darbo grupė (1996 m.) širdies ritmo (ŠR) svyravimus suskirstė į ultra žemo dažnio (ULF), labai žemo dažnio (VLF), žemo dažnio (LF) ir aukšto dažnio (HF) juostas. Vienas iš būdų kaip gauti šias dekompozicijas – atlikti greitąją Furje transformaciją [7].

**1.3 lentelė.** ŠRV dažnio srities matavimai [7]

Parametras	Matavimo vienetas	Aprašymas
ULF galia	ms <sup>2</sup>	Ypač žemo dažnio juostos ( $\leq 0,003$ Hz) absoliutinė galia
VLF galia	ms <sup>2</sup>	Labai žemo dažnio juostos (0,0033–0,04 Hz) absoliutinė galia
LF pikas	Hz	Aukščiausias žemo dažnio juostos dažnis (0,04–0,15 Hz)
LF galia	ms <sup>2</sup>	Žemųjų dažnių juostos (0,04–0,15 Hz) absoliutinė galia
LF galia	nu	Santykinė žemo dažnio juostos (0,04–0,15 Hz) galia įprastais vienetais
LF galia	%	Santykinė žemo dažnio juostos (0,04–0,15 Hz) galia
HF pikas	Hz	Aukšto dažnio juostos maksimalus dažnis (0,15–0,4 Hz)
HF galia	ms <sup>2</sup>	Aukšto dažnio juostos (0,15–0,4 Hz) absoliutinė galia
HF galia	nu	Aukšto dažnio juostos (0,15 – 0,4 Hz) santykinė galia įprastais vienetais
HF galia	%	Santykinė galia aukšto dažnio juostoje (0,15–0,4 Hz)
LF / HF	%	LF ir HF galios santykis

Netiesinės ŠRV savybės yra pagrįstos matematiniais metodais, pvz., fraktaline analize, chaoso teorija, taip pat gali suteikti detalesnes signalo charakteristikas. Šie metodai gali būti naudojami išgauti signalo savybes, kurios gali būti panaudojamos prognozavimo modeliui. Taip pat netiesinės savybės gali būti naudojamos šablonams identifikuoti, kurie nebūtų matomi naudojant tiesinius metodus.

**1.4 lentelė.** ŠRV netiesiniai matavimai [7]

Parametras	Matavimo vienetas	Aprašymas
------------	-------------------	-----------

Parametras	Matavimo vienetas	Aprašymas
S	ms	Elipsės plotas, atspindintis bendrą ŠRV
SD1	ms	Poincaré grafiko standartinis nuokrypis statmenas $x=y$ tiesei
SD2	ms	Poincaré grafiko standartinis nuokrypis lygus $x=y$ tiesei
SD1/SD2	%	SD1 ir SD2 santykis
$ApEn$		Apytikslė entropija, kuria matuojamas laiko eilučių reguliarumas ir sudėtingumas.
$SampEn$		Imties entropija, kuria matuojamas laiko eilutės reguliarumas ir sudėtingumas.
DFA $\alpha_1$		Svyravimų analizė, apibūdinanti trumpalaikius svyravimus.
DFA $\alpha_2$		Svyravimų analizė, apibūdinanti ilgalaikius svyravimus.
$D_2$		Koreliacijos matmuo, pagal kurį apskaičiuojamas mažiausias kintamųjų, reikalingų sistemos dinamikos modeliui sudaryti, skaičius.

### 1.3. Duomenų rinkinių analizė hipertenzijai prognozuoti

#### 1.3.1. SHAREE

Viena iš dažniausiai naudojamų duomenų bazių yra atvirai prieinama *SHAREE* (angl. *Smart Health for Assessing the Risk of Events via ECG*). Ji buvo specialiai sukurta norint ištirti galimybę identifikuoti hipertenziją panaudojant širdies kintamumo analizę. Šią duomenų bazę sudaro 24 valandų trukmės holterio įrašai (EKG signalai) iš 139 pacientų.

EKG holterio įrašai buvo atlikti hipertenzija sergantiems pacientams po ligos gydymo praėjus ne mažiau nei mėnesiui. Pacientai, kurių amžius 55 ir vyresni, buvo stebimi dar 12 mėnesių po atliktų holterio įrašų, siekiant užregistruoti širdies, kraujagyslių ir smegenų kraujagyslių įvykius.

Kiekvienas įrašas yra apie 24 valandų trukmės ir jį sudaro trys EKG signalai, iš kurių kiekvienas yra imamas 128 mėginių per sekundę (angl. *samples per second*) dažniu ir 8 bitų tikslumu. Šiame duomenų rinkinyje yra jau išskirti QRS kompleksai panaudojant specialiai tam sukurtą algoritmą [11].

#### 1.3.2. PTB

Nacionalinis Vokietijos metrologijos institutas (vok. *Physikalisch-Technische Bundesanstalt*) (toliau *PTB*) taip pat išleido viešai prieinamą EKG duomenų rinkinį. Šią duomenų bazę sudaro 549 įrašai paimti iš 290 tiriamųjų, kurių amžius svyruoja nuo 17 iki 87 metų.

Kiekvienas tiriamajam buvo padaryti nuo vieno iki penkių įrašų. Kiekvieną įrašą sudaro 15 vienu metu matuojamų signalų: klasikiniu metodu registruojant 12 derivacijų (I, II, III, aVR, aVL, aVF, V1, V2, V3, V4, V5, V6) kartu su 3 Franko ortogonaliomis derivacijomis (VX, VY, VZ). Kiekvienas signalas imamas 1000 mėginių per sekundę ir 16 bitų tikslumu. Taip pat yra suteikiama kiekvieno tiriamojo ligos istorija, kuri gali būti panaudota kaip įvestis prognozavimo modeliui.

#### 1.3.3. RR intervalai iš sveikų žmonių

Dauguma tyrimų orientuojasi į vyresnius asmenis, tačiau šio tyrimo pacientų amžius svyruoja nuo 1 mėnesio iki 55 metų. Šį duomenų rinkinį sudaro 147 pacientai, iš kurių yra 72 vyriškos ir 67

moteriškos lyties atstovai. Didžioji dalis tiriamųjų yra jaunesni nei 12 mėnesių. Kiekvieno paciento įrašai yra 24 valandų ilgio, kurie yra skaitmeninami 128 Hz dažniu. Taip pat šie įrašai buvo analizuoti rankiniu būdu siekiant identifikuoti ir pataisyti R pikus.

#### 1.3.4. *MIMIC-III Waveform*

Tai viena didžiausių viešai prieinamų duomenų bazių [12]. Ją sudaro 67830 skirtingų įrašų rinkinių (daugiausiai EKG, FPG) iš 30000 intensyvios terapijos skyriaus pacientų. Fiziologinių bangų įrašus šioje duomenų bazėje sudaro iki aštuonių signalų, įrašytų vienu metu, kurie skaitmeninami 125 Hz dažniu. Jų skiriamoji geba yra 8, 10 arba 12 bitų.

#### 1.3.5. Duomenų rinkinių apibendrinimas

Atlikus esamų duomenų analizę, galima matyti, jog yra pakankamai tiek sveikų, tiek hipertenzija sergančių pacientų duomenų. Modeliams sudaryti galima naudoti *SHAREE* kartu su *PTB* duomenų rinkiniais norint sudaryti modelį vyresnio amžiaus žmonių grupei.

1.5 lentelė. Duomenų rinkinių palyginimas

Pavadinimas	Sveikų pacientų skaičius	Pacientų skaičius su diagnozuotomis ligomis	Pacientų amžius	Signalai
<i>SHAREE</i>	0	139	> 54	EKG
<i>PTB</i>	52	216	Vidurkis: 58.6	EKG
RR intervalai iš sveikų žmonių	147	0	71 pacientas jaunesnis nei metai 10 pacientų vyresni nei 18	ŠRV
<i>MIMIC III Waveforms</i>	~30000 (bendrai su ligotais pacientais)	~30000 (bendrai su sveikais pacientais)	Įvairūs	EKG, FPG, DBP, SBP

#### 1.4. Egzistuojančių sprendimų analizė hipertenzijai nustatyti


##### 1.4.1. Ortogonalinių bangelių filtrų rinkinio sistema hipertenzijos lygio nustatymui

Ortogonalinių bangelių filtrų rinkinio sistema (angl. *orthogonal wavelet filter bank system*) (toliau *OWFB*) yra matematinis metodas naudojamas išskaidyti signalą į skirtingų dažnių komponentus. Ši sistema naudoja ortogonalinių bangelių rinkinį, kurios yra specialios funkcijos galinčios kompaktiškai ir efektyviai pavaizduoti signalą. Filtrų rinkiniai signalui pritaiko žemų ir aukštų dažnių filtrus, kurie ir padalina signalą į atskiras dažnių juostas [27]. Tuomet, šios dažnių juostos gali būti analizuojamos atskirai. Tai suteikia detalesnę informaciją apie patį signalą.

Viename iš darbų yra klasifikuojami EKG signalai panaudojant būtent tokią bangelių sistemą [8]. Eksperimentams buvo panaudota *SHAREE* EKG signalų duomenų bazė, kurioje yra 139 pacientų duomenys. Iš pradžių signalai buvo segmentuoti į 5 minučių laiko intervalus. Tuomet segmentuoti EKG signalai buvo išskaidyti į šešias bangelių subjuostas panaudojant *OWFB*. Iš visų šešių išskaidytų bangelių, buvo išgautos signalo fraktalo dimensijos (angl. *signal fractional dimension*, SFD) ir logaritminės energijos (angl. *log-energy*, LOGE) savybės. Naudojant studento t-testo reitingą, buvo pasirinktos bangelės su aukščiausiais LOGE ir SFD įverčiais. Naudojant šias savybes, buvo sukurtas hipertenzijos indeksas galintis nustatyti žemo ir aukšto lygio hipertenziją.



Diskrečių bangelių transformaciją galima pasiekti iteruojant žemo dažnio filtrus viename filtrų rinkinyje (toliau FLB). Prieš tai minėtame darbe ortogonalinių bangelių filtravimo rinkinio sistema sudaro dviejų filtrų bankų rinkiniai: vienas pavadintas sintezės FLB ir kitas analizės FLB. Abu filtrų bankai turi aukšto ir žemo dažnio filtrus. Analizės FLB, žemo ( $A_0(z)$ ) ir aukšto ( $A_1(z)$ ) dažnių filtrų išvestys buvo sumažintos dviem kartais, o sintezės FLB, žemo ( $B_0(z)$ ) ir aukšto ( $B_1(z)$ ) dažnių filtrų įvestys buvo padidintos dviem kartais (**1.2 pav.**). Analizės ir sintezės žemo dažnio filtrai yra atvirkštinės kopijos laiko atžvilgiu, o tai yra svarbi *OWFB* charakteristika.



**1.2 pav.** Dviejų kanalų *OWFB* [8]

Savybių išskyrimas iš signalų buvo itin svarbi darbo dalis, kuri leido teisingai klasifikuoti žemos ir aukštos rizikos hipertenzijos EKG signalus. Logaritminė energija (*LOGE*) yra apskaičiuojama EKG signalo kiekvienai išskaidytai bangelėi:

$$LOGE_m = \log \sum_n |r_m(n)|^2; \quad (1)$$

čia  $LOGE_m$  yra logaritminė energija  $m$ -tosios bangelės ir  $r_m(n)$  yra amplitudė  $m$ -tosios bangelės  $n$ -tojo pavyzdžio. Taip pat yra apskaičiuojamas signalo fraktalo dimensija. Signalo fraktalo dimensija yra matas, kuris nusako signalo sudėtingumą ir panašumą. Tai matematinis konceptas, kuris gali būti naudojamas apibūdinti signalo netolygumą ir triukšmingumą. *SFD* lygtis gali būti aprašoma taip:

$$SFD = \frac{\log(P_m)}{\log\left(\frac{1}{m}\right)}; \quad (2)$$

čia  $P_m$  yra skaičius panašių šablonų, kurie užpildo originalų šabloną ir  $m$  yra santykis naudojamas išskaidyti pradinį modelį į  $P_m$  panašių modelių. Gavus šiuos du įverčius, galima apskaičiuoti galutinę hipertenzijos diagnozės įvertį *HDI*:

$$HDI = 6 - (3 * LOGE_{SB2} + 4 * LOGE_{SB3} + SFD_{SB6}) - 15 * (SFD_{SB2} + SFD_{SB3} + SFD_{SB4}). \quad (3)$$

Panaudojus šį įvertį, buvo pasiektas idealus 100 % žemos ir aukštos rizikos hipertenzijos klasifikavimo procentas. Tačiau darbe buvo naudota 87 % žemos rizikos ir 13 % aukštos rizikos hipertenzijos EKG signalai. Dėl tokio duomenų disbalanso, rezultatai realioje aplinkoje gali skirtis.

#### 1.4.2. Mašininio mokymo metodų taikymas hipertenzijai prognozuoti

Prižiūrimojo mokymo algoritmai taip pat yra taikomi hipertenzijai klasifikuoti. Viename iš tyrimų, klasifikavimo algoritmai buvo panaudoti atskiriant pacientus į sveikus, turinčius hipertenziją arba koronarinę širdies ligą [13]. Tyrimas buvo orientuotas į širdies ritmo variabilumo analizę ir jo panaudojimą prognozuojant ligas. Po duomenų normalizavimo, klasifikavimui buvo panaudoti tikimybinis neuroninis tinklas (angl. *probabilistic neural network*) (toliau PNN), K artimiausių kaimynų metodas ir atraminių vektorių klasifikatorių (angl. *support vector machine*) (toliau SVM). Šiame tyrime buvo surinkti duomenys iš 64 pacientų (20 sveikų, 21 turintis hipertenziją ir 23 turintis vainikinių arterijų ligas). ŠRV savybėms išgauti buvo panaudoti jau anksčiau aprašyti tiesiniai (laiko ir dažnio srities) bei netiesiniai metodai (SD1, SD2, *ApEn*, *SampEn*). Panaudojus visas, tiesiniais ir netiesiniais metodais gautas savybes, buvo pasiektas net 96 % klasifikavimo tikslumas, panaudojant atraminių vektorių klasifikatorių. Neuroninis tinklas, kartu su K artimiausių kaimynų metodu, taip pat klasifikavo bent 90 % tikslumu. SVM taip pat buvo panaudotas ir kitame tyrime, kuris tapo šio darbo pagrindu [14]. Šiame tyrime yra rankiniu būdu (eksperto pagalba) segmentuojamas EKG signalas į atskirus širdies dūžius. Tuomet šie dūžiai yra vaizduojami paveikslėlyje ir klasifikuojami panaudojant SVM ir visiškai sujungtą neuroninį tinklą. Savybėms išgauti iš paveikslėlių yra panaudojamas orientuotų gradientų histogramos algoritmas. Tačiau šis algoritmas nebuvo testuotas hipertenzijai. Taip pat nėra aiškus jo tikslumas naudojant tik vieną širdies dūžį, o ne 15.

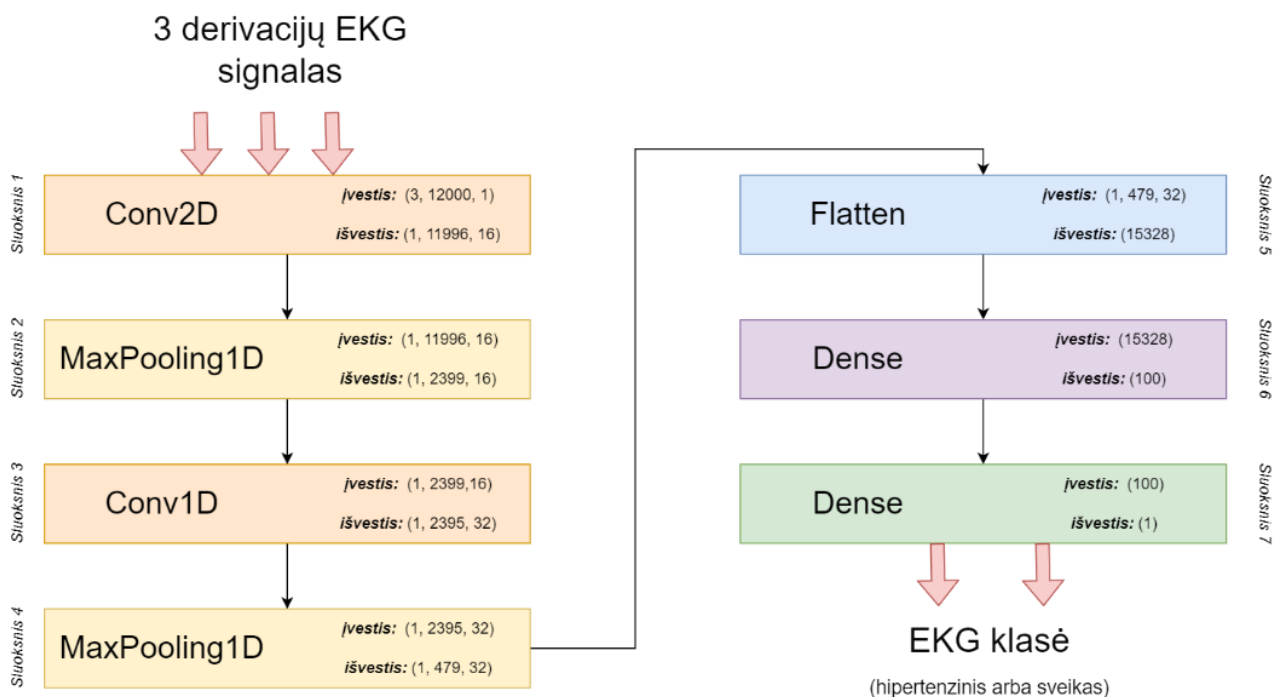
Kitame tyrime, kuriame taip pat buvo atliekamas ŠRV tyrimas ir jo panaudojimas klasifikacijai (žemos arba aukštos rizikos) galimiems kraujagyslių įvykiams (pvz., miokardo infarktas, insultas) hipertenzija sergantiems pacientams. [15] Šis tyrimas taip pat rėmėsi tiesiniais bei netiesiniais metodais savybėms iš signalo išgauti. Gautos savybės buvo naudojamos tolimesnei klasifikatorių tikslumo analizei. Atlikus matavimus, buvo gautas aukščiausias 85,7 % tikslumas klasifikuojant žemos ir aukštos rizikos hipertenzija sergančius pacientus naudojant atsitiktinių miškų metodą (angl. *random forest*) (toliau RF). Šis metodas taip pat identifikavo svarbiausias savybes (pateiktos pirmos penkios pagal svarbą):

1. CD (koreliacijos dimensija);
2. *SampEn*;
3. LF pikas;
4. SD2;
5. LF galia.

Atsitiktinių medžių metodui taip pat nereikėjo atlikti atskiro savybių parinkimo. Šiam metodui buvo panaudotos visos savybės. Vienas iš atliktų tyrimų pasiekė net 95,9 % žemos rizikos hipertenzijos aptikimo tikslumą panaudojant atsitiktinių miškų metodą [16]. Tačiau tokiems tiksliesiems duomenims prireikė net iki 8 valandų ilgio EKG įrašų.

Konvoliucinių neuroninių tinklų panaudojimas taip pat yra gan dažnas reiškinys EKG signalų srityje. Dviejų lygių konvoliucinis tinklas buvo panaudotas ir hipertenzijai prognozuoti [17]. Buvo pasiūlyta dviejų pakopų giliojo konvoliucinio neuroninio tinklo architektūra, kuri pirmoje pakopoje gali klasifikuoti sergančius arba sveikus pacientus ir antroje pakopoje klasifikuoja žemos arba aukštos rizikos hipertenzijos pacientus. Šiame tyrime buvo panaudotas visas elektrokardiogramos signalas iš trijų elektrodų (I, II ir V1). Diskretizavimo dažnis buvo suvienodintas iki 128 Hz. Šio

neuroninio tinklo architektūra (žr. **1.3 pav.**) prima 3 (derivacijos) x 12000 (pavyzdžių dydis (angl. sample size)) ir pateikia 0 (hipertenzija) arba 1 (sveikas).



**1.3 pav.** Tyrime pasiūlyta konvoliucinio tinklo architektūra hipertenzijai klasifikuoti [17]

Dar vienas kinų mokslininkų pasiūlytas hibridinis modelis sugeba prognozuoti nuolatinį sistolinį ir diastolinį kraujo spaudimą [18]. Šis hibridinį modelį sudaro 50-ies sluoksnių neuroninis tinklas, kuriame yra praleidžiamos jungtys (dar kitaip vadinamas *ResNet*) kartu su ilgos-trumpos atminties neuroniniu tinklu (angl. *Long short-term memory*) (toliau *LSTM*). Iš pradžių, *ResNet* yra naudojamas morfologinėms savybėms išgauti iš EKG signalo. *LSTM* dažnai naudojamas su laiku susijusiomis savybėms išgauti. Gautos išvestys iš abiejų modelių yra naudojamos kaip įvestys į du visiškai sujungtus sluoksnius, kurie tiesiškai transformuoja įvestis ir yra aktyvuojami iš anksto nustatyta netiesine transformacija. Galiausiai yra įvertinamos sistolinio ir diastolinio kraujo spaudimo reikšmės. Panašus modelis buvo panaudotas ir kitame tyrime [19]. Rekurentinio neuroninio tinklo, kurį sudaro kelių sluoksnių *LSTM* neuroniniai tinklai, vidutinė kvadratinė paklaida sistolinio ir diastolinio kraujo spaudimo: 3,73 (mm Hg) ir 2,43 (mm Hg), atitinkamai. Tačiau šiame tyrime buvo panaudoti du skirtingi signalai: EKG ir FPG.

### 1.4.3. Statistinė ŠRV analizė hipertenzijai nustatyti

Analizuojant širdies ritmo variabilumą, buvo nustatyta, kad netiesinės analizės metu gauti parametrai dažnai skiriasi tarp sveikų ir hipertenzija sergančių pacientų [20]. Tyrimo metu buvo gautos reikšmės vaizduojant reikšmių sekas *Poincare* grafiku. Šis metodas vaizduoja ŠRV reikšmių seką prieš tokią pačią seką, paslinktą vienu žingsniu. X ašis galėtų būti  $(x_t + x_{t+1} + x_{t+2}, \dots)$ , o Y ašis  $(x_{t+1} + x_{t+2} + x_{t+3}, \dots)$ . Tuomet yra apskaičiuojami parametrai SD1 (RR intervalų nuokrypis trumpame periode), SD2 (RR intervalų nuokrypis ilgame periode) ir SD1/SD2 santykis. Taip pat buvo apskaičiuota koreliacijos entropija  $K_2$  bei koreliacijos dimensija  $D_2$ . Mokslininkai nustatė, kad sveiko žmogaus *Poincare* grafiku gautos reikšmės yra gerokai aukštesnės lyginant su hipertenzija sergančiais pacientais (nuo 1/3 iki 2 kartų). Kaip ir SD1 bei SD2 reikšmėse, hipertenzijos pacientai turėjo mažesnes vidutines reikšmes. Taip pat buvo atliktas *Mann-Whitney U* testas. Tai yra

neparametrinis testas, kuris dažniausiai naudojamas patikrinti skirtumus tarp vidutinių reikšmių dvejose grupėse, kai pasirenkamas tam tikras kintamasis. Buvo pastebėti reikšmingi skirtumai tarp sveikų ir hipertenzija sergančių pacientų pasirinkus kintamuosius D<sub>2</sub> (4,92 ir 4,37 atitinkamai) ir K<sub>2</sub> (3,85 ir 3,60 atitinkamai)

#### 1.4.4. Hipertenzijos nustatymo metodų apibendrinimas

Apžvelgus kitų mokslininkų tyrimus galima matyti, kad yra tiksliai prognozuojančių modelių (žr. **1.6 lentelę**). Yra taikomi signalo apdorojimo, mašininio mokymo bei statinės analizės metodai. Tačiau dauguma nėra pritaikyti atpažinti sveikus ir hipertenzija sergančius pacientus ir yra taikomi tam tikromis sąlygomis. Beveik visi algoritmai reikalauja EKG arba ŠRV signalų, kurie būtų bent kelių minučių trukmės. Taip pat galima matyti, kad dažniausiai yra naudojama *SHAREE* duomenų bazė.

**1.6 lentelė.** Egzistuojančių sprendimų palyginimas

Šaltinis	Signalai	Klasifikatoriai	Duomenų bazė	Pasiektas rezultatas	Privalumai / trūkumai
<i>Hypertension Diagnosis Index for Discrimination of High-Risk Hypertension ECG Signals Using Optimal OWFB</i> [8]	EKG	Bangelių analizė	<i>SHAREE</i>	100 % tikslus žemos ir aukštos rizikos hipertenzijos klasifikavimas	Didelis duomenų disbalansas. Metodas realioje aplinkoje gali nebūti toks tikslus.
<i>Automated classification of hypertension and coronary artery disease patients by PNN, KNN, and SVM classifiers using ŠRV analysis Machine Learning in Bio-Signal Analysis and Diagnostic Imaging</i> [13]	ŠRV	PNN, KNN, SVM	Privati	96 % klasifikavimo tikslumas panaudojant SVM	Atlikti testai apima tik po 10 žmonių iš skirtingos kategorijos
<i>Automatic Prediction of Cardiovascular and Cerebrovascular Events Using Heart Rate Variability Analysis</i> [15]	ŠRV	RF	<i>SHAREE</i>	Gauti sumaišymo matricos įvertinimai: Jautrumas: 71,4 % Specifiškumas: 87,8 %	Skirta jau žinomiems hipertenzijos pacientams nuspėti galimiems kraujagyslių įvykiams (pvz., miokardo infarktas, insultas)
<i>Multiscale Fine-Grained Heart Rate Variability Analysis for Recognizing the Severity of Hypertension</i> [16]	ŠRV	Naive Bayes, SVM, RF	<i>SHAREE</i>	95,1 % tikslumas	Reikalingi 8 valandų ilgumo EKG duomenys.
<i>A two-stage Deep CNN Architecture for the Classification of Low-risk and High-risk</i>	EKG	CNN	<i>SHAREE, PTB</i>	98,10 % tikslumas klasifikuojant sveikus ir	Reikalingas kelių minučių trukmės EKG signalas

<i>Hypertension Classes using Multi-lead ECG Signals [17]</i>				hipertenzija sergančius pacientus	
<i>Continuous blood pressure measurement from one-channel electrocardiogram signal using deep-learning techniques [18]</i>	EKG	<i>ResNet-LSTM</i>	<i>MIMIC III</i>	MAD (SBP) – 9,99 MAD (DBP) – 4,61	Tiksliai prognozuojantis modelis tačiau reikia 25 sekundžių trukmės EKG signalo. Taip pat nėra aiški kitų faktorių (kitos ligos, vaistai) įtaka.
<i>Nonlinear analyses of heart rate variability in hypertension [20]</i>	ŠRV	Statistinė analizė	Privati	Nustatyta, kad SD1, SD2, D <sub>2</sub> ir K <sub>2</sub> reikšmės hipertenzijos pacientams yra mažesnės, nei sveikų	
<i>Long-term Blood Pressure Prediction with Deep Recurrent Neural Networks [19]</i>	EKG, FPG	<i>LSTM</i>	Privati	MAD (SBP) – 3.73 MAD (DBP) – 2.43	Reikalingi du skirtingi signalai: EKG ir FPG.
<i>Multi-lead ECG heartbeat classification of heart disease based on HOG local feature descriptor [14]</i>	EKG	SVM, NN	<i>PTB, Baqyatallah</i> (privati)	99,9 % (SVM, <i>PTB</i> rinkiniui) 99,4 % (NN, <i>PTB</i> rinkiniui) 99,8 % (SVM, <i>Baqyatallah</i> rinkiniui) 99<1 % (NN, <i>PTB</i> rinkiniui)	Reikalingi duomenys iš 15 elektrodų. Taip pat EKG segmentavimas nėra automatizuotas. Klasifikavimas nėra atliekamas hipertenzijai.

## 1.5. EKG signalo filtravimo metodų analizė

### 1.5.1. *Butterworth* filtras

*Butterworth* filtras, dar kartais vadinamas maksimaliai plokščiu filtru, yra vienas dažniausiai sutinkamų filtravimo metodų apdorojant signalus dažnių srityje. Šis filtras pasižymi puikiomis dažninėmis charakteristikomis, dažniausiai naudojamas signalams išlyginti ir pašalinti triukšmą. *Butterworth* filtras turi savybę, jog dažnių charakteristikos kreivė (angl. *frequency response curve*) yra visad lygi praleidžiamojame juostoje (dažnių diapazonas, kuris gali praeiti pro filtrą). Būtent ši savybė padeda efektyviai išfiltruoti signalą ir pašalinti tendencijas.

### 1.5.2. *Wiener* filtras

Amerikiečių matematikas bei kompiuterijos mokslininkas Norbertas Wieneris, 1949-ais pasiūlė signalo filtravimo metodą, kuris geba pašalinti triukšmą. Jis skirtas sumažinti vidutinę kvadratinę paklaidą tarp apskaičiuoto signalo (angl. *estimated signal*) ir tikrojo pagrindinio signalo. Šis algoritmas tai pasiekia adaptyviai reguliuojant filtro parametrus. *Wiener* filtras remiasi triukšmingo

signalu filtravimu ir naudoja norimo signalo ir esančio triukšmo spektrines savybes, laikydamas juos atsitiktiniais procesais su tiesine savybe [21].

Šis tiesinis filtras kartu su koeficientais  $W_k$  yra pritaikomas apskaičiuotam signalui. Įvesties signalas,  $x(n)$  yra sudarytas iš norimo signalo  $d(n)$  ir triukšmo  $v(n)$ .

$$x(n) = d(n) + v(n). \quad (3)$$

Norimas signalas  $d(n)$  yra gaunamas pritaikant EKG signalui  $W_k$  koeficientus. Gautas signalas  $y(n)$  turėtų būti kuo artimesnis  $d(n)$ . Taigi klaidos signalas  $e(n)$  turėtų būti minimalus. Pritaikantis algoritmas stengiasi pakoreguoti svorius  $W_k$  taip, jog vidutinė kvadratinė paklaida būtų kuo mažesnė.

$$e = \min(E(e(n)^2)); \quad (4)$$

čia

$$e(n) = y(n) - d(n). \quad (5)$$

K eilės diskretus *Wiener* filtras naudoja šią lygybę surasti  $y(n)$  reikšmę:

$$y(n) = \sum_{k=0}^{N-1} W_k (d(n-k) * v(n-k)). \quad (6)$$

Svarbiausia šio *Wiener* filtro savybė yra *Wiener-Hopf* lygtis, kuri apskaičiuoja optimalius  $W_k$  svorius:

$$\sum_{l=0}^{p-1} W_{ol} r_{xx}(k-l) = r_{xd}(-l); \quad (7)$$

čia  $W_{o0}, W_{o1}, \dots, W_{op-1}$  yra optimalios filtro koeficientų reikšmės,  $r_{xx}$  yra  $x(n)$  autokorealiacijos funkcija ir  $r_{xd}$  kryžminės korealiacijos funkcija tarp  $x(n)$  ir  $d(n)$ .

Šis filtras taip pat dažnai naudojamas nuotraukų rekonstrukcijai. Tačiau elektrokardiogramos atveju jis sumažina įvairaus tipo triukšmą bei nereikalingus artefaktus kartu išsaugodamas svarbią fiziologinę informaciją. *Wiener* filtras pademonstravo puikius rezultatus pašalinant bazinės linijos svyravimus, baltąjį triukšmą (angl. *white Gaussian noise*) bei kompozitinį triukšmą [21].

### 1.5.3. Kalman filtras

Rudolfo E. Kalmano pasiūlytas filtras taip pat siekia įvertinti ir sumažinti galimą triukšmą pateiktame signale [21]. Jis yra adaptyvus (kaip ir *Wiener* filtras) ir yra itin naudingas kai dinamiškose situacijose kai triukšmo charakteristikos gali keistis laikui bėgant. Šio filtro įgyvendinimą galima skirstyti į dvi dalis: laiko atnaujimo (angl. *time update*) ir matavimų atnaujimo (angl. *measurement update*). Laiko atnaujimo dalyje yra suskaičiuojama būsenos bei klaidų kovariacijos matricos. Atnaujinimo dalyje yra suskaičiuojamas Kalmano prieaugio reikšmė (angl. *Kalman gain*), kuri yra naudojama pataisyti prieš tai apskaičiuotas matricas. Įvestims, šis filtras naudoja prieš tai gautas išvestis, todėl filtras tampa geresnis.

#### 1. Laiko atnaujimo dalis

1.1. Prognozuoti sekančią būseną:

$$d_k = A \times d_{k-1} + B \times u_k. \quad (8)$$

1.2. Prognozuoti klaidos kovariaciją:

$$P_k = A \times P_{k-1} \times A^T \times Q_k. \quad (9)$$

2. Laiko atnaujimo dalis:

2.1. Apskaičiuoti Kalmano priaugį:

$$K = P_k \times H^T \times (H \times P_k \times H^T \times R)^{-1}. \quad (10)$$

2.2. Atnaujinti sekančią būseną:

$$d_k = d_k + K \times (x_k - H \times d_k). \quad (11)$$

2.3. Atnaujinti klaidos kovariaciją:

$$P_k = (I - K \times H) \times P_k. \quad (12)$$

Šie žingsniai yra pastoviai kartojami ir n-tosios būsenos išvestis tampa (n+1)-tosios būsenos įvestimi. Prognozuota signalo reikšmė yra žymima  $d_k^{\wedge}$ . Kur  $x_k$  yra žymimas išmatuotas EKG signalas,  $K$  – Kalmano priaugis,  $u_k$  – kontrolinis signalas,  $A$  – būsenos perėjimo modelis (angl. *state transition model*),  $B$  – valdymo įvesties modelis,  $Q_k$  – proceso triukšmo kovariacija,  $R$  – stebėjimo triukšmo kovariacija,  $H$  – stebėjimo modelis,  $P_k$  – klaidos kovariacija.

Pagrindinė šio filtro problema – netiesinės sistemos. Šis filtras veikia puikiai, kol sistema yra tiesinė, tačiau dauguma egzistuojančių sistemų yra netiesinės, todėl jo našumas itin suprastėja esant netiesinei sistemai [21]. Elektrokardiogramos signalas iš esmės yra netiesinis, todėl šis filtras nebūtinai yra geras pasirinkimas. Tačiau šis filtras gali veikti, jei EKG signale yra palyginti nedideli netiesiškumai.

## 1.6. Išmanieji įrenginiai, skirti registruoti EKG bei ŠRV signalus

Technologinės naujovės vis labiau įsitvirtina kasdieniniame gyvenime, o vartotojai vis anksčiau pradeda stebėti savo sveikatą naudojant programinę ir techninę įrangą. Išmanieji dėvimieji įrenginiai yra elektroniniai prietaisai, kuriuos galima dėvėti ant kūno kaip aksesuarą. Taip pat yra ir specialių įrenginių jau įmontuotų į pačius drabužius. Pažanga dėvimųjų įrenginių srityje suteikė naujų galimybių diagnozuoti širdies ir kraujagyslių ligas bei jų rizikos veiksnius. Tarp šių įrenginių yra tokie prietaisai kaip išmanieji laikrodžiai, žiedai ir apyrankės. Dauguma jų turi didelę skaičiavimo galią ir sudėtingus jutiklius, kurie gali suteikti naujų išvalgų apie sveikatą. Yra apskaičiuota, kad šiuo metu 20 % JAV gyventojų turi išmaniuosius dėvimuosius įrenginius, o pasaulinė rinka augs 25 % per metus ir iki 2025 m. pasieks 70 milijardų JAV dolerių [22]. Šie įrenginiai gali matuoti elektrinę širdies veiklą ir jų suteikiami duomenys gali būti naudojami hipertenzijai prognozuoti.

### 1.6.1. Polar H10

*Polar H10*<sup>1</sup> yra širdies susitraukimų dažnio jutiklis sukurtas atletams ir sporto mėgėjams. Įrenginys naudoja elektrokardiografiją matuoti širdies ritmą. *Polar H10* belaidžiu ryšiu perduoda informaciją išmaniesiems telefonams ar laikrodžiams. Jis yra vienas iš populiariausių pasirinkimų, kuris įrodė, kad teisingai įvertina RR intervalus ramybės ir fizinio krūvio sąlygomis [23].

Lentelėse (žr. 1.7 ir 1.8 lenteles) galima matyti palyginimą tarp klasikinės elektrokardiogramos, kuri atliekama panaudojant 12 elektrodų prieš ir po fizinio krūvio [24].

1.7 lentelė. matavimų palyginimas prieš fizinį krūvį

	RR (ms)		Širdies ritmas (bpm)	
	H10	EKG	H10	EKG
Vidurkis	987,6	987,5	63,2	63,2
Standartinis nuokrypis	201,1	201,1	13,1	13,1
<i>p</i> reikšmė	0,56		0,74	
Koheno <i>d</i> reikšmė	0,56		0,74	
Pearsono <i>r</i> reikšmė	1,00		1,00	

1.8 lentelė. matavimų palyginimas po fizinio krūvio

	RR (ms)		Širdies ritmas (bpm)	
	H10	EKG	H10	EKG
Vidurkis	686,4	686,3	88,9	88,9
Standartinis nuokrypis	90,5	90,4	11,9	11,9
<i>p</i> reikšmė	0,50		0,50	
Koheno <i>d</i> reikšmė	0,14		0,14	
Pearsono <i>r</i> reikšmė	1,00		1,00	

### 1.6.2. Apple Watch 4

*Apple* yra viena iš sveikatos technologijų ir sveikatingumo stebėjimo prietaisų pramonės lyderė. 2015 metais buvo pirmą kartą pristatytas išmanusis laikrodis *Apple Watch*. Nuo pat pasirodymo, jis išlaikė didžiausią rinkos dalį ir nuolat tobulino išmaniųjų laikrodžių galimybes. Šie laikrodžiai pirmiausiai buvo skirti kaip sveikatingumo priemonės, kaupiančios papildomą informaciją apie žmogaus sveikatą, tokią kaip širdies ritmas, širdies ritmo kintamumas bei kvėpavimo dažnis. Šio laikrodžio elektrokardiogramos funkcija buvo patvirtinta JAV Maisto ir vaistų administracijos (angl. *FDA*).

<sup>1</sup> <https://www.polar.com/en/sensors/h10-heart-rate-sensor>



Viename iš tyrimų, kurį atliko ispanų mokslininkai, buvo palyginti *Apple Watch 4* ir *Polar H7* širdies ritmo matuoklio duomenys (žr. **1.9** ir **1.10** lenteles) [25].

**1.9 lentelė.** *Polar H7* ir *Apple Watch* palyginimas

	Ramybės būseną	Streso būseną
<i>Polar H7</i> RR intervalų vidurkis (standartinis nuokrypis) (ms)	869,28 (114,01)	834,78 (97,43)
<i>Apple Watch</i> RR intervalų vidurkis (standartinis nuokrypis) (ms)	869,23 (114,39)	834,70 (97,84)
Praleistų RR intervalų vidurkis (standartinis nuokrypis) %	10,98 (9,78)	9,45 (7,30)

### 1.6.3. Kiti išmanieji įrenginiai fiziologiniams signalams analizuoti

Žinoma egzistuoja ir išmaniųjų įrenginių, kurie gali stebėti kraujo spaudimą ir pranešti galimus sutrikimus. Vienas iš tokių yra *Omron* gamintojo sukurtas kraujo matuoklis (laikrodžio formos), kuris yra patvirtintas JAV maisto ir vaistų administracijos. Šis laikrodis matuoja kraujo spaudimą oscilometriniu būdu, t.y. skaičiuojant osciliacijas oro išleidimo iš apyrankės metu. Taip pat Pietų Korėjos gamintojas *Samsung* išleido *Galaxy Watch 4*<sup>2</sup> išmanųjį laikrodį, kuris gali atlikti elektrokardiogramą ir nustatyti kraujo spaudimą. Tačiau, kad atlikti kraujo spaudimo matavimus, prieš tai reikia sukalibruoti laikrodį su tiksliu kraujospūdžio matuokliu ir toliau kas mėnesį sukalibruoti iš naujo. Taip pat šis įrenginys dar nėra patvirtintas JAV maisto ir vaistų administracijos. Indų kompanija *YAWAY* sukūrė išmanų laikrodį gebantį taip pat apytiksliai nustatyti kraujo spaudimą panaudojant širdies ritmą ir kraujotaką pirštų galiukuose (naudojant pulso tranzito laiko metodą).

### 1.7. Mobiliosios programėlės fiziologiniams signalams analizuoti

Rinkoje egzistuoja ne vienas produktas galintis analizuoti fiziologinius signalus ir juos interpretuoti. Atlikus *Google Play* esančių mobiliųjų programėlių analizę, buvo išskirtos penkios pagrindinės programėlės, kurios yra skirtos sveikatai stebėti. Dauguma jų nėra automatizuotos ir naudoja rankiniu būdu įvestus duomenis. Tuomet iš šių duomenų gali pateikti įžvalgas apie sveikatos būklę. Taip pat yra programėlių, kurios skirtos naudoti su tam skirta aparatine įranga (pvz. kraujospūdžio matuokliu galinčiu perduoti duomenis bevieliu būdu). Daugiausiai funkcijų turinti programėlė yra *Kubios HRV*. Ši programėlė naudoja patobulintą QRS komplekso aptikimo algoritmą, kurį pirmą kartą pristatė Panas ir Tompkinsas 1985 metais. *Kubios HRV* gali analizuoti žmogaus atsistatymą po aktyvios veiklos, taip pat pateikti įžvalgų apie bendrą sveikatos būklę. Tačiau ši programėlė nesuteikia įžvalgų apie galimą hipertenziją.

**1.10 lentelė.** Mobilųjų aplikacijų palyginimas

Pavadinimas	Reikalingi įrenginiai	Automatizuota	Pritaikyta hipertenzijai	Papildomos funkcijos
<i>Blood pressure</i>	Kraujospūdžio	Ne	Ne	

2 <https://www.samsung.com/lt/watches/galaxy-watch/galaxy-watch4-black-bt-sm-r870nzkaeud/>

	matuoklis			
<i>Smart BP</i>	Kraujospūdžio matuoklis	Duomenys automatiškai perkeliama iš <i>Google Fit</i>	Taip	Diagramos, kraujospūdžio analizė
<i>Hello heart</i>	Kraujospūdžio matuoklis	Taip, duomenys automatiškai perkeliama į programėlę	Taip	Kraujospūdžio analizė
<i>Withings health mate</i>	Kraujospūdžio matuoklis	Taip	Taip	Kraujospūdžio analizė, diagramos
<i>Kubios HRV</i>	<i>Polar H10</i> arba kitoks <i>Bluetooth</i> įrenginys siunčiantis RR	Taip	Ne	Atsistatymo analizė, sveikatos būklės analizė

### 1.8. Hipertenzijos prognozavimo metodų ir priemonių analizės išvados

Analizės metu pastebėta, kad yra itin gerai prognozuojančių modelių. Vienas iš pagrindinių kriterijų lemiančių tikslumą, yra savybių išskyrimas (angl. *feature extraction*) ir filtravimas. Savybių išskyrimo metu buvo panaudotos laiko, dažnio srities bei netiesinės savybės iš ŠRV. Taip pat buvo panaudoti neuroniniai tinklai išskirti savybes iš EKG ir PPG. Dauguma tyrimų naudojant EKG signalus, turėjo didesnę klasifikavimo tikslumą. Tačiau naudojant tik RR intervalus ir širdies ritmo variabilumą (ŠRV) taip pat pavyko pasiekti gerų rezultatų (virš 90 %) esant tam tikromis sąlygomis. Vienas iš didžiausių trūkumų yra tas, jog nėra automatizuoto metodo, galinčio atpažinti hipertenziją iš itin trumpų signalų. Analizuoti metodai reikalauja ilgų signalų, nėra pritaikyti būtent hipertenzijai arba nėra automatizuoti. Atlikus mobilių programėlių analizę, pastebėta, kad rinkoje nėra programėlių, galinčių realiu laiku analizuoti ir klasifikuoti kraujo spaudimą naudojant trumpus EKG signalus.

## 2. EKG signalų tyrimo hipertenzijai prognozuoti projekto specifikacija

### 2.1. Reikalavimai

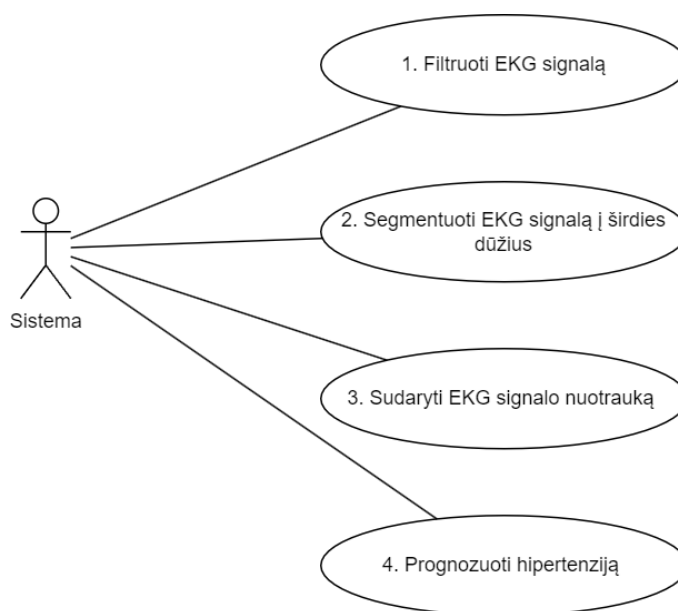
Kuriamam hipertenzijos prognozavimo metodui išskirti funkciniai reikalavimai:

1. filtruoti EKG signalą ir pašalinti galimą triukšmą;
2. išskirti širdies ritmo intervalus iš EKG signalo;
3. sudaryti širdies dūžių nuotraukas iš EKG signalo;
4. prognozuoti hipertenziją.

Taip pat šiam metodui yra išskirti ir nefunkciniai reikalavimai:

1. algoritmas turi prognozuoti bent 85 % tikslumu;
2. algoritmui turi užtekti duomenų tik iš vieno elektrodo.

Aprašyti funkciniai reikalavimai yra pateikiami sistemos panaudos atvejų diagramoje (2.1 pav.):



2.1 pav. Hipertenzijos prognozavimo metodo panaudos atvejų diagrama

EKG signalo filtravimas (žr. 2.1 lentelę) yra atliekamas pats pirmasis. Vartotojo pateiktas elektrokardiogramos signalas yra filtruojamas panaudojant *Butterworth* filtrą. Šis filtras užtikrina, jog būtų pašalintas galimas žemo dažnio triukšmas, tendencijos ir signalas būtų paruoštas segmentacijai.

2.1 lentelė. Filtruoti EKG signalą panaudos atvejo specifikacija

<b>ID</b>	1.
<b>Pavadinimas</b>	Filtruoti EKG signalą.
<b>Aprašymas</b>	Galimo triukšmo pašalinimas iš EKG signalo.
<b>Aktoriai</b>	Sistema.
<b>Pradinės sąlygos</b>	Turi būti įrašytas EKG signalas.
<b>Pagrindiniai žingsniai</b>	Užsikrauti EKG signalą į atmintį ir jam pritaikyti pasirinktą filtrą (pvz. <i>Butterworth</i> ).

<b>Galutinės sąlygos</b>	Gražinamas filtruotas EKG signalas.
--------------------------	-------------------------------------

Šiuo panaudotos atveju (žr. **2.2 lentelę**) metu, filtruotas signalas yra padalinamas yra atskirus širdies dūžius. Segmentacijai yra panaudojamas algoritmas iš *biopeaks* paketo. Segmentavimo metu yra gaunami elektrokardiogramos signalo intervalai priklausantys vienam širdies dūžiui.

**2.2 lentelė.** Segmentuoti EKG signalą į širdies dūžius panaudos atvejo specifikacija

<b>ID</b>	2.
<b>Pavadinimas</b>	Segmentuoti EKG signalą į širdies dūžius.
<b>Aprašymas</b>	Programiškai išskirstyti visą EKG signalą į atskirus intervalus.
<b>Aktoriai</b>	Sistema.
<b>Pradinės sąlygos</b>	Privalo būti išvalytas EKG signalas.
<b>Pagrindiniai žingsniai</b>	EKG signalas yra suskirstomas į intervalus pirmiausiai surandant R pikus ir juos panaudojant signalo segmentacijai.
<b>Galutinės sąlygos</b>	Gaunamas masyvas su EKG signalų intervalais, kuriame yra vienas širdies dūžis.

Gavus elektrokardiogramos signalų intervalus, yra sudaromos 480 taškų aukščio ir pločio nuotraukos. Iš jų yra pašalinamos ašys ir paliekamas tik pavaizduotas signalas. Pilną panaudos atvejo specifikaciją galima matyti lentelėje (žr. **2.3 lentelę**).

**2.3 lentelė.** Sudaryti EKG signalo nuotrauką panaudos atvejo specifikacija

<b>ID</b>	3.
<b>Pavadinimas</b>	Sudaryti EKG signalo nuotrauką.
<b>Aprašymas</b>	Pagal duotą EKG signalą sudaryti nuotrauką.
<b>Aktoriai</b>	Sistema.
<b>Pradinės sąlygos</b>	Turi būti paduotas vieno širdies dūžio EKG signalas.
<b>Pagrindiniai žingsniai</b>	Paduotas EKG signalas yra vaizduojamas X ir Y ašyse, pašalinamas tinklelis bei rėmelis ir paliekamas tik signalas.
<b>Galutinės sąlygos</b>	Sukuriamas 480 taškų aukščio ir pločio nuotrauka.

Susidarius duomenų rinkinį iš turimų elektrokardiogramų, širdies dūžio nuotraukos yra klasifikuojamos naudojant konvoliucinį neuroninį tinklą ir nustatoma ar pacientas turi hipertenziją ar ne (žr. **2.4 lentelę**).

**2.4 lentelė.** Prognozuoti hipertenziją panaudos atvejo specifikacija

<b>ID</b>	4.
<b>Pavadinimas</b>	Prognozuoti hipertenziją.
<b>Aprašymas</b>	Pagal duotą nuotrauką sudaryt
<b>Aktoriai</b>	Sistema.
<b>Pradinės sąlygos</b>	Turi būti sukurta EKG signalo nuotrauka.
<b>Pagrindiniai žingsniai</b>	Nuotrauka yra paduodama į konvoliucinį neuroninį tinklą, kuris atlieka klasifikaciją ir nusprendžia ar pacientas turi hipertenziją.
<b>Galutinės sąlygos</b>	Gražinamas hipertenzijos prognozavimo rezultatas.

## 2.2. EKG signalo filtravimas

Signalui filtruoti yra naudojamas *Butterworth* filtras. Šis filtras yra plačiai naudojamas apdorojant signalus, įskaitant EKG signalų analizę ir valymą. Jis priklauso begalinio impulsinio atsako (angl. *infinite impulse response* arba IIR) filtrų šeimai ir pasižymi tolygia dažnine charakteristika bei maksimaliai plokščia praleidžiamąja juosta. *Butterworth* filtras paprastai naudojamas siekiant pašalinti triukšmą ir artefaktus, kartu išsaugant pagrindinio širdies signalo vientisumą. Jis veikia slopindamas dažnių komponentus, esančius už norimo praleidžiamosios juostos diapazono ribų, ir praleisdamas dažnius, esančius praleidžiamojoje juostoje, su minimaliais nuokrypiais. Ribinį dažnį, kuris lemia perėjimą tarp praleidžiamosios ir stabdomosios juostos, galima reguliuoti pagal konkrečias EKG signalo triukšmo charakteristikas. Valant elektrokardiogramos signalą, *Butterworth* filtras taikomas įvairiems triukšmo tipams pašalinti, įskaitant bazinės linijos svyravimus, elektros linijos trikdžius (50 arba 60 Hz), raumenų artefaktus ir aukšto ir žemo dažnio triukšmą. Šie triukšmo šaltiniai gali paveikti EKG analizės tikslumą ir patikimumą, todėl labai svarbu juos pašalinti prieš tolesnį apdorojimą.

*Butterworth* filtras gali būti įgyvendintas kaip žemo, aukšto, juostinio arba uždarojo dažnio filtras, atsižvelgiant į konkrečius slopintinus triukšmo dažnius. Tačiau šiame darbe yra naudojamas žemo dažnio filtras, kuris yra aprašomas lygtyje:

$$H(s) = \frac{s^n}{B_n(s)}; \quad (13)$$

čia  $s$  yra komplekso dažnio kintamasis,  $n$  – funkcijos laipsnis. Taip pat yra pateikiamas normalizuotas *Butterworth* polinomas:

$$B_n(s) = \begin{cases} \prod_{k=0}^{\frac{n}{2}-1} \left( s^2 - 2 \cos \left( 2\pi \frac{2k+n+1}{4n} \right) s + 1 \right), & \text{jei } n \text{ lyginis} \\ (s+1) \prod_{k=0}^{\frac{n-1}{2}-1} \left( s^2 - 2 \cos \left( 2\pi \frac{2k+n+1}{4n} \right) s + 1 \right), & \text{jei } n \text{ nelyginis.} \end{cases} \quad (14)$$

Taip pat elektrokardiogramos signalui yra atliekamas standartizavimas. Standartizavimas apdoroja signalą ir leidžia palyginti skirtingų pacientų, prietaisų ir sveikatos priežiūros įstaigų EKG signalus. Tai užtikrina, kad būtų galima analizuoti ir interpretuoti EKG duomenis, nepriklausomai nuo jų šaltinio. Standartizavimo formulė:


$$x = \frac{x - \mu}{\sigma}; \quad (15)$$

čia  $\mu$  yra duomenų  $x$  vidurkis, o  $\sigma$  – standartinis nuokrypis.

## 2.3. Signalų skirstymas į širdies dūžius

Panašiam tyrimui EKG signalas yra taip pat skirstomas į atskirus širdies dūžius [14]. Vienas iš esminių algoritmo apribojimų yra rankinis signalo segmentavimas į atskirus širdies dūžius. Šiam metodui yra reikalingas kardiologas (ekspertas), kuris tiksliai nustato segmentų lokacijas (žr. 2.2 pav.). Tuomet tos pačios segmentų lokacijos yra pritaikomos likusiems keturiolikai EKG derivacijų. Signalų segmentavimas užtrunka didžiąsą laiko dalį, todėl sprendimas nėra pritaikytas

automatizuotoje aplinkoje. Yra tyrimų, kur signalas yra segmentuojamas ir klasifikuojamas naudojant neuroninius tinklus, tačiau šis sprendimas reikalauja apmokyto modelio ir daugiau resursų.



**2.2 pav.** Eksperto segmentuotas EKG signalas

Šiame tyrime yra naudojamas automatinis intervalų aptikimas. EKG signalas yra segmentuojamas naudojant algoritmą iš *biopeaks* paketo. Pirmiausia segmentavimo algoritmas išskiria širdies susitraukimų dažnį. Toliau, apskaičiuojamas modulatorius  $m$ , dalijant širdies susitraukimų dažnį iš 60. Tai naudojama prisitaikyti langelio dydžiui pagal širdies susitraukimų dažnį. Tada, langelio ribos nustatomos priskiriant langelio pradžios ir pabaigos reikšmes. Numatytosios reikšmės yra  $-0,35 * m$  ir  $\frac{0,5}{m}$  atitinkamai, tai sukuria langelį, kuris prasideda 0,35 sekundės prieš R viršūnę ir baigiasi 0,5 sekundės po jos. R viršūnės yra surandamos naudojant gradientų metodą. Pirmiausia jis apskaičiuoja EKG signalo, filtruoto aukštųjų dažnių filtru, gradientą, o vėliau nustato gradiento slenkstį pagal signalo charakteristikas. Tada algoritmas, nustatydamas gradiento slenkstį, identifikuoja QRS kompleksus ir juose randa R pikus. Tokie derinami parametrai kaip *smoothwindow*, *avgwindow* ir *mindelay* leidžia pritaikyti (angl. *customize*) viršūnių aptikimo procesą. Gautos R viršūnės grąžinamos kaip indeksai. Viso algoritmo pseudokodas yra matomas **2.3 pav.**

---

**Algorithm 1** Segment Heartbeats

---

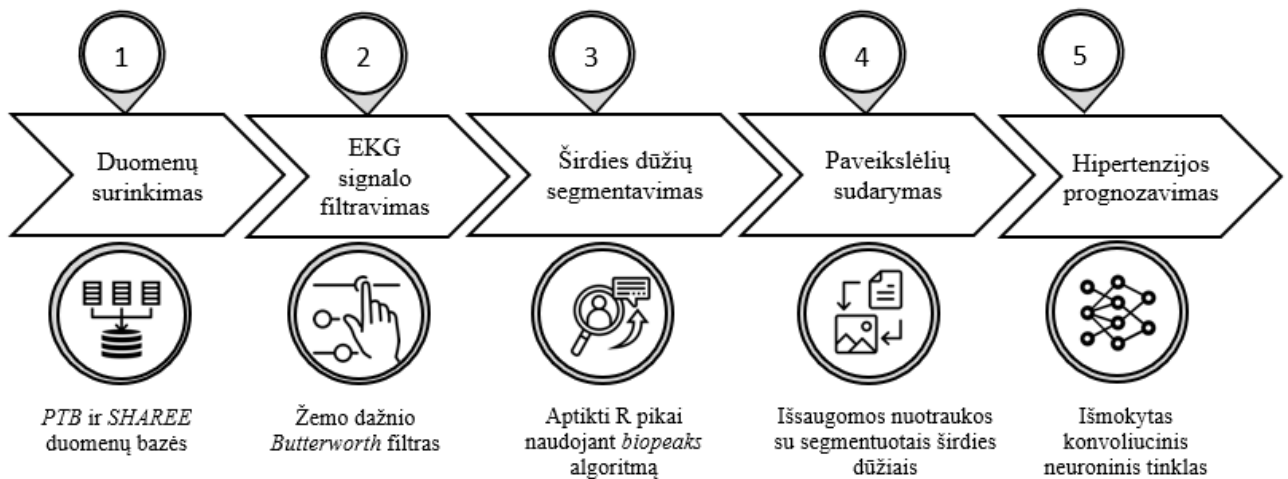
```
function SEGMENT_HEARTBEATS(ecg_signal)
    heart_rate = ESTIMATE_HEART_RATE(ecg_signal)
    modulator_m = heart_rate / 60
    cell_start = -0.35 * modulator_m
    cell_end = 0.5 * modulator_m
    if heart_rate  $\geq$  80 then
        cell_start = cell_start - c
        cell_end = cell_end + c
    end if
    r_peaks = FIND_R_PEAKE(ecg_signal) ▷ Use the biopeaks method
    heartbeats = []
    for r_peak in r_peaks do
        window_start = r_peak + cell_start
        window_end = r_peak + cell_end
        heartbeat = EXTRACT_HEARTBEAT(ecg_signal, window_start, window_end)
        append to heartbeats
    end for
    return heartbeats
end function
function FIND_R_PEAKE(ecg_signal)
    grad = COMPUTE_GRADIENTS(ecg_signal)
    absgrad = COMPUTE_ABSOLUTE_GRADIENTS(grad)
    smoothgrad = SMOOTH_SIGNAL(absgrad)
    avggrad = SMOOTH_SIGNAL(smoothgrad)
    gradthreshold = COMPUTE_GRADIENT_THRESHOLD(avggrad)
    qrs = IDENTIFY_QRS(smoothgrad, gradthreshold)
    beg_qrs, end_qrs = ELIMINATE_QRS_ENDS(qrs)
    peaks = IDENTIFY_R_PEAKE(ecg_signal, beg_qrs, end_qrs)
    result = INITIALIZE_RESULT_LIST
    for each QRS in the ecg_signal do
        len_qrs = COMPUTE_QRS_LENGTH(beg_qrs, end_qrs)
        if QRS length is sufficient then
            locmax = IDENTIFY_LOCAL_MAXIMA(ecg_signal, beg_qrs, end_qrs)
            if local maxima found then
                peak = IDENTIFY_MOST_PROMINENT_MAXIMUM(locmax)
                delay = ENFORCE_MINIMUM_DELAY(peak, peaks)
                if delay between peaks is sufficient then
                    Add the peak to the result list
                end if
            end if
        end if
    end for
    result = CONVERT_LIST_TO_INTEGERS(result)
    return result
end function
```

---

**2.3 pav.** Segmentacijos algoritmo pseudokodas (sudarytas autoriaus remiantis *biopeaks* ir *Neurokit2*)

## 2.4. Hipertenzijos prognozavimas


Šiame darbe yra naudojama pasiūlyta konvoliucinio neuroninio tinklo architektūra *Net* hipertenzijai prognozuoti. Pasiūlyto algoritmo žingsnius galima matyti **2.4 pav.**



2.4 pav. Algoritmo žingsniai

Šiuo metodu yra naudojamas pilnas EKG signalo paveikslėlis, kuris yra paduodamas neuroniniam tinklui. Algoritmo idėja kilo iš kito tyrimo [14], kuriame yra naudojamas panašus metodas, tačiau duomenys yra gaunami iš visų 15 EKG derivacijų. Taip pat savybių gauti yra naudojamas orientuotų gradientų histogramos (angl. *histogram of oriented gradients*) metodas [28].

Norint pradėti savybių išskyrimą, EKG signalas yra suskirstomas į atskirus širdies dūžius. Tai padeda izoliuoti ir atskirti svarbius širdies ritmo elementus analizei. Tuomet šis EKG signalas yra vaizduojamas 480 taškų dydžio nuotraukoje (2.5 pav.). Paveikslėlyje signalas yra vizualiai reprezentuojamas ir atspindi širdies elektrinį aktyvumą tam tikru laiko tarpsniu. Norint tinkamai paruošti paveikslėlį neuroniniam tinklui, iš jo yra pašalinamas tinklelis, ašių reikšmės ir paliekamas tik signalas. Tai leidžia tinklui fokusuoti tik į širdies ritmo savybes ir nereikalingą informaciją.



2.5 pav. Dviejų sveikų (a), b)) ir hipertenzinių (c), d)) širdies dūžių EKG signalų pavyzdžiai

Naudojant konvoliucinį neuroninį tinklą (toliau CNN), savybės yra gaunamos iš paruošto EKG paveikslėlio. CNN yra giliojo mokymosi modelis, kuris turi specialius sluoksnius savybėms gauti iš paveikslėlių. CNN mokosi iš duomenų apie įvairias širdies ritmo savybes, kurias sukelia hipertenzija, ir automatiškai išgrynina svarbiausias savybes, kurios leidžia tinklui klasifikuoti, ar pacientas turi hipertenziją ar ne. Šį išgryninimą atlieka konvoliucinio neuroninio tinklo branduoliai (angl. *kernels*). Jie yra mažos matricos, kurios yra naudojamos atliekant matematinės konvoliucijos operacijas. Šie branduoliai slenka per įvesties duomenis, atlikdami elementų daugybas ir sumas. Taip pat yra naudojamas ADAM (angl. *adaptive moment estimation*) optimizatorius, kuris padeda modeliui greičiau konverguoti. Reiktų atkreipti dėmesį, jog šiame tyrime prieš paduodant nuotrauką neuroniniam tinklui, ji yra sumažinama iki 64x64 taškų dydžio, dėl RAM atminties taupymo. Modelio treniravimas yra vykdomas iteratyviai keičiant tinklo svorius, siekiant sumažinti klaidą ir



padidinti tikslumą. Treniravimo metu CNN modelis išmoksta identifikuoti specifines savybes, kurios yra susijusios su hipertenzija ir gali padėti atskirti hipertenzijos atvejus nuo sveikų pacientų.

Norint įvertinti skirtingus mašininio mokymo modelius, yra naudojamos skirtingos metrikos. Iš pradžių yra sudaroma maišaties matrica, kurioje galime pamatyti teisingai ir neteisingai klasifikuotus pacientus. Ją sudaro keturios reikšmės: tikri teigiami (TP), klaidingi teigiami (FP), tikri neigiami (TN), klaidingi neigiami (FN). Naudojant šią maišaties matricą galime apskaičiuoti du pagrindinius įverčius: tikslumą ir jautrumą. Specifiškumas parodo teigiamų prognozių tikslumą apskaičiuodamas jį padalinant tikrai teigiamai klasifikuotus pacientus iš visų teigiamai klasifikuotų pacientų (tikrai ir klaidingai teigiamų). Specifiškumo formulė:

$$\text{Specifiškumas} = \frac{TP}{TP + FP} \cdot \quad (16)$$

Taip pat yra naudojamas ir jautrumas. Jis parodo kiek tikrai teigiamų pacientų buvo identifikuota iš visų galimų teigiamų. Jautrumo formulė:

$$\text{Jautrumas} = \frac{TP}{TP + FN} \cdot \quad (17)$$

Panaudojant šiuos du įverčius galima apskaičiuoti F1 reikšmę. Ši reikšmė yra harmoninis vidurkis tarp tikslumo ir jautrumo. F1 formulė:

$$F1 = \frac{2TP}{2TP + FP + FN} \cdot \quad (18)$$

Eksperimentams įvertinti naudojama ir rečiau sutinkamas *Matthew* koreliacijos koeficientas (MCC) [29]. Ši metrika įvertina dvejetainių klasifikacijų kokybę atsižvelgiant tiek į tikrus, tiek į klaidingus teigiamus ir neigiamus rezultatus išvedant vieną reikšmę, kuri atspindi koreliaciją tarp žinomų (tikrų) ir prognozuojamų reikšmių (blogiausia reikšmė = -1, geriausia = 1).

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \cdot \quad (19)$$

### 3. EKG signalų tyrimo hipertenzijai prognozuoti eiga ir rezultatai

Šiame skyriuje yra atliekama EKG signalų analizė. Taip pat yra palyginami filtruoti signalai ir ištestuojamas pasiūlytas hipertenzijos prognozavimo algoritmas. Yra atliekamas palyginimas tarp keturių skirtingų klasifikavimo modelių: *ResNet50*, *ResNet152*, *Net* ir *SVM*. *SVM* tyrime yra įgyvendinamas metodas, kuris buvo šio tyrimo pagrindas: klasifikavimas naudojant savybes išgautas iš širdies dūžių nuotraukų panaudojant HOG (angl. *histogram of oriented gradients*) algoritimą.

#### 3.1. Eksperimentų aplinka

Eksperimentams yra naudojamas stacionarus kompiuteris su šiais parametrais:

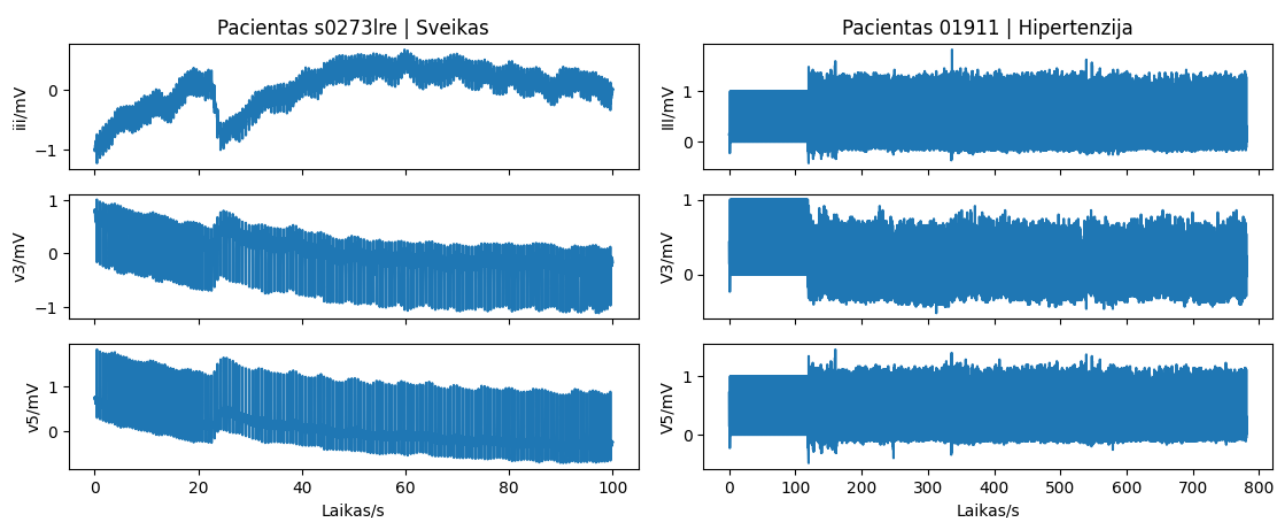
**3.1 lentelė.** Eksperimentų metu naudotos įrangos specifikacijos

Dalis	Modelis
CPU	<i>Intel Core i7-3770</i>
GPU	<i>Nvidia GTX 1060</i>
RAM	8 GB
OS	<i>Ubuntu 22.04</i>

Kodas yra parašytas ir vykdomas naudojant *Python* (3.10) programavimo kalbą.


#### 3.2. EKG analizė hipertenzijai prognozuoti

Eksperimentams yra naudojamos dvi laisvai prieinamos duomenų bazės: *SHAREE* ir *PTB*, hipertenzija sergančių ir sveikų atitinkamai. Hipertenzijai prognozuoti bus naudojami duomenys iš trijų elektrodų (III, V3 ir V5), nes būtent tiek yra *SHAREE* duomenų rinkinyje. Duomenų pavyzdžius galima matyti žemiau pateiktuose grafikuose (žr. **3.1 pav.**). Grafikuose yra matyti žodžiai sveikas ir hipertenzija. Jie yra vartojami norint akcentuoti sveikų žmonių EKG signalus ir hipertenzija sergančių žmonių EKG signalus.




**3.1 pav.** EKG iš visų trijų derivacijų

Duomenims vaizduoti buvo paimti pirmi 100000 reikšmių. Iš šių grafikų galime matyti, jog hipertenzija sergančių pacientų duomenų rinkinys turi daugiau triukšmo. Taip pat yra matoma, jog *PTB* duomenų rinkinys turi tendencijas (angl. *trends*) kilti aukštyn arba leistis žemyn, kurias reikėtų pašalinti. Pažiūrėjus į hipertenzinio signalo grafiką, galima išvelgti, jog matavimai prasideda tik nuo antros minutės, todėl pradžia bus išimta iš testavimo. Taip pat į šiuos signalus galime pažvelgti vaizduojant ir mažesnę duomenų imtį (žr. **3.2 pav.**).




a)




b)

**3.2 pav.** EKG III-os derivacijos signalų pavyzdžiai: a) sveikas, b) hipertenzinis

Pažiūrėjus į trumpesnės trukmės signalų pavyzdžius, galima pamatyti tą pačią kilimo tendenciją sveikame signale. Taip pat galima pamatyti ir hipertenzinio signalo netolygumą (staigų kritimą ties ketvirta sekunde). Šie signalo triukšmai turėtų būti pašalinti atlikus filtravimą su Butterworth filtru. Visiškai nmodifikuotus signalai yra vaizduojami naudojant spektrogramas. Jos yra naudingos, nes signalo vaizdas yra pateikiamas laiko ir dažnio pavidalu, kas leidžia vizualizuoti dažnio komponentų pokyčius laikui bėgant. Elektokardiogramų signalų spektrogramas galima matyti žemiau esančiuose paveikslėliuose (žr. **3.3 pav.** ir **3.4 pav.**).




**3.3 pav.** Hipertenzinio EKG signalo spektrograma




**3.4 pav.** Sveiko žmogaus EKG signal spektrograma

Iš spektrogramų (žr. **3.3 pav.** ir **3.4 pav.**) yra matyti, jog signalai skiriasi savo triukšmo pasiskirstymu. Sveikas EKG signalas turi daugiau triukšmo žemuose dažniuose, bet mažiau aukštuose. Panaši tendencija yra pastebima ir hipertenziniame signale, kai daugiau triukšmo yra žemuose dažniuose, tačiau aukštesni dažniai taip pat turi triukšmo.

Kaip ir prieš tai minėta, pagrindinis šių signalų skirtumas yra tas, jog jie buvo skaitmeninti skirtingu dažniu. *SHAREE* ėmė pavyzdžius 128 kartų per sekundę (128 Hz), o *PTB* – 1000 pavyzdžių per sekundę (1000 Hz arba 1 KHz). Norint suvienodinti signalų skaitmeninimo dažnį buvo panaudota *resample* funkcija iš *scipy* bibliotekos. Ši funkcija naudoja greitąją *Furje* transformaciją (angl. *Fast Fourier transformation*), kuriai reikia, kad signalas būtų periodinis (koks ir yra EKG). Žemiau esantis grafikas (žr. **3.5 pav.**) vaizduoja originalų ir sumažinto dažnio signalą (po 1500 reikšmių).



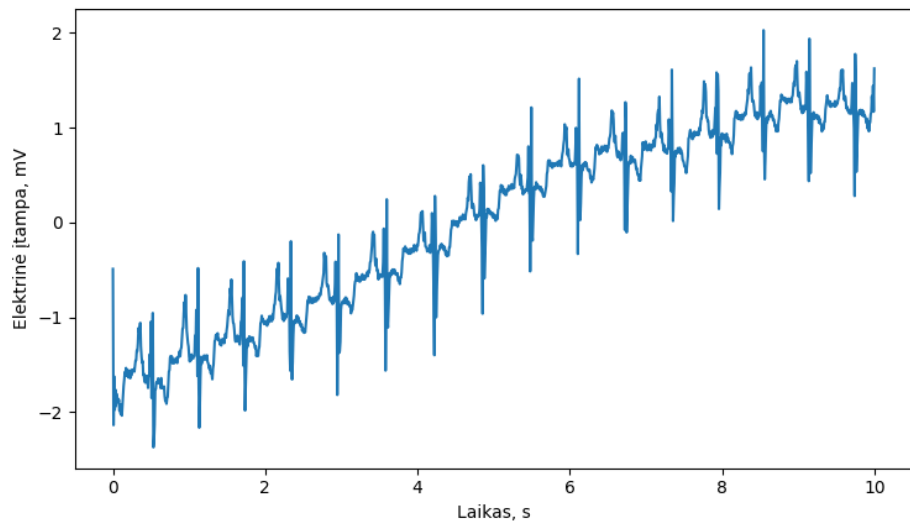
a)




b)

**3.5 pav.** Sveiko žmogaus signalas su originaliu (a) ir sumažintu (b)) diskretizavimo dažniu

Sumažinus sveiko signalo dažnį, kaip ir prieš tai minėta, EKG signalams yra atliekamas standartizavimas.




a)




b)

**3.6 pav.** Standartizuoti EKG signalai: a) sveikas, b) hipertenzinis

Atlikus standartizavimą, galima matyti (žr. **3.6 pav.**), jog signalo triukšmas (tendencijos, reikšmių šokinėjimai) nepakito. Tačiau pasikeitė signalo reikšmės (vidurkis tapo 0, standartinis nuokrypis – 1). Toliau yra naudojamas *Butterworth* žemo dažnio filtras (angl. *high-pass*) norint išlyginti signalą bei pašalinti triukšmą (žr. **3.7 pav.**).




a)



b)

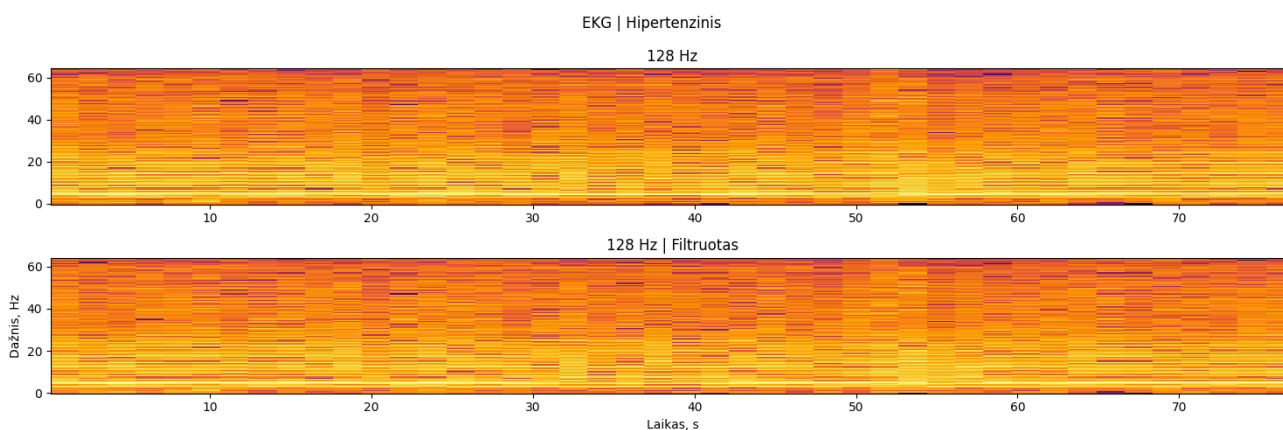
**3.7 pav.** Standartizuoti ir filtruoti (žemo dažnio) EKG signalai: a) sveikas, b) hipertenzinis

Po *Butterworth* filtro pritaikymo, signalas susilygino, buvo pašalintos tendencijos bei žemo dažnio triukšmas. Filtrui buvo pasirinktas 4 funkcijos laipsnis kartu su 0,5 ribiniu dažniu (angl. *cutoff frequency*). Šiuos elektrokardiogramos signalų pasikeitimus galima pavaizduoti ir spektrogramose (žr. **3.8 pav.**).



**3.8 pav.** Sveiko žmogaus signalo spektrogramos

Pirmoje spektrogramoje iš trijų (žr. **3.8 pav.**) galima matyti originalų sveiko paciento signalą. Yra matoma, jog šio signalo žemo dažnio komponentai yra ryškesnis nei aukšto dažnio komponentai. Tai reiškia, kad jų amplitudės yra didesnės tam tikrais laiko intervalais. Panaudojus greitąją *Furje* transformaciją ir sumažinus elektokardiogramos signalo diskretizavimo dažnį iki 128 Hz, galime pastebėti, jog spektrograma suvienodėjo (šiek tiek dar liko mažesnės amplitudės žemuose dažniuose). Toliau pritaikius *Butterworth* žemo dažnio filtrą, amplitudės šiek tiek išaugo, bet spektrograma liko tolygi.




**3.9 pav.** Hipertenzinio signalo spektrogramos

Hipertenziniam signalui nebuvo sumažintas diskretizavimo dažnis, nes signalas ir taip buvo diskretizuotas 128 Hz dažniu. Atlikus filtravimą su *Butterworth* filtru, matome (žr. **3.9 pav.**), jog signalas beveik nepasikeitė. Yra matomi neryškūs pakitimai žemuose dažniuose. Tačiau vienas iš pagrindinių filtravimo plusų, buvo pašalinti nežymūs judesio ar kvėpavimo metu atsiradę artefaktai.




### 3.3. Duomenų rinkinio sudarymas

Atlikus signalų filtravimą, elektrokardiograma yra suskirstoma į atskirus širdies dūžius. Atskirų širdies dūžių segmentavimas yra atliekamas panaudojant anksčiau aprašytą algoritmą (žr. **2.3 pav.**). Pritaikius šį algoritmą galime matyti (žr. **3.10 pav.**), kad jis puikiai suskirsto visą elektrokardiogramos signalą (raudona spalva pažymėtos linijos reiškia širdies dūžio pradžią).



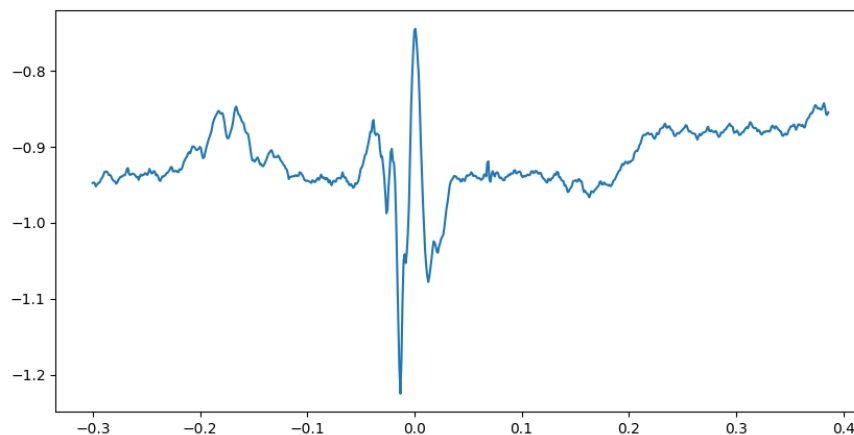
a)



b)

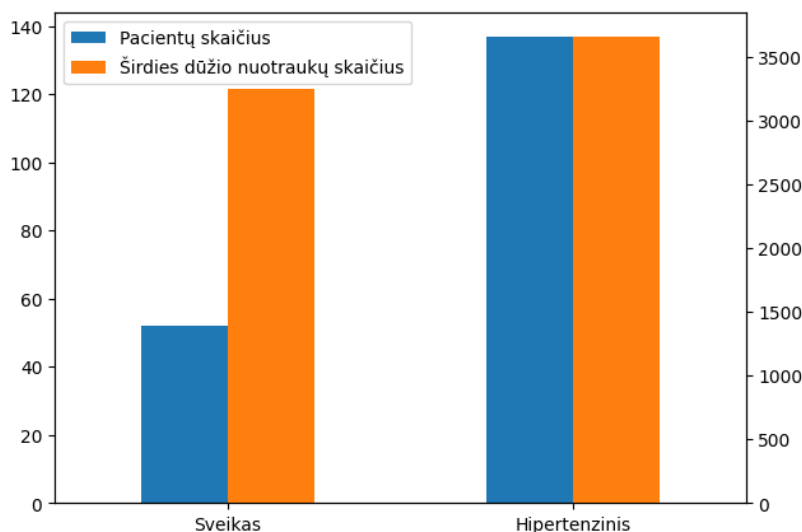
**3.10 pav.** Segmentuoti EKG signalai: a) sveiko žmogaus; b) hipertenzija sergančio žmogaus

Gautą širdies dūžio elektrokardiogramos signalą galima vaizduoti grafike (žr. **3.11 pav.**). Atskyrus visus širdies dūžių intervalus, jie yra vaizduojami ir išsaugomi 480 taškų aukščio ir pločio nuotraukoje. Išgautas signalas yra pavaizduotas naudojant X ir Y ašis, tačiau galutinėje širdies dūžio nuotraukoje ašys yra pašalinamos, spalva yra paverčiama į juodą ir paveikslėlyje lieka tik baltas fonas ir juoda linija.



**3.11 pav.** Išskirtas širdies dūžio EKG signalas

Atlikus elektrokardiogramos signalo segmentavimą ir išsaugojus visas širdies dūžių nuotraukas, gauname duomenų rinkinį su apytiksliai 7000 elementų. Matome, kad sudarytame duomenų rinkinyje yra netolygus pasiskirstymas pacientų skaičiaus atžvilgiu, tačiau sveikų žmonių duomenų rinkinyje yra ilgesnės kardiogramos, kas leido išgauti daugiau širdies dūžių ir sudaryti vienodesnį duomenų rinkinį.



**3.12 pav.** Duomenų rinkinio pasiskirstymas

### 3.4. Konvoliucinių neuroninių tinklų tyrimas hipertenzijai nustatyti

Sudarytoms nuotraukoms klasifikuoti yra naudojami konvoliuciniai neuroniniai tinklai. Prieš paduodant paveikslėlius į neuroninį tinklą, jie yra sumažinami iki 64 taškų pločio ir aukščio dėl atminties taupymo. Norint išsiaiškinti, su kuriais modeliais ir kokiomis parametru reikšmėmis galima pasiekti tiksliausius klasifikavimo rezultatus, buvo atliekami testai su įvairiais duomenų apdorojimo metodais bei skirtingomis neuroninių tinklų architektūromis.

#### 3.4.1. ResNet tyrimas

ResNet tyrime buvo pasirinktas tinklas su 50 paslėptų sluoksnių arba kitaip ResNet50. Pats mažiausias ResNet tinklas buvo pasirinktas dėl kompiuterinių resursų apribojimų, kai tuo tarpu

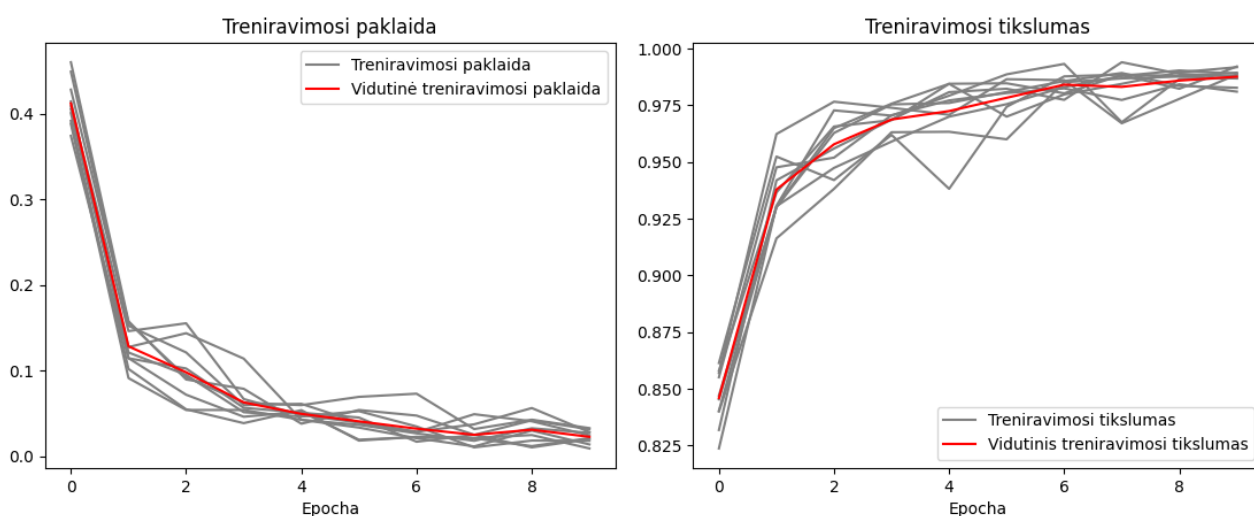
*ResNet101* ir *ResNet152* tinklams neužteko GPU atminties. Duomenų rinkinys buvo suskirstytas į tris dalis: treniravimo imtis, validacijos imtis ir testavimo imtis. Kiekviena iš jų atitinkamai turėjo 70 %, 15 % ir 15 % pacientų duomenų pasiskirstymą. Šis pasiskirstymas buvo pasirinktas siekiant neįtraukti tų pačių pacientų į keletą imčių (pvz. treniravimo ir validacijos). Vienas iš padalinių pavyzdžių yra matomas lentelėje žemiau (žr. **3.2 lentelė**).

**3.2 lentelė.** Duomenų rinkinio pasiskirstymas

Klasė	Treniravimo	Validacijos	Testavimo
Sveiki	36	11	5
Hipertenziniai	96	17	24


Siekiant išsiaiškinti modelio tikslumą, modelis buvo mokomas 10 kartų iš naujo su skirtingais duomenų rinkinių pasiskirstymais. Vienas treniravimas truko 10 epochų, o grupės dydis (angl. *batch size*) buvo 64 elementai. Grafikuose pilka linija yra vaizduojamos kiekvieno treniravimo reikšmės skirtingų epochų metu, o raudona linija parodo vidurkį iš visų 10 iteracijų rezultatų.

Žiūrint į modelio rezultatus, galime matyti, kad treniravimosi metu paklaida nuosekliai mažėjo. Žinoma, grafike matosi vienos iteracijos paklaidos pakilimas 8 epochą. Analogiškai kilo testavimo tikslumas.




**3.13 pav.** *ResNet50* modelio treniravimosi metrikos

Validacijos tikslumas nebuvo toks pat stabilus lyginant su testavimo tikslumu ir paklaida. Iš grafiko galime spręsti, jog modelio tikslumas nukrisdavo tam tikromis epochomis. Galime teigti, kad tolimesniems eksperimentams, galime naudoti mažiau epochų (vieną arba dvi), nes tinklas persimoko.



3.14 pav. ResNet50 modelio validacijos reikšmės


Taip pat galime pažvelgti ir į maišaties matricą (angl. *confusion matrix*). Matome, kad vienas iš dešimties apmokytų modelių turėjo 92,36 % tikslumą klasifikuojant hipertenzinius ir sveikus širdies dūžius. Modelis daugiau suklydo identifikuojant sveikus pacientus (daugiau klaidingų neigiamų rezultatų).



3.15 pav. ResNet50 modelio klasifikavimo rezultatų maišaties matrica

### 3.4.2. Net tyrimas

Šiame tyrime taip pat yra naudojamas naujai sudarytas neuroninis tinklas su 3 konvoliuciniiais sluoksniais. Pirmajame sluoksnyje yra pavaizduotas įvesties paveikslėlis (64 taškų aukščio ir pločio). Po kiekvieno sluoksnio yra atliekama normalizacija. Taip pat po konvoliucinio sluoksnio atsitiktinai yra pašalinamos atsitiktinės koeficientų reikšmės jų reikšmėms priskiriant 0. Šis procesas yra vadinamas išmetimu (angl. *dropout*). Tai leidžia neuroniniam tinklui nepersimokyti. Atsitiktinės tikimybės reikšmė  $p = 0,5$  (50 procentų tikimybė, jog reikšmė bus nulis). Šią architektūrą taip pat galime matyti ir pateiktame grafiniame paveikslėlyje (žr. 3.16 pav.).



3.16 pav. Sudaryto *Net* modelio architektūra

Geriau ši architektūra yra suprantama *Python* kodo pavidalu (žr. 3.17 pav.). Programinio kodo iškarpoje yra sudarytas modelis naudojant vieną iš populiariausių mašininio mokymosi karkasų *PyTorch*.

```
class Net(nn.Module):
    def __init__(self):
        super(Net, self).__init__()

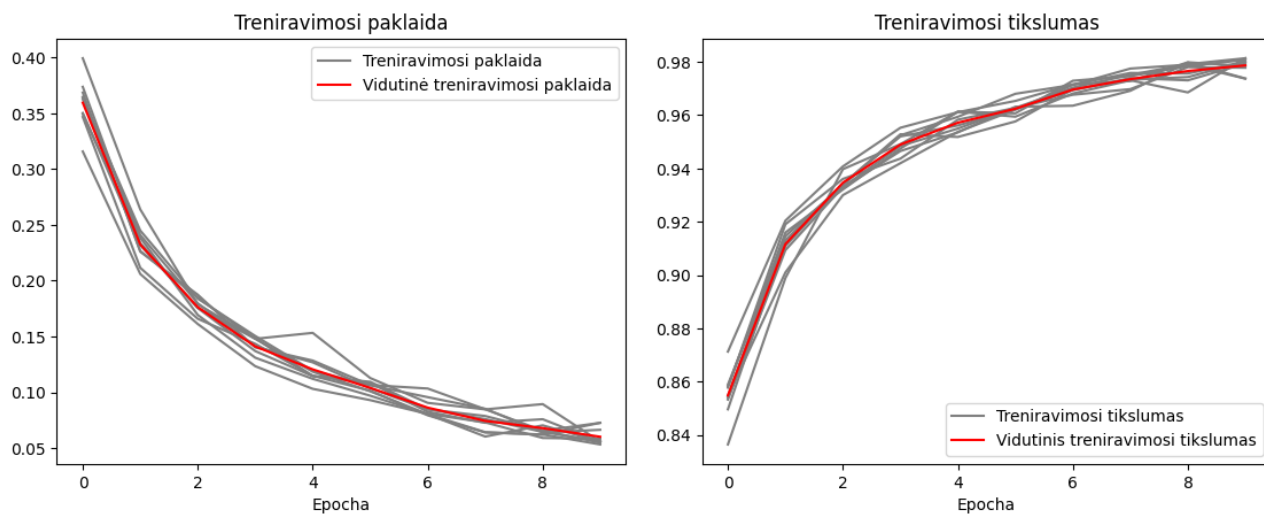
        # CNN layers
        self.conv1 = nn.Conv2d(1, 100, kernel_size=5)
        self.bn1 = nn.BatchNorm2d(100)
        self.conv2 = nn.Conv2d(100, 150, kernel_size=3)
        self.bn2 = nn.BatchNorm2d(150)
        self.conv3 = nn.Conv2d(150, 250, kernel_size=3)
        self.bn3 = nn.BatchNorm2d(250)
        self.conv_drop = nn.Dropout2d()
        self.fc1 = nn.Linear(250*6*6, 350)
        self.fc2 = nn.Linear(350, 150)
        self.fc3 = nn.Linear(150, 2)

    def forward(self, x):
        x = self.bn1(F.max_pool2d(F.leaky_relu(self.conv1(x)),2))
        x = self.conv_drop(x)
        x = self.bn2(F.max_pool2d(F.leaky_relu(self.conv2(x)),2))
        x = self.conv_drop(x)
        x = self.bn3(F.max_pool2d(F.leaky_relu(self.conv3(x)),2))
        x = self.conv_drop(x)
        x = x.view(-1, 250*6*6)
        x = F.relu(self.fc1(x))
        x = F.dropout(x, training=self.training)
        x = F.relu(self.fc2(x))
        x = self.fc3(x)
        return F.log_softmax(x, dim=1)
```

3.17 pav. *Net* neuroninio tinklo *PyTorch* programinis kodas

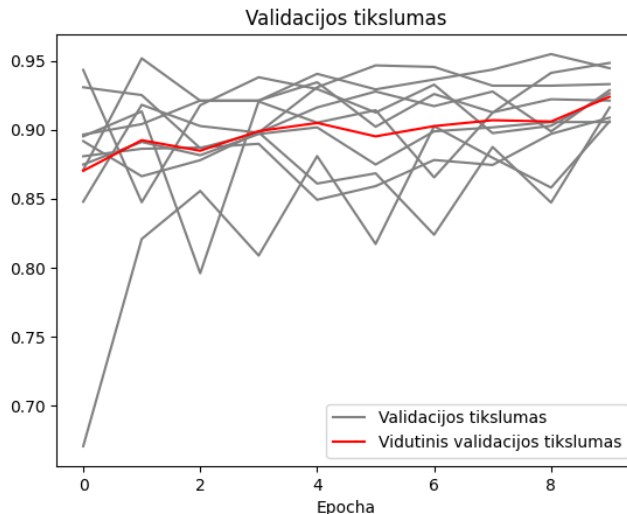
Žiūrint į modelio rezultatus, galime matyti, kad treniravimosi metu paklaida nuosekliai mažėjo. Žinoma, grafike matosi vienos paklaidos pakilimas 8 epochą. Analogiškai kilo testavimo tikslumas iteracijos

Pažvelgus į sudaryto ir apmokyto modelio rezultatus, galime matyti, kad treniravimosi metu paklaida nuosekliai mažėjo kaip ir *ResNet50* atveju. Šis kilimas buvo stabilesnis lyginant su praeitu modeliu. Analogiškai kilo testavimo tikslumas.



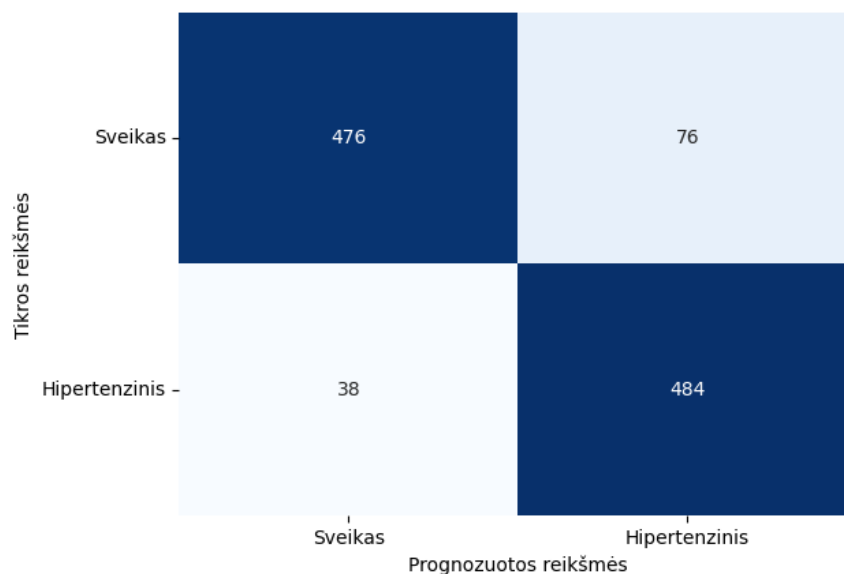
**3.18 pav.** *Net* modelio treniravimosi metrikos

Atliekant prognozavimą su validacijos duomenų rinkiniu, modelis dažnu atveju buvo net tikslesnis nei *ResNet50* nepaisant to, kad yra gerokai mažesnis. Tačiau jis taip pat turėjo validacijos nukritimų iki 70 %, nors jų buvo mažiau lyginant su didesniu modeliu.



**3.19 pav.** *Net* modelio validacijos reikšmės


Lyginant su *ResNet50* modeliu, šis vienas iš 10 sudarytų *Net* modelių turėjo mažesnę prognozavimo tikslumą su testavimo duomenų rinkiniu (89,389 %).



3.20 pav. *Net* modelio maišaties matrica


### 3.4.3. SVM modelio tyrimas

Kaip ir prieš tai minėta, šio prognozavimo metodo pagrindas buvo tyrimas, kuriame buvo panaudotas SVM klasifikatorius [14]. Šiam klasifikatoriui buvo paduodamos nuotraukų savybės (angl. *features*) iš 12 elektrodų duomenų. Savybės iš kiekvienos širdies dūžio nuotraukos buvo išgautos naudojant orientuotų gradientų histogramos metodą (angl. *histogram of oriented gradients*). Norint išsiaiškinti šio modelio tikslumą, taip pat šis metodas buvo pritaikytas ir hipertenziją turintiems pacientams. Taip pat norėta išsiaiškinti, kaip tiksliai SVM prognozuoja naudojant duomenis tik iš vieno elektrodo. Eksperimentui buvo panaudotas tas pats duomenų rinkinys kaip ir konvoliuciniams neuroniniams tinklams. Tinkamiausio hiperparametro paieškai buvo pritaikyta  $k$  žingsnių kryžminė validacija (angl. *k-fold cross-validation*). Buvo atlikta 10 iteracijų, kurios metu buvo pritaikyta 5 žingsnių kryžminė validacija ( $k = 5$ ). Po kryžminės validacijos yra apskaičiuojamos vidutinės reikšmės iš kiekvienos  $k$  iteracijos. Iš rezultatų galime matyti, jog tiksliausiai prognozuoja modelis, kuriame reguliavimo parametras  $C$  yra 5. Maža  $C$  reikšmė reiškia, jog leidžiame daugiau nukrypimų (angl. *outliers*), didesnė – mažiau.



### 3.21 pav. SVM modelio treniravimosi metrikos

Panaudojus SVM kartu su hiperparametru  $C=5$ , buvo gautas 78,53 % tikslumas naudojant testavimo duomenų imtį, kurioje nėra pacientų iš testavimo ir validacijos duomenų imčių.



3.22 pav. SVM modelio maišaties matrica

#### 3.4.4. Modelių apibendrinimas


Atlikus modelių testavimą, rezultatus galime apibendrinti naudojant lentelę (žr. **3.3 lentelę**). Matome, kad vidutiniškai *Net* modelis yra tikslesnis lyginant su testavimo duomenų imtimi. Taip pat *ResNet50* modelis turi didesnių paklaidų šuolių, lyginant su sukurtu *Net* architektūros modeliu. Žinoma, šiuos tikslumus gali įtakoti ir segmentavimo metu ne visai tiksliai sudarytos širdies dūžių nuotraukos. Įgyvendinus SVM ir HOG algoritmais grįstą metodą, buvo gautas šiek tiek mažesnis tikslumas su testavimo duomenimis, lyginant su konvoliuciniais neuroniniais tinklais – 78 %.

3.3 lentelė. Modelių palyginimas

Modelis	Iteracijos	Epochos	Vidutinis treniravimo tikslumas	Vidutinis validacijos tikslumas	Vidutinis testavimo tikslumas
<i>ResNet50</i>	10	10	99 %	94 %	91%
<i>Net</i>	10	10	98 %	94 %	92 %
SVM	10	-	98 %	87%	78 %

Visų iteracijų tikslumus galima matyti stačiakampėje diagramoje (žr. **3.23 pav.**).






3.23 pav. Modelių testavimo tikslumai


### 3.5. Spektrogramų klasifikavimo tyrimas

Atliekant tyrimą su elektrokardiogramų signalais, taip pat kilo idėja atlikti klasifikavimą su jau prieš tai apžvelgtomis spektrogramomis. Atlikus paiešką šia tema, buvo rastas panašus tyrimas [26], kuriame buvo atliktas pacientų klasifikavimas pagal ligas naudojant spektrogramų paveikslėlius, tačiau norėta išsiaiškinti kaip šis būdas veiktų būtent klasifikuojant hipertenziją. Tyrimo metu yra sudaromi dviejų rūšių duomenų rinkiniai: filtruotas ir ne. Filtruotam duomenų rinkiniui yra pritaikomas *Butterworth* aukšto ir žemo dažnio filtras. Jų ribiniai dažniai yra atitinkamai 40 Hz ir 0.5 Hz atitinkamai. Kiekvieno paciento elektrokardiogramos signalas buvo pavaizduotas intervalais: vienai spektrogramai buvo imama po 5000 elektrokardiogramos reikšmių. Kaip ir širdies dūžių intervalai, šios spektrogramos buvo vaizduotos 480 taškų aukščio ir pločio nuotraukoje (žr. 3.24 pav.). Pirmojo bandymo metu nebuvo taikomas joks signalo apdorojimas.




3.24 pav. Hipertenzinio (kairėje) ir sveiko (dešinėje) signalų spektrogramos iš 5000 reikšmių

Šis duomenų rinkinys buvo klasifikuojamas panaudojant *Net* architektūrą. Priešingai nei kiti eksperimentai, čia modelis buvo apmokytas tik vieną kartą 10 epochų. Iš rezultatų galime matyti (žr. **3.25 pav.**), kad klasifikavimas buvo atliktas idealiai. Žinoma, tai gali įtakoti ir skirtingos signalų charakteristikos, kurios matomos iš ganėtinai skirtingų spektrogramų.



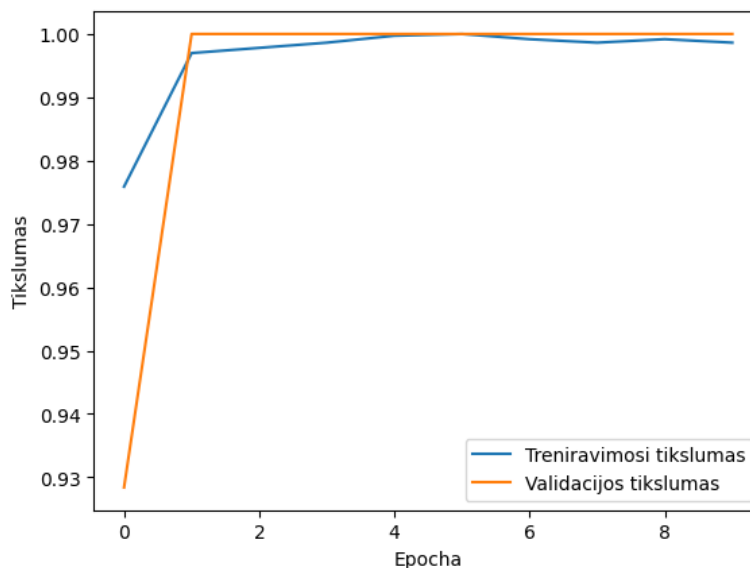
**3.25 pav.** Treniravimosi ir validacijos tikslumų grafikas klasifikuojant spektrogramas

Antrojo bandymo metu buvo pritaikytas žemo dažnio *Butterworth* filtras. Kadangi šių duomenų rinkinių diskretizavimo dažnis skiriasi, norėta pritaikyta filtra, kuris vienodai pašalintų žemus dažnius ir tas vienodumas atsispindėtų spektrogramoje (žr. **3.26 pav.**). Todėl ribinis dažnis buvo pasirinktas 128/1000. Filtravimas buvo atliktas naudojant *butter* funkciją iš *scipy* bibliotekos.



**3.26 pav.** Filtruotų hipertenzinio (kairėje) ir sveiko (dešinėje) signalų spektrogramos


Kaip ir prieš tai, vėl buvo panaudotas *Net* architektūros neuroninis tinklas. Po 10 epochų galime matyti, kad rezultatai iš esmės yra beveik identiški (žr. **3.27 pav.**). Modelis idealiai klasifikuoja hipertenzinius ir sveikus pacientus. Todėl galime teigti, kad būtent šiuo, spektrogramų, atveju *Butterworth* žemo dažnio filtras neturi jokios įtakos išskyrus tą faktą, jog modelis pasiekė idealų klasifikavimo tikslumą šiek tiek anksčiau ir tolimesni mokymo etapai buvo pertekliniai.



**3.27 pav.** Treniravimosi ir validacijos tikslumų grafikas klasifikuojant filtruotų signalų spektrogramas


### 3.6. EKG klasifikatorių tyrimas

Vienas iš būdų pašalinti tendencijas bei norimo dažnio signalus yra filtravimas. Šiuo atveju yra naudojamas žemo ir aukšto dažnio *Butterworth* filtras. Pritaikius žemo dažnio filtrą galime panaikinti signalo tendencijas bei itin žemus dažnius. Su aukšto dažnio filtru galime pašalinti aukštus dažnius. *PTB* duomenų rinkiniui yra naudojami 0,5 Hz ir 400 Hz *Butterworth* filtro ribiniai dažniai (angl. *cutoff frequency*). Pritaikius šį filtrą rezultatai matomi **3.28 pav.**



**3.28 pav.** Skirtingų filtravimų palyginimas sveiko žmogaus EKG signalui

Taip pat šie filtrai yra pritaikomi ir *SHAREE* duomenų rinkiniui su 0,5 Hz ir 40 Hz ribiniais dažniais. Atlikus filtravimą šiam rinkiniui, buvo pašalintas aukšto ir žemo dažnio triukšmas. Aiškių tendencijų signale nebuvo, todėl pasikeitimai yra minimalūs (žr. **3.29 pav.**).



**3.29 pav.** Skirtingų filtravimų palyginimas hipertenziniam EKG signalui

Šiuo tyrimu yra siekiama išsiaiškinti kaip skirtingi filtravimo būdai įtakoja modelių tikslumą. Taip pat analizuojant skirtingas duomenų rinkinių variacijas yra taikomi kiti apdorojimo būdai, tokie kaip: išmetamas pirmas širdies dūžio paveikslėlis, išmetami pirmas ir paskutinis širdies dūžio paveikslėliai, yra pritaikomi žemo, aukšto dažnio arba abu *Butterworth* filtrai, atliekamas standartizavimas, normalizavimas, diskretizavimo dažnio sumažinimas. Taip yra sudaromos skirtingos duomenų rinkinio variacijos. Toliau yra atliekamas toks pat kaip ir aukščiau aprašytas modelio treniravimas ir testavimas naudojant 10 konvoliucinių neuroninių tinklų modelių (10 iteracijų, kurių metu yra iš naujo mokomas ir testuojamas modelis), kurie yra apmokomi 3 epochas. Vienintelis skirtumas yra tas, jog šiame tyrime yra naudojamas didesnis *ResNet152* neuroninis tinklas nei prieš tai naudotas *ResNet50*. Visi treniravimo parametrai aprašyti lentelėje (žr. **3.4 lentelę**).

**3.4 lentelė.** Treniravimo hiperparametrai

Parametras	Reikšmė
Modelis	<i>ResNet152</i>
Tikslo funkcija	Kryžminė entropija
Optimizatorius	ADAM
Mokymosi sparta	0,001
Epochos	2
Partijos dydis	32

Kadangi šiems eksperimentams yra naudojamas didesnis konvoliucinis neuroninis tinklas, tai yra reikalingas kompiuteris su galingesniais parametrais. Šiems eksperimentams yra naudojama galingesnė vaizdo plokštė *RTX 4090*. Pilni parametrai yra aprašyti lentelėje (žr. **3.5 lentelę**).

**3.5 lentelė.** EKG filtravimo tyrimo metu naudoto kompiuterio specifikacija

Dalis	Modelis


CPU	<i>Intel Core i7-13770</i>
GPU	<i>Nvidia RTX 4090</i>
RAM	24 GB
OS	<i>Ubuntu 22.04</i>

Kiekvienas eksperimentas yra sunumeruotas. Todėl toliau, kiekvienoje lentelėje ir grafike, eksperimentai yra pateikiami sunumeruoti. Eksperimento pavadinimą galima rasti lentelėje (žr. **3.6 lentelę**).

**3.6 lentelė.** Atliktų eksperimentų pavadinimai

Eksperimento nr.	Eksperimento pavadinimas
1.	Pritaikytas tik žemo dažnio filtras
2.	Pritaikytas tik žemo dažnio filtras + sveiki signalai sumažinti iki 128 Hz
3.	Tik originalūs signalai
4.	Signalai normalizuoti
5.	Sveiki signalai sumažinti iš 1000Hz iki 128Hz
6.	Sveiki signalai filtruoti tik žemo dažnio filtru
7.	Signalai normalizuoti + filtruoti aukšto ir žemo dažnio filtrais
8.	Signalai standartizuoti, filtruoti aukšto ir žemo dažnio filtrais, ir atmesta pirma nuotrauka
9.	Signalai standartizuoti, filtruoti aukšto ir žemo dažnio filtrais
10.	Signalai standartizuoti ir filtruoti žemo dažnio filtru

Atlikus *ResNet152* treniravimą bei testavimą, galime matyti itin skirtingus rezultatus tarp skirtingų duomenų rinkinių (žr. **3.30 pav.**).

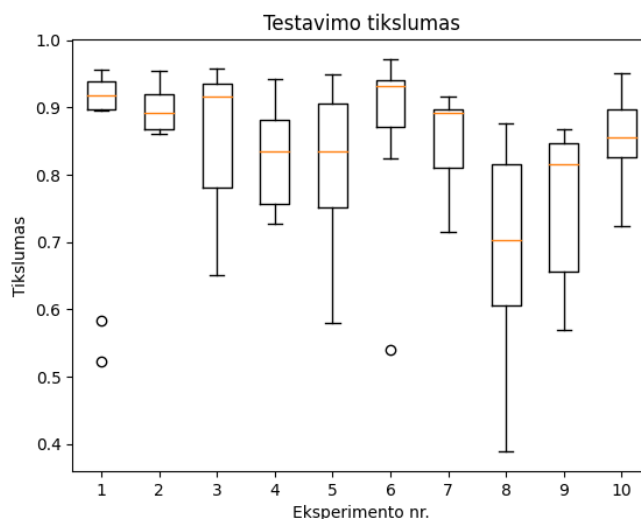


**3.30 pav.** *ResNet152* eksperimentų treniravimosi tikslumai

Atlikus eksperimentus yra matyti, kad buvo itin gerai prognozuojančių modelių. Vienus iš geriausių rezultatų treniravimosi ir validacijos prasme turėjo eksperimentas, kurio metu buvo naudojami tik originalūs signalai, t.y. jiems nebuvo pritaikyti filtrai, signalo standartizavimas ar normalizavimas


bei diskretizavimo dažnio sumažinimas. Kadangi hipertenziniai ir sveiki EKG signalai skiriasi savo forma dėl diskretizavimo dažnio skirtumų (128 Hz ir 1000 Hz), tai tikėtina, jog būtent dėl to rezultatai yra geri. Taip pat itin gerus rezultatus pademonstravo modeliai, kurie klasifikavimo duomenų rinkinį kuriam buvo pritaikytas tik žemo dažnio *Butterworth* filtras.

Atlikus modelių testavimą, galima matyti panašias tendencijas. Pirmas, trečias bei šeštas eksperimentai klasifikavo širdies dūžių nuotraukas itin tiksliai - dažniausiai virš 90 %. Tačiau buvo modelių, kurių tikslumas su testavimo duomenų rinkiniu buvo 40 % ar net mažiau.




3.31 pav. *ResNet152* eksperimentų testavimo tikslumai

Tokie patys eksperimentai buvo atlikti naudojant šiame tyrime sudarytą konvoliucinį neuroninį tinklą *Net*. Tiesa, pagrindinis skirtumas lyginant su *ResNet152* yra tas, jog tinklas buvo mokomas 10 epochų, o ne 3. Žvelgiant į validacijos tikslumus, galima matyti, kad buvo modelių kurių tikslumas krisdavo mažiau nei 50 %. Tai itin matosi pirmame, šeštame bei septintame eksperimentuose. Tačiau eksperimentuose, kur kiekvieno modelio tikslumas buvo virš 80 %, modelis buvo itin stabilus ir neturėjo validacijos kritimų, lyginant su *ResNet152*, kur beveik kiekvienas eksperimentas turėjo validacijos tikslumo nukritimų.




3.32 pav. *Net* eksperimentų treniravimosi tikslumai

Žiūrint į testavimo rezultatus, galima taip pat pamatyti skirtumus lyginant su *ResNet152*. Modelis itin gerai klasifikavo širdies dūžius, kai duomenų rinkinys buvo filtruotas su žemo dažnio *Butterworth* filtru bei sveikų signalų diskretizavimo dažnis sumažintas iki 128 Hz (eksperimentas nr. 2). Taip pat geri rezultatai buvo kai signalai buvo tiesiog normalizuoti.




**3.33 pav.** *Net* eksperimentų testavimo tikslumai

Žiūrint į *ResNet* modelius ir matant kaip greitai jie persimoko, buvo taip pat ištestuota ir šiek tiek mažesnė konvoliucinio neuroninio tinklo architektūra *MobileNetV2*. Šis tinklas buvo apmokomas penkias epochas. Iš validacijos tikslumų (žr. **3.34 pav.**) galima matyti, kad šis modelis itin tiksliai klasifikavo septinto eksperimento širdies dūžių nuotraukas, kai tuo tarpu visi kiti modeliai turėjo prastesnius tikslumus.




**3.34 pav.** *MobileNetV2* eksperimentų treniravimosi tikslumai

Atlikus modelio testavimą, galima matyti (žr. **3.35 pav.**), kad modelis tam tikruose eksperimentuose klasifikavo tiksliau. Tai itin matosi pirmame, trečiame, septintame eksperimentuose. Taip pat *MobileNetV2* turėjo mažiau tikslumo nukritimų (mažiausias testavimo tikslumas buvo šiek tiek mažiau nei 70 %).



**3.35 pav.** *MobileNetV2* eksperimentų testavimo tikslumai


Kaip ir prieš tai minėta, šiame tyrime *ResNet50* modelis (kartu su *ResNet152*) buvo apmokytas tik dvi epochas. Toks epochų skaičius pasirinktas norint išvengti persimokymo. Tačiau atlikus treniravimą dvi epochas, galima matyti, kad modelio prognozavimas yra labai nestabilus lyginant su *ResNet152*. Šio modelio validacijos tikslumas svyruoja tarp 40 % ir 100 %.



**3.36 pav.** *ResNet50* eksperimentų treniravimosi tikslumai

Testavimo rezultatuose (žr. 3.37 pav.) skirtumas tarp iteracijų matomas dar aiškiau. Klasifikavimo tikslumas svyruoja tarp 40 % ir beveik 100 %. Tačiau geriausius rezultatus galima matyti eksperimente, kuriame panaudoti normalizuoti ir filtruoti (aukšto ir žemo dažnio filtrais) paveikslėliai (septintas eksperimentas).





**3.37 pav.** *ResNet50* eksperimentų testavimo tikslumai

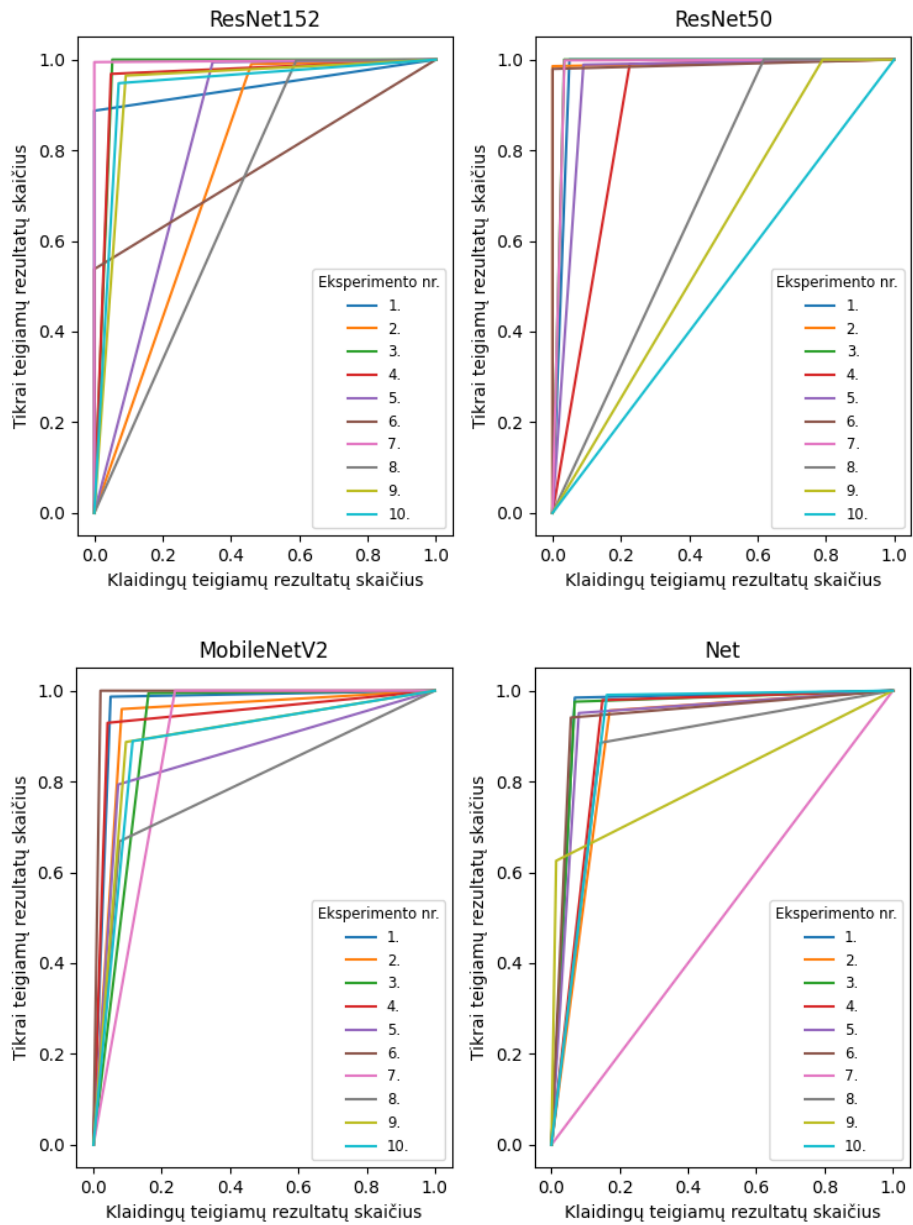
Žvelgiant į visus modelių rezultatus (žr. **3.7 lentelę**), galima matyti, kad išsiskiria du modeliai: pasiūlytas *Net* ir *MobileNetV2*. Šių architektūrų modeliai, dažniausiai turi didžiausią tikslumą klasifikuojant pacientus naudojant testavimo duomenis.

**3.7 lentelė.** Eksperimentų treniravimo ir testavimo tikslumai

Eksperimento nr.	Modelis	Vidutinis treniravimosi tikslumas	Vidutinis validacijos tikslumas	Vidutinis testavimo tikslumas
1.	<i>ResNet152</i>	0,9504	0,8432	0,8528
	<i>ResNet50</i>	0,9621	0,8907	0,8699
	<i>MobileNetV2</i>	0,9740	0,9053	<b>0,8969</b>
	<i>Net</i>	0,987	0,742	0,713
2.	<i>ResNet152</i>	0,9248	0,8530	0,8982
	<i>ResNet50</i>	0,9464	0,8332	0,8252
	<i>MobileNetV2</i>	0,9458	0,8385	0,8531
	<i>Net</i>	0,979	0,897	<b>0,911</b>
3.	<i>ResNet152</i>	0,9524	0,8507	0,8603
	<i>ResNet50</i>	0,9693	0,9005	0,8969
	<i>MobileNetV2</i>	0,9793	0,9114	<b>0,9190</b>
	<i>Net</i>	0,989	0,829	0,831
4.	<i>ResNet152</i>	0,9228	0,8160	0,8262
	<i>ResNet50</i>	0,9364	0,8778	0,8902
	<i>MobileNetV2</i>	0,9514	0,8685	0,8711
	<i>Net</i>	0,981	0,905	<b>0,909</b>
5.	<i>ResNet152</i>	0,9392	0,8242	0,8191
	<i>ResNet50</i>	0,9418	0,8221	0,8009
	<i>MobileNetV2</i>	0,9521	0,8660	0,8772
	<i>Net</i>	0,979	0,921	<b>0,918</b>

6.	<i>ResNet152</i>	0,9364	0,8884	0,8797
	<i>ResNet50</i>	0,9633	0,8628	0,8536
	<i>MobileNetV2</i>	0,9806	0,8809	<b>0,8887</b>
	<i>Net</i>	0,987	0,766	0,760
7.	<i>ResNet152</i>	0,9481	0,8764	0,8569
	<i>ResNet50</i>	0,9639	0,7621	0,7593
	<i>MobileNetV2</i>	0,9802	0,9303	<b>0,9269</b>
	<i>Net</i>	0,987	0,729	0,641
8.	<i>ResNet152</i>	0,8969	0,6696	0,6872
	<i>ResNet50</i>	0,9151	0,7144	0,7251
	<i>MobileNetV2</i>	0,9203	0,7959	0,7978
	<i>Net</i>	0,978	0,799	<b>0,815</b>
9.	<i>ResNet152</i>	0,9041	0,7432	0,7577
	<i>ResNet50</i>	0,9080	0,7028	0,7056
	<i>MobileNetV2</i>	0,9285	0,8145	<b>0,8097</b>
	<i>Net</i>	0,977	0,815	0,809
10.	<i>ResNet152</i>	0,9289	0,8634	0,8551
	<i>ResNet50</i>	0,9403	0,8102	0,7909
	<i>MobileNetV2</i>	0,9491	0,8413	0,8562
	<i>Net</i>	0,979	0,909	<b>0,921</b>

Žvelgiant į ROC kreives (žr. **3.38 pav.**), galime matyti, kad *MobileNetV2* ir *Net* modeliai prognozavo itin gerai. Tie patys eksperimentai dažniausiai turėdavo proporcingus tikslumus lyginant su kitais eksperimentais. Išsiskyrė 7 eksperimentas, kuriame signalai normalizuoti ir filtruoti aukšto bei žemo dažnio filtrais. *Net* tikslumas buvo prastas ir žiūrint į ROC kreivę, prognozavimas prilygo atsitiktiniam klasifikavimui. Taip pat įdomu tai, kad *Net* modelis tiksliau klasifikavo filtruotus bei standartizuotus duomenis (8 eksperimentas), lyginant su *ResNet152*. Taip pat matome, kad *MobileNetV2* neturėjo eksperimentų kuriuose tikslumas prilygo atsitiktiniam klasifikavimui.



**3.38 pav.** *ResNet152, ResNet50, MobileNetV2* ir *Net* ROC kreivės

Taip pat metrikos, tokios kaip, specifiškumas, jautrumas, F1 įvertis, MCC, AUC yra pateiktos lentelėje (žr. **3.8 lentelę**). Matome, kad *ResNet50* pasiekė didžiausią klasifikavimo specifiškumą (97,5 %) klasifikuojant nemodifikuotus signalus. *MobileNetV2* pasiekė aukščiausias jautrumo, F1, MCC ir AUC reikšmes, 96,9 %, 93,6 %, 85,5 % ir 92,4 % atitinkamai.

**3.8 lentelė.** *ResNet152, ResNet50, MobileNetV2* bei *Net* testavimo metrikos

Eksperimento nr.	Modelis	Specifiškumas	Jautrumas	F1	MCC	AUC
1.	<i>ResNet152</i>	0,841	0,961	0,885	0,732	0,853
	<i>ResNet50</i>	<b>0,939</b>	0,823	0,841	0,759	0,863
	<i>MobileNetV2</i>	0,867	<b>0,967</b>	<b>0,913</b>	<b>0,789</b>	<b>0,880</b>
	<i>Net</i>	0,717	0,749	0,666	0,498	0,719
2.	<i>ResNet152</i>	<b>0,914</b>	0,887	0,897	0,790	0,885

	<i>ResNet50</i>	0,878	0,849	0,834	0,682	0,832
	<i>MobileNetV2</i>	0,840	0,919	0,874	0,703	0,844
	<i>Net</i>	0,891	<b>0,946</b>	<b>0,913</b>	<b>0,822</b>	<b>0,914</b>
3.	<i>ResNet152</i>	0,868	0,906	0,872	0,741	0,857
	<i>ResNet50</i>	<b>0,975</b>	0,848	0,895	0,810	0,904
	<i>MobileNetV2</i>	0,917	<b>0,959</b>	<b>0,936</b>	<b>0,828</b>	<b>0,910</b>
	<i>Net</i>	0,838	0,935	0,868	0,659	0,812
4.	<i>ResNet152</i>	0,838	0,896	0,852	0,670	0,818
	<i>ResNet50</i>	<b>0,928</b>	0,875	0,895	0,792	0,898
	<i>MobileNetV2</i>	0,866	0,902	0,883	0,734	0,862
	<i>Net</i>	0,900	<b>0,942</b>	<b>0,919</b>	<b>0,814</b>	<b>0,902</b>
5.	<i>ResNet152</i>	0,908	0,767	0,801	0,679	0,826
	<i>ResNet50</i>	0,810	0,925	0,840	0,616	0,792
	<i>MobileNetV2</i>	0,869	0,898	0,879	0,744	0,880
	<i>Net</i>	<b>0,900</b>	<b>0,959</b>	<b>0,927</b>	<b>0,835</b>	<b>0,911</b>
6.	<i>ResNet152</i>	0,859	0,949	<b>0,900</b>	0,751	0,871
	<i>ResNet50</i>	<b>0,921</b>	0,855	0,862	0,740	0,857
	<i>MobileNetV2</i>	0,832	<b>0,969</b>	0,891	<b>0,777</b>	<b>0,885</b>
	<i>Net</i>	0,661	0,782	0,709	0,575	0,771
7.	<i>ResNet152</i>	<b>0,935</b>	0,834	0,869	0,726	0,870
	<i>ResNet50</i>	0,769	0,764	0,739	0,562	0,757
	<i>MobileNetV2</i>	0,909	<b>0,966</b>	<b>0,935</b>	<b>0,855</b>	<b>0,924</b>
	<i>Net</i>	0,878	0,617	0,596	0,419	0,690
8.	<i>ResNet152</i>	0,670	<b>0,966</b>	0,775	0,388	0,656
	<i>ResNet50</i>	<b>0,843</b>	0,718	0,688	0,523	0,728
	<i>MobileNetV2</i>	0,796	0,891	0,838	0,567	0,773
	<i>Net</i>	0,814	0,911	<b>0,848</b>	<b>0,644</b>	<b>0,803</b>
9.	<i>ResNet152</i>	0,752	<b>0,906</b>	0,803	0,549	0,750
	<i>ResNet50</i>	0,815	0,732	0,710	0,500	0,732
	<i>MobileNetV2</i>	0,804	0,857	0,825	0,625	<b>0,813</b>
	<i>Net</i>	<b>0,839</b>	0,877	<b>0,840</b>	<b>0,633</b>	0,802
10.	<i>ResNet152</i>	0,832	0,880	0,840	0,725	0,854
	<i>ResNet50</i>	0,834	0,837	0,783	0,643	0,798
	<i>MobileNetV2</i>	0,858	0,897	0,872	0,717	0,856
	<i>Net</i>	<b>0,908</b>	<b>0,949</b>	<b>0,927</b>	<b>0,837</b>	<b>0,918</b>

### 3.7. Prognozavimo modelių greitaveikos tyrimas


Konvoliucinių neuroninių tinklų architektūros gali labai įtakoti greitaveikos rezultatus. Šiame tyrime yra siekiama išsiaiškinti, kiek laiko užtrunka bei kiek atminties reikalauja modelių treniravimas bei testavimas. Kaip ir prieš tai atliktame tyrime, greitaveikai yra naudojama ta pati aparatinė įranga su RTX 4090 vaizdo plokšte. Greitaveikos testų metu, yra matuojamas laikas kiek

laiko užtrunka vienos partijos treniravimas bei testavimas (32 paveikslėliai) ir išvedamas vidurkis. Iš rezultatų galime matyti (žr. **3.9 lentelę**), kad laikas tiesiogiai priklauso nuo modelio dydžio. Todėl didžiausias modelis (*ResNet152*) užtruko ilgiausiai, o mažiausiai laiko reikėjo pasiūlytam *Net* modeliui.

**3.9 lentelė.** Modelių greitaveikos rezultatai vieną epochą

Modelis	Treniravimas, ms	Testavimas, ms
<i>ResNet152</i>	95,19	24,99
<i>ResNet50</i>	37,13	8,61
<i>MobileNetV2</i>	30,76	8,33
<i>Net</i>	<b>5,88</b>	<b>1,06</b>

Taip pat į šiuos laikus galima pažvelgti naudojant epochas. Grafike (žr. **3.39 pav.**) yra pavaizduota kiek užtruko viso duomenų rinkinio treniravimas ir testavimas kiekvieną epochą. Matome, kad ilgiausiai užtruko didžiausias neuroninis tinklas *ResNet152*. Žinoma, mažiausiai laiko treniruojant ir testuojant reikėjo pasiūlytam mažiausiam modeliui *Net*. Žvelgiant į vidutinį treniravimo laiką, jis buvo beveik 19 kartų trumpesnis, o testavimo laikas beveik 25 kartus mažesnis.



**3.39 pav.** Modelių greitaveika kiekvieną epochą

Žinoma modelių treniravimas bei testavimas reikalauja kompiuterinių resursų. Vaizdo plokštės operatyviosios atminties naudojimas buvo tikrinamas treniravimo metu. Reikšmės gautos naudojant *nvidia-smi* komandą (žr. **3.10 lentelę**).

**3.10 lentelė.** Modelių operatyviosios atminties sunaudojimas

Modelis	Atminties kiekis, MiB
<i>ResNet152</i>	2498
<i>ResNet50</i>	1526
<i>MobileNetV2</i>	1244
<i>Net</i>	1035

### **3.8. Diskusija ir hipertenzijos prognozavimo metodo apribojimai**

Svarbu pažymėti, kad gauti rezultatai gali skirtis nuo realių duomenų, kadangi testavimo metu buvo naudotos viešai prieinamos duomenų bazės, kurios dažniausiai yra sudarytos idealiomis klinikinėmis sąlygomis. Kitas svarbus aspektas – tyrimas, kuriame buvo atlikti abu signalo filtravimo metodai (aukšto ir žemo dažnio filtras). Nustatyta, jog gauti rezultatai, kai naudojami abu filtravimo metodai, yra prastesni nei naudojant vien tik žemo dažnio filtrą. Šis pastebėjimas gali turėti svarbių praktinių pasekmių, ypač siekiant optimizuoti širdies ritmo signalų analizės procesus. Dar vienas svarbus aspektas, atkreipiantis dėmesį į automatizavimo svarbą. Automatizuotų procesų metu yra rizika įtraukti netikslių širdies plakimo signalų. Ši įtaka gali neigiamai paveikti gautų rezultatų tikslumą ir patikimumą, todėl svarbu tokius aspektus įvertinti ir ieškoti būdų, kaip mažinti blogų signalų skaičių. Ši sritis gali reikalauti papildomų tyrimų ir tobulinimų, siekiant užtikrinti tikslesnius ir patikimesnius rezultatus.

## Išvados

1. Apžvelgus esančius hipertenzijos prognozavimo algoritmus, buvo rasta modelių architektūrų, gebančių itin gerai prognozuoti hipertenzinius sutrikimus. Hipertenzijai prognozuoti yra naudojamos įvairios metodologijos: bangelių analizė, konvoliuciniai neuroniniai tinklai, trumpos-ilgos atminties tinklai, atsitiktiniai miškai. Tačiau kiekvienas iš analizuotų metodų turėjo tam tikrų trūkumų arba veikė specifinėmis sąlygomis.
2. Atlikus išsamesnę algoritmų analizę, buvo identifikuoti skirtingi trūkumai: reikalingi nuo kelių minučių iki aštuonių valandų trukmės EKG signalai, nėra automatizuoti, klasifikuoja tik aukštos ir žemos rizikos pacientus. Todėl buvo sukurta hipertenzijos prognozavimo metodika ir pasiūlyta konvoliucinio neuroninio tinklo architektūra. Metodo pagrindu tapo kitas tyrimas, kuriame klasifikuojami širdies dūžiai iš 15 elektrodų panaudojant SVM ir HOG algoritmus, tačiau hipertenzija klasifikuojama nebuvo. Taip pat buvo išspręsta EKG signalo segmentavimo problema, dėl kurios reikėjo ekspertui rankiniu būdu segmentuoti EKG signalą. Signalo segmentacijai buvo panaudotas algoritmas iš *biopeaks* paketo.
3. Įgyvendintas autoriaus pasiūlytas hipertenzijos prognozavimo algoritmas. Atlikus modelio testavimą buvo gautas virš 92 % klasifikavimo tikslumas su testavimo duomenimis panaudojant pasiūlytą *Net* architektūros modelį. Eksperimentų metu šis *Net* modelis buvo lyginamas su kitomis konvoliucinių neuroninių tinklų architektūromis *ResNet152*, *ResNet50* bei *MobileNetV2*. Iš visų modelių tiksliausiai klasifikavo *Net* ir *MobileNetV2* modeliai.
4. Atlikus klasifikavimą panaudojant spektro analizės nuotraukas buvo gautas beveik idealus klasifikatorius. Pritaikius širdies dūžiams skirtingus filtravimo metodus, didžiausias testavimo tikslumas (92,69 %) buvo gautas panaudojant *MobileNetV2* architektūrą kartu su normalizuotais signalais, kurie buvo filtruoti aukšto ir žemo dažnio *Butterworth* filtru.
5. Greitaveikos rezultatai parodė, kad pasiūlyto *Net* modelio treniravimo laikas yra beveik 19 kartų trumpesnis, o testavimas – 25 kartus greitesnis nei *ResNet152*.

## Literatūros sąrašas

1. ROTH, G.A. ir kt. Global Burden of Cardiovascular Diseases and Risk Factors, 1990–2019. In *Journal of the American College of Cardiology* [interaktyvus]. 2020. Vol. 76, no. 25, p. 2982–3021. [žiūrėta 2022-09-18]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/33309175/>.
2. Hypertension, World Health Organisation [interaktyvus]. 2024 [žiūrėta 2022-09-18]. Prieiga per internetą: <https://www.who.int/news-room/fact-sheets/detail/hypertension>.
3. UNGER, T. ir kt. 2020 International Society of Hypertension Global Hypertension Practice Guidelines. In *Hypertension* [interaktyvus]. 2020. Vol. 75, no. 6, p. 1334–1357. [žiūrėta 2022-10-05]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/32370572/>.
4. ISSA, Z.F. ir kt. Ventricular Arrhythmias in Inherited Channelopathies. In *ResearchGate* [interaktyvus]. 2012. [žiūrėta 2022-10-05]. Prieiga per internetą: [https://www.researchgate.net/publication/288241572\\_Ventricular\\_Arrhythmias\\_in\\_Inherited\\_Channelopathies](https://www.researchgate.net/publication/288241572_Ventricular_Arrhythmias_in_Inherited_Channelopathies).
5. ATTIA, Z.I. ir kt. Screening for cardiac contractile dysfunction using an artificial intelligence-enabled electrocardiogram. In *Nature medicine* [interaktyvus]. 2019. Vol. 25, no. 1, p. 70–74. [žiūrėta 2022-10-05]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/30617318/>.
6. Visuotinė lietuvių enciklopedija. Elektrokardiografija [interaktyvus]. [žiūrėta 2022-10-11]. Prieiga per internetą: <https://www.vle.lt/straipsnis/elektrokardiografija/>
7. SHAFFER, F. - GINSBERG, J.P. An Overview of Heart Rate Variability Metrics and Norms. In *Frontiers in public health* [interaktyvus]. 2017. Vol. 5. [žiūrėta 2022-10-11]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/29034226/>.
8. JAYPAL SINGH RAJPUT ir kt. Hypertension Diagnosis Index for Discrimination of High-Risk Hypertension ECG Signals Using Optimal Orthogonal Wavelet Filter Bank. In *International journal of environmental research and public health/International journal of environmental research and public health* [interaktyvus]. 2019. Vol. 16, no. 21, p. 4068–4068. [žiūrėta 2022-10-11]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/31652712/>.
9. JAYPAL SINGH RAJPUT ir kt. Automated detection of severity of hypertension ECG signals using an optimal bi-orthogonal wavelet filter bank. In *Computers in biology and medicine* [interaktyvus]. 2020. Vol. 123, p. 103924–103924. [žiūrėta 2022-10-11]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/32768053/>.
10. MOHANAD ALKHODARI ir kt. Predicting Hypertensive Patients With Higher Risk of Developing Vascular Events Using Heart Rate... In *ResearchGate* [interaktyvus]. 2020. [žiūrėta 2022-10-18]. Prieiga per internetą: [https://www.researchgate.net/publication/344854725\\_Predicting\\_Hypertensive\\_Patients\\_With\\_Higher\\_Risk\\_of\\_Developing\\_Vascular\\_Events\\_Using\\_Heart\\_Rate\\_Variability\\_and\\_Machine\\_Learning](https://www.researchgate.net/publication/344854725_Predicting_Hypertensive_Patients_With_Higher_Risk_of_Developing_Vascular_Events_Using_Heart_Rate_Variability_and_Machine_Learning).
11. MOODY, G. - JIANG, D. A robust open-source algorithm to detect onset and duration of QRS complexes. In *Computers in cardiology* [interaktyvus]. 2017. [žiūrėta 2022-10-19]. Prieiga per internetą: <https://www.semanticscholar.org/paper/A-robust-open-source-algorithm-to-detect-onset-and-Moody-Jiang/2c8f9f1222cde533a9989d0c510c4230f91884de>.
12. MOODY, B. ir kt. MIMIC-III Waveform Database. In *Physionet.org* [interaktyvus]. 2020. [žiūrėta 2024-05-16]. Prieiga per internetą: <https://physionet.org/content/mimic3wdb/1.0/>.
13. PODDAR, M.G. ir kt. Automated Classification of Hypertension and Coronary Artery Disease Patients by PNN, KNN, and SVM Classifiers Using HRV Analysis. In *Elsevier eBooks* [interaktyvus]. 2019. p. 99–125. [žiūrėta 2022-10-23]. Prieiga per internetą: <https://www.sciencedirect.com/science/article/pii/B9780128160862000059?via%3Dihub>.
14. ALI, M. ir kt. Multi-lead ECG heartbeat classification of heart disease based on HOG local feature descriptor. In *Computer methods and programs in biomedicine* [interaktyvus]. 2023. Vol. 3, p. 100093–100093. [žiūrėta 2022-11-03]. Prieiga per internetą: <https://www.sciencedirect.com/science/article/pii/S2666990023000022>.



15. MELILLO, P. ir kt. Automatic Prediction of Cardiovascular and Cerebrovascular Events Using Heart Rate Variability Analysis. In *PloS one* [interaktyvus]. 2015. Vol. 10, no. 3, p. e0118504–e0118504. [žiūrėta 2022-11-05]. Prieiga per internetą: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0118504>.
16. NI, H. ir kt. Multiscale Fine-Grained Heart Rate Variability Analysis for Recognizing the Severity of Hypertension. In *Computational and mathematical methods in medicine* [interaktyvus]. 2019. Vol. 2019, p. 1–9. [žiūrėta 2022-11-15]. Prieiga per internetą: <https://www.hindawi.com/journals/cmmm/2019/4936179/>.
17. JAIN, P. ir kt. A two-stage deep CNN architecture for the classification of low-risk and high-risk hypertension classes using multi-lead ECG signals. In *Informatics in medicine unlocked* [interaktyvus]. 2020. Vol. 21, p. 100479–100479. [žiūrėta 2022-11-18]. Prieiga per internetą: <https://www.sciencedirect.com/science/article/pii/S2352914820306304>.
18. MIAO, F. ir kt. Continuous blood pressure measurement from one-channel electrocardiogram signal using deep-learning techniques. In *Artificial intelligence in medicine* [interaktyvus]. 2020. Vol. 108, p. 101919–101919. [žiūrėta 2022-11-18]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/32972654/>.
19. SU, P. ir kt. Long-term blood pressure prediction with deep recurrent neural networks. In *ResearchGate* [interaktyvus]. 2018. [žiūrėta 2022-11-18]. Prieiga per internetą: [https://www.researchgate.net/publication/324377127\\_Long-term\\_blood\\_pressure\\_prediction\\_with\\_deep\\_recurrent\\_neural\\_networks](https://www.researchgate.net/publication/324377127_Long-term_blood_pressure_prediction_with_deep_recurrent_neural_networks).
20. B.K. KOICHUBEKOV ir kt. Nonlinear analyses of heart rate variability in hypertension. In *Annales de cardiologie et d'angéiologie* [interaktyvus]. 2018. Vol. 67, no. 3, p. 174–179. [žiūrėta 2022-11-18]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/29753421/>.
21. MANJU B.R - SNEHA M.R ECG Denoising Using Wiener Filter and Kalman Filter. In *Procedia computer science* [interaktyvus]. 2020. Vol. 171, p. 273–281. [žiūrėta 2022-11-18]. Prieiga per internetą: <https://www.sciencedirect.com/science/article/pii/S1877050920309947>.
22. MARKET, P. Wearable Medical Devices Market Demand & Trends, Report 2024-2032. In *Polaris* [interaktyvus]. 2024. [žiūrėta 2022-11-18]. Prieiga per internetą: <https://www.polarismarketresearch.com/industry-analysis/wearable-medical-devices-market>.
23. RAHEL GILGEN-AMMANN ir kt. RR interval signal quality of a heart rate monitor and an ECG Holter at rest and during exercise. In *European journal of applied physiology* [interaktyvus]. 2019. Vol. 119, no. 7, p. 1525–1532. [žiūrėta 2022-12-10]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/31004219/>.
24. SCHAFFARCZYK, M. ir kt. Validity of the Polar H10 Sensor for Heart Rate Variability Analysis during Resting State and Incremental Exercise in Recreational Men and Women. In *Sensors* [interaktyvus]. 2022. Vol. 22, no. 17, p. 6536–6536. [žiūrėta 2022-12-10]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/36081005/>.
25. HERNANDO, D. ir kt. Validation of the Apple Watch for Heart Rate Variability Measurements during Relax and Mental Stress in Healthy Subjects. In *Sensors* [interaktyvus]. 2018. Vol. 18, no. 8, p. 2619–2619. [žiūrėta 2022-12-10]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/30103376/>.
26. HUANG, J. ir kt. ECG Arrhythmia Classification Using STFT-Based Spectrogram and Convolutional Neural Network. In *ResearchGate* [interaktyvus]. 2019. [žiūrėta 2023-10-15]. Prieiga per internetą: [https://www.researchgate.net/publication/334407179\\_ECG\\_Arrhythmia\\_Classification\\_Using\\_STFT-Based\\_Spectrogram\\_and\\_Convolutional\\_Neural\\_Network](https://www.researchgate.net/publication/334407179_ECG_Arrhythmia_Classification_Using_STFT-Based_Spectrogram_and_Convolutional_Neural_Network).
27. VAIDYANATHAN, P. P. *Multirate Systems and Filter Banks*. Prentice Hall, 1993. ISBN 0136057187

28. FREEMAN, William T. ir Michal ROTH. Orientation Histograms for Hand Gesture Recognition. Tech. Rep. TR94-03, Mitsubishi Electric Research Laboratories, Cambridge, MA. 1994.
29. MATTHEWS, B.W. Comparison of the predicted and observed secondary structure of T4 phage lysozyme. In *Biochimica et biophysica acta. Proteins and proteomics* [interaktyvus]. 1975. Vol. 405, no. 2, p. 442–451. [žiūrėta 2023-04-03]. Prieiga per internetą: <https://pubmed.ncbi.nlm.nih.gov/1180967/>.

## Priedai

### 1 Priedas. *DAMMS 2023* konferencijos plakatas

Pristatytas pranešimas 14-toje *Data Analysis Methods for Software Systems* konferencijoje. Trakšelis K., Bikulčienė L., Butkevičiūtė E. *Automated Hypertension Detection Using Convolutional Neural Networks*.

### 2 Priedas. Straipsnis *Computers in Biology and Medicine* žurnale

Pateiktas straipsnis *Computers in Biology and Medicine* žurnalui. Butkevičiūtė E., Trakšelis K., Bikulčienė L. *Automated Hypertension Detection Using Extracted Heartbeat Images and CNN Classifiers*. *Computers in Biology and Medicine*. 2024.