



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

EKG požymių išskyrimas Lagranžo rodikliais ir jų klasifikavimas dirbtiniais neuroniniais tinklais

Baigiamasis magistro studijų projektas

Vaiva Petrauskaitė

Projekto autorė

Doc. Dr. Mantas Landauskas

Vadovas

Kaunas, 2023



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

EKG požymių išskyrimas Lagranžo rodikliais ir jų klasifikavimas dirbtiniais neuroniniais

Baigiamasis magistro studijų projektas

Taikomoji matematika (6211AX006)

Vaiva Petrauskaitė

Projekto autorė

Doc. Dr. Mantas Landauskas

Vadovas

Prof. Dr. Mayur Pal

Recenzentas

Kaunas, 2023



Kauno technologijos universitetas

Matematikos ir gamtos mokslų fakultetas

Vaiva Petrauskaitė

EKG požymių išskyrimas Lagranžo rodikliais ir jų klasifikavimas dirbtiniais neuroniniais tinklais

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.

Vaiva Petrauskaitė

Patvirtinta elektroniniu būdu

Petrauskaitė, Vaiva. EKG požymių išskyrimas Lagranžo rodikliais ir jų klasifikavimas dirbtiniais neuroniniais tinklais. Magistro studijų baigiamasis projektas / vadovas doc. dr. Mantas Landauskas; Kauno technologijos universitetas, Matematikos ir gamtos mokslų fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Taikomoji matematika (Matematikos mokslai).

Reikšminiai žodžiai: mašininis mokymas, dirbtiniai neuroniniai tinklai, širdies nepakankamumas, Lagranžo rodikliai, *AlexNet* architektūra, *ResNet* architektūra, EKG.

Kaunas, 2023. 82 p.

Santrauka

Širdies nepakankamumas yra viena iš pagrindinių mirties priežasčių visame pasaulyje, todėl šią ligą svarbu aptikti kuo anksčiau. Ieškoma pagalbinių būdų, padedančių diagnozuoti šią ligą šios srities specialistams – kardiologams. Magistro baigiamajame projekte apdoroti realūs elektrokardiogramos širdies nepakankamumo ir normalaus sinusinio ritmo signalai, išskirti Lagranžo pirmas ir Lagranžo antras rodikliai, su kuriais paruošti dvimačiai skaitmeniniai vaizdai dirbtinių neuroninių tinklų klasifikavimui į sergančių širdies nepakankamumu ir normalų sinusinį širdies ritmą, turinčių pacientų klases. Šie dvimačiai skaitmeniniai vaizdai yra konstruojami, rekonstruojant atraktorių trimatėje fazinėje erdvėje. Turimi du vėlinimai, kurių įvairios kombinacijos atitinka skaitmeninio vaizdo elemento poziciją. O atitinkamo atraktoriaus parametras, suskaičiuotas, naudojant Lagranžo rodiklius, yra šios matricos elementas. Toks dvimačių skaitmeninių vaizdų gavimas yra šio baigiamojo projekto naujumas.

Projekto tikslas yra sukurti ir ištirti Lagranžo rodikliais paremtą požymių, kaip skaitmeninių vaizdų, išskyrimo metodą, skirtą širdies nepakankamumui elektrokardiogramos segmentuose aptikti. Klasifikaciją į širdies nepakankamumo ir normalų sinusinį širdies ritmą, turinčių pacientų klases atliekama naudojant dirbtinių neuroninių tinklų *ResNet* ir *AlexNet* architektūras, išbandant skirtingus parametrus: epocų skaičių, mokymo spartos, paveikslėlių padalijimo mokymui parametras, optimizacijos funkcijas („Adam“ ir „SGD“). Geriausio *ResNet* architektūros modelio suvidurkinti rezultatai gauti, naudojant pirmo Lagranžo rodiklio dvimačius skaitmeninius vaizdus, pasiektas bendras tikslumas 99,198 %. Geriausio *AlexNet* architektūros modelio suvidurkinti rezultatai gauti, naudojant pirmo Lagranžo rodiklio dvimačius skaitmeninius vaizdus, pasiektas bendras tikslumas 99,104 %.

Petrauskaitė, Vaiva. Extracting ECG features with Lagrange descriptors and their classification using artificial neural networks / supervisor doc. dr. Mantas Landauskas; Faculty of Mathematics and Natural Sciences, Kaunas University of Technology.

Study field and area (study field group): Applied Mathematics (Mathematical Sciences).

Keywords: machine learning, artificial neural networks, heart failure, Lagrangian descriptors, *AlexNet* architecture, *ResNet* architecture, ECG.

Kaunas, 2023. 82 p.

Summary

Heart failure is the main condition of death in the world, and this is the reason why detecting of this disease as early as possible is important. Efforts are being made to aid cardiologists in diagnosing the disease. Real electrocardiogram heart failure and normal sinus rhythm signals were processed in the Master's final degree project. Lagrange first and second descriptors were computed, and two-dimensional digital images were created and prepared to be used for classification of patients into heart failure and normal sinus rhythm classes using artificial neural networks. The two-dimensional digital images were constructed by reconstructing the attractor in three-dimensional phase space. Using different combinations of two time delays, in this respect the position of the digital image element was determined. The corresponding attractor's parameter, which was calculated using Lagrange descriptors, is an element of this matrix. This way of constructing two-dimensional digital image is novel feature extraction approach.

The objective of the project is to create and evaluate a Lagrangian-based feature extraction method that uses two-dimensional digital images to detect heart failure in electrocardiogram segments. The *ResNet* and *AlexNet* artificial neural network architectures were utilized to classify patients into belonging to heart failure and normal sinus rhythm classes. Various parameters, such as the number of epochs, learning rate, batch size, and optimization functions (Adam and SGD), were tested. The best *ResNet* architecture model achieved an overall accuracy of 99,198 % using two-dimensional digital images of the first Lagrange descriptor. The top performing *AlexNet* architecture model also used two-dimensional digital images of the first Lagrange descriptor, with an overall accuracy of 99,104 %.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Santrumpų ir terminų sąrašas	12
Įvadas	13
1. Literatūros apžvalga	14
1.1. Širdies nepakankamumas	14
1.1.1. Širdies nepakankamumo vystymasis	14
1.1.2. Širdies nepakankamumo statistika	15
1.2. Elektrokardiograma	15
1.2.1. Normalaus sinusinio ritmo bangos sandara	15
1.2.2. Širdies nepakankamumo ir normalaus sinusinio ritmo EKG skirtumai	16
1.3. Širdies nepakankamumu sergančių žmonių EKG duomenų tyrimų apžvalga.....	17
1.4. Tyrimai, kuriuose naudojami Lagranžo rodikliai	25
1.5. Literatūros apžvalgos apibendrinimas	28
2. Duomenys ir tyrimo metodai	29
2.1. Duomenų apžvalga	29
2.2. Lagranžo rodikliai	31
2.2.1. Pirmas Lagranžo rodiklis.....	31
2.2.2. Antras Lagranžo rodiklis	32
2.3. Tyrimo eigos schema ir naudota programinė įranga	32
2.4. Mašininis mokymasis	35
2.4.1. Dirbtiniai neuroniniai tinklai	36
3. Tyrimų rezultatai ir jų aptarimas	40
3.1. Duomenų rinkiniai.....	40
3.2. Skaimeninių dvimačių vaizdų apžvalga	40
3.3. <i>ResNet</i> architektūra paremti dirbtinių neuroninių tinklų modeliai	45
3.3.1. Dvimačių požymių, paremtų L1 rodikliu, klasifikavimas.....	45
3.3.2. Dvimačių požymių, paremtų L2 rodikliu, klasifikavimas.....	51
3.4. Alexnet architektūra paremti dirbtinių neuroninių tinklų modeliai	59
3.4.1. Dvimačių požymių, paremtų L1 rodikliu, klasifikavimas.....	59
3.4.2. Dvimačių požymių, paremtų L2 rodikliu, klasifikavimas.....	67
3.5. Mašininio mokymo metodų rezultatų palyginimas	76
Išvados	78
Literatūros sąrašas	79

Lentelių sąrašas

1 lentelė. <i>AlexNet</i> architektūra.....	39
2 lentelė. EKG segmentų požymių, paremtų L1 rodikliu, visų <i>ResNet</i> modelių tikslumo įverčiai, naudojant testavimo rinkinį.....	51
3 lentelė. EKG segmentų požymių, paremtų L2 rodikliu, visų <i>ResNet</i> modelių tikslumo įverčiai, naudojant testavimo rinkinį.....	58
4 lentelė. EKG segmentų požymių, paremtų L1 rodikliu, visų <i>AlexNet</i> modelių tikslumo įverčiai, naudojant testavimo rinkinį.....	67
5 lentelė. EKG segmentų požymių, paremtų L2 rodikliu, visų <i>AlexNet</i> modelių tikslumo įverčiai, naudojant testavimo rinkinį.....	76
6 lentelė. Pirmu ir antru Lagranžo rodikliu paremtų dvimačių skaitmeninių vaizdų klasifikavimo dirbtiniais neuroniniais tinklais geriausių <i>AlexNet</i> ir <i>ResNet</i> architektūrų modelių tikslumo įverčiai	77

Paveikslų sąrašas

1 pav. Didysis kraujo apytakos ratas [2]; 1) dešinysis prieširdis; 2) kairysis prieširdis; 3) kairysis skilvelis; 4) dešinysis skilvelis; 5) plaučių vena; 6) aorta; 7) plaučių arterija.....	14
2 pav. Normalaus sinusinio ritmo EKG sandara [7].....	16
3 pav. Širdies nepakankamumo (a) ir normalaus sinusinio ritmo (b) EKG segmentai [8]	17
4 pav. Širdies nepakankamumo duomenų bazės tiriamųjų pasiskirstymas pagal lytį	29
5 pav. Širdies nepakankamumo duomenų bazės tiriamųjų pasiskirstymas pagal amžių	29
6 pav. Pirmo tiriamojo širdies nepakankamumo EKG intervalo pavyzdys.....	30
7 pav. Normalaus sinusinio ritmo duomenų bazės tiriamųjų pasiskirstymas pagal lytį	30
8 pav. Normalaus sinusinio ritmo duomenų bazės tiriamųjų pasiskirstymas pagal amžių	30
9 pav. Pirmo tiriamojo normalaus sinusinio ritmo EKG intervalo pavyzdys	31
10 pav. Pirmu Lagranžo rodikliu paremtas dvimačių skaitmeninių vaizdų sukūrimo eigos schema	33
11 pav. Antru Lagranžo rodikliu paremtas dvimačių skaitmeninių vaizdų sukūrimo eigos schema	34
12 pav. Dvimačių skaitmeninių vaizdų klasifikacijos dirbtiniais neuroniniais tinklais eigos schema	34
13 pav. Dirbtinių neuroninių tinklų architektūra.....	37
14 pav. <i>ResNet</i> liekamųjų blokų diagrama	38
15 pav. <i>AlexNet</i> modelio schema	39
16 pav. Procentinis duomenų pasiskirstymas klasėse.....	40
17 pav. Dvimačiai, dažniausiai pasikartojantys, širdies nepakankamumo pacientų skaitmeniniai vaizdai, paremti L1 rodikliu, duomenų rinkiniuose; a) pirmojo paciento; b) antrojo paciento; c) trečiojo paciento; d) ketvirtojo paciento; e) penktojo paciento; f) šeštojo paciento; g) septintojo paciento; j) aštuntojo paciento; k) devintojo paciento; l) dešimtojo paciento; m) vienuoliktojo paciento; n) dvyliktojo paciento; o) tryliktojo paciento; p) keturioliktojo paciento; r) penkioliktojo paciento	41
18 pav. Dvimačiai, dažniausiai pasikartojantys, normalaus sinusinio ritmo klasės, pacientų skaitmeniniai vaizdai, paremti L1 rodikliu, duomenų rinkiniuose; a) pirmojo paciento; b) antrojo paciento; c) trečiojo paciento; d) ketvirtojo paciento; e) penktojo paciento; f) šeštojo paciento; g) septintojo paciento; h) aštuntojo paciento; j) devintojo paciento; k) dešimtojo paciento; l) vienuoliktojo paciento; m) dvyliktojo paciento; n) tryliktojo paciento; o) keturioliktojo paciento; p) penkioliktojo paciento; r) šešioliktojo paciento; s) septynioliktojo paciento; t) aštuonioliktojo paciento	42
19 pav. Dvimačiai, dažniausiai pasikartojantys, širdies nepakankamumo pacientų skaitmeniniai vaizdai, paremti L2 rodikliu, duomenų rinkiniuose; a) pirmojo paciento; b) antrojo paciento; c) trečiojo paciento; d) ketvirtojo paciento; e) penktojo paciento; f) šeštojo paciento; g) septintojo paciento; h) aštuntojo paciento; j) devintojo paciento; k) dešimtojo paciento; l) vienuoliktojo paciento; m) dvyliktojo paciento; n) tryliktojo paciento; o) keturioliktojo paciento; p) penkioliktojo paciento	43
20 pav. Dvimačiai, dažniausiai pasikartojantys, normalaus sinusinio ritmo klasės, pacientų skaitmeniniai vaizdai, paremti L2 rodikliu, duomenų rinkiniuose; a) pirmojo paciento; b) antrojo paciento; c) trečiojo paciento; d) ketvirtojo paciento; e) penktojo paciento; f) šeštojo paciento; g) septintojo paciento; h) aštuntojo paciento; j) devintojo paciento; k) dešimtojo paciento; l) vienuoliktojo paciento; m) dvyliktojo paciento; n) tryliktojo paciento; o) keturioliktojo paciento; p) penkioliktojo paciento; r) šešioliktojo paciento; s) septynioliktojo paciento; t) aštuonioliktojo paciento	44

21 pav. Dažniausiai pasikartojančios anomalijos, visuose skaitmeninių vaizdų duomenų rinkiniuose	44
22 pav. EKG segmentų požymių, parentų L1, pirmo <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	45
23 pav. EKG segmentų požymių, parentų L1, pirmo <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	46
24 pav. EKG segmentų požymių, parentų L1, antro <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	46
25 pav. EKG segmentų požymių, parentų L1, antro <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	46
26 pav. EKG segmentų požymių, parentų L1, trečio <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	47
27 pav. EKG segmentų požymių, parentų L1, trečio <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	47
28 pav. EKG segmentų požymių, parentų L1, ketvirtro <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	48
29 pav. EKG segmentų požymių, parentų L1, ketvirtro <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	48
30 pav. EKG segmentų požymių, parentų L1, penkto <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	49
31 pav. EKG segmentų požymių, parentų L1, penkto <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	49
32 pav. EKG segmentų požymių, parentų L1, šešto <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	50
33 pav. EKG segmentų požymių, parentų L1, šešto <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	50
34 pav. EKG segmentų požymių, parentų L1 rodikliu, geriausio <i>ResNet</i> modelio penki tikslumo įverčiai, naudojant testavimo rinkinį	51
35 pav. EKG segmentų požymių, parentų L2, pirmo <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	52
36 pav. EKG segmentų požymių, parentų L2, pirmo <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	52
37 pav. EKG segmentų požymių, parentų L2, antro <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	53
38 pav. EKG segmentų požymių, parentų L2, antro <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	54
39 pav. EKG segmentų požymių, parentų L2, trečio <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	54
40 pav. EKG segmentų požymių, parentų L2, trečio <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	55
41 pav. EKG segmentų požymių, parentų L2, ketvirtro <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	55
42 pav. EKG segmentų požymių, parentų L2, ketvirtro <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	56
43 pav. EKG segmentų požymių, parentų L2, penkto <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	56

44 pav. EKG segmentų požymių, parentų L2, penkto <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	57
45 pav. EKG segmentų požymių, parentų L2, šešto <i>ResNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	57
46 pav. EKG segmentų požymių, parentų L2, šešto <i>ResNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	58
47 pav. EKG segmentų požymių, parentų L2 rodikliu, geriausio <i>ResNet</i> modelio penki tikslumo įverčiai, naudojant testavimo rinkinį	59
48 pav. EKG segmentų požymių, parentų L1, pirmo <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	60
49 pav. EKG segmentų požymių, parentų L1, pirmo <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	60
50 pav. EKG segmentų požymių, parentų L1, antro <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	61
51 pav. EKG segmentų požymių, parentų L1, antro <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	61
52 pav. EKG segmentų požymių, parentų L1, trečio <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	62
53 pav. EKG segmentų požymių, parentų L1, trečio <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	62
54 pav. EKG segmentų požymių, parentų L1, ketvirto <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	63
55 pav. EKG segmentų požymių, parentų L1, ketvirto <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	63
56 pav. EKG segmentų požymių, parentų L1, penkto <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	64
57 pav. EKG segmentų požymių, parentų L1, penkto <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	64
58 pav. EKG segmentų požymių, parentų L1, šešto <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	65
59 pav. EKG segmentų požymių, parentų L1, šešto <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	65
60 pav. Pirmo Lagranžo rodiklio septinto <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą rezultatai	66
61 pav. EKG segmentų požymių, parentų L1, septinto <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	66
62 pav. EKG segmentų požymių, parentų L1 rodikliu, geriausio <i>AlexNet</i> modelio penki tikslumo įverčiai, naudojant testavimo rinkinį	67
63 pav. EKG segmentų požymių, parentų L2, pirmo <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	68
64 pav. EKG segmentų požymių, parentų L2, pirmo <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	68
65 pav. EKG segmentų požymių, parentų L2, antro <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	69
66 pav. EKG segmentų požymių, parentų L2, antro <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	69

67 pav. EKG segmentų požymių, paremtų L2, trečio <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	70
68 pav. EKG segmentų požymių, paremtų L2, trečio <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	70
69 pav. EKG segmentų požymių, paremtų L2, ketvirto <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	71
70 pav. EKG segmentų požymių, paremtų L2, ketvirto <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	71
71 pav. EKG segmentų požymių, paremtų L2, penkto <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	72
72 pav. EKG segmentų požymių, paremtų L2, penkto <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	72
73 pav. EKG segmentų požymių, paremtų L2, šešto <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	73
74 pav. EKG segmentų požymių, paremtų L2, šešto <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	73
75 pav. EKG segmentų požymių, paremtų L2, septinto <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	74
76 pav. EKG segmentų požymių, paremtų L2, septinto <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	74
77 pav. EKG segmentų požymių, paremtų L2, aštunto <i>AlexNet</i> modelio mokymosi tikslumo bei nuostolio per epochą dinamika.....	75
78 pav. EKG segmentų požymių, paremtų L2, aštunto <i>AlexNet</i> modelio tikslumo įverčiai, naudojant testavimo rinkinį	75
79 pav. EKG segmentų požymių, paremtų L2 rodikliu, geriausio <i>AlexNet</i> modelio penki tikslumo įverčiai, naudojant testavimo rinkinį	76

Santrumpų ir terminų sąrašas

Santrumpos:

ANN – dirbtiniai neuroniniai tinklai

AUC – plotas po jautrumo kaip specifiškumo funkcijos kreive (angl. *Area Under the ROC Curve*)

CNN – sąsūkų neuroniniai tinklai

EKG – elektrokardiograma

DI – dirbtinis intelektas

LD – Lagranžo rodikliai

ResNet – liekamasis tinklas (angl. *Residual Network*)

SVM – atraminių vektorių mašina

ŠN – širdies nepakankamumas

TLK – tarptautiniai ligų kodai

QRS – širdies ritmo dažnis

QT – širdies ritmas

Terminai:

Mašininio mokymosi parametrai – parametrai, kuriuos algoritmai išmoksta patys ir (arba) įvertina mokymo metu konkrečiam duomenų rinkiniui.

Hiperparametrai – tai kintamieji, kuriems mašininio mokymosi inžinieriai arba duomenų mokslininkai nurodo tikslias vertes, kad galėtų reguliuoti, kaip algoritmai mokosi.

Įvadas

Dažniausiai širdies ligos ar veiklos sutrikimai diagnozuojami kardiologo, kuris vizualiai įvertina paciento elektrokardiogramos įrašą. Širdies nepakankamumas yra labai dažna liga, kuri yra pagrindinė mirties priežastis, mediciniame mirties liudijime ši liga, kaip gretutinė mirties priežastis, pažymima pusei visų mirusiųjų žmonių, pastebima, kad kiekvienais metais tokių atvejų skaičius didėja. Remiantis Jungtinės Amerikos Valstijos (JAV) širdies nepakankamumo asociacijos pateikta informacija beveik 6,5 milijono vyresnių nei 20 metų amerikiečių serga širdies nepakankamumu, kasmet nustatoma 960 000 naujų širdies nepakankamumo atvejų, o ateityje, iki 2030 m., numatoma, jog šios ligos paplitimas JAV padidės iki daugiau nei 8 milijonų. Higienos instituto duomenis, tiek 2004 m., tiek 2013 m. 54 - 56 % visų mirčių Lietuvoje sudarė mirtys nuo širdies ir kraujagyslių ligų. Pagal šiuos skaičius Lietuva yra pirmaujanti šalis Europoje. Kadangi svarbu, kuo anksčiau aptikti širdies nepakankamumą, ieškoma pagalbinių būdų, kurie galėtų padėti gydytojams diagnozuoti šią ligą. Vienas iš būdų, norint nustatyti širdies nepakankamumą be vizualaus kardiologo įvertinimo yra mašininis mokymas. Realus mašininio mokymo taikymas širdies ligoms, kartu ir širdies nepakankamumui, diagnozuoti įgyvendinamas per išmaniuosius laikrodžius. Išgaunami 2 derivacijų EKG duomenys, kurie paverčiami į 10 derivacijų EKG ir taip gaunami 12 derivacijų EKG signalai. Signalai mokomi bei, jei fiksuojamas, širdies nepakankamumui būdingas signalas, apie tai informuojami laikrodžio savininkai.

Šiame darbe pacientų, kurie turi širdies nepakankamumą ir kurie neturi, klasifikacija atliekama pasitelkiant dirbtinių neuroninių tinklų *ResNet* ir *AlexNet* architektūras, prieš tai iš duomenų segmentų apskaičiuojant pirmą ir antrą Lagranžo rodiklius bei iš jų formuojant matricas ir jas traktuojant kaip skaitmeninius vaizdus (paveikslėlius), kurie naudojami dirbtinio neuroninio tinklo mokymui, validavimui ir testavimui.

Tikslas: Sukurti ir iširti Lagranžo rodikliais paremtą požymių, kaip skaitmeninių vaizdų, išskyrimo metodą, skirtą širdies nepakankamumui elektrokardiogramos segmentuose aptikti.

Uždaviniai:

1. išanalizuoti elektrokardiogramos klasifikavimo metodų aibę, atliekant mokslo publikacijų analizę;
2. sukonstruoti dvimatį požymį elektrokardiogramos segmentui, kuris būtų paremtas Lagranžo rodikliu L1 arba L2 bei naudotų fazinės erdvės rekonstravimo principą;
3. programiškai realizuoti dvimačio požymio išskyrimą elektrokardiogramos segmentams;
4. parinkti dirbtinių neuroninių tinklų modelius, kurie būtų skirti klasifikuoti pacientus į turinčių širdies nepakankamumą ir jo neturinčių klases, atlikti modelių mokymą su realių pacientų EKG įrašais;
5. pateikti tyrimo išvadas apie sukurto dvimačio požymio konstravimo metodo tinkamumą EKG segmentų klasifikavimui.

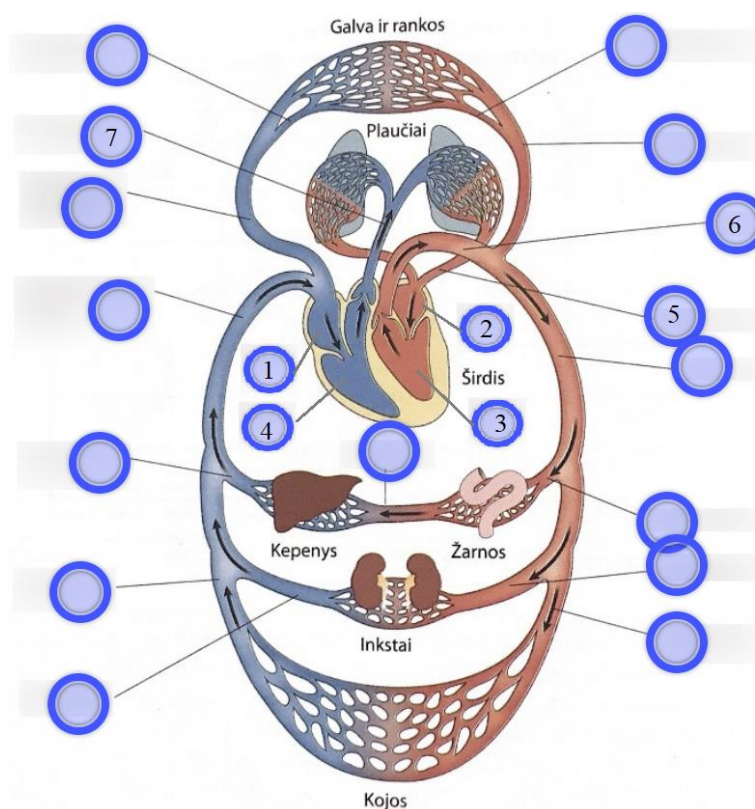
1. Literatūros apžvalga

1.1. Širdies nepakankamumas

Širdies nepakankamumas (ŠN), tai yra liga, kuri atsiranda dėl širdies veiklos susilpnėjimo, kai dėl jos nebėra užtikrinamas kiekvieno organo aprūpinimas deguonimi ir maisto medžiagomis, tuomet atsiranda ligos simptomai. Širdies nepakankamumo simptomai pasireiškia bendru nuovargiu, skausmu krūtinėje, galvos skausmu, dusuliu, kosuliu, odos pamėlynavimu, atminties pablogėjimu, kojų patinimu, bendru silpnumu bei dažnu širdies plakimu [1].

1.1.1. Širdies nepakankamumo vystymasis

Širdis yra sudaryta iš kairiosios pusės bei dešinėsios, kurios tarpusavyje dirba harmoningai ir taip užtikrina kraujo apytaką. Kraujas organizme cirkuliuoja didžiuoju ir mažuoju apytakos ratais. Iš raumenų, galvos, vidaus organų, veninis kraujas (kuris atsakingas už deguonies ir maisto medžiagų atidavimą) tuščiosiomis venomis grįžta į dešinįjį prieširdį (žr. 1 pav.), o per triburį vožtuvą – į dešinįjį skilvelį (žr. 1 pav.). Iš dešiniojo skilvelio kraujas teka į plaučių arterijos šakas (per plaučių arterijos vožtuvą). Plaučiuose veninis kraujas atiduoda anglies dvideginį ir paima deguonį, taip tapdamas arteriniu. Iš plaučių arterinis kraujas venomis grįžta į kairįjį prieširdį. Iš jo teka į kairįjį skilvelį. Iš kairiojo skilvelio pro aortos vožtuvą jis išstumiamas į aortą [1].



1 pav. Didysis kraujo apytakos ratas [2]; 1) dešinysis prieširdis; 2) kairysis prieširdis; 3) kairysis skilvelis; 4) dešinysis skilvelis; 5) plaučių vena; 6) aorta; 7) plaučių arterija

Aorta organizme išsišakoja į smulkias bei vidutinio stambumo arterijas. Jų funkcija yra krauju aprūpinti kiekvieną organą. Taigi širdis dirba vienu metu „siurblio ir pompos“ principu. Širdis pradeda silpti dėl įvairių faktorių veikimo, dėl to sutrinka kraujo cirkuliacija – vystosi širdies

nepakankamumas. Skiriamos širdies nepakankamumo rūšys: ūminis ir lėtinis, kairiosios širdies, dešinėsios ir abiejų širdies pusių nepakankamumas [2].

1.1.2. Širdies nepakankamumo statistika

Remiantis Jungtinės Amerikos Valstijos (JAV) širdies nepakankamumo asociacijos pateikta informacija širdies nepakankamumas yra labai dažna liga. Nepaisant medicininės pažangos, šis susirgimas Jungtinėse Amerikos Valstijose tarp gyventojų yra populiarėjantis. Beveik 6,5 milijono vyresnių nei 20 metų amerikiečių serga širdies nepakankamumu, kasmet nustatoma 960 000 naujų širdies nepakankamumo atvejų. Širdies nepakankamumas yra ne tik didelė problema, su kuria susiduria daugybė žmonių, bet ir pagrindinė mirties priežastis. Širdies nepakankamumas tiesiogiai lemia apie 8,5 % visų mirčių, įvykusių nuo širdies ligų. Kai kuriais skaičiavimais, širdies nepakankamumas lemia apie 36 % visų mirčių nuo širdies ir kraujagyslių ligų. Viena tyrimo pažymima, kad širdies nepakankamumas yra įrašomas kaip mirties priežastis kas aštuntame mirties liudijime. Ateityje, iki 2030 m., numatoma, jog šios ligos paplitimas JAV padidės iki daugiau nei 8 milijonų, dėl rizikos veiksnių, tokių kaip hipertenzija ar geresnio išgyvenamumo po miokardo infarkto [3].

Nemažėjantis sergamumas širdies ligomis pastebimas ir Lietuvoje. Higienos instituto duomenis, tiek 2004 m., tiek 2013 m. 54 - 56 % visų mirčių Lietuvoje sudarė mirtys nuo širdies ir kraujagyslių ligų. Pagal šiuos skaičius Lietuva yra pirmaujanti šalis Europoje. Pastebima, kad širdies ligomis serga vis jaunesni žmonės [4].

Sveikatos apsaugos ministerija (SAM) kartu su Lietuvos kardiologų draugija 2017 m. gegužės 4 d. organizavo konferenciją „Širdies nepakankamumo epidemija: lūžio taškas“, kurioje buvo pristatyta statistika bei faktai apie širdies nepakankamumą. Statistiniai duomenys rodo, kad nuo 50 % iki 70 % pacientų, kuriems jauname amžiuje pasireiškia hipertenzija, vėliau serga širdies nepakankamumu. ŠN, kaip gretutinė mirties priežastis, fiksuojama pusei visų mirusiųjų žmonių ir ši dalis vis didėja. 2010 m. mirė 42 120 žmonių, iš kurių 17 554 asmenų medicininiam mirties liudijime gretutine mirties priežastimi buvo pažymėtas ŠN (41,7 %), o 2016 m. mirė 41 106 žmonės, iš jų 21 499 (52,3 %) ŠN buvo įrašyta kaip gretutinė mirties priežastis. 2016 m. Lietuvoje širdies nepakankamumu sirgo 92 115, arba 3,2 %, gyventojų (36 847 tai yra 2,8 %, vyrai ir 55 268 (3,6 proc.) moterys). Lyginant su 2001 m., sergančiųjų skaičius padidėjo 2,5 karto (vyrų – 2,8 karto, moterų – 2,3 karto), miesto gyventojų padaugėjo 2,8 karto, kaimo – 2,3 karto [5].


1.2. Elektrokardiograma

Tai tyrimas, kuris atliekamas siekiant diagnozuoti širdies ritmo sutrikimo ligas. EKG dažniausiai atliekamas sveikatos įstaigose elektrokardiografu, pats tyrimas trunka nuo 5 iki 10 minučių. Testui atlikti pritvirtinami elektrodai prie rankų, kojų ir krūtinės. Atsižvelgiant į elektrodų skaičių, atliekami skirtingi EKG, gali būti 1, 2, 6 ar 12 derivacijų elektrokardiogramos. Kuo daugiau naudojama derivacijų, tuo išsamesnis širdies tyrimas, pavyzdžiui 1 derivacija naudojama tik pagrindiniam širdies stebėjimui, o 12 derivacijų EKG pateikia išsamų širdies veiklos vaizdą [6].

1.2.1. Normalaus sinusinio ritmo bangos sandara

Pagal intervalus galima apskaičiuoti širdies ritmą, kadangi įrašymo greitis nekinta. Pagrindinė EKG bangos sandara (žr. 2 pav.):


- 1) P banga – tai pirmoji ciklo banga, atitinkanti prieširdžių depoliarizaciją. Jo trukmė svyruoja nuo 60 iki 120 ms, o amplitudė (arba aukštis) yra 2,5 mm arba mažesnė [7].
- 2) QRS kompleksas – atitinka skilvelių depoliarizaciją ir susidaro iš 3 bangu, kurios seka viena kitą: Q bangos, kuri neigiama ir maža; R bangos, kuri yra labai aukšta teigiama smailė; S bangos, kuri yra maža ir neigiama [7].
- 3) ST – tai yra laikotarpis, kai visos skilvelių ląstelės yra depoliarizuotos ir todėl nėra aptinkami jokie elektriniai judesiai [7].
- 4) T ir U bangos – T banga ne visada atpažįstama, gali būti mažos vertės; U banga, kurią taip pat ne visada galima įvertinti dėl papiliarinių raumenų repoliarizacijos [7].
- 5) QT intervalas – reiškia elektrinę sistolę, t.y. laiką, per kurį įvyksta skilvelių depoliarizacija ir repoliarizacija. Paprastai trunka nuo 350 iki 440 ms [7].



2 pav. Normalaus sinusinio ritmo EKG sandara [7]

1.2.2. Širdies nepakankamumo ir normalaus sinusinio ritmo EKG skirtumai

Širdies nepakankamumą iš EKG įrašo pastebėti gali tik patyręs ekspertas. Kiekvieno ŠK sergančio žmogaus atveju elektrokardiograma atrodo neidentiškai, tačiau galima išvelgti dominuojančius pakitimus. Kamilu M Karaye širdies nepakankamumu sergančių pacientų elektrografinių pakitimų tyrime pastebėjo, kad iš 113 tirtų pacientų ilgas koreguotas QT intervalas būdingas 71,4 % tirtųjų [8].



3 pav. Širdies nepakankamumo (a) ir normalaus sinusinio ritmo (b) EKG segmentai [8]

1.3. Širdies nepakankamumu sergančių žmonių EKG duomenų tyrimų apžvalga

Sudestna Nahak‘as, Akanksha Pathak‘as, Goutam‘as Saha straipsnyje aptarė sukurtų požymių bei jų klasifikavimo mokymo vertinimą širdies aritmijos ir širdies nepakankamumo nustatymui, naudojant EKG duomenis [9]. Elektrokardiograma (EKG) laikoma viena iš svarbiausių diagnostinių priemonių, kuria galima ištirti gyvybei pavojingus širdies veiklos sutrikimus, tokius kaip širdies aritmija ar širdies nepakankamumas. Pastebėta, kad prieširdžių aritmija ir širdies nepakankamumas yra glaudžiai susijusios ligos, viena liga daro įtaką kitos atsiradimui, o turint abi diagnozes padidėja mirtingumo tikimybė. Norint išvengti staigaus širdies nepakankamumo, būtina laiku diagnozuoti šias ligas. Šiame darbe taikomi du skirtingi metodai, skirti širdies aritmijai, širdies nepakankamumui ir sveikų žmonių normaliam sinusiniam ritmui klasifikuoti naudojant EKG fragmentus. Pirmas naudotas metodas naudoja rankiniu būdu sukurtą požymių modelį, pagal kurį iš EKG fragmentų yra išgaunama daug tiesinių ir netiesinių požymių. Tiesiniai požymiai fiksuoja kintamumo laike ir taškų padėties elektrokardiogramoje informaciją, o netiesiniai požymiai padeda išskirti sudėtingumą ir kiekybiškai įvertinti nestacionaraus signalo neapibrėžtumą. Antrame metode taikomas požymių mokymusi pagrįstas metodas, jame naudojamas iš anksto išmokytas gilus mokymosi tinklas, siekiant automatiškai iš pasikartojančių laike elektrokardiogramos segmentų išgauti atitinkamus klasifikacijos rezultatus. Buvo ištirti ir sujungti abu metodai, siekiant ištirti jų efektyvumą širdies nepakankamumo bei širdies aritmijos ligoms diagnozuoti. Be to, šiame tyrime panaudota nauja subjekto lygmens EKG klasifikacija. Patys duomenys buvo paimti iš „Physionet“ duomenų bazės ir su jais pasiūlyta kombinuota dviejų metodų sistema, pasiekti rezultatai: pasiektas tikslumas yra 99,06 %, jautrumas – 99,14 %, specifiškumas – 99,68 % pakartotinių mokymų tikslumas – 99,32 % [9].

V. Jahmunah‘as, E.Y.K. Ng, Tan Ru San, U. Rajendra Acharya atlikto tyrimo apžvalgoje aptarė automatinę vainikinių arterijų ligos, miokardo infarkto ir širdies nepakankamumo nustatymą naudojant neuroninių tinklų bei *GaborCNN* modelius mokytus EKG signalais [10, 11, 28]. Nagrinėti šias ligas yra svarbu, kadangi širdies ir kraujagyslių ligos yra pagrindinės mirties priežastys visame pasaulyje. Laiku diagnozuoti ir gydyti širdies ligas yra labai svarbu, kad būtų sumažintos komplikacijos. Elektrokardiogramos (EKG) signalai yra dažniausiai naudojami kaip diagnostinė priemonė širdies ligoms nustatyti, todėl ir buvo naudojami tyrime. Sukurtas modelis skirtas elektrokardiogramos signalus klasifikuoti į sveikus, turinčius vainikinių arterijų ligą, miokardo

infarktą ir širdies nepakankamumą klases, naudojant sąsūkų neuroninio tinklo (CNN) ir *GaborCNN* modelius. Nesubalansuotam duomenų rinkiniui subalansuoti buvo naudojamas svorių balansavimas. Neuroninių tinklų modeliu buvo gauti rezultatai: tikslumas – 99,55 %, specifiškumas – 99,67 % ir jautrumas – 99,27 %. *GaborCNN* metodu buvo gauti rezultatai: tikslumas – 98,74 %, jautrumas – 99,46 % ir specifiškumas – 98,74 %. Abu modeliai davė gerus rezultatus, tačiau *GaborCNN* modelis yra priimtinesnis dėl aukštų rezultatų ir mažesnio skaičiavimo sudėtingumo, palyginti su CNN modeliu. Tai pirmasis tyrimas, kuriame siūlomas *GaborCNN* modelis, skirtas atlikti sveikų, koronarinės arterijos ligos, miokardo infarkto ir stazinio širdies nepakankamumo klasių klasifikavimą naudojant EKG signalus. Minėtus metodus siūloma ištirti naudojant didesnę duomenų bazę. Pasiūlyti metodai gali padėti gydytojams atlikti širdies ir kraujagyslių ligų patikrą naudojant EKG signalus [10].

Ahmed'as S. Eltrass'as, Mazhar'as B. Tayel'is, Abeer'as I. Ammar'as tyrimo apžvalgoje aptarė naują automatizuotą CNN gilaus mokymosi metodą EKG širdies nepakankamumo ir širdies aritmijos identifikavimui, naudojant pastovią Q nestacionarią Gaboro transformaciją [11]. Elektrokardiograma (EKG) yra svarbus diagnostikos metodas įvairių rūšių širdies ligoms interpretuoti ir identifikuoti. Šiame darbe siūlomas naujas giluminio mokymosi metodas, skirtas širdies nepakankamumo ir aritmijos identifikavimui, su mažais skaičiavimo ištekliais bei duodantis aukštą tikslumą. Šiame tyrime pirmą kartą pristatomas naujas EKG diagnostikos algoritmas, kuris sujungia sąsūkų neuroninį tinklą su pastoviu Q nestacionariu Gaboro transformavimu (CQ-NSGT). Ištirtas CQ-NSGT algoritmas, siekiant transformuoti 1D EKG signalą į 2D signalų dažnio paveikslėlį laike, kuris perduodamas į iš anksto paruoštą neuroninių tinklų modelį (CNN). Išskirtos funkcijos naudojant *AlexNet* architektūrą išskiriamos kaip pagrindinės funkcijos, kurias naudojant daugiasluoksnių perceptronų tinklų (MLP) metodą galima atskirti skirtingas, sveikųjų, širdies aritmijos bei širdies nepakankamumo klases. Siūlomo neuroninio tinklo našumas kartu su CQ-NSGT lyginant su neuroninio tinklo modeliu kartu su bangelių transformacija, atskleidžia CQ-NSGT algoritmo efektyvumą. Modelis mokytas EKG duomenimis parodo, kad jo tikslumas didesnis nei kiti metodai. Gaunami rezultatai: tikslumas – 98,8 %, jautrumas – 98,87 %, specifiškumas – 99,21 % ir tikslumas – 99,20 %. Tai parodo pasiūlyto metodo pranašumą EKG diagnostikoje [11].

R.K. Tripathy, Mario R.A. Paternina, Juan'as G. Arrieta straipsnyje nagrinėjo širdies nepakankamumo nustatymą pagal elektrokardiogramos signalus, naudodami Stockwell'o transformaciją ir hibridinę klasifikavimo schemą [12]. Širdies nepakankamumas yra gyvybei pavojinga širdies liga, kuri atsiranda, kai širdies siurbimo veikla yra mažesnė nei įprastai. Šiame straipsnyje siūlomas naujas būdas, kaip sukurti klasifikatoriais pagrįstą sistemą, skirtą automatiniam širdies nepakankamumo nustatymui. Šis metodas pagrįstas Stockwell'o transformacijos ir dažnio dalijimo taikymu, kad būtų galima analizuoti laiko ir dažnio matricas, gaunamas iš elektrokardiogramos (EKG) signalų. Tada pagal EKG subjektines matricas įvertinamos entropijos savybės. Siekiant aptikti širdies nepakankamumą, taikoma hibridinė klasifikavimo schema, kurioje atsižvelgiama į reto vaizdavimo klasifikatorių ir atstumų nuo artimiausių kaimynų vidurkį. Metodo efektyvumui nustatyti naudojami širdies nepakankamumą turinčių tiriamųjų EKG signalai ir normalaus sinusinio ritmo signalai iš viešai prieinamų duomenų bazių. Rezultatai rodo, kad siūloma sistema sėkmingai aptinka širdies nepakankamumo ligą, o jos tikslumas, jautrumas ir specifiškumas yra atitinkamai 98,78 %, 98,48 % ir 99,09 %. Taip pat atliktas palyginimas su esamais širdies nepakankamumo nustatymo metodais. EKG signalo laiko ir dažnio entropijos požymiai dažnių diapazone nuo 11 Hz iki 30 Hz pasižymi didesniu efektyvumu nustatant širdies nepakankamumą

naudojant hibridinį klasifikatorių. Šis metodas gali būti naudojamas automatizuotam šio ligos nustatymui nuotolinės sveikatos priežiūros stebėjimo sistemose [12].

Vidya K. Sudarshan'as, U. Rajendra Acharya, Shu Lih Oh straipsnyje aprašė širdies nepakankamumo diagnostiką naudojant dviejų medžių kompleksinę bangų transformaciją ir statistinius požymius, išskirtus iš 2 sekundžių trukmės EKG signalų [13, 15]. Elektrokardiogramos kritinių signalo požymių nustatymas yra labai svarbus prognozuojant širdies nepakankamumą. EKG signalo analizė, atliekama taikant kompiuterizuotus metodus, gali pagreitinti diagnozavimo procesą ir padėti tinkamai gydyti širdies nepakankamumu sergančius pacientus. Todėl šiame darbe siūloma dvigubo medžio kompleksinė bangų transformacija (angl. *dual tree complex wavelets transform*) pagrįsta metodika, skirta automatizuotai atpažinti EKG signalus, turinčius širdies nepakankamumą, iš normalių signalų. Eksperimente atliktas 2 sekundžių trukmės EKG segmentų pakėlimas iki šešių lygių DTCWT, kad būtų gaunami koeficientai. Iš šių DTCWT koeficientų išgauti statistiniai požymiai ir suranguoti taikant *Bhattacharyya*, entropijos, mažiausio pertekliaus didžiausios svarbos (mRMR), imtuvo operacinių charakteristikų (ROC), *Wilcoxon*, *t-testo* ir *reljefoF* metodus. Išreitinguotiems požymiams taikomi artimiausio kaimyno (KNN) ir sprendimų medžio (DT) klasifikatoriai, kad būtų galima automatizuotai atskirti širdies nepakankamumo nuo sveikų EKG signalų. Naudojant 45 požymius buvo pasiektas 99,86 % tikslumas, 99,78 % jautrumas ir 99,94 % specifiškumas, nustatant širdies nepakankamumo paveiktus EKG signalus. Siūlomas metodas gali tiksliai aptikti sergančius pacientus, naudojant tik 2 s trukmės EKG signalą, todėl tai padeda gydytojams sutaupyti laiko ir toliau tirti širdies nepakankamumo sunkumo laipsnį ir gydymo būdus [13].

Ankit'as A. Bhurane, Manish'as Sharma, Ru San-Tan'as straipsnyje aprašė efektyvų stazinio širdies nepakankamumo aptikimą naudojant dažnių lokalizuotus filtrų bankus (angl. *frequency localized filter banks*) diagnozei pagal EKG signalus [14]. Širdies nepakankamumo diagnozė dažniausiai nustatoma remiantis klinikinių simptomų, požymių, vaizdinių tyrimų rezultatų vertinimu ir invaziniu intrakardinio spaudimo matavimu. Elektrokardiograma (EKG) yra specifinis tyrimas širdies nepakankamumui diagnozuoti, o EKG signalo analizė, siekiant nustatyti galimą ligą, reikalauja daug rankų darbo ir atitinkamų įgūdžių bei patirties, kad būtų galima išvelgti subtilius širdies veiklos sutrikimus, kurie gali būti susiję su širdies nepakankamumu. Iškelta hipotezė bei tikslas, kad atpažinus EKG signalo nukrypimus, kurie gali atsirasti sergant širdies nepakankamumu, galima pagreitinti ir optimizuoti diagnozę naudojant mašininį mokymąsi. Pasiūlytas metodas buvo išbandytas su keturiais skirtingais normalių ir širdies nepakankamumo EKG signalų rinkiniais, gautais iš viešai prieinamų duomenų bazių. Eksperimentai atlikti naudojant trumpus (2 sekundžių trukmės) EKG segmentus. Penki skirtingi požymiai (neraiški entropija, Renyi entropija, Higuchi fraktalinis matmuo, Kraskovo entropija ir energija) buvo išskirti iš EKG segmentų banginės dekompozicijos, naudojant dažnių lokalizacijos filtrų bankus. Mokymui ir klasifikavimui, naudojama kvadratinė atraminių vektorių mašina (QSVM). Vertinimui naudotas 10-ies kartų kryžminės validacijos metodas. Pasiiekti rezultatai: tikslumas – 99,66 %, jautrumas – 99,82 %, o specifiškumas – 99,28 % visiems keturiems duomenų rinkiniams [14].

Rashidah'as Funke Olanrewaju, S. Noorjannah'as Ibrahim'as, Ani Liza Asnawi straipsnyje aprašė EKG signalų klasifikavimą širdies aritmijai ir širdies nepakankamumui nustatyti remiantis tolydžiąją bangelių transformacija ir dirbtiniais neuroniniais tinklais [15]. Pasaulio sveikatos organizacijos (PSO) ataskaitos duomenimis, kasmet dėl širdies ir kraujagyslių ligų žūsta apie 17,9 mln. žmonių, tai yra pagrindinė mirties priežastis. 80 proc. širdies ir kraujagyslių ligų atvejų sudaro širdies priepuoliai ir insultai. Šiame darbe stengiamasi tiksliai prognozuoti įprastas širdies ligas, tokias kaip aritmija ir

širdies nepakankamumas, kartu su normaliu sinusiniu ritmu, remiantis integruotu modeliu, sukurtu naudojant tolydžiujų bangelių transformaciją ir dirbtinius neuroninius tinklus. Šiame tyrime pasiūlytas metodas analizuoja elektrokardiogramos (EKG) signalo laiko ir dažnio ypatybes, pirmiausia 1D EKG signalus konvertuojant į 2D skalogramos vaizdus, o vėliau 2D vaizdai naudojami kaip įvestis dirbtinio neuroninio tinklo modelį *AlexNet*. EKG signalai į 2D vaizdus konvertuojami dėl to, kad *AlexNet* mokymo tikslais giluminius požymius lengviau išgauti iš vaizdų, o ne iš neapdorotų duomenų. Šiam tyrimui naudotas duomenų rinkinys buvo gautas iš Masačusetso technologijos instituto „Bostono Beth Israel“ ligoninės (MIT-BIH) aritmijų duomenų bazės, MIT-BIH normalaus sinusinio ritmo duomenų bazės ir „Beth Israel Deaconess“ medicinos centro (BIDMC) stazinio širdies nepakankamumo duomenų bazės. Šiame darbe nustatyti geriausiai tinkantys *AlexNet* modelio parametrai, kuriuos naudojant galima efektyviai prognozuoti dažniausiai pasitaikančias širdies ligas 98,7 % tikslumu. Pasiękti klasifikavimo tikslumai: širdies aritmijos prognozavimui 98 % (2 % duomenų buvo suklasifikuoti kaip normalus sinusinis ritmas), 98 % tikslumu buvo prognozuojama širdies nepakankamumo klasė, o 100 % tikslumu normalaus sinusinio ritmo klasė. Šis darbas taip pat lyginamas su naujausiais EKG klasifikavimo tyrimais, atliktais širdies ligoms nustatyti, ir įrodo, kad tai yra veiksmingas klasifikavimo metodas [15].

Evanthia E.Tripoliti, G. Papadopou, Georgia S. Karanasiou straipsnyje aprašė širdies nepakankamumu sergančių „New York Heart“ asociacijos pacientų įvertinimą, remiantis mašininio mokymosi metodais. Šio darbo tikslas – pristatyti automatizuotą metodą, skirtą širdies nepakankamumo NYHA klasės pasikeitimo nustatymui pacientams, sergantiems širdies nepakankamumu, taikant klasifikavimo metodus. Siūlomas metodas sudarytas iš trijų pagrindinių etapų: duomenų apdorojimo, požymių atrankos ir klasifikavimo. Širdies nepakankamumo lygio įvertinimas pagal NYHA klasę nagrinėjamas sudarant 3 klases: antro lygio, trečio lygio ir ketvirto lygio. Buvo išskirti 76 požymiai iš kurių buvo atrinkta 11, toliau šie požymiai naudojami algoritmams mokytis, siekiant kokybiškai atskirti tris širdies nepakankamumo klases. Atliekamas mašininis mokymas pasitelkiant atraminių vektorių mašinos, neuroninių tinklų, atsitiktinių medžių, atsitiktinių miškų ir genetinių algoritmais. Siūlomas metodas mokomas ir testuojamas su 378 pacientų duomenų rinkiniu, taikant 10-ies kartų kryžminę validaciją. Didžiausias pasiektas tikslumas yra 97 % antro lygio širdies nepakankamumo klasei, 87 % trečio lygio ir 67 % ketvirto lygio [16].

Kwon‘as J, Jo Y ir Lee S straipsnyje aprašė išmaniųjų laikrodžių (Galaxy Watch Active ir Apple Watch 6) EKG signalo patobulinimą, širdies nepakankamumui nustatyti. Sukurtas dirbtinio intelekto pagrindu veikiantis EKG išgavimas naudojant išmanųjį laikrodį, siekiant aptikti širdies nepakankamumo požymius, apie tai informuojant laikrodžio nešiotojus [17, 29]. Mokymo ir testavimo imtims naudojami 2 ligoninių duomenys, kurios straipsnyje užkoduotos raidėmis A ir B. Dirbtinis intelektas įgyvendintas 2 etapais: pirmiausia buvo sukurtas AI modelis (EKG2T), kuris 2 derivacijų EKG duomenis paverstų 10 derivacijų EKG ir taip gautume 12 derivacijų EKG. EKG2T, tai gilus mokymosi modelis, pagrįstas GAN (angl. *Generative adversarial network*) architektūra, kuris išmokytus EKG verčia į informacinius EKG ir taip mokydamas. Šiai dirbtinio intelekto modelio daliai naudojami A ligoninės vyresnių nei 18-os metų pacientų EKG duomenys. Antra dirbtinio intelekto modelio dalis, skirta HFrEF nustatymui naudojant 10 sekundžių trukmės 12-os derivacijų EKG. Šios dalies modelio pagrindas – sąsūkų neuroninis tinklas. Buvo naudojami pacientų duomenys, kuriems per paskutines 14 dienų buvo atlikta echokardiografija. Testavimo imčiai naudojami suaugusiųjų pacientų duomenys iš B ligoninės, kurie tą pačią dieną turėjo 2 derivacijų išmaniojo laikrodžio ir echokardiografijos tyrimus. Gauti rezultatai: DI jautrumas, specifiškumas,

teigiama prognostinė vertė ir neigiama prognostinė vertė buvo atitinkamai 0,897, 0,860, 0,258 ir 0,994. Išvados: Išmanusis laikrodis su dirbtiniu intelektu gali nustatyti širdies nepakankamumą su pakankamu efektyvumu [17].

Cinar'as A, Tuncer'as S straipsnyje apraše normalaus sinusinio ritmo, širdies aritmijos ir širdies nepakankamumo EKG signalų klasifikavimą, naudojant LSTM (angl. *Long Short Term Memory*) ir hibridinius *CNN-SVM* giliuosius neuroninius tinklus. Pastarąjį dešimtmetį klasifikavimo ir ligų prognozavimo svarba pagal EKG signalus padidėjo tiek pacientams, tiek gydytojams. Šiame straipsnyje pateikta gilaus mokymosi architektūra pasižymi dideliu tikslumu EKG signalų klasifikavimui į normalaus sinusinio ritmo, širdies aritmijos bei širdies nepakankamumo klases. Siūloma architektūra pagrįsta hibridine atraminių vektorių mašina *Alexnet-SVM*. Iš viso 192 EKG signaluose yra 96 širdies aritmijos, 30 širdies nepakankamumo, 36 normalaus sinusinio ritmo signalai. Pirmiausia šie signalai klasifikuojami atraminių vektorių mašinos KNN algoritmu, pasiekiant 68,75 % ir 65,63 % tikslumus. Tuomet neapdoroti signalai klasifikuojami LSTM, taip pasiekiamas 90,67 % tikslumas. Tuomet gaunamos signalų spektrogramos, vaizdams taikomas hibridinis *Alexnet-SVM* algoritmas ir gaunamas 96,77 % tikslumas. Rezultatai rodo, kad taikant siūlomą giliojo mokymosi architektūrą, EKG signalai klasifikuojami tiksliau nei įprastiniai mašininio mokymosi klasifikatoriai [18].

Grun'as D, Rudolfas F, Gumpfer'as N straipsnyje aprašė širdies nepakankamumo nustatymą pagal EKG duomenis naudojant dirbtinį intelektą – metaanalizę. Elektrokardiografija yra greitas ir pasiekiamas metodas, norint diagnozuoti įvairias širdies ligas, tuo pačiu ir širdies nepakankamumą. Dirbtinis intelektas gali būti naudojamas pusiau automatinei EKG analizei. Atlikto tyrimas tikslas yra apžvelgti dirbtinio intelekto naudojimą nustatant širdies nepakankamumą iš EKG signalų ir atlikti metaanalizę. Paieška apie dirbtinį intelektą atlikta „PubMed“ ir „Google Scholar“ duomenų bazėse, kuriose ieškota straipsnių, susijusių su dirbtinio intelekto galimybėmis prognozuoti širdies nepakankamumą pagal EKG signalus. Apžvalgoje naudojami tik straipsniai, paskelbti recenzuojamuose žurnaluose. Iš viso rastos 5 ataskaitos, apimančios 57027 pacientus ir 579134 EKG duomenų rinkinius. Dirbtinio intelekto nustatyti širdies nepakankamumo nustatymo EKG tikslumai buvo nuo 0,92 iki 0,99. Taikant atsitiktinių efektų modelį apskaičiuotas tikslumas 0,987. Naudojant kontingencijos lenteles, diagnostiniai santykiai svyravo nuo 3,44 (95 % pasikliautinis intervalas (PI) = 3,12-3,76) iki 13,61 (95 % PI = 13,14–14,08). Metaanalizės diagnostinis tikimybių santykis 7,59 (95 % PI = 5,85–9,34). Atsižvelgiant į atliktą analizę galima patvirtinti DI gebėjimą prognozuoti ŠN iš standartinių 12-os derivacijų EKG signalų [19].

Acharya U, Fujita H, Oh S straipsnyje aprašė gilaus sąsūkų neuroninio tinklo modelį automatinei širdies nepakankamumo diagnozei nustatyti iš EKG signalų [20, 22, 28]. Nagrinėjant EKG signalus vizualiniu vaizdu dažnai pasitaiko klaidų dėl mažos EKG signalų amplitudės ar trukmės, todėl yra sunkiau diagnozuoti širdies nepakankamumą. Automatizuota sistema gali padidinti EKG signalų diagnostikos objektyvumą ir patikimumą sergant širdies nepakankamumu. Straipsnyje pateikiama 11-os sluoksnių gilaus sąsūkų neuroninio tinklo (angl. *deep convolutional neuron network*) CNN modelį, skirtą ŠN diagnozuoti. Šiam siūlomam CNN modeliui reikia mažo pirminio EKG signalų apdorojimo, nereikia jokių inžinerinių požymių ar klasifikavimo. Siūlomam CNN modeliui išmokyti ir patvirtinti buvo naudojami keturi skirtingi duomenų rinkiniai (A, B, C ir D). Iš keturių rinkinių B rinkinys pasiekė didžiausią tikslumą - 98,97 %, specifiškumą – 99,01 % ir jautrumą – 98,87 %. Pasiūlytas CNN modelis gali būti pritaikytas praktikoje ir pasitarnauti kaip diagnostinė pagalba kardiologams, objektyviau ir greičiau interpretuojant EKG signalus [20].

Masetic Z, Subasi A straipsnyje aprašė širdies nepakankamumo nustatymą naudojant atsitiktinių miškų klasifikatorių. Šio straipsnio tikslas yra įvertinti mašininio mokymosi metodų efektyvumą kuriant modelį, kuris pagal ilgalaikes EKG laiko eilutes klasifikuotų normalų sinusinį ritmą ir širdies nepakankamumą. Tyrimo metodai atlikti dviem etapais: požymių išskyrimo ir klasifikavimo etapais. Požymių išskyrimo etape požymiams išgauti taikomas autoregresinis Burg metodas. Klasifikavimo etape nagrinėjami penki skirtingi klasifikatoriai: pasirinkimų medis (angl. *decision tree*), k artimiausio kaimyno metodas, atraminių vektorių mašina, dirbtiniai neuroniniai tinklai ir atsitiktinių miškų klasifikatorius. EKG signalai buvo paimti iš BIDMC širdies nepakankamumo ir PTB EKG diagnostikos duomenų bazių ir suklasifikuoti taikant įvairias kombinacijas. Eksperimento rezultatai įvertinti keliais statistiniais rodikliais (jautrumas, specifiškumas, tikslumas, F matas ir ROC kreivė). Nustatyta, kad atsitiktinio miško metodas užtikrina 100 % klasifikavimo tikslumą. Atliktos išvados, kad gauti tikslumai taikant atsitiktinių miškų metodą parodo, kad klasifikavimas yra tikslus ir gali būti naudojamas nustatant širdies nepakankamumą medicinoje [21].

Akbilgic'as O, Butler'as L, Karabayir'as I straipsnyje aprašė elektrokardiografinį dirbtinio intelekto modelį širdies nepakankamumui prognozuoti. Atliktame tyrime vertinamas elektrokardiogramos (EKG) naudingumas prognozuojant širdies nepakankamumo riziką. Naudojami aterosklerozės rizikos bendruomenėse tyrimo (ARIC) pradinių apsilankymų (1987-1989 m.) duomenys. Širdies nepakankamumo atvejai buvo nustatyti pagal TLK kodus. Į tyrimą buvo įtraukti dalyviai, kurių EKG buvo geros kokybės, o dalyviai, kuriems buvo paplitęs ŠN nebuvo įtraukti. EKG dirbtinio intelekto modelis, skirtas širdies nepakankamumui prognozuoti, buvo sukurtas kaip gilus liekamosios vertės sąsūkų neuroninis tinklas, naudojant standartinę 12-os derivacijų EKG. Iš viso tyrime dalyvavo 14 613 (45 % vyrų, vidutinis amžius 54 ± 5) dalyvių. Iš viso 803 (5,5 %) dalyviams per 10 metų nuo pradinio tyrimo pradžios išsivystė širdies nepakankamumas. Sąsūkų neuroninis tinklas, naudojantis tik EKG, pasiekė 0,756 (0,717-0,795) AUC pagal testavimo duomenis. ARIC ir Framinghamo širdies tyrimo ŠN rizikos skaičiuoklių AUC buvo 0,802 (0,750-0,850) ir 0,780 (0,740-0,830). Didžiausia AUC 0,818 (0,778-0,859) buvo gauta, kai EKG-DI modelio išvestis, amžius, lytis, rasė, kūno masės indeksas, rūkymo statusas, išeminė širdies liga, cukrinis diabetas, sistolinis kraujospūdis ir širdies susitraukimų dažnis buvo naudojami kaip ŠN prognozės rodikliai. EKG-DI modelio išvestis buvo svarbiausias širdies nepakankamumui prognozuojantis veiksnys. Gautos išvados, kad EKG-DI modelis, paremtas tik iš EKG gauta informacija, savarankiškai prognozuoja ŠN, o jo tikslumas prilygsta esamų Framinghamo ir ARIC rizikos skaičiuoklių tikslumui [22].

Geweid'as G, Abdallah'as M straipsnyje aprašė automatinį širdies nepakankamumo identifikacijos metodą, naudojant patobulintą atraminių vektorių mašiną, pagrįstą dualumo optimizavimo metodu [23, 26]. Širdies nepakankamumo ligos nustatymo iš EKG signalų procesu siekiama sutrumpinti širdies nepakankamumu sergančių pacientų diagnostikos laiką ir pagerinti diagnozės tikslumą. EKG signalo segmentavimo problema yra sudėtinga dėl kelių EKG signalų laiko intervalo ir amplitudės panašumo bei triukšmo EKG signaluose. Šiame straipsnyje siūlomas naujas identifikavimo metodas, padedantis pašalinti dabartines problemas, tokias kaip širdies ritmo trukmės persidengimas laiko intervale nuo vienos PQRST bangos iki kitos. Aprašomas hibridinis dvigubo SVM ir neparimetrinio algoritmo metodas, skirtas širdies aritmijai pastebėti iš EKG signalų, dėl kurio padidėja patikimumas ir tikslumas nustatant ir diagnozuojant širdies nepakankamumo klases ankstyvosiose stadijose. Toks neparimetrinis algoritmas skirtas algoritmui mokyti, su tikslu gauti du SVM modelius. Dviguba problema suteikia kitokią perspektyvą, kuri yra geresnė ir kartais paprastesnė už pradinę problemą. Ši funkcija naudojama širdies nepakankamumo ligai EKG signaluose aptikti, lyginant SVM modelio

ir dvigubo SVM modelio išvestis. Eksperimentai rodo, kad hibridinis metodas duoda gerų rezultatų, yra efektyvesnis ir padidina širdies nepakankamumo ligos aptikimo tikslumą iki 94,97 %. Modelis geriausiai prognozuoja diagnozes tiems pacientams, kurie serga keliomis ligomis ir kuriems iš pradžių nebuvo nustatytas širdies nepakankamumas [23].

Li D, Tao Y, Zhao J straipsnyje aprašė širdies nepakankamumo klasifikavimą pagal EKG segmentus, naudojant daugialypį likutinį tinklą. Nustačius širdies nepakankamumo diagnozę, klinikiniai specialistai turi laiku įvertinti ŠN klasę. Įrodyta, kad elektrokardiogramos (EKG) signalai yra naudingi vertinant širdies nepakankamumo klasę. Kadangi EKG sutrikimai yra subtilūs, gydytojams sunku nustatyti EKG skirtumus tarp klasių. Siekiant padėti gydytojams nustatyti tikslią diagnozę, pasiūlytas *ResNet* modelis, skirtas automatiškai klasifikuoti ŠN į keturias kategorijas pagal Niujorko širdies asociacijos (NYHA) funkcinės klasifikacijos sistemą. Be to, siekiant, kad pateikti rezultatai būtų tikroviškesni, duomenų rinkiniui padalyti tarp pacientų naudota paradigma, taikytas EKG signalų segmentavimas į du skirtingus intervalus. Tyrimo rezultatai rodo, kad *ResNet-34* modelis pasiekė atitinkamai 93,49 %, 93,44 % ir 93,60 % vidutinę teigiamą prognozinę vertę, jautrumą ir tikslumą dviejų sekundžių EKG segmentams. Be to, penkių sekundžių EKG segmentų vidutinė teigiama prognozavimo vertė, jautrumas ir tikslumas atitinkamai yra 94,16 %, 93,79 % ir 94,29 %. Pasiūlytas metodas gali būti naudojamas kaip pagalbinė priemonė, padedanti gydytojams klasifikuoti širdies nepakankamumą [24].

Mašetik'as Z, Subasi A straipsnyje aprašė širdies nepakankamumo nustatymą naudojant C4.5 sprendimų medžio algoritmą. Šio tyrimo tikslas įvertinti C4.5 sprendimų medžio metodo efektyvumą, kuriant modelį, kuris pagal ilgalaikes EKG laiko eilutes nustatytų ir atskirtų normalų sinusinį ritmą nuo širdies nepakankamumo (ŠN). Tyrimas atliktas dviem etapais: požymių išskyrimu, naudojant autoregresijos (AR) modulį ir klasifikavimu taikant C4.5 sprendimų medžio metodą. EKG signalai buvo gauti iš BIDMC širdies nepakankamumo duomenų bazės ir suklasifikuoti, nustatant metodo parametrus bandymo būdu. Tyrimo rezultatai parodė, kad C4.5 sprendimų medžio metodo pasiektas tikslumas yra 99,86 % , jautrumas – 99,77 %, specifiškumas – 99,93 %. Metodas turi potencialą prognozuoti širdies nepakankamumą [25].

Saeed'as S, Yousif'as R straipsnyje aprašė Slantleto (angl. *Slantlet*) transformacija pagrįstą statistinių požymių išskyrimą normaliam sinusiniui ritmui, širdies aritmijai ir širdies nepakankamumui elektrokardiogramoje klasifikuoti. Kompiuterizuoto projektavimo CAD sistema gali suteikti gydytojams informaciją apie galimą paciento širdies ligos diagnozę (širdies aritmiją ar širdies nepakankamumą) iš elektrokardiogramos signalų. Šiame darbe iš MIT-BIH ARR duomenų bazės paimti 900 EKG segmentai, proporcingai 3 anksčiau minėtoms klasėms. Išskirtos ir atrinktos naujos Slantleto transformacijos statistinės savybės, skirtos širdies ligoms klasifikuoti pagal EKG signalus. Remiantis Slantleto pranašumu lokalizuoti laiką, palyginti su tradicine bangeline transformacija, 12 iš 14 statistinių požymių sėkmingai išlaikė ANOVA testą, kurio p reikšmė 10⁻³. Po to atitinkami požymiai pateikti trims gerai žinomiems klasifikatoriams (atraminių vektorių mašinai, k-artimiausio kaimyno ir naiviajam Bajeso). Testai parodė, kad galima pasiekti 99,254 % klasifikavimo AUC vidurkį naudojant Slantleto transformacija pagrįstus požymius kartu su SVM klasifikatoriumi, kuris yra susijęs su prižiūrimojo mašininio mokymosi algoritmu, naudojamu regresijai ir klasifikavimui, pasižymintis dideliu apibendrinimo gebėjimu. Jis atlieka dviejų grupių problemų klasifikavimą. SVM klasifikatorius nustato geriausią hiperplokštumą, kuri atskiria kiekvieną teigiamą ir neigiamą mokymo segmentą [26].

Zhang'as Y, Xia M straipsnyje aprašė gilaus neuroninio tinklo taikymą širdies nepakankamumui nustatyti, naudojant EKG signalus. Šiame straipsnyje, remiamasi kompiuterinės *DenseNet* versijos idėjos, ji patobulinta taip, kad būtų galima pritaikyti širdies nepakankamumo aptikimo užduočiai, taip pagerinant modelio diagnostikos tikslumą. Siekiant pagerinti algoritmo patikimumą, sukurta širdies nepakankamumo duomenų bazė, naudojant *PhysioBank* duomenis, kurioje buvo daugiau įvairių duomenų, lyginant su panašiais tyrimais. Atliktos įvairios treniravimo variacijos su sukurta duomenų baze. Galiausiai pateiktas vertinimo metodas, pagrįstas pacientų sumaišymo modeliu, kad būtų objektyviau įvertintas metodo veiksmingumas. Rezultatai rodo, kad toks algoritmas gali veiksmingai nustatyti širdies nepakankamumą, o jo tikslumas, jautrumas ir specifiškumas atitinkamai yra 94,97 %, 89,38 % ir 99,5 %. Šiame tyrime pasiūlytas algoritmas gali suteikti patikimų įžvalgų gydytojams ir gali būti naudojamas nešiojamuosiuose prietaisuose, kad būtų galima vykdyti pacientų stebėseną realiu laiku [27].

Porumb'as M, Iadanza E, Massaro S straipsnyje aprašė sąsukų neuroninio tinklo metodą širdies nepakankamumui nustatyti. Nepaisant to, kad naujausiuose moksliniuose tyrimuose pateikiami metodai, orientuoti į pažangų signalų apdorojimą ir mašininį mokymąsi, iki šiol iš esmės nebuvo atsižvelgta į sąsukų neuroninių tinklų (CNN) metodų taikymo galimybes automatiniam širdies nepakankamumo nustatymui. Šiame tyrime ši svarbi dalis sprendžiama pateikiant CNN modelį, kuris tiksliai nustato ŠN tik pagal vieną neapdorotą elektrokardiogramos (EKG) širdies dūžį, taip pat sugretinant esamus metodus, pagrįstus širdies ritmo kintamumu. Modelis mokomas ir testuojamas viešai prieinamuose EKG duomenų rinkiniuose, kuriuos iš viso sudaro 490 505 širdies dūžiai. Pasiektas 100 % širdies nepakankamumo nustatymo tikslumas. Svarbu tai, kad modelis taip pat nustato tas širdies ritmo sekas ir EKG morfologines charakteristikas, kurios skiria klases ir todėl yra svarbios nustatant ŠN. Apskritai, šis tyrimas patobulina dabartinę širdies nepakankamumo nustatymo metodiką ir patenkina klinikinių praktikų poreikius, nes suteikia tikslią ir visiškai aiškią priemonę, padedančią priimti sprendimus dėl ŠN nustatymo [28].

Koole M, Kauw D, Winter'as M straipsnyje aprašė sveikatos nuotolinio stebėjimo galimybės mobiliąją versiją suaugusiems pacientams, sergantiems įgimtomis širdies ligomis (ŠL). Aritmijos ir širdies nepakankamumas yra dažnos diagnozės suaugusiems pacientams, sergantiems įgimtomis širdies ligomis. Mobilioji sveikata (m-sveikata) suteikia galimybę kasdien stebėti ir laiku reaguoti į būklės pablogėjimo rodiklius. Pateikiamas stebėjimo perspektyvinis registras, kuriuo siekiama įvertinti "m-sveikatos" nuotolinio stebėjimo programos, skirtos aritmijos, širdies nepakankamumo ir kraujospūdžio valdymui suaugusiems asmenims, sergantiems širdies ligomis, pagrįstumą. Simptomiški suaugę pacientai, sergantys ŠL, įtraukiami į m-sveikatos nuotolinio stebėjimo programą, kurioje vertinama vienos derivacijos EKG, kraujospūdis ir svoris. Esant simptomams, gali būti atliekami papildomi matavimai. Duomenys renkami suderintosioms mobiliosiomis programėlėmis. Su pacientais susisiekiama, jei viršijami rodikliai arba nustatoma aritmija, kad būtų pakoreguotas gydymas arba paneigiami pastebėti rodikliai. Gyvenimo kokybei ir savireguliacijai įvertinti naudojami duomenys apie naudojimąsi skubios pagalbos paslaugomis, hospitalizaciją ir paciento pranešamų rezultatų rodikliai. Tyrime dalyvauti buvo pakviesti 129 širdies ligomis sergantys pacientai, dalyvuti sutiko 55 pacientai. Pradiniame etape 22 pacientams buvo nustatyta didesnė arba lygi II širdies nepakankamumo klasei, 43 pacientai turėjo širdies aritmijas, 8 pacientai sirgo hipertenzija. Vidutinis stebėjimo laikotarpis – 3 mėnesiai, vienas pacientas nutraukė gydymą, o galutinis dalyvių išitraukimas – 97 % [29].

Krishnakumar'as S, Yasodha. M, Veronica Priyadharshini. J straipsnyje aprašė aritmijos ir širdies nepakankamumo nustatymą, klasifikuojant EKG signalus su gilaus mokymosi neuroniniu tinklu. Pripažįstama, kad dėl individualaus širdies ritmo kintamumo ir būdingo triukšmo tiksliai nustatyti širdies ir kraujagyslių ligas yra sudėtinga užduotis net ir specialistams. Dabartinis priežiūros standartas, tai vizualinis EKG tyrimas. Siekiant įveikti EKG rodmenų trūkumus, buvo sukurti kompiuterinės diagnostikos metodai. Šiame tyrime naudojami modifikuoti gilaus mokymosi neuroniniai tinklai, skirti EKG signalams klasifikuoti į tris kategorijas: aritmiją, širdies nepakankamumą ir normalų sinusinį ritmą. Šiame darbe naudojami neuroniniai tinklai *AlexNet* ir *GoogLeNet*. EKG signalai surenkami iš internetinių šaltinių ir konvertuojami į skalogramą. Skalogramos vaizdai padalijami į mokymo ir testavimo duomenų rinkinius santykiu 8:2. Tuomet mokymo duomenų aibė mokoma naudojant abu neuroninius tinklus. Abiejų architektūrų atliktų prognozių tikslumas apskaičiuojamas naudojant sumaišymo matricą. Tarp šių dviejų tinklų *GoogLeNet* buvo pranašesnis už *AlexNet*, jo tikslumas siekė 96,88 %. Remiantis gautais rezultatais, *GoogLeNet* architektūra yra tikslesnis būdas širdies aritmijai ir širdies nepakankamumui nustatyti [30].

Guler'as I, Ubeyli E straipsnyje aprašė EKG širdies ritmo klasifikatorių, sukurtą naudojant kombinuotą neuroninio tinklo modelį. Šiame straipsnyje parodoma, kaip naudojant kombinuotą neuronų tinklo modelį parenkamas modelis elektrokardiogramos (EKG) dūžiams klasifikuoti. EKG signalai buvo išskaidyti į dažnio reprezentacijas laike, naudojant diskrečiąją bangelių transformaciją, o jų pasiskirstymui pavaizduoti buvo apskaičiuoti statistiniai požymiai. EKG ritmams klasifikuoti buvo įtraukti pirmojo lygio tinklai, kaip įvesties duomenis naudojant statistinius požymius. Siekiant pagerinti diagnostikos tikslumą, antrojo lygio tinklai buvo mokyti naudojant pirmojo lygio tinklų išvestis kaip įvesties duomenis. Keturių tipų EKG dūžiai (normalus dūžis, širdies nepakankamumo dūžis, skilvelinės tachiaritmijos dūžis, prieširdžių virpėjimo dūžis), gauti iš „Physiobank“ duomenų bazės, buvo suklasifikuoti 96,94 % tikslumu naudojant kombinuotą neuroninį tinklą. Jungtinio neuroninio tinklo modelis pasiekė didesnę tikslumą nei įprastas neuroninio tinklo modelis [31].

1.4. Tyrimai, kuriuose naudojami Lagranžo rodikliai

Sebastiano Raffa, Gianmario Merisio, Francesco Toppoto straipsnyje aprašė riboto judėjimo regionų paiešką dvinarių asteroidų aplinkoje, naudojant Lagranžo rodiklius. Trajektorijos projektavimas labai neramioje aplinkoje, pavyzdžiui, dvinariuose asteroiduose, yra sudėtingas uždavinys. Tam paprastai reikia naudoti realius neautonominis dinaminis modelius, kuriuose periodiniai sprendiniai, gauti autonominėse sistemose, išnyksta. Šiame straipsnyje Lagranžo rodikliai naudojami trikdomam plokščiajam dviaukščiam elipsiniam apribotam keturių kūnų uždaviniui spręsti, kad būtų galima rasti riboto judėjimo regionus per baigtinį horizontą apie Dimorfą, antrinį Didymos dvinarės sistemos kūną. Rezultatai rodo, kad Lagranžo rodikliai sėkmingai atskleidžia fazinės erdvės organizacines struktūras tiek netrikdomų, tiek trikdomų plokščiųjų dveiliptinių ribotų keturių kūnų uždavinyje. Kai nėra Saulės spinduliuotės spaudimo, vizualiai identifikuojamos riboto judėjimo sritys, taip suteikiant prieigą prie plataus ribotų orbitų apie Dimorfą pasirinkimo. Ir atvirkščiai, esant Saulės spinduliuotės slėgiui, dauguma struktūrų suyra, todėl atsiranda didelis nestabilus judėjimo regionas su retomis išimtimis. Lagranžo rodikliai skaičiavimo požiūriu nereikalauja daug išteklių, tai dinaminiai rodikliai, kuriuos būtų patogu taikyti astrodinamikoje [32].

Mantas Landauskas ir Minvydas Ragulskis straipsnyje aprašė pacientų EKG segmentų grupavimą, remiantis Lagranžo rodikliais, prieš staigią širdinę mirtį. Straipsnyje pristatomas naujas metodas EKG

segmentų klasterizavimui, pagrįstas Lagranžo rodikliais. Šis metodas pradedamas nuo 2D požymių išskyrimo naudojant Lagranžo rodiklius. Tada požymiai transformuojami į latentinius vektorius, kurie klasterizuojami naudojant k-vidurkių algoritmą. Tyrimo objektas – vizualizuoti EKG segmentų 2D požymių klasterių dinamiką pacientams prieš išstinkant staigiai širdies mirčiai. Pagrindinė šio tyrimo išvada yra ta, kad Lagranžo rodikliais grindžiamas požymių išskyrimas gali skirtingai žymėti skirtingus EKG segmentus, nors esama ir tam tikrų panašumų. Tirtu būdu išskirtų požymių sekimą būtų galima laikyti universalia priemone ar net ekspertine sistema anomalijoms aptikti kitose dinaminėse sistemose. Kad ekspertinė sistema būtų visiškai automatizuota, tereikia pažymėti klasterių centrus ir (arba) dydžius [33].

Andrėjus Junginger'as ir Rigobert'as Hernandez'as straipsnyje aprašė Lagranžo rodiklius disipatyvinėse sistemose. Nuo laiko priklausomų sistemų reakcijos dinamiką galima išspręsti naudojant nuo persikirtimo laisvą skiriamąjį paviršių, susijusį su pereinamosios būsenos trajektorija, t. y. unikalios trajektorija, kuri, reaguojant į tam tikrą nuo laiko priklausomą potencialą, visą laiką yra susieta su barjero sritimi. Bendrą procedūrą, pagrįstą Lagranžo rodiklių minimizavimu sukūrė Craven'as ir Hernandez'as, kad sukonstruotų šią konkrečią trajektoriją, nereikalaudami perturbacinių plėtinių naiviosios pereinamosios būsenos taško barjero viršuje atžvilgiu. Metodo išplėtimas, siekiant atsižvelgti į disipaciją judėjimo lygtyse, reikalauja papildomų šiame straipsnyje nustatytų aplinkybių, nes Lagranžo rodiklio apskaičiavimas apima trajektorijų integravimą pirmyn ir atgal laike. Šie du įnašai apskritai yra labai skirtingi, nes trinties narys gali veikti kaip energijos šaltinis (atbuliniu laiku) arba sugėriklis (tiesioginiu laiku), todėl gali būti prarasta informacija apie fazinės erdvės struktūrą dėl to, kad dominuoja tik vienas iš narių. Šiam poveikiui kompensuoti Lagranžo rodiklyje įvedama svorių schema ir parodoma, kad terminės Langevino dinamikos atveju ji išsaugo esmines fazinės erdvės struktūras, o nesvariųjų atveju jos prarandamos [34].

Gabrielius G. Karlas ir F. Borond'as straipsnyje aprašė Lagranžo rodiklius atviriesiems žemėlapiams. Pagrindinėms atvirų žemėlapių savybėms atskleisti pritaikoma Lagranžo rodiklių koncepcija, kuri buvo pristatyta kaip veiksmingas chaotiškų sistemų fazinės erdvės struktūrų indikatorius. Jos taikomos atviram tribakerio žemėlapiui - paradigminiam ne tik klasikinio, bet ir kvantinio chaoso pavyzdžiui. Toks apibrėžimas leidžia labai paprastai nustatyti vidinę chaotiškąją atstojamojo struktūrą, kuri yra pagrindinė invariantiška aibė, valdanti šios sistemos dinamiką. Aiškiai aptinkami šiai aibei priklausantys periodinių orbitų (PO) homoklininiai raizginiai. Tai taip pat gali turėti svarbių pasekmių chaotinei sklaidai ir kuriant atvirų sistemų trumpųjų PO pusiau klasikinę teoriją [35].

Ana M. Mancho, Stephen'as Wiggins'as, Jezabel'is Curbelo, Karolina Mendoza straipsnyje aprašė Lagranžo rodikliais paremtą, nuo laiko priklausomų dinaminė sistemų fazinės erdvės struktūrų atskleidimo metodą. Sukurti nauji metodai, skirti atskleisti geometrines struktūras fazinėje erdvėje, kurios galioja aperiodiškai nuo laiko priklausomoms dinaminėms sistemoms, vadinamoms Lagranžo rodikliais. Šie dydžiai grindžiami baigtinio laiko išilgai trajektorijų integravimu, kuris yra būdingas ribotai, teigiamai geometrinei ir (arba) fizikinei pačios trajektorijos savybei. Aptariama bendra Lagranžo rodiklių konstravimo metodika ir „euristinis argumentas“, paaiškinantis, kodėl šis metodas sėkmingai padeda atskleisti geometrines struktūras dinaminės sistemos fazinėje erdvėje. Šis argumentas pagrindžiamas aiškiais skaičiavimais, susijusiais su etaloniniu uždaviniu, turinčiu hiperbolinį fiksuotąjį tašką su stabiliais ir nestabiliais analitiškai žinomais kolektorais. Nagrinėjami keli kiti etaloniniai pavyzdžiai, leidžiantys įvertinti Lagranžo rodiklių efektyvumą, atskleidžiant invariantiškus torius ir šlyties sritį. Visame straipsnyje atliekami ir aptariami Lagranžo rodiklių efektyvumo palyginimai su baigtinio laiko Liapunovo eksponentais (FTLE) ir tam tikrų vektorių

lauko komponentų baigtiniais laiko vidurkiais. Visais atvejais Lagranžo rodikliai yra tikslesni ir skaičiavimo požiūriu efektyvesni už šiuos metodus. Taip pat atliekami skaičiavimai trimačiam, aperiodiškai nuo laiko priklausomam vektorių apibrėžtam kaip duomenų rinkinys. Šie pavyzdžiai taip pat lyginami su FTLE ir laiko vidurkiais, ir daromos panašios išvados kaip ir lyginamųjų pavyzdžių atveju [36].

Pedenon'as-Orlanducci Remi, Ana Maria Mancho, Makrina Agaoglou straipsnyje aprašė globalų dinamikos vizualizavimą pagal Lagranžo rodiklius bei pritaikymą diskrečioms ir tolydžioms sistemoms. Šiame straipsnyje pristatomas naujas visuotinės dinamikos rodiklis, pagrįstas Lagranžo rodiklių metodu, skirtas tvarkingiems ir deterministiniams chaotiškiems judesiams daugiamatėse sistemose atskirti. Pasirinktam šio metodo įgyvendinimui reikalingos žinios tik apie orbitas baigtiniuose laiko languose, nereikia skaičiuoti dinamikos tangentinio vektoriaus (t. y. nereikia variacinių lygčių). Norint parodyti, kad šis metodas padeda vizualizuoti įvairias dinamines elgsenas, ypač išryškinti chaotiškas sritis, atkuriami keli klasikinių sistemų stabilumo žemėlapiai, gauti skirtingais fazinės erdvės metodais. Etaloniniai pavyzdžiai yra susiję su diskrečiomis ir tolydžiomis beveik integruojamomis dinaminėmis sistemomis, kuriose svarbią vietą užima rezonansai. Tarp jų yra Čirikovo standartinis žemėlapis, didesnės dimensijos simplektiniai ir tūrį išsaugantys žemėlapiai, fundamentalūs rezonansų modeliai ir 3 laisvumo laipsnių beveik integruojama Hamiltono sistema su tankiu rezonansų tinklu. Taigi, rodiklis yra svarbus siekiant suprasti fazinės erdvės pernešimą, kuriam tarpininkauja rezonansai beveik integruojamose sistemose, kaip visur paplitę dangaus mechanikoje ar astrodinamikoje [37].

Francisco Balibrea-Iniesta, Carlos'as Lopesino, Stephen'as Wiggins'as, Ana M. Mancho straipsnyje aprašė stochastinių diferencialinių lygčių Lagranžo rodiklius, kaip įrankį stochastinių dinaminė sistemų faziniam portretui atskleisti. Remiantis ankstesniais darbais, skirtais deterministinėms sistemoms, pristatomas fazinės erdvės vaizdavimo apibendrinamo būdas, paremtas Lagranžo rodiklių metodu stochastinėms diferencialinėms lygtims. Analogiškai deterministinių diferencialinių lygčių aplinkoje Lagranžo rodikliai grafiškai pateikia išskirtas trajektorijas ir hiperbolines struktūras, atsirandančias stochastinėje dinamikoje, pavyzdžiui, atsitiktinius fiksuotus taškus ir jų stabilus bei nestabilus kolektočius. Analizuojama, kokia prasme struktūros sudaro kliūtis pernašai stochastinėse sistemose. Taikomas metodas keliems etaloniniams pavyzdžiams, kuriuose deterministinės fazinės erdvės struktūros yra gerai suprantamos. Visų pirma pasiūlytas metodas taikomas triukšmingam balno taškui, stochastiškai priverstinei Duffingo lygčiai ir stochastiniam dvigubam srovių modeliui, kuris yra etalonas skysčių pernašai analizuoti [38].

Montes'as, J., Revuelta, F., Borondo, F. straipsnyje aprašė Lagranžo rodiklius ir taisyklingą judėjimą. Prieš dešimtmetį aprašyti Lagranžo rodikliai tapo galingu įrankiu, leidžiančiu labai paprastai atskleisti dinaminė sistemų fazinės erdvės subtilybes. Jie buvo plačiai naudojami chaotiškam judėjimui įvairiose situacijose tirti, tačiau daug mažiau dėmesio buvo skiriama taikymams taisyklingose fazinės erdvės srityse. Šiame straipsnyje parodoma šio, neseniai sukurto, matematinio įrankio potencialą, kai juo tinkamai manipuluojant galima apskaičiuoti ir visapusiškai apibūdinti bendrinių sistemų invariantinius torius. Metodui iliustruoti pateikiamas taikymas gerai žinomam Hénon-Heileso Hamiltonianui - paradigmিনিам netiesinių mokslų pavyzdžiui. Visų pirma parodoma, kad Lagranžo rodikliai, susiję su taisyklingomis orbitomis, dalijant per integravimo laiką, svyruoja apie asimptotinę vertę, o tai leidžia apskaičiuoti dažnius, apibūdinančius invariantinius torius, kuriuose vyksta taisyklingas judėjimas [39].

Viktoras Garidas, S. Wiggins straipsnyje aprašė Lagranžo rodiklius ir klasikinės mechanikos veiksmo integralą. Šiame straipsnyje parodyta, kaip klasikinės Hamiltono mechanikos veiksmo integralas sujungiamas su Lagranžo rodiklių metodologine sistema. Veiksmu pagrįstą Lagranžo rodiklis (LD) pritaikytas standartiniams etaloniniams uždaviniams - tiesiniam balno taškui ir tiesiniam osciliatoriui, kuriems galima atlikti skaičiavimus. Veiksmu pagrįstas LD tiksliai atskleidžia hiperbolinės balno pusiausvyros stabilias ir nestabilias daugdaras, taip pat tiesinio osciliatoriaus dažnį. Taip pat nagrinėtos dviejų laisvumo laipsnių Hamiltono sistemos, kurios atsiranda cheminių reakcijų dinamikoje. Veiksmais pagrįsta LD sėkmingai atskleidė reakcijos dinamiką valdančias fazinių erdvių struktūras, t. y. nestabilią periodinę orbitą ir jos stabilias ir nestabilias daugiamates orbitas. Taip pat parodyta, kaip jį galima panaudoti Kolmogorovo-Arnoldo-Moserio toriams (t. y. kvaziperiodinėms orbitoms) šiame dviejų laisvumo laipsnių Hamiltono sistemoms atrasti. Paskutiniame pavyzdyje parodyta, kad veiksmu pagrįstą LD galima naudoti stochastinėse sistemose. Konkrečiai parodyta, kaip juos galima naudoti stochastinėms sistemoms atskleisti homoklininį susipynimą stochastiškai priverstiniame Duffingo osciliatoriuje. Pagrįsta, kad ryšys tarp veiksmo integralų ir Lagranžo rodiklių gali padėti naujai pažvelgti į globaliąją Hamiltono dinamiką. Pavyzdžiui, neseniai buvo parodyta, kad Lagranžo rodikliai gali būti naudojami siekiant suprasti neapibrėžtumą fazinės erdvės struktūrų požiūriu [40].

1.5. Literatūros apžvalgos apibendrinimas


Širdies nepakankamumas yra labai dažna liga bei pagrindinė mirties priežastis su prognozuojama augimo tendencija ateityje. Pastebima, kad širdies ligomis serga vis jaunesni žmonės, o remiantis statistiniais duomenimis Lietuva yra pirmaujanti šalis Europoje. Siekiant nustatyti širdies nepakankamumą elektrokardiografu atliekamas EKG tyrimas, po kurio kardiologas nustato diagnozę. Kadangi ŠN iš EKG įrašo pastebėti gali tik patyręs ekspertas ieškoma pagalbinių būdų, kurie gali padėti gydytojams prognozuoti širdies ligas. Vienas iš tokių būdų yra mašininis mokymas. Yra sukurta mobilioji programėlė, kurios pagalba, naudojant išmaniuosius laikrodžius, paimami dviejų derivacijų EKG signalai bei mašinio mokymo pagalba nustatoma ar reikėtų pasitikrinti savo sveikatą dėl galimos širdies ligos rizikos. Iš literatūros apžvalgos aukštas širdies ligų, įskaitant širdies nepakankamumą, naudojant EKG segmentus, tikslumas gaunamas gilių neuroninių tinklų *AlexNet*, *GoogLeNet* bei *ResNet* architektūromis, Stockwell'o transformacija, hibridiniais mašinio mokymo metodais, dažnių lokalizuotais filtrų bankais, tolydžiąją bangelių transformacija, atsitiktinių miškų, sprendinių medžių bei atraminių vektorių mašinų modeliais. Lagranžo rodikliai plačiai taikomi astrodinamikoje, atviruosiuose žemėlapiuose, dinaminėse, diskrečiose, tolydžiose bei stochastinėse sistemose ir dangaus mechanikoje. Pristatytas Lagranžo rodikliais paremtas EKG segmentų požymių išskyrimo metodas, kurio rezultatai parodė, kad toks metodas gali būti naudingas anomalijoms aptikti. Todėl tokio metodo naudojimas duomenų paruošimui yra logiškas, taip pat kaip ir aukštą klasifikavimo tikslumą pasiekiančių dirbtinių neuroninių tinklų *ResNet* ir *AlexNet* architektūrų taikymas prognozavimui. Atlikus literatūros analizę pastebėta, kad tokių Lagranžo rodiklių taikymų beveik nėra, ypačingai pritaikymo medicinos srityje, naudojant EKG įrašus, todėl tai yra šio baigiamąjo projekto naujumas ir išskirtinumas.

2. Duomenys ir tyrimo metodai

Šiame skyriuje pateikiama detali duomenų apžvalga, jų apdorojimo metodai kartu su procesų diagramomis bei formulėmis. Pateikiami naudoti metodai širdies nepakankamumo bei normalaus sinusinio ritmo klasifikavimui. Aprašomos naudotos tikslumų charakteristikos, dirbtinių neuroninių tinklų *ResNet* ir *AlexNet* architektūrų aprašymai, pateikiama tyrimo eigos schema.


2.1. Duomenų apžvalga

Tyrimo metu naudoti elektrokardiogramų signalų duomenys yra paimti iš „Physionet“ duomenų bazės svetainės. Širdies nepakankamumui tirti naudota „BIDMC širdies nepakankamumo“ duomenų bazė, kurioje yra 15-os asmenų: 11 vyrų bei 4 moterų (žr. 4 pav.), diagnozuotų 3-4 klasės širdies nepakankamumu, ilgalaikiai elektrokardiogramos įrašai [41].




4 pav. Širdies nepakankamumo duomenų bazės tiriamųjų pasiskirstymas pagal lytį

Tiriamųjų amžius yra gana įvairus. Vyrų amžiaus pasiskirstymas svyruoja nuo 22 metų iki 71 metų, o moterų nuo 54 metų iki 63 metų (žr. 5 pav.) [41].




5 pav. Širdies nepakankamumo duomenų bazės tiriamųjų pasiskirstymas pagal amžių ir lytį

Kiekvieno tiriamojo elektrokardiogramos įrašas trunka apie 20 valandų, saugomi 2 EKG signalai, tyrimui naudojami antro EKG signalo įrašai. Elektrokardiogramų dažnis yra 250 signalų per sekundę su 12 bitų skiriamąją geba. EKG įrašyti „Beth Israel“ ligoninėje Bostone (Jungtinėse Amerikos Valstijose), elektrokardiogramos duomenų pavyzdys pateikiamas 6 pav. [41].



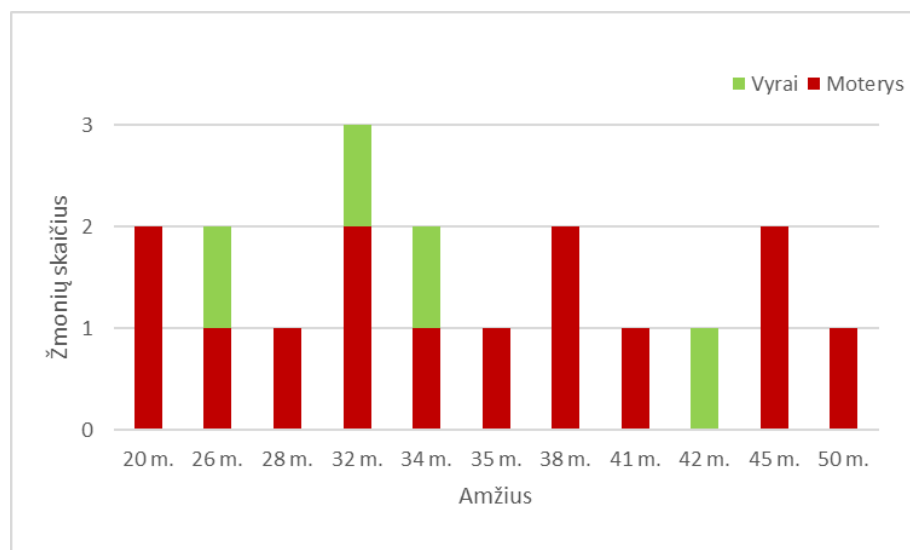
6 pav. Pirmo tiriamojo širdies nepakankamumo EKG intervalo pavyzdys

Projekte taip pat naudojami ir sveikų žmonių ilgalaikiai elektrokardiogramos įrašai, paimti iš „MIT-BIH normalaus sinusinio ritmo“ duomenų bazės „Physionet“ svetainės. Duomenų bazėje yra 18-os žmonių (žr. 7 pav.) ilgalaikiai elektrokardiogramos įrašai iš aritmijos laboratorijos, esančios „Beth Israel“ ligoninėje Bostone (Jungtinėse Amerikos Valstijose) [42].




7 pav. Normalaus sinusinio ritmo duomenų bazės tiriamųjų pasiskirstymas pagal lytį

Normalaus sinusinio ritmo duomenų bazėje vyrų amžiaus pasiskirstymas (žr. 8 pav.) svyruoja nuo 26 metų iki 42 metų, o moterų nuo 20 metų iki 50 metų [42].



8 pav. Normalaus sinusinio ritmo duomenų bazės tiriamųjų pasiskirstymas pagal amžių ir lytį

Kiekvieno tiriamojo elektrokardiogramos įrašas trunka nuo 8 valandų iki 13 valandų ir 50 minučių, saugomi 2 EKG signalai, tyrimui naudojami antro EKG signalo įrašai. Elektrokardiogramų dažnis yra 128 signalų per sekundę. Elektrokardiogramos duomenų pavyzdys pateikiamas 9 pav. [42].



9 pav. Pirmo tiriamojo normalaus sinusinio ritmo EKG intervalo pavyzdys

2.2. Lagranžo rodikliai

Tai funkcijos, gautos iš dalelių trajektorijų (laiko eilučių, kurias pagal dinaminę sistemą formuoja skysčių srautai, šio projekto atveju, tai EKG laiko eilutė). Šiomis funkcijomis nuo laiko $t - \tau$ iki laiko $t + \tau$ įvertinamas teigiamo dydžio, pavyzdžiui, greičio modulio, pagreičio modulio, greičio arba pagreičio modulio, pakelto tam tikru fiksuotu laipsniu, integralas išilgai dalelės trajektorijos ir t. t. Viena iš šių labai dažnai naudojamų funkcijų, vadinama funkcija L , yra Manney'o ir Lawrence'o aptariamame darbe naudota funkcija, kuri laikoma greičio modulio išilgai trajektorijos integralu. Jis nurodo trajektorijos nubrėžto kelio ilgį. Šios funkcijos yra naudingos, nes pagal savybes išryškina pagrindinės dinaminės sistemos hiperbolinių trajektorijų invariantiškas stabilias ir nestabilias daugdaras, veikia kaip požymių išskyrimo metodai [43].

Kadangi pirmasis Lagranžo rodiklis nusako laiko eilutės ilgį, o kiti taip pat skaičiuojami panašiai, tai yra euristinių argumentų, kurie pagrindžia Lagranžo rodiklių praktinį taikymą:

1. Jeigu trajektorijos su artimomis pradinėmis sąlygomis, evoliucionuojant laikui pirmyn išlieka artimos laiko intervale $(t - \tau, t + \tau)$ tai tikimasi, kad jų lanko ilgiai taip pat bus artimi [43];
2. Ties ribomis tarp pritraukimo sričių, kuriose yra trajektorijos su kokybiškai skirtinga elgsena per laiko intervalą $(t - \tau, t + \tau)$ tikimasi, kad lanko ilgiai trajektorijų, prasidedančių abejose ribose pusėse, nebus artimi laiko intervale [43].
3. Taigi šios ribos pažymimos staigiu pokyčiu $L1$, kur staigus pokytis reiškia, kad $L1$ išvestinė, einanti skersai šių ribų, yra trūki pritraukimo sričių ribose [43].

2.2.1. Pirmas Lagranžo rodiklis

Nagrinėkime elektrokardiogramą $E_i, i = \overline{1, N}$. Fiksuokime 2 laiko vėlinimus: τ_1 ir τ_2 . Tarkime, kad EKG signalas transformuojamas į trimatį signalą, kurio pirmoji komponentė $s1$ tiesiogiai imama iš E_i . Antroji komponentė taip pat imama iš E_i , tačiau nevertinami pirmieji τ_1 stebėjimai. Trečioji komponentė analogiškai imama iš E_i , neimami pirmieji τ_1 ir τ_2 stebėjimai. Sulygiavus visų

komponenčių pradinius stebėjimus gauname trimačių koordinačių seką: (s_1, s_2, s_3) . Šias koordinates galime įsivaizduoti kaip kreivę trimatėje erdvėje. L_1 apibrėžiamas kaip šios kreivės ilgis.

$$F1(\tau_1, \tau_2) = L1_{\tau_1, \tau_2} \quad (1)$$

$$L1_{\tau_1, \tau_2} = \sum_{i=2}^{N-\tau_1-\tau_2} \sqrt{(s1_i - s1_{(i-1)})^2 + (s2_i - s2_{(i-1)})^2 + (s3_i - s3_{(i-1)})^2} \quad (2)$$

$$s1_i = E_i, i = \overline{1, (N - \tau_1 - \tau_2)} \quad (3)$$

$$s2_i = E_i, i = \overline{1 + \tau_1, (N - \tau_2)} \quad (4)$$

$$s3_i = E_i, i = \overline{1 + \tau_1 + \tau_2, N} \quad (5)$$

Čia $F1(\tau_1, \tau_2)$ – dvimatė požymių matrica;

τ_1, τ_2 – vėlinimai;

E_i – elektrokardiogramos segmentas;

N – elektrokardiogramos taškų skaičius;

s_1, s_2, s_3 – elektrokardiogramos koordinačių vektoriai;

L_1 – pirmas Lagranžo rodiklis.

2.2.2. Antras Lagranžo rodiklis

Iš fizikos žinoma, kad pagreitis yra greičio išvestinė. Pirmasis Lagranžo rodiklis buvo apskaičiuotas trimatei kreivei, kuri originalioje publikacijoje įvardijama kaip dalelės greitis. Šio projekto atveju EKG išvestinė gali būti traktuojama kaip šios įsivaizduojamos dalelės pagreitis. E_i išvestinės rekonstruotos trajektorijos ilgis yra antrasis E_i Lagranžo rodiklis. Kadangi projekte nagrinėjami realūs duomenys, tai išvestinės apskaičiuojamos skaitiškai, tai yra:

$$s'3_i = s3_i - s3_{(i-1)} \quad (6)$$

Tokiu būdu s_1, s_2 ir s_3 formulėj pakeitę jų atitinkamomis skaitinėmis išvestinėmis, gaunamas toks Lagranžo rodiklis:

$$F2(\tau_1, \tau_2) = L2_{\tau_1, \tau_2} \quad (7)$$

$$L_2 = \sum_{i=2}^{N-\tau_1-\tau_2} \sqrt{\mathbf{S1} + \mathbf{S2} + \mathbf{S3}} \quad (8)$$

$$\text{Čia: } \mathbf{S1} = \left((s1_i - s1_{(i-1)}) - (s1_{(i-1)} - s1_{(i-2)}) \right)^2$$

$$\mathbf{S2} = \left((s2_i - s2_{(i-1)}) - (s2_{(i-1)} - s2_{(i-2)}) \right)^2$$

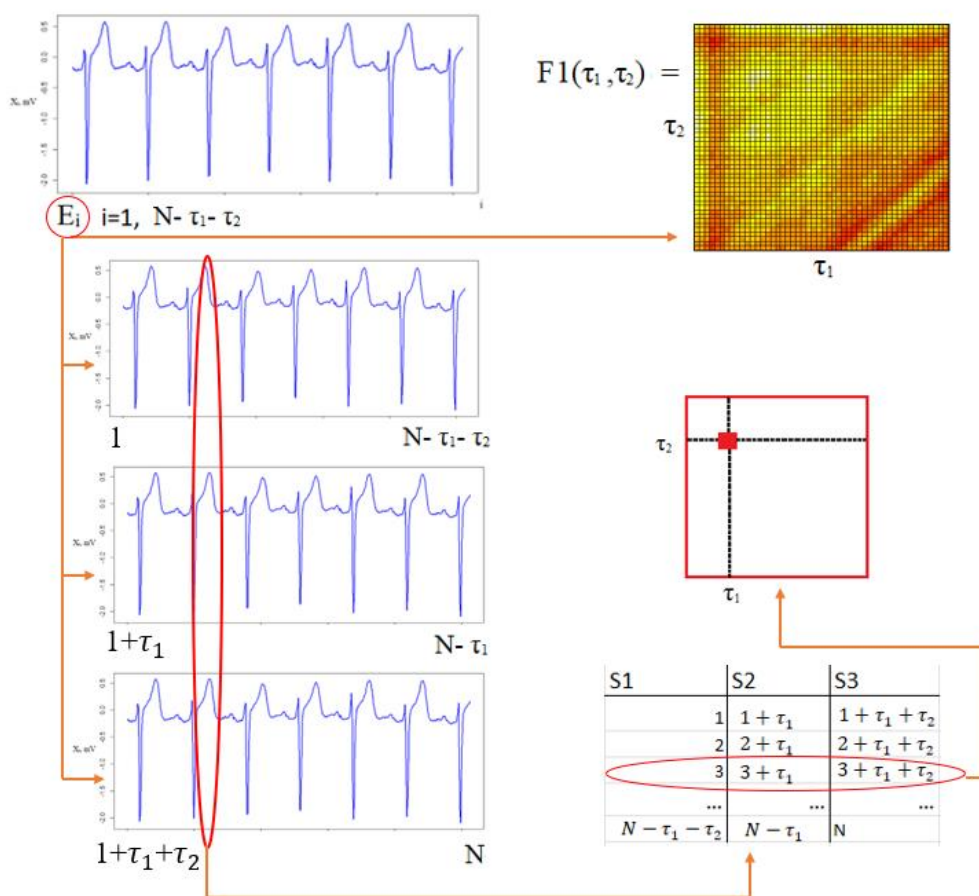
$$\mathbf{S3} = \left((s3_i - s3_{(i-1)}) - (s3_{(i-1)} - s3_{(i-2)}) \right)^2$$

2.3. Tyrimo eigos schema ir naudota programinė įranga

Tyrimo tikslas yra sukurti ir iširti Lagranžo rodikliais paremtą požymių, kaip skaitmeninių vaizdų, išskyrimo metodą, skirtą širdies nepakankamumui elektrokardiogramos segmentuose aptikti. Tikslui pasiekti naudojamos dvi programos: „RStudio“, kuri buvo skirta dvimačių skaitmeninių vaizdų

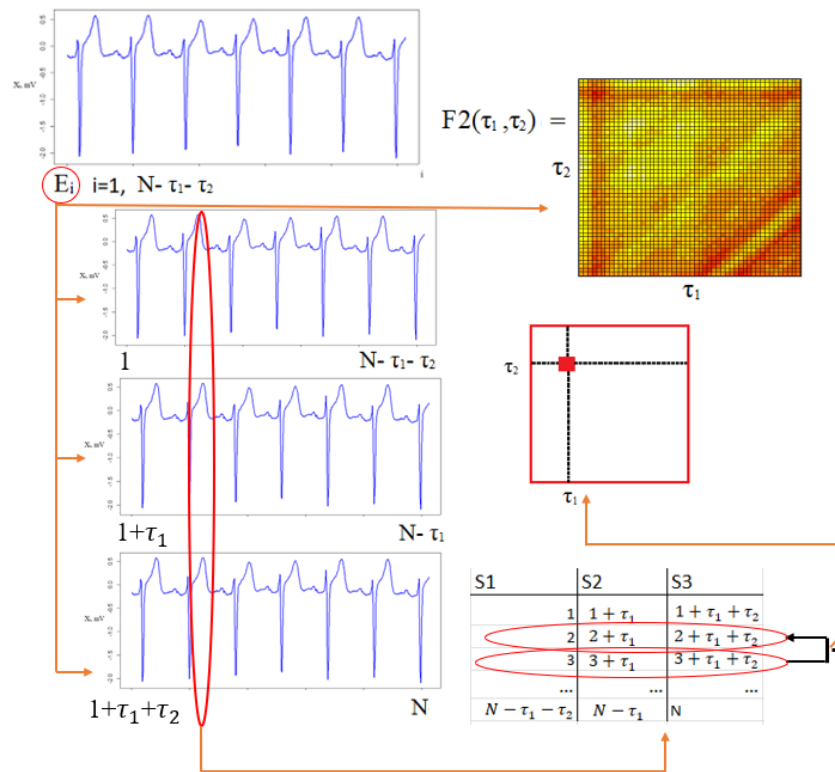
paruošimui, naudojant Lagranžo pirmą ir Lagranžo antrą rodiklius bei „Python“, kuri buvo skirta mašininiam mokymui atlikti.

Pirmiausia elektrokardiogramų signalų stebėjimo dažnis suvienodinamas iki 128 Hz, jog tokio pačio ilgio duomenų segmentai iš skirtingų EKG atitiktų vienodus laiko intervalus. Tuomet iš EKG signalų paruošiami dvimačiai skaitmeniniai vaizdai, naudojant Lagranžo rodiklius. Pirmo Lagranžo rodiklio dvimačiai skaitmeniniai vaizdai ruošiami šia tvarka (žr. 10 pav.): EKG signalai suskirstomi į segmentus s_1, s_2, s_3 , kurie vienas nuo kito skiriasi vėlinimais τ_1, τ_2 . Tuomet sulygiuojame vektorius, taip gauname koordinates trimatėje erdvėje, skaičiuojame jų ilgius. Suformuojame matricą, kurios pozicijoje τ_1, τ_2 yra elementas $L1_{\tau_1, \tau_2}$. Tai yra reikšmes užpildome Lagranžo rodikliais (trajektorijų ilgiais), paremtais Euklido atstumu.



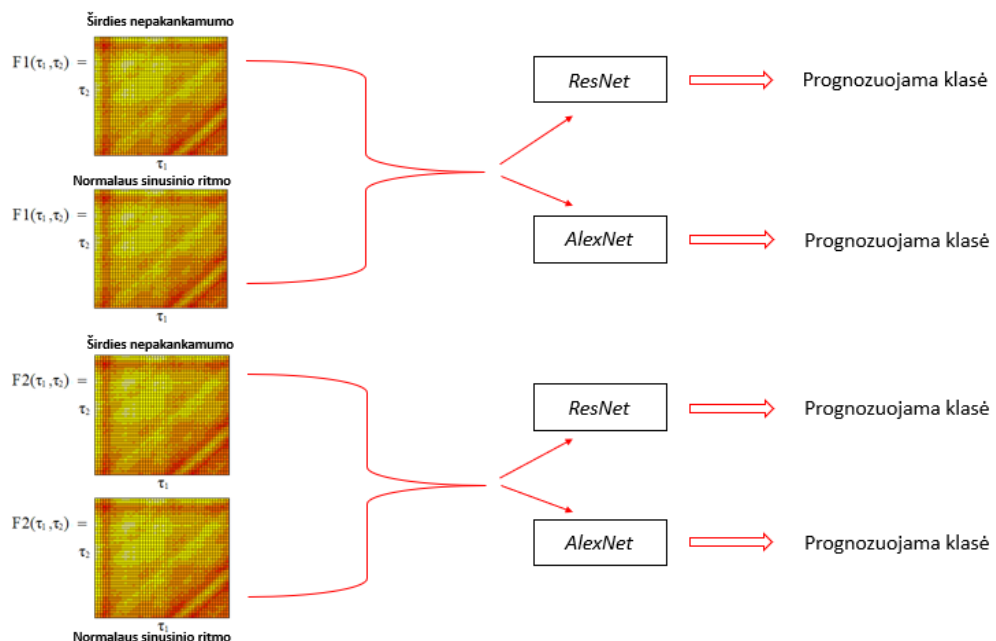
10 pav. Pirmu Lagranžo rodikliu paremtas dvimačių skaitmeninių vaizdų sukūrimo eigos schema

Antro Lagranžo rodiklio dvimačiai skaitmeniniai vaizdai ruošiami analogiškai, tik skaičiavimai atliekami su EKG skaitine išvestine žr. 11 pav. Kiekvienas skaitmeninis vaizdas, sudarytas iš 4 sekundžių EKG.



11 pav. Antru Lagranžo rodikliu paremtas dvimačių skaitmeninių vaizdų sukūrimo eigos schema

Tokiais būdais EKG segmentui, kaip požymiui, sukuriamas skaitmeninis vaizdas. Tokio tipo duomenys naudojami mašiniame mokyme (žr. 12 pav.). Pirmiausia paveikslėliai dalijami į treniravimo (80 %), validavimo (20 %) ir testavimo (10 %) dalis. Tuomet su treniravimo ir validavimo duomenimis atliekama klasifikacija dirbtiniais neuroniniais tinklais *ResNet* ir *AlexNet* architektūromis, nustatant skirtingus modelių parametrus (epocų skaičių, mokymo spartos, paveikslėlių padalijimo mokymui parametras, optimizacijos funkcijas). Gaunami rezultatai bei klasifikavimo tikslumai. Nustatomas geriausias modelis ir Lagranžo rodiklis, su kuriais gaunami aukštesni tikslumai.



12 pav. Dvimačių skaitmeninių vaizdų klasifikacijos dirbtiniais neuroniniais tinklais eigos schema

2.4. Mašininis mokymasis

Mašininis mokymasis, tai dirbtinio intelekto šaka, kuri remiasi praeities duomenimis, norint prognozuoti ateities duomenis. Mašininis mokymasis remiasi skirtingais algoritmais ir metodikomis, mokosi ir priima sprendimus be žmogaus įsikišimo ir yra pritaikomas klasifikacijos, regresinės analizės, vaizdų atpažinimo uždaviniuose [44].

Norint prognozuoti duomenis, buvo naudojamos kelios dirbtinių neuroninių tinklų architektūros: *Resnet50* ir *AlexNet*. Jų tikslumas buvo vertinamas atsižvelgiant į šiuos rodiklius:

1. Bendras tikslumas, kuris parodo kokia dalis duomenų prognozuojama teisingai ir apskaičiuojamas pagal formulę:

$$T = \frac{TP+TN}{TP+TN+FP+FN} \quad (9)$$

Čia TP – teisingai suklasifikuotų „0“ klasės duomenų skaičius;

FP – neteisingai suklasifikuotų „0“ klasės duomenų skaičius;

TN – teisingai suklasifikuotų „1“ klasės duomenų skaičius;

FN – neteisingai suklasifikuotų „1“ klasės duomenų skaičius.

2. Tikslumas (angl. *precision*), kuris parodo kokia dalis modelio priskirtų duomenų konkrečiai klasei buvo teisinga, apskaičiuojamas pagal formulę:

$$P = \frac{TP}{TP+FP} \quad (10)$$

3. Jautrumas (angl. *recall*), kuris parodo kokia dalis vienos klasės duomenų buvo suklasifikuota teisingai, apskaičiuojamas pagal formulę:

$$R = \frac{TP}{TP+FN} \quad (11)$$

4. F1 tikslumas, kuris apjungia tikslumą ir jautrumą bei atsižvelgia į duomenų kiekio balansą kiekvienoje klasėje, apskaičiuojamas pagal formulę:

$$F1 = \frac{2 \times P \times R}{P + R} \quad (12)$$

Mašininio mokymo metu naudojamų modelio parametrų bei įvertinimo charakteristikos:

Modelio tikslumas – naudojamas modelio našumui įvertinti. Jis apskaičiuojamas procentais, nustačius modelio parametrus. Tai yra matas, kuris parodo modelio prognozės tikslumą lyginant su tikraisiais duomenimis [45].

Praradimo funkcija (angl. *loss*) – naudojama mašininio mokymosi algoritmui optimizuoti. Nuostoliai apskaičiuojami mokymo ir validacijos metu, o jų interpretacija grindžiama tuo, kaip gerai modelis veikia šiose dviejose aibėse. Tai yra kiekvieno mokymo arba patvirtinimo rinkinių pavyzdžio padarytų klaidų suma. Nuostolio reikšmė reiškia, kaip prastai ar gerai elgiasi modelis po kiekvienos optimizavimo iteracijos [45].

Mašininio mokymo metu naudojamų duomenų rinkinių reikšmės:

Treniravimo duomenys – duomenų rinkinys, kuris naudojamas modeliui mokyti (svoriai ir nuokrypiai). Tai pradiniai duomenys, kuriuos mašininio mokymosi algoritmas analizuoja, kad išmokyti dėsnį ir ryšius iš įvesties požymių ir išvesties kintamųjų [46].

Validavimo duomenys – duomenų imtis, naudojama siekiant nešališkai įvertinti modelio atitikimą mokymo duomenų rinkiniui derinant modelio hiperparametrus. Modelis iš šių duomenų nesimoko [46].

Testavimo duomenys – duomenų imtis, naudojama siekiant nešališkai įvertinti galutinį modelio atitikimą mokymo duomenų rinkiniui. Ji naudojama tik tada, kai modelis pilnai išmokytas ir patvirtintas atitinkamai treniravimo ir validavimo duomenų imtimis. Jei modelis pasiekia aukštą tikslumą su testavimo duomenimis, tai parodo, kad modelis klasifikuoti duomenis tinkamas, jei žemą – modelis per daug prisitaiko prie mokymo duomenų ir nėra tinkamas klasifikacijai [46].

Aktyvacijos funkcijos:

„**Adam**“ – alternatyvus optimizavimo algoritmas, kuris užtikrina efektyvesnius neuroninio tinklo svorius, kuris skirta gradiento mažinimui. Toks metodas efektyvus, kai turima daug duomenų ir parametrų [47]. Veikimo principas:

$$\omega_{t+1} = \omega_t - \hat{m}_t \left(\frac{\alpha}{\sqrt{\hat{v}_t + \epsilon}} \right) \quad (13)$$

Čia ϵ vėlinimo konstanta, kad būtų išvengta dalybos iš 0 problema

α – žingsnio dydžio parametras arba mokymosi greitis (pagal nutylėjimą 0,001);

\hat{v}_t – ankstesnių gradientų poslinkio kvadratų suma;

\hat{m}_t – gradientų poslinkio sanakaupa laiku t (dabartiniu laiku);

ω_t – svoriai momentu t .

„**SGD**“ – yra stochastinis gradientinis nusileidimas, naudojamas mašininio mokymosi modeliams optimizuoti.

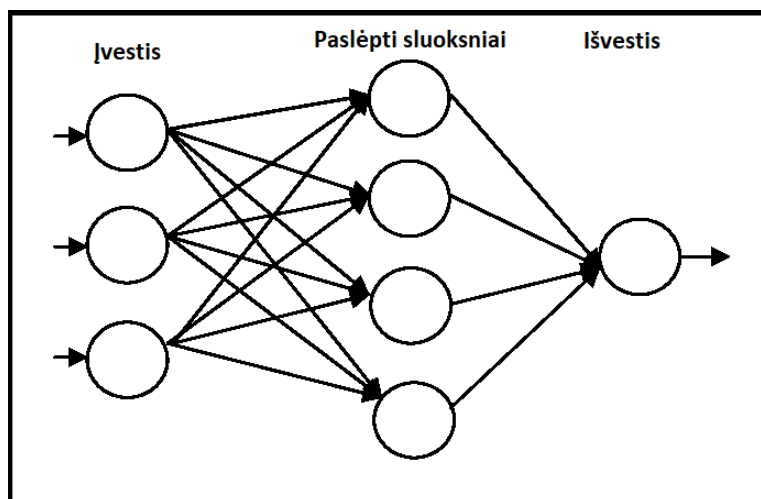
$$\theta_j = \theta_j - \alpha(\hat{y}^i - y^i)x_j^i \quad (14)$$

Čia x^i treniravimo duomenys

y^i treniravimo duomenų klasė

2.4.1. Dirbtiniai neuroniniai tinklai

Dirbtiniai neuroniniai tinklai (ANN) yra mašininio mokymosi metodas bei gilus mokymosi algoritmų pagrindas. Pavadinimas ir struktūrą panaši į žmogaus smegenis, dėl imitacinių biologinių neuronų tarpusavio signalų perdavimo būdo. Dirbtinių neuronų tinklus sudaro mazgų sluoksniai, kuriuose yra įvesties sluoksnis, vienas ar daugiau paslėptų sluoksnių bei išvesties sluoksnis (žr. 13 pav.). Kiekvienas mazgas, arba dirbtinis neuronas, jungiasi su kitu mazgu, kuris turi atitinkamą svorį bei slenkstį. Jei kurio nors atskiro mazgo išvestis viršija nustatytą slenkstinę vertę, tas mazgas aktyvuojamas ir siunčia duomenis į kitą tinklo sluoksnį. Priešingu atveju jokie duomenys į kitą tinklo sluoksnį neperduodami. Neuroniniai tinklai remiasi treniravimo duomenimis, kad mokymosi eigoje mokytųsi ir pagerintų klasifikavimo tikslumą [48].



13 pav. Dirbtinių neuroninių tinklų architektūra

Mašininio mokymo metu naudojami parametrai:

Mokymosi sparta (angl. *learning rate*) – mašininio mokymosi ir statistikos srityje, naudojamas optimizavimo algoritmo derinimo parametras, kuriuo nustatomas žingsnio dydis kiekvienoje iteracijoje, siekiant minimizuoti nuostolių funkciją.

Epochų skaičius – visiško perėjimo per mokymo duomenų rinkinį skaičius.

Padalijimo mokymui parametras (angl. *batch size*) – tai duomenų, kurie apdorojami prieš atnaujinant modelį, skaičius. Padalijimo mokymui parametras turi būti didesnis arba lygus vienetui ir mažesnis arba lygus mokymo duomenų rinkinio pavyzdžių skaičiui.

Mašininio mokymo metu naudojamos aktyvacijos funkcijos:

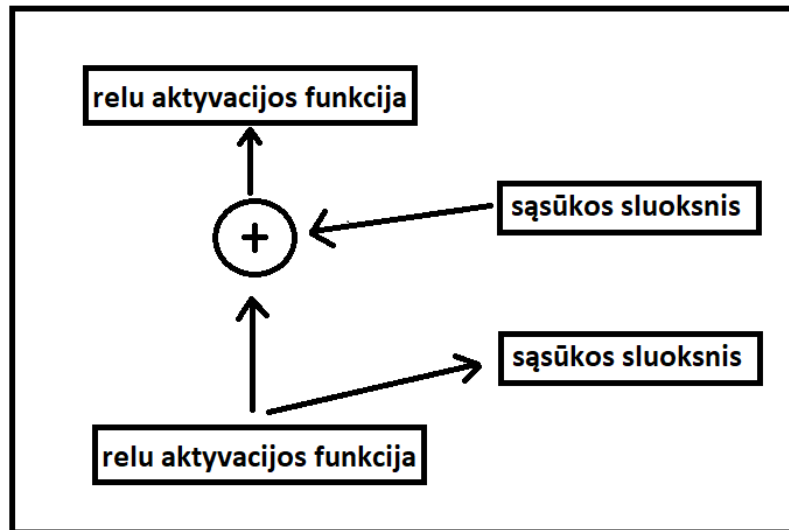
Rel-U aktyvacijos funkcija – vienas iš aktyvacijos sluoksnių, visos pikselių reikšmės, kurios yra mažesnės už 0, konvertuojamos į 0, bet jei pikselių vertės yra didesnės už 0, reikšmės paliekamos tokios pačios. Rel-U aktyvavimo lygtis:

$$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x \geq 0 \end{cases} \quad (15)$$

Sigmoid aktyvacijos funkcija – aktyvacijos sluoksnis, kuris naudojamas dvejetainių klasių klasifikacijai. Šis aktyvavimo sluoksnis yra sigmoidės formos.

2.4.1.1. Dirbtinių neuroninių tinklų *ResNet* architektūra

ResNet architektūra naudojama vaizdų klasifikavimui ir atpažinimui. Šio tinklo architektūrinė idėja yra liekamieji blokai, jų privalumas, kad kiekvienas paslėptas sluoksnis naudoja informaciją ne tik iš ankstesnio sluoksnio išėjimų, bet ir originalius, dar nenaudotus, duomenis požymių išgavimui. Naudojama trumpesnio kelio jungtis, kad būtų galima peršokti kelis (2-3 sluoksnius). Trumpesnio kelio jungties idėja, kad tolimesnis sluoksnis duoda geresnę arba tokį patį rezultatą nei ankstesnis sluoksnis. Praktinėje dalyje naudojamas *ResNet50* tinklas, kuris sudarytas iš 50 sluoksnių. Tinklą sudaro praleidimo jungtis, aktyvavimo funkcija, 2 blokai (projekcijos bei kartojamų tapatybės), filtrų skaičiaus ir rinkinio normalizacijos [49]. *Resnet* likutinių blokų schema pateikiama 14 pav.



14 pav. *ResNet* liekamųjų bloką diagrama

Sluoksniai priklauso nuo jiems suteiktų parametrų, pavyzdžiui skirtingų dydžių filtrų nustatymo, grupės normalizavimo dydžio, po kurio aktyvuojama relu funkcija. Likutinis sluoksnis remiasi išėjimais gautais iš ankstesnių sluoksnių, o galutinis išėjimas yra likutinio ir ankstesnių sluoksnių suma [49]. Tyrimė naudojama *ResNet* tinklo architektūra:

Įvesties sluoksnis: Tinklo įvestis yra 50x50 skaitmeninis vaizdas.

Sąsūkų sluoksniai: pirmasis sluoksnis yra 7x7 sąsūkos sluoksnis su 64 filtrais, po kurio seka 3x3 sujungimo (angl. *max pooling*) sluoksnis. Po to seka daugiau sluoksnių, su skirtingu branduolių skaičiumi.


Likutiniai blokai: kiekvieną likutinį bloką sudaro du 3x3 konvoliuciniai sluoksniai su trumpąja jungtimi, kuri apeina sąsūkų sluoksnius.

Pilnai sujungti sluoksniai: po sąsūkų sluoksnių tinklas užbaigiamas globaliu sujungimo sluoksniu, po kurio seka pilnai sujungtas sluoksnis 1 neuronų mazgu ir 2 išėjimais.

Sigmoid aktyvacijos funkcija: paskutinio pilnai sujungto sluoksnio išvestis perduodama per *sigmoid* aktyvacijos funkciją, kad būtų gautos galutinės klasės tikimybės.

2.4.1.2. Dirbtinių neuroninių tinklų *AlexNet* architektūra

AlexNet architektūrą paprastai sudaro keli sąsūkų sluoksnių rinkiniai, sujungti su kaupiamuoju sluoksniu (angl. *pooling layer*) ir visiškai sujungtu sluoksniu. Sąsūkų sluoksnių funkcija - išgauti įvesties vaizdų požymius į pikselio vertę, po to procesas tęsiamas kaupiamajame sluoksnyje, kuriame didžiausia vertė arba vidutinė vertė yra naudojama kaip sumažinamoji, kad modelis būtų kompaktiškas be erdvinės informacijos praradimo. Po funkcijų gavimo, visiškai sujungtas sluoksnis prisideda prie klasifikavimo rezultatų išskyrimo [50]. *AlexNet* schema pavaizduota 15 pav.



15 pav. AlexNet modelio schema

AlexNet modelį, naudojamą tyrime, sudaro aštuoni mokomieji sluoksniai, penki konvoliucijos sluoksniai ir trys visiškai sujungti sluoksniai. Visuose mokomuosiuose sluoksniuose naudojama *ReLU* aktyvavimo funkcija, išskyrus paskutinį visiškai sujungtą sluoksnį, kuriame naudojama *sigmoid* funkcija. Architektūrą taip pat sudaro netreniruojami sluoksniai: trys sujungimo sluoksniai, du normalizavimo sluoksniai ir du išmetimo (angl. *dropout*) sluoksniais su 50 % neurono išjungimo tikimybe (naudojamas pertekliniam pritaikymui sumažinti). Tyrimo dalyje naudota AlexNet architektūros schema pateikta 1 lentelėje.

1 lentelė. AlexNet architektūra

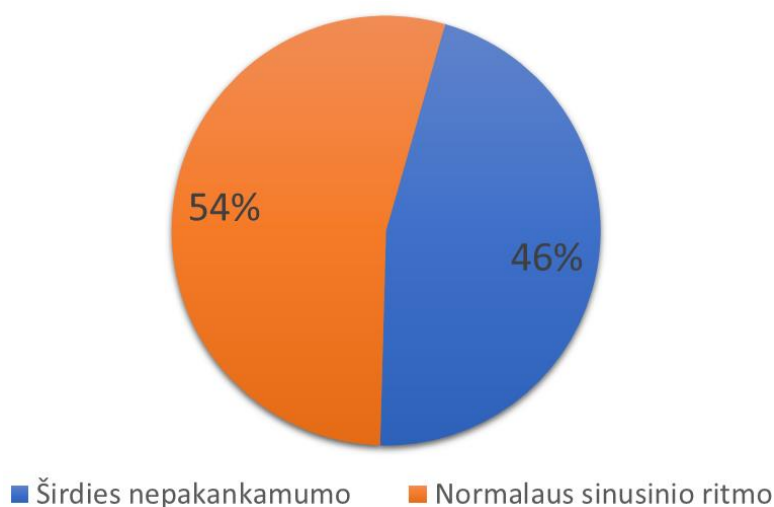
Sluoksnis	Įvestis	Išvestis
Įvestis	(None, 50, 50, 3)	(None, 50, 50, 3)
Sąsūkos 1 (Conv2D)	(None, 50, 50, 3)	(None, 15, 15, 96)
Sujungimo 1 (MaxPooling2D)	(None, 15, 15, 96)	(None, 7, 7, 96)
Sąsūkos 2 (Conv2D)	(None, 7, 7, 96)	(None, 7, 7, 256)
Sujungimo 2 (MaxPooling2D)	(None, 7, 7, 256)	(None, 3, 3, 256)
Sąsūkos 3 (Conv2D)	(None, 3, 3, 256)	(None, 3, 3, 384)
Sąsūkos 4 (Conv2D)	(None, 3, 3, 384)	(None, 3, 3, 384)
Sąsūkos 5 (Conv2D)	(None, 3, 3, 384)	(None, 3, 3, 256)
Sujungimo 3 (MaxPooling2D)	(None, 3, 3, 256)	(None, 1, 1, 256)
Išlyginimo (Flatten)	(None, 1, 1, 256)	(None, 256)
Tankiojo 1 (Dense)	(None, 256)	(None, 4096)
Tankiojo 2 (Dense)	(None, 4096)	(None, 4096)
Tankiojo 3 (Dense)	(None, 4096)	(None, 1)
Išvestis	(None, 1)	(None, 1)

3. Tyrimų rezultatai ir jų aptarimas

Šiame skyriuje pateikiami mašininio mokymo dirbtinių neuroninių *ResNet* ir *AlexNet* architektūrų modelių rezultatai su pirmo ir antro Lagranžo rodiklių dvimačių skaitmeninių vaizdų duomenų rinkiniais. Pateikiamas modelių rezultatų palyginimas, išskiriamas geriausias modelis. Pažymima, kad rezultatų apžvalgoje „0“ klasė žymi normalaus sinusinio ritmo klasę (normalius širdies signalus), o „1“ klasė – širdies nepakankamumo.

3.1. Duomenų rinkiniai


Tiek pirmo, tiek antro Lagranžo rodiklio dvimačių skaitmeninių vaizdų skaičius 67 584, iš kurių 31 087 priklauso širdies nepakankamumo, o 36 497 normalaus sinusinio ritmo klasėms. Treniravimui naudojama 70 % dvimačių skaitmeninių vaizdų, validavimui – 20 %, testavimui – 10 %. Širdies nepakankamumo ir normalaus sinusinio ritmo procentalus duomenų pasiskirstymas parodytas 16 pav.



16 pav. Procentinis duomenų pasiskirstymas klasėse


3.2. Skaitmeninių dvimačių vaizdų apžvalga

Širdies nepakankamumo klasės, paremti pirmu Lagranžo rodikliu, dažniausiai pasikartojančių pacientų duomenų rinkiniuose, dvimačiai skaitmeniniai vaizdai pavaizduoti 17 pav. Visi paveikslėliai turi juodais ovalais pažymėtus tamsesnius plačius taškus, taip pat visi, išskyrus 14 paciento duomenų rinkinyje, figūravo nuo juodai pažymėto ovalo išeinančios horizontalios ir vertikalios linijos. Visi dvimačiai vaizdai, išskyrus pirmojo, aštuntojo bei keturioliktojo paciento, turi šviesiai rožine spalva pažymėtomis tiesėmis, pasvirusias linijas. Baltu stačiakampiu pažymėtos vietos rodo trikampio formos požymį dešiniajame apatiniame kampe, kuris pastebimas visuose pacientų rinkiniuose išskyrus pirmo, trečio, šešto, aštunto bei keturiolikto paciento skaitmeniniuose vaizduose. Vizualiai įvertinus kiekvieno paciento visus dvimačius vaizdus, pastebėta, kad pirmojo, septintojo, aštuntojo ir keturiolikto paciento duomenų rinkiniuose figūruoja daugiau anomalijų bei variacijų skaitmeninių vaizdų nei kitų pacientų duomenų rinkiniuose.




17 pav. Dvimačiai, dažniausiai pasikartojantys, širdies nepakankamumo pacientų skaitmeniniai vaizdai, paremti L1 rodikliu, duomenų rinkiniuose; a) pirmojo paciento; b) antrojo paciento; c) trečiojo paciento; d) ketvirtojo paciento; e) penktojo paciento; f) šeštojo paciento; g) septintojo paciento; j) aštuntojo paciento; k) devintojo paciento; l) dešimtojo paciento; m) vienuoliktojo paciento; n) dvyliktojo paciento; o) tryliktojo paciento; p) keturioliktojo paciento; r) penkioliktojo paciento

Normalaus sinusinio ritmo klasės, paremti pirmu Lagranžo rodikliu, dažniausiai pasikartojančių pacientų duomenų rinkiniuose, dvimačiai skaitmeniniai vaizdai pavaizduoti 18 pav. Lyginant su 17 pav. skaitmeniniais vaizdais, paveikslėliai šviesesni ir labiau struktūrizuoti. Visuose skaitmeniniuose vaizduose, išskyrus antrojo paciento, kairiajame viršutiniame kampe matomas ryškus taškas bei horizontalios linijos, kurios, priešingai nei širdies nepakankamumo klasės skaitmeniniuose vaizduose, yra siauresnės bei šviesesnės atspalvio. Dešiniajame apatiniame kampe, išskyrus septintojo, aštuntojo, devintojo ir šešioliktojo paciento duomenų rinkinius, matoma viena arba dvi ryškios ir plonesnės bei šviesesnės nei širdies nepakankamumo klasės skaitmeniniai vaizdai, įstrižos linijos. Taigi, skaitmeniniai vaizdai, paremti pirmuoju Lagranžo rodikliu, abiejose klasėse turi panašius požymius, tačiau normalaus sinusinio ritmo klasėje atitinkami požymiai yra šviesesni bei siauresni nei širdies nepakankamumo klasės vaizduose.



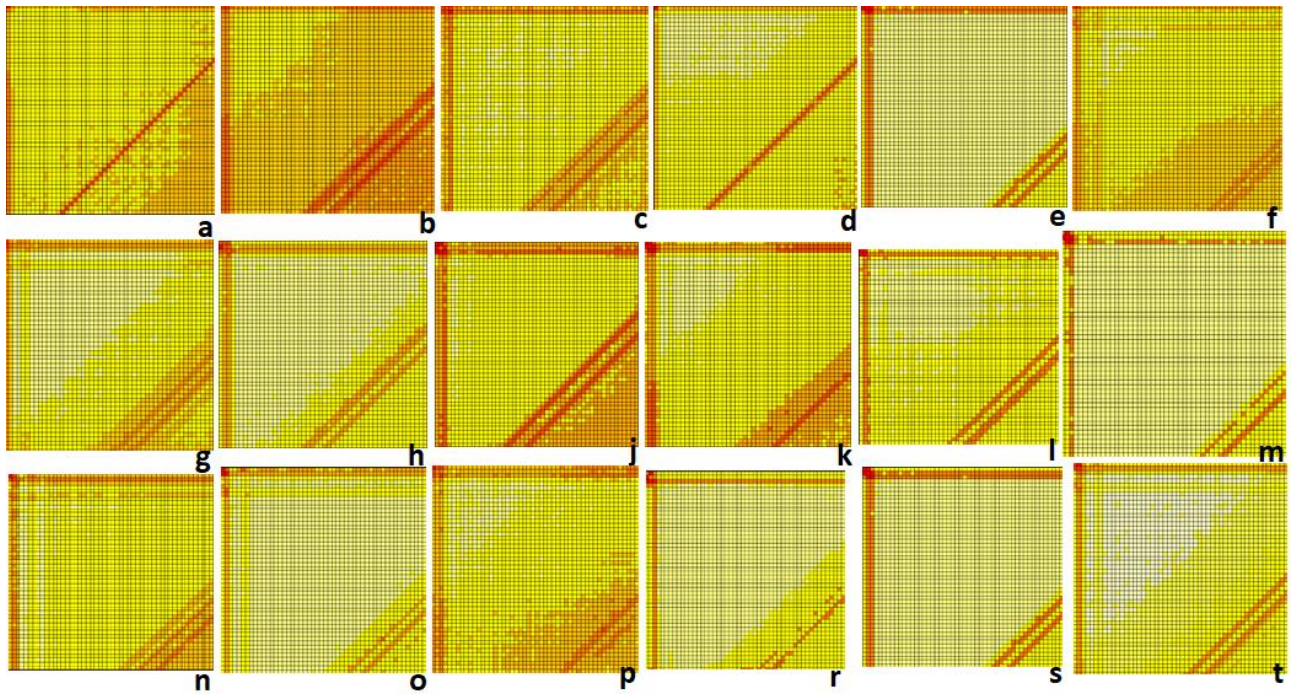
18 pav. Dvimačiai, dažniausiai pasikartojantys, normalaus sinusinio ritmo klasės, pacientų skaitmeniniai vaizdai, paremti L1 rodikliu, duomenų rinkiniuose; a) pirmojo paciento; b) antrojo paciento; c) trečiojo paciento; d) ketvirtojo paciento; e) penktojo paciento; f) šeštojo paciento; g) septintojo paciento; h) aštuntojo paciento; j) devintojo paciento; k) dešimtojo paciento; l) vienuoliktojo paciento; m) dvyliktojo paciento; n) tryliktojo paciento; o) keturioliktojo paciento; p) penkioliktojo paciento; r) šešioliktojo paciento; s) septynioliktojo paciento; t) aštuonioliktojo paciento

Širdies nepakankamumo klasės, paremti antru Lagranžo rodikliu, dažniausiai pasikartojančių pacientų duomenų rinkiniuose, dvimačiai skaitmeniniai vaizdai pavaizduoti 19 pav. Iš karto galima pastebėti, kad paveikslėliuose figūruoja šviesesnės spalvos, lyginant su skaitmeniniais vaizdais, paremtais pirmu Lagranžo rodikliu. Taškas kairiajame viršutiniame kampe išliko, tačiau skiriasi iš jo išeinančių horizontalių linijų skaičius. Pirmojo, antrojo, ketvirtojo, ir devintojo pacientų duomenų rinkiniuose figūruoja dvigubos horizontalios linijos, o likusių pacientų duomenų rinkiniuose – viengubos. Galima pastebėti, kad visų klasių dvimačiuose skaitmeniniuose vaizduose dešiniajame apatiniame kampe yra suformuotas trikampis, jis atskirtas lygiagrečiomis linijomis, išskyrus pirmojo, trečiojo, ketvirtojo, šeštojo, devintojo ir dešimtojo paciento skaitmeninius vaizdus – juose matomas trikampis be linijų. Septintojo ir tryliktojo paciento paveikslėliuose pastebimą trikampį lygiagrečios linijos kerta, o ne atskiria nuo likusios paveikslėlio dalies. Vizualiai peržiūrėjus kiekvieno paciento dvimačių skaitmeninių vaizdų duomenų rinkinius pastebėta, kad daugiausia anomalijų bei įvairių variacijų yra šeštojo, devintojo bei keturioliktojo pacientų duomenų rinkiniuose.




19 pav. Dvimačiai, dažniausiai pasikartojantys, širdies nepakankamumo pacientų skaitmeniniai vaizdai, paremti L2 rodikliu, duomenų rinkiniuose; a) pirmojo paciento; b) antrojo paciento; c) trečiojo paciento; d) ketvirtojo paciento; e) penktojo paciento; f) šeštojo paciento; g) septintojo paciento; h) aštuntojo paciento; j) devintojo paciento; k) dešimtojo paciento; l) vienuoliktojo paciento; m) dvyliktojo paciento; n) tryliktojo paciento; o) keturioliktojo paciento; p) penkioliktojo paciento

Normalaus sinusinio ritmo klasės, paremti antru Lagranžo rodikliu, dažniausiai pasikartojančių pacientų duomenų rinkiniuose, dvimačiai skaitmeniniai vaizdai pavaizduoti 20 pav. Pastebima, kad panašiai kaip širdies nepakankamumo klasėje, paremtoje tuo pačiu antru Lagranžo rodikliu, kairiajame apatiniame kampe figūruoja dvi įstrižos linijos, išskyrus pirmojo, ketvirtojo bei dešimtojo pacientų skaitmeniniuose vaizduose, juose figūruoja viena įstriža linija. Visuose vaizduose kairiajame viršutiniame kampe pastebimas taškas bei iš jo išeinančios vertikali ir horizontali linijos, užimančios mažą ploto dalį, priešingai nei širdies nepakankamumo klasėje, kurioje tokios linijos platesnės ar dvigubos, su didesniu tašku viršutiniame kairiajame kampe. Devintojo paciento dažniausiai pasikartojančiame dvimačiame skaitmeniniame vaizde struktūra panašiausia į širdies nepakankamumo klasės paveikslėlius, kurie paremti antru Lagranžo rodikliu, tačiau kitų klasių paveikslėliai, paremti L2 rodikliu, vizualiai skiriasi nuo širdies nepakankamumo klasės.



20 pav. Dvimačiai, dažniausiai pasikartojantys, normalaus sinusinio ritmo klasės, pacientų skaitmeniniai vaizdai, paremti L2 rodikliu, duomenų rinkiniuose; a) pirmojo paciento; b) antrojo paciento; c) trečiojo paciento; d) ketvirtojo paciento; e) penktojo paciento; f) šeštojo paciento; g) septintojo paciento; h) aštuntojo paciento; j) devintojo paciento; k) dešimtojo paciento; l) vienuoliktojo paciento; m) dvyliktojo paciento; n) tryliktojo paciento; o) keturioliktojo paciento; p) penkioliktojo paciento; r) šešioliktojo paciento; s) septynioliktojo paciento; t) aštuonioliktojo paciento

Visuose, tiek antru, tiek pirmu Lagranžo rodikliu, paremtuose dvimačiuose skaitmeniniuose paveikslėliuose vizualiai pastebėtos anomalijos. Labiausiai išsiskiriančios iš kitų skaitmeninių vaizdų ir dažniausiai pasikartojančios anomalijos pavaizduotos 21 pav. Tokiu anomalijų skaičius nebuvo didelis, tačiau jos gali duoti didesnę paklaidą klasifikacijoje dirbtiniais neuroniniais tinklais. Anomalijos galėjo atsirasti, dėl papildomo triukšmo ar sujudėjimo EKG tyrimo metu.




21 pav. Dažniausiai pasikartojančios anomalijos, visuose skaitmeninių vaizdų duomenų rinkiniuose

3.3. ResNet architektūra paremti dirbtinių neuroninių tinklų modeliai

3.3.1. Dvimačių požymių, paremtų L1 rodikliu, klasifikavimas

3.3.1.1. Pirmo tinklo modelio rezultatai

Visi paveikslėliai naudojami *Resnet* treniravimui ir validavimui paduodami į tinklą originaliu 50x50 dydžio formatu. Toliau aprašomas likutinis blokas (angl. *identity block*), jog sluoksnio aktyvacija būtų perkeliama į gilesnį neuroninio tinklo sluoksnį bei sąsūkų blokas, kuris sudaro esminį požymių išskyrimo komponentą. Modeliui svorių nenustatome, kadangi bus naudojami atsitiktiniai svoriai. Galiausiai aprašomas kompiliatorius su optimizacijos funkcija „Adam“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 30 su 32 paveikslėlių padalijimo mokymui parametru (angl. *batch size*). Modelio mokymas truko 34 918 sekundes (9 h 41 min 58 s). Naudojami 2 pilnai sujungti sluoksniai su 2 „relu“ aktyvacijos funkcijomis atitinkamai su 256 ir 128 neuronų skaičiumi ir išėjimo sluoksniu su „sigmoid“ aktyvacijos funkcija. Galima matyti 22 pav., kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – mažėjančią. Iš grafikų matoma, kad modelis nepersimoko, kadangi validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo tikslumai ir nuostoliai abėjuose grafikuose nėra nutolę vienas nuo kito, todėl modelis mokytas pakankamai.



22 pav. EKG segmentų požymių, paremtų L1, pirmo *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 23 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 98,32 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99,95 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 96,3 %. Modelis teisingai priskyrė 97,09 % normalaus sinusinio ritmo klasės duomenų bei 99,93 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 98,5 %, o širdies nepakankamumo – 98,08 %.

	precision	recall	f1-score	support
0	0.9709	0.9995	0.9850	3741
1	0.9993	0.9630	0.9808	3028
accuracy			0.9832	6769
macro avg	0.9851	0.9812	0.9829	6769
weighted avg	0.9836	0.9832	0.9831	6769

23 pav. EKG segmentų požymių, paremtų L1, pirmo *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.1.2. Antro tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą pakeičiamas paveikslėlių padalijimo mokymui parametras į 16. Vienai epochai mokytis naudojami 2 948 dvimačiai skaitmeniniai vaizdai. Modelio mokymas truko 39 510 sekundes (10 h 58 min 30 s). Galima matyti 24 pav., kad modelio mokymosi tikslumas stabiliai didėjo, o modelio nuostolis – mažėjo. Iš grafikų matoma, kad modelis nepersimoko, kadangi validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės abejuose grafikuose nėra nutolusios viena nuo kitos, todėl modelis mokytas pakankamai, matomas didelis nuostolis ties 23 epocha ir tikslumo praradimas ties 14 epocha, tačiau su vėlesnėmis epochomis, tiek tikslumas, tiek nuostolis nusistovėjo.



24 pav. EKG segmentų požymių, paremtų L1, antro *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 25 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 99,2 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99,3 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 99,07 %. Modelis teisingai priskyrė 99,19 % normalaus sinusinio ritmo klasės duomenų bei 99,2 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 99,25 %, o širdies nepakankamumo – 99,14 %.

	precision	recall	f1-score	support
0	0.9919	0.9930	0.9925	3592
1	0.9920	0.9907	0.9914	3124
accuracy			0.9920	6716
macro avg	0.9920	0.9919	0.9919	6716
weighted avg	0.9920	0.9920	0.9920	6716

25 pav. EKG segmentų požymių, paremtų L1, antro *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.1.3. Trečio tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą naudojami „ImageNet“ svoriai. Galiausiai aprašomas kompiliatorius su optimizacijos funkcija „Adam“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetainei klasei. Naudojamas epochų skaičius 30 su 32 paveikslėlių padalijimo mokymui parametru (angl. *batch size*). Modelio mokymas truko 36 715 sekundes (10 h 11 min 55 s). Galima matyti 26 pav., kad modelio mokymosi tikslumas stabiliai didėjo. Iš grafikų matoma, kad modelis nepersimoko, kadangi validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Iš modelio nuostolio grafiko galima matyti, kad validavimo aibės nuostolis su kiekviena epocha nėra mažėjantis, iš to galima spręsti, kad modelį reikėtų tobulinti.



26 pav. EKG segmentų požymių, paremtų L1, trečio *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika

Iš 27 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 66,52 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99,6 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 26,53 %. Modelis teisingai priskyrė 62,1 % normalaus sinusinio ritmo klasės duomenų bei 98,19 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 76,41 %, o širdies nepakankamumo – 41,78 %. Toks modelis tikslumo nepagerino, yra linkęs širdies nepakankamumo klasės dvimačius skaitmeninius vaizdus priskirti normalaus sinusinio ritmo klasei.


	precision	recall	f1-score	support
0	0.6211	0.9960	0.7651	3710
1	0.9819	0.2653	0.4178	3068
accuracy			0.6652	6778
macro avg	0.8015	0.6306	0.5914	6778
weighted avg	0.7844	0.6652	0.6079	6778

27 pav. EKG segmentų požymių, paremtų L1, trečio *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.1.4. Ketvirto tinklo modelio rezultatai

Norint pagerinti modelio tikslumą modeliui svorių nenustatome, kadangi bus naudojami atsitiktiniai svoriai. Aprašomas naujas kompiliatorius su optimizacijos funkcija „SGD“. Naudojama nuostolių

funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 30 su 32 paveikslėlių padalijimo mokymui parametru (angl. *batch size*). Modelio mokymas truko 46 514 sekundes (12 h 55 min 14 s). Galima matyti 28 pav., kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – mažėjančią. Iš grafikų matoma, kad modelis nepersimoko, kadangi validavimo aibės tikslumas nusistovėjęs. Validavimo ir treniravimo aibės abėjuose grafikuose nėra nutolusios viena nuo kitos, todėl modelis mokytas pakankamai. Matoma, kad modelio mokymui užtenka 25 epochų.



28 pav. EKG segmentų požymių, paremtų L1, ketvirto *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika

Iš 29 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 99,01 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99,73 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,12 %. Modelis teisingai priskyrė 98,5 % normalaus sinusinio ritmo klasės duomenų bei 99,66 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 99,11 %, o širdies nepakankamumo – 98,89 %.


	precision	recall	f1-score	support
0	0.9850	0.9973	0.9911	3741
1	0.9966	0.9812	0.9889	3028
accuracy			0.9901	6769
macro avg	0.9908	0.9893	0.9900	6769
weighted avg	0.9902	0.9901	0.9901	6769

29 pav. EKG segmentų požymių, paremtų L1, ketvirto *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.1.5. Penkto tinklo modelio rezultatai

Norint pagerinti modelio tikslumą modeliui svorių nenustatome, kadangi bus naudojami atsitiktiniai svoriai. Aprašomas kompiliatorius su optimizacijos funkcija „SGD“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 30 su 16 paveikslėlių padalijimo mokymui parametru (angl. *batch size*). Modelio mokymas truko 64 650 sekundes (17 h 57 min 30 s). Galima matyti 30 pav., kad modelio mokymosi tikslumas stabiliai didėjo. Iš grafikų matoma, kad modelis nepersimoko, kadangi validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Iš modelio nuostolio grafiko galima matyti, kad validavimo kreivė su kiekviena epocha nėra mažėjanti, iš to galima spręsti, kad

modelį reikėtų tobulinti. Iš modelio tikslumo grafiko galima pastebėti, kad paskutinėmis epochomis validavimo kreivės tikslumas mažėjo, modelis galimai persimokė, mokymui užtenka 25 epochų, kadangi tuo metu tikslumas nebesikeičia, nusistovi.



30 pav. EKG segmentų požymių, paremtų L1, penkto *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 31 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 97,99 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99,84 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 95,71 %. Modelis teisingai priskyrė 96,64 % normalaus sinusinio ritmo klasės duomenų bei 99,79 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 98,21 %, o širdies nepakankamumo – 97,71 %. Toks modelis tikslumo nepagerino, yra linkęs širdies nepakankamumo klasės dvimačius skaitmeninius vaizdus priskirti normalaus sinusinio ritmo klasei.

	precision	recall	f1-score	support
0	0.9664	0.9984	0.9821	3741
1	0.9979	0.9571	0.9771	3028
accuracy			0.9799	6769
macro avg	0.9821	0.9777	0.9796	6769
weighted avg	0.9805	0.9799	0.9799	6769

31 pav. EKG segmentų požymių, paremtų L1, penkto *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.1.6. Šešto tinklo modelio rezultatai

Norint pagerinti modelio aprašomas kompiliatorius su optimizacijos funkcija „SGD“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid. Naudojamas epochų skaičius 25 su 16 paveikslėlių padalijimo mokymui parametru (angl. *batch size*). Modelio mokymas truko 33 077 sekundes (9h 11 min 17 s). Galima matyti 32 pav., kad modelio mokymosi tikslumas stabiliai didėjo. Iš grafikų matoma, kad modelis nepersimoko, kadangi validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Iš modelio nuostolio grafiko galima matyti, kad validavimo kreivė su kiekviena epocha nėra mažėjanti, iš to galima spręsti, kad modelį reikėtų tobulinti.



32 pav. EKG segmentų požymių, parentų L1, šešto *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika

Iš 33 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 98,55 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveiksliukai („0“ klasė) teisingai suklasifikuoti 98,45 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,68 %. Modelis teisingai priskyrė 98,93 % normalaus sinusinio ritmo klasės duomenų bei 98,1 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 98,69 %, o širdies nepakankamumo – 98,39 %.

	precision	recall	f1-score	support
0	0.9893	0.9845	0.9869	3741
1	0.9810	0.9868	0.9839	3028
accuracy			0.9855	6769
macro avg	0.9851	0.9856	0.9854	6769
weighted avg	0.9855	0.9855	0.9855	6769

33 pav. EKG segmentų požymių, parentų L1, šešto *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.1.7. Geriausias pirmo Lagranžo rodiklio *ResNet* modelis

Atlikus skaičiavimus, visi modelių rezultatai matomi 2 lentelėje. Iš rezultatų matoma, kad geriausią bendrą tikslumą pasiekė antras modelis. F1 geriausią tikslumą, kuris apjungia jautrumo ir tikslumo rezultatus taip pat pasiekė antrasis modelis. Trumpiausiai mokėsi šeštasis modelis, tačiau jo tikslumai buvo žymiai prastesni už antro modelio, todėl geriausias modelis pirmo Lagranžo rodiklio paveikslėlių klasifikacijai yra antras modelis su padalijimo mokymui parametru 16, optimizacijos funkcija „Adam“ bei epochų skaičiumi 30.

2 lentelė. EKG segmentų požymių, paremtų L1 rodikliu, visų *ResNet* modelių tikslumo įverčiai, naudojant testavimo rinkinį

<i>ResNet</i> modelis	Bendras tikslumas	Tikslumas		Jautrumas		F1 tikslumas		Mokymo laikas (s)
		„0“ klasė	„1“ klasė	„0“ klasė	„1“ klasė	„0“ klasė	„1“ klasė	
Pirmas modelis	98,32 %	97,09 %	99,93 %	99,95 %	96,3 %	98,50 %	98,08 %	34 918
Antras modelis	99,2 %	99,19 %	99,2 %	99,3 %	99,07 %	99,25 %	99,14 %	39 510
Trečias modelis	66,52 %	62,11 %	98,19 %	99,6 %	26,53 %	76,51 %	41,78 %	36 715
Ketvirtas modelis	99,01 %	98,5 %	99,66 %	99,73 %	98,12 %	99,11 %	98,89 %	46 514
Penktas modelis	97,99 %	96,64 %	99,79 %	99,84 %	95,71 %	98,21 %	97,71 %	64 650
Šeštas modelis	98,55 %	98,93 %	98,1 %	98,45 %	98,68 %	98,69 %	98,39 %	33 077

Norint gauti optimalius pirmo Lagranžo rodiklio geriausio modelio rezultatus, mokymas ir validavimas bei testavimas atliekamas dar 4 kartus, o rezultatai vidurkinami. Rezultatai parodyti 34 pav. Vidutinis modelio mokymo laikas 38 614 s (10 h 43 min 34 s). Bendras vidutinis modelio tikslumas 0,99198 (99,198 %), vidutinis „0“ klasės jautrumas 0,99288 (99,288 %), vidutinis „1“ klasės jautrumas 0,99086 (99,086 %), vidutinis „0“ klasės tikslumas 0,99226 (99,226 %), vidutinis „1“ klasės tikslumas 0,99154 (99,154 %), vidutinis F1 „0“ klasės tikslumas 0,9926 (99,26 %), vidutinis F1 „1“ klasės tikslumas 0,99122 (99,122 %).

	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9919	0.9930	0.9925	3592	0	0.9929	0.9948	0.9939	3670
1	0.9920	0.9907	0.9914	3124	1	0.9938	0.9916	0.9927	3089
accuracy			0.9920	6716	accuracy			0.9933	6759
macro avg	0.9920	0.9919	0.9919	6716	macro avg	0.9934	0.9932	0.9933	6759
weighted avg	0.9920	0.9920	0.9920	6716	weighted avg	0.9933	0.9933	0.9933	6759
	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9908	0.9973	0.9940	3671	0	0.9919	0.9930	0.9925	3592
1	0.9967	0.9888	0.9927	3044	1	0.9920	0.9907	0.9914	3124
accuracy			0.9934	6715	accuracy			0.9920	6716
macro avg	0.9937	0.9931	0.9934	6715	macro avg	0.9920	0.9919	0.9919	6716
weighted avg	0.9935	0.9934	0.9934	6715	weighted avg	0.9920	0.9920	0.9920	6716
	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9948	0.9932	0.9940	3670					
1	0.9919	0.9938	0.9929	3089					
accuracy			0.9935	6759					
macro avg	0.9934	0.9935	0.9934	6759					
weighted avg	0.9935	0.9935	0.9935	6759					


34 pav. EKG segmentų požymių, paremtų L1 rodikliu, geriausio *ResNet* modelio penki tikslumo įverčiai, naudojant testavimo rinkinį

3.3.2. Dvimačių požymių, paremtų L2 rodikliu, klasifikavimas

3.3.2.1. Pirmo tinklo modelio rezultatai

Visi paveikslėliai naudojami *Resnet* treniravimui ir validavimui paduodami į tinklą originaliu 50x50 dydžio formatu. Toliau aprašomas likutinis blokas (angl. *identity block*), jog sluoksnio aktyvacija būtų perkeliama į gilesnį neuroninio tinklo sluoksnį bei sąsukų blokas, kuris sudaro esminį požymių

išskyrimo komponentą. Modeliui svoriai nėra nustatomi, kadangi naudojami atsitiktiniai svoriai. Galiausiai aprašomas kompiliatorius su optimizacijos funkcija „Adam“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 30 su 32 paveikslėlių padalijimo mokymui parametru. Modelio mokymas truko 28 602 sekundes (7 valandas 56 minutes 42 sekundes). Naudojami 2 pilnai sujungti sluoksniai su 2 „relu“ aktyvacijos funkcijomis atitinkamai su 256 ir 128 neuronų skaičiumi, ir išėjimo sluoksniu su „sigmoid“ aktyvacijos funkcija. Galima matyti 35 pav., kad modelio mokymo tikslumas stabiliai didėjo, o modelio nuostolis – svyravo. Iš grafikų matoma, kad modelis nepersimoko, kadangi nėra staigaus validavimo aibės kritimo. Galima pastebėti, kad modelis nėra geras ar mokytas pakankamai, kadangi tiek modelio tikslumo, tiek nuostolio grafikuose validacijos kreivė nėra nusistovėjusi, atitolusi nuo treniravimo aibės kreivės.



35 pav. EKG segmentų požymių, paremtų L2, pirmo *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika

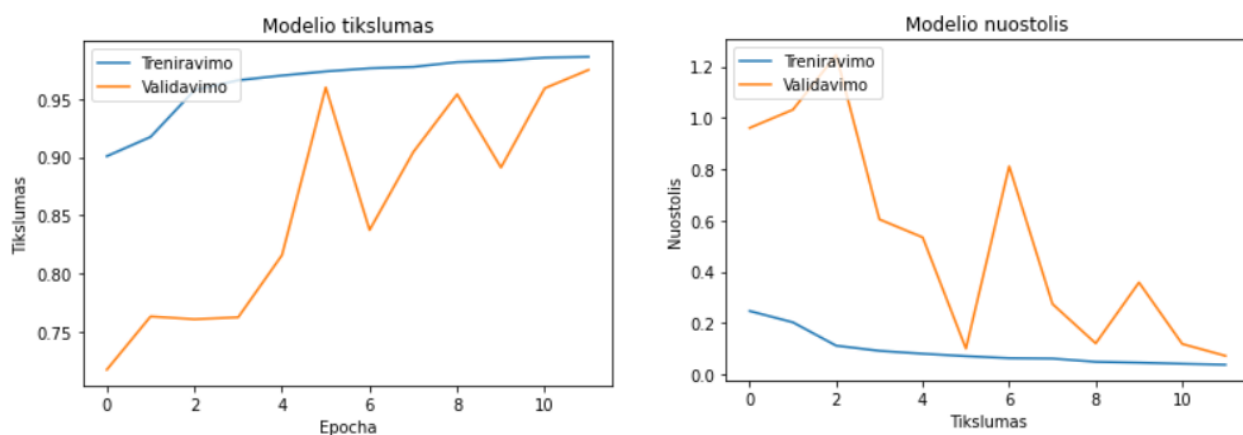
Iš 36 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 97 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 94 %. Modelis teisingai priskyrė 95 % normalaus sinusinio ritmo klasės duomenų bei 99 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 97 %, o širdies nepakankamumo – 97 %.

	precision	recall	f1-score	support
0	0.95	0.99	0.97	3710
1	0.99	0.94	0.97	3068
accuracy			0.97	6778
macro avg	0.97	0.97	0.97	6778
weighted avg	0.97	0.97	0.97	6778

36 pav. EKG segmentų požymių, paremtų L2, pirmo *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.2.2. Antro tinklo modelio rezultatai

Visi paveikslėliai naudojami *Resnet* treniravimui ir validavimui paduodami į tinklą originaliu 50x50 dydžio formatu. Toliau aprašomas likutinis blokas (angl. *identity block*), jog sluoksnio aktyvacija būtų perkeliama į gilesnį neuroninio tinklo sluoksnį bei sąsūkų blokas, kuris sudaro esminį požymių išskyrimo komponentą. Modeliui svorių nenustatome, tam naudojami atsitiktiniai svoriai. Vėliau aprašomas kompiliatorius su optimizacijos funkcija „Adam“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“ ir „sigmoid“ aktyvacijos funkcija. Nustatomas epochų skaičius 12 su 32 paveikslėlių padalijimo mokymui parametru, kadangi iš pirmo modelio nuostolio ir tikslumo rezultatų matoma, kad 12-oje epochoje pasiekiami geriausi rodikliai. Modelio mokymas truko 13 489 sekundes (3 valandas 44 minutes 49 sekundes). Naudojami 2 pilnai sujungti sluoksniai su 2 „relu“ aktyvacijos funkcijom bei atitinkamai su 256 ir 128 neuronų skaičiumi, ir išėjimo sluoksniu su „sigmoid“ aktyvacijos funkcija. Galima matyti 37 pav., kad modelio mokymo tikslumas stabiliai didėjo, o modelio nuostolis – mažėjo. Iš grafikų matoma, kad modelis nepersimoko, kadangi nėra staigaus atitolimo tarp validavimo bei treniravimo aibės. Galima pastebėti, kad modelis nėra mokytas pakankamai, kadangi tiek modelio tikslumo, tiek nuostolio grafikuose validacijos aibė nėra nusistovėjusi, o atitolusi nuo treniravimo aibės kreivės.



37 pav. EKG segmentų požymių, paremtų L2, antro *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 38 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 80 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 100 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 57 %. Modelis teisingai priskyrė 74 % normalaus sinusinio ritmo klasės duomenų bei 100 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 85 %, o širdies nepakankamumo – 72 %.

	precision	recall	f1-score	support
0	0.74	1.00	0.85	3710
1	1.00	0.57	0.72	3068
accuracy			0.80	6778
macro avg	0.87	0.78	0.79	6778
weighted avg	0.86	0.80	0.79	6778

38 pav. EKG segmentų požymių, paremtų L2, antro *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.2.3. Trečio tinklo modelio rezultatai

Norint sumažinti persimokymo tikimybę, pirmiausia buvo pakoreguotas treniravimo vaizdų imties pateikimas į neuroninių tinklų *ResNet* architektūros modelį. Pridedamas vertikalus vaizdo poslinkis su verte 0,2 bei horizontalus vaizdo poslinkis su verte 0,2, vaizdo iškraipymas išilgai ašiai (angl. *shear range*) su 0,15 verte, vaizdo sumažinimas ir padidinimas su 15 % verte, nustatoma, jog šie pokyčiai taikomi atsitiktiniams dvimačiams skaitmeniniams vaizdams. Visi paveikslėliai sumažinami iki 50x50 dydžio. Toliau aprašomas likutinis blokas (angl. *identity block*), jog sluoksnio aktyvacija būtų perkeliama į gilesnį neuroninio tinklo sluoksnį bei sąsūkų bloką, kuris sudaro esminį požymių išskyrimo komponentą. Modeliui svorių nenustatome, naudojami atsitiktiniai svoriai. Galiausiai aprašomas kompiliatorius su optimizacijos funkcija „Adam“. Naudojama nuostolių funkcija „binary crossentropy“ bei epochų skaičius 30 su 32 paveikslėlių padalijimo mokymui parametru. Modelio mokymas truko 37 027 sekundes (10 valandų 17 minučių ir 7 sekundes). Galima matyti 39 pav., kad modelio mokymo tikslumas stabiliai didėjo, o modelio nuostolis – mažėjo. Iš grafikų matoma, kad modelis nepersimoko, kadangi nėra staigaus validavimo bei treniravimo aibės kritimo. Galima pastebėti, kad modelis mokytas pakankamai, kadangi tiek modelio tikslumo, tiek nuostolio grafikuose validacijos aibė svyruoja apie tą pačią reikšmę.



39 pav. EKG segmentų požymių, paremtų L2, trečio *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika

Iš 40 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 95 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 95 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 94 %. Modelis teisingai priskyrė 95 % normalaus sinusinio ritmo klasės duomenų bei 94 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į

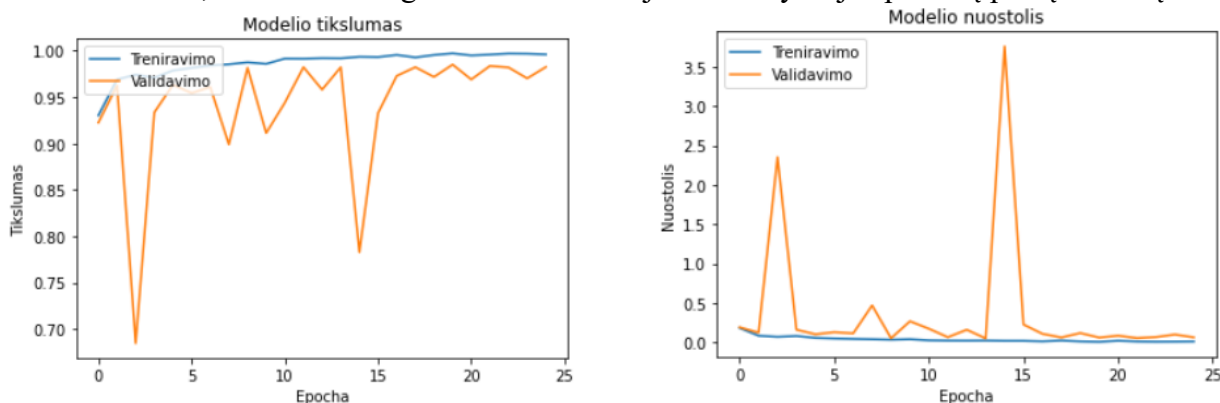
duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 95 %, o širdies nepakankamumo – 94 %.

	precision	recall	f1-score	support
0	0.95	0.95	0.95	3710
1	0.94	0.94	0.94	3068
accuracy			0.95	6778
macro avg	0.95	0.95	0.95	6778
weighted avg	0.95	0.95	0.95	6778

40 pav. EKG segmentų požymių, paremtų L2, trečio *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.2.4. Ketvirto tinklo modelio rezultatai

Visi paveikslėliai naudojami *Resnet* treniravimui ir validavimui paduodami į tinklą originaliu 50x50 dydžio formatu. Toliau aprašomas likutinis blokas (angl. identity block), jog sluoksnio aktyvacija būtų perkeliama į gilesnį neuroninio tinklo sluoksnį bei sąsukų blokas, kuris sudaro esminį požymių išskyrimo komponentą. Modeliui nustatomi „ImageNet“ svoriai. Galiausiai aprašomas kompiliatorius su optimizacijos funkcija „Adams“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“ bei epochų skaičius 25 su 32 paveikslėlių padalijimo mokymui parametru. Modelio mokymas truko 31 625 sekundes (8 h 47 min 5s). Galima matyti 41 pav., kad modelio apsimokymo tikslumas stabiliai didėjo, o modelio nuostolis – mažėjo. Iš grafikų matoma, kad modelis nepersimoko, kadangi nėra staigaus validavimo bei treniravimo aibės reikšmių kritimo. Galima pastebėti, kad modelis mokytas pakankamai, kadangi tiek modelio tikslumo, tiek nuostolio grafikuose validacijos aibė svyruoja aplink tą pačią reikšmę.



41 pav. EKG segmentų požymių, paremtų L2, ketvirto *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 42 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 98 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 97 %. Modelis teisingai priskyrė 98 % normalaus sinusinio ritmo klasės duomenų bei 99 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 99 %, o širdies nepakankamumo – 98 %.

	precision	recall	f1-score	support
0	0.99	0.98	0.99	3710
1	0.97	0.99	0.98	3068
accuracy			0.98	6778
macro avg	0.98	0.99	0.98	6778
weighted avg	0.98	0.98	0.98	6778

42 pav. EKG segmentų požymių, paremtų L2, ketvirto *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.2.5. Penkto tinklo modelio rezultatai

Norint pagerinti modelio tikslumą modeliui svorių nenustatome, kadangi naudojami atsitiktiniai svoriai. Aprašomas naujas kompiliatorius su optimizacijos funkcija „SGD“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 25 su 16 paveikslėlių padalijimo mokymui parametru (angl. *batch size*). Modelio mokymas truko 38 493 sekundes (10 h 41min 33s). Galima matyti 43 pav., kad modelio mokymo tikslumas stabiliai didėjo, o modelio nuostolis – svyravo. Iš grafikų matoma, kad modelis nepersimoko, kadangi nėra staigaus validavimo bei treniravimo aibės reikšmių kritimo. Galima pastebėti, kad modelis nėra geras ar mokytas pakankamai, kadangi tiek modelio tikslumo, tiek nuostolio grafikuose validacijos aibė svyruoja aplink tą pačią reikšmę. Taip pat galima matyti, kad validavimo ir treniravimo aibės yra atitulusios viena nuo kitos, todėl modelį dar reikėtų tobulinti.



43 pav. EKG segmentų požymių, paremtų L2, penkto *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 44 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 97,89 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 96,49 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 99,56 %. Modelis teisingai priskyrė 99,62 % normalaus sinusinio ritmo klasės duomenų bei 95,95 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 98,03 %, o širdies nepakankamumo – 97,72 %.

	precision	recall	f1-score	support
0	0.9962	0.9649	0.9803	3710
1	0.9595	0.9956	0.9772	3068
accuracy			0.9789	6778
macro avg	0.9779	0.9803	0.9788	6778
weighted avg	0.9795	0.9789	0.9789	6778

44 pav. EKG segmentų požymių, paremtų L2, penkto *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.2.6. Šešto tinklo modelio rezultatai

Norint pagerinti modelio tikslumą modeliui svorių nenustatome, kadangi naudojami atsitiktiniai svoriai. Aprašomas naujas kompiliatorius su optimizacijos funkcija „SGD“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 30 su 16 paveikslėlių padalijimo mokymui parametru (angl. *batch size*). Modelio mokymas truko 50 939 sekundes (14 h 8 min 59 s). Galima matyti 45 pav., kad modelio mokymo tikslumas stabiliai didėjo, o modelio nuostolis – svyravo. Iš grafikų matoma, kad modelis nepersimoko, kadangi nėra staigaus validavimo aibės tikslumo ar nuostolio reikšmių kritimo. Galima pastebėti, kad modelis nėra mokytas pakankamai, kadangi tiek modelio tikslumo, tiek nuostolio grafikuose validacijos kreivė svyruoja aplink tą pačią tikslumo reikšmę.



45 pav. EKG segmentų požymių, paremtų L2, šešto *ResNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika

Iš 46 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 99,13 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99,25 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,99 %. Modelis teisingai priskyrė 99,17 % normalaus sinusinio ritmo klasės duomenų bei 99,09 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 99,21 %, o širdies nepakankamumo – 99,04 %.

	precision	recall	f1-score	support
0	0.9917	0.9925	0.9921	3710
1	0.9909	0.9899	0.9904	3068
accuracy			0.9913	6778
macro avg	0.9913	0.9912	0.9912	6778
weighted avg	0.9913	0.9913	0.9913	6778

46 pav. EKG segmentų požymių, paremtų L2, šešto *ResNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.3.2.7. Geriausias antro Lagranžo rodiklio *ResNet* modelis

Atlikus skaičiavimus, visi modelių rezultatai matomi 3 lentelėje. Iš rezultatų matoma, kad geriausią bendrą tikslumą pasiekė šeštas modelis. F1 geriausią „0“ klasės tikslumą, kuris apjungia jautrumo ir tikslumo rezultatus pasiekė ketvirtas modelis, o „1“ klasės – šeštas. Geriausias modelis pirmo Lagranžo rodiklio paveikslėlių klasifikacijai yra šeštas modelis, kadangi pasiekė geriausią bendrą tikslumą bei „1“ klasės F1 tikslumą (laikoma, kad širdies nepakankamumo klasės tikslumas svarbesnis nei normalaus sinusinio ritmo). Geriausio modelio parametrai: padalijimo mokymui parametras 16, optimizacijos funkcija „SGD“ bei epochų skaičius 30. Trumpiausiai mokėsi antras modelis, tačiau jo tikslumai buvo žymiai prastesni už šešto modelio.

3 lentelė. EKG segmentų požymių, paremtų L2 rodikliu, visų *ResNet* modelių tikslumo įverčiai, naudojant testavimo rinkinį

<i>ResNet</i> modelis	Bendras tikslumas	Tikslumas		Jautrumas		F1 tikslumas		Mokymo laikas (s)
		„0“ klasė	„1“ klasė	„0“ klasė	„1“ klasė	„0“ klasė	„1“ klasė	
Pirmas modelis	97 %	95 %	99 %	99 %	94 %	97 %	97 %	28 602
Antras modelis	80 %	74 %	100 %	100 %	57 %	85 %	72 %	13 489
Trečias modelis	95 %	95 %	94 %	95 %	94 %	95 %	94 %	37 027
Ketvirtas modelis	98 %	99 %	97 %	98 %	99 %	99 %	98 %	31 625
Penktas modelis	97,89 %	99,62 %	95,95 %	96,49 %	99,56 %	98,03 %	97,72 %	38 493
Šeštas modelis	99,13 %	99,17 %	99,1 %	98,45 %	98,68 %	98,69 %	98,39 %	50 939

Norint gauti optimalius antro Lagranžo rodiklio geriausio modelio rezultatus, mokymas ir validavimas bei testavimas atliekamas dar 4 kartus, o rezultatai vidurkinami. Rezultatai parodyti 47 pav. Vidutinis modelio mokymo laikas 44 723 s (12 h 25 min 23 s). Bendras vidutinis modelio tikslumas 0,98616 (98,616 %), vidutinis „0“ klasės jautrumas 0,98792 (98,792 %), vidutinis „1“ klasės jautrumas 0,9843 (98,43 %), vidutinis „0“ klasės tikslumas 0,98678 (98,678 %), vidutinis „1“ klasės tikslumas 0,98546 (98,546 %), vidutinis F1 „0“ klasės tikslumas 0,98732 (98,732 %), vidutinis F1 „1“ klasės tikslumas 0,9852 (98,52 %).

	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9917	0.9925	0.9921	3710	0	0.9871	0.9836	0.9854	3710
1	0.9909	0.9899	0.9904	3068	1	0.9804	0.9846	0.9825	3068
accuracy			0.9913	6778	accuracy			0.9841	6778
macro avg	0.9913	0.9912	0.9912	6778	macro avg	0.9838	0.9841	0.9840	6778
weighted avg	0.9913	0.9913	0.9913	6778	weighted avg	0.9841	0.9841	0.9841	6778
	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9761	0.9914	0.9837	3710	0	0.9966	0.9717	0.9840	3710
1	0.9894	0.9707	0.9799	3068	1	0.9670	0.9961	0.9813	3068
accuracy			0.9820	6778	accuracy			0.9827	6778
macro avg	0.9827	0.9810	0.9818	6778	macro avg	0.9818	0.9839	0.9826	6778
weighted avg	0.9821	0.9820	0.9820	6778	weighted avg	0.9832	0.9827	0.9828	6778
	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9881	0.9947	0.9914	3593					
1	0.9938	0.9860	0.9898	3066					
accuracy			0.9907	6659					
macro avg	0.9909	0.9903	0.9906	6659					
weighted avg	0.9907	0.9907	0.9907	6659					


47 pav. EKG segmentų požymių, paremtų L2 rodikliu, geriausio *ResNet* modelio penki tikslumo įverčiai, naudojant testavimo rinkinį

3.4. Alexnet architektūra paremti dirbtinių neuroninių tinklų modeliai

3.4.1. Dvimačių požymių, paremtų L1 rodikliu, klasifikavimas

3.4.1.1. Pirmo tinklo modelio rezultatai

Visi paveikslėliai naudojami *AlexNet* treniravimui ir validavimui paduodami į tinklą originaliu 50x50 dydžio formatu. Modeliui svorių nenustatome, kadangi naudojami atsitiktiniai svoriai. Naudojamas kompiliatorius su optimizacijos funkcija „Adam“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 100 su 32 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,0001. Modelio mokymas truko 34 341 sekundes (9 h 32 min 21 s). 48 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas ir modelio nuostolis didėjant epochų skaičiui nenusistovėjo. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės abėjuose modelio nuostolio grafikuose nėra nutolusios viena nuo kitos, todėl modelis mokytas pakankamai, tačiau modelio nuostolio grafike galima matyti nuostolio reikšmių nestabilumą, kas rodo, kad modelį reikėtų tobulinti.



48 pav. EKG segmentų požymių, paremtų L1, pirmo *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 49 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 97,46 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 98,77 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 95,92 %. Modelis teisingai priskyrė 96,61 % normalaus sinusinio ritmo klasės duomenų bei 98,51 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 97,68 %, o širdies nepakankamumo – 97,2 %.

	precision	recall	f1-score	support
0	0.9877	0.9661	0.9768	3741
1	0.9592	0.9851	0.9720	3028
accuracy			0.9746	6769
macro avg	0.9734	0.9756	0.9744	6769
weighted avg	0.9749	0.9746	0.9746	6769

49 pav. EKG segmentų požymių, paremtų L1, pirmo *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.1.2. Antro tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą naudojamas kompiliatorius su optimizacijos funkcija „Adam“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 100 su 32 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,00001. Modelio mokymas truko 34 893 sekundes (9 h 41 min 33 s). 50 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas ir modelio nuostolis didėjant epochų skaičiui nenusistovėjo. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės abejuose modelio nustolio grafike nėra nutolusios viena nuo kitos, todėl modelis mokytas pakankamai.



50 pav. EKG segmentų požymių, paremtų L1, antro *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 51 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 99,07 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99,52 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,51 %. Modelis teisingai priskyrė 98,81 % normalaus sinusinio ritmo klasės duomenų bei 99,4 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 99,16 %, o širdies nepakankamumo – 98,96 %.

	precision	recall	f1-score	support
0	0.9881	0.9952	0.9916	3741
1	0.9940	0.9851	0.9896	3028
accuracy			0.9907	6769
macro avg	0.9910	0.9902	0.9906	6769
weighted avg	0.9907	0.9907	0.9907	6769

51 pav. EKG segmentų požymių, paremtų L1, antro *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.1.3. Trečio tinklo modelio rezultatai

Visi paveikslėliai naudojami *AlexNet* treniravimui ir validavimui paduodami į tinklą originaliu 50x50 dydžio formatu. Modeliui svorių nenustatome, kadangi naudojami atsitiktiniai svoriai. Naudojamas kompiliatorius su optimizacijos funkcija „Adam“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetainiai klasei. Naudojamas epochų skaičius 100 su 32 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,000001. Modelio mokymas truko 35 236 sekundes (9 h 47 min 16 s). 52 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – stabilų. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės abėjuose grafikuose nėra nutolusios viena nuo kitos, todėl modelis mokytas pakankamai.



52 pav. EKG segmentų požymių, paremtų L1, trečio *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 53 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 99,08 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99,55 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,51 %. Modelis teisingai priskyrė 98,81 % normalaus sinusinio ritmo klasės duomenų bei 99,43 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 99,17 %, o širdies nepakankamumo – 98,97 %.

	precision	recall	f1-score	support
0	0.9881	0.9955	0.9917	3741
1	0.9943	0.9851	0.9897	3028
accuracy			0.9908	6769
macro avg	0.9912	0.9903	0.9907	6769
weighted avg	0.9909	0.9908	0.9908	6769

53 pav. EKG segmentų požymių, paremtų L1, trečio *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.1.4. Ketvirto tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą, naudojamas kompiliatorius su optimizacijos funkcija „Adam“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 100 su 16 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,0001. Modelio mokymas truko 35 864 sekundes (9 h 57 min 44 s). 54 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – mažėjančią. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės abėjuose grafikuose nėra nutolusios viena nuo kitos, todėl modelis mokytas pakankamai.



54 pav. EKG segmentų požymių, parentų L1, ketvirto *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 55 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 97,77 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 96,87 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,88 %. Modelis teisingai priskyrė 99,07 % normalaus sinusinio ritmo klasės duomenų bei 96,24 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 97,96 %, o širdies nepakankamumo – 97,54 %.

	precision	recall	f1-score	support
0	0.9907	0.9687	0.9796	3741
1	0.9624	0.9888	0.9754	3028
accuracy			0.9777	6769
macro avg	0.9765	0.9787	0.9775	6769
weighted avg	0.9780	0.9777	0.9777	6769

55 pav. EKG segmentų požymių, parentų L1, ketvirto *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.1.5. Penkto tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą, naudojamas kompiliatorius su optimizacijos funkcija „Adam“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“. Naudojamas epochų skaičius 100 su 16 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,00001. Modelio mokymas truko 36 581 sekundes (10 h 9 min 41 s). 56 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – stabilų. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės tikslumo grafike nėra nutolusios viena nuo kitos, todėl modelis mokytas pakankamai, tačiau nuostolio grafike, nuostolio validavimo aibė nemažėjo kartu su treniravimo aibe, todėl tokį modelį dar reikėtų tobulinti.



56 pav. EKG segmentų požymių, paremtų L1, penkto *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 57 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 98,98 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 98,9 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 99,08 %. Modelis teisingai priskyrė 99,25 % normalaus sinusinio ritmo klasės duomenų bei 98,65 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 99,08 %, o širdies nepakankamumo – 98,86 %.

	precision	recall	f1-score	support
0	0.9925	0.9890	0.9908	3741
1	0.9865	0.9908	0.9886	3028
accuracy			0.9898	6769
macro avg	0.9895	0.9899	0.9897	6769
weighted avg	0.9898	0.9898	0.9898	6769

57 pav. EKG segmentų požymių, paremtų L1, penkto *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.1.6. Šešto tinklo modelio rezultatai

Visi paveikslėliai naudojami *AlexNet* treniravimui ir validavimui paduodami į tinklą originaliu 50x50 dydžio formatu. Modeliui svorių nenustatome, kadangi naudojami atsitiktiniai svoriai. Naudojamas kompiliatorius su optimizacijos funkcija „Adam“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“. Naudojamas epochų skaičius 100 su 16 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,000001. Modelio mokymas truko 37 006 sekundes (10 h 16 min 46 s). 58 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – mažėjančią. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės abejuose grafikuose nėra nutolusios viena nuo kitos, todėl modelis mokytas pakankamai.



58 pav. EKG segmentų požymių, paremtų L1, šešto *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 59 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 98,55 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99,12 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,51 %. Modelis teisingai priskyrė 98,8 % normalaus sinusinio ritmo klasės duomenų bei 98,91 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 98,96 %, o širdies nepakankamumo – 98,71 %.

	precision	recall	f1-score	support
0	0.9880	0.9912	0.9896	3741
1	0.9891	0.9851	0.9871	3028
accuracy			0.9885	6769
macro avg	0.9885	0.9882	0.9883	6769
weighted avg	0.9885	0.9885	0.9885	6769

59 pav. EKG segmentų požymių, paremtų L1, šešto *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.1.7. Septinto tinklo modelio rezultatai

Visi paveikslėliai naudojami *AlexNet* treniravimui ir validavimui paduodami į tinklą originaliu 50x50 dydžio formatu. Modeliui svorių nenustatome, kadangi naudojami atsitiktiniai svoriai. Siekiant pagerinti modelio tikslumą naudojamas kompiliatorius su optimizacijos funkcija „SGD“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“. Naudojamas epochų skaičius 100 su 16 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,00001. Modelio mokymas truko 39 300 sekundes (10 h 55 min). 60 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – mažėjančią. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės abejuose grafikuose nėra nutolusios viena nuo kitos, todėl modelis mokytas pakankamai.



60 pav. Pirmo Lagranžo rodiklio septinto *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą rezultatai

Iš 61 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 98,26 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 98,34 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,15 %. Modelis teisingai priskyrė 98,5 % normalaus sinusinio ritmo klasės duomenų bei 97,96 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 98,42 %, o širdies nepakankamumo – 98,05 %.

	precision	recall	f1-score	support
0	0.9850	0.9834	0.9842	3741
1	0.9796	0.9815	0.9805	3028
accuracy			0.9826	6769
macro avg	0.9823	0.9825	0.9824	6769
weighted avg	0.9826	0.9826	0.9826	6769

61 pav. EKG segmentų požymių, paremtų L1, septinto *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.1.8. Geriausias pirmo Lagranžo rodiklio *AlexNet* modelis

Atlikus skaičiavimus, visi modelių rezultatai matomi 4 lentelėje. Iš rezultatų matoma, kad geriausią bendrą tikslumą pasiekė trečias modelis. Abiejų klasių geriausią, jautrumą, F1 tikslumą geriausią „0“ klasės tikslumą, kuris apjungia jautrumo ir tikslumo rezultatus taip pat pasiekė trečias modelis, todėl jis laikomas geriausiu modeliu pirmo Lagranžo rodiklio skaitmeninių vaizdų klasifikacijai. Geriausio modelio parametrai: padalijimo mokymui parametras 32, mokymosi spartos parametras 0,000001, optimizacijos funkcija „Adam“ bei epochų skaičius 100. Trumpiausiai mokėsi pirmas modelis, tačiau jo tikslumai buvo žymiai prastesni už šešto modelio.

4 lentelė. EKG segmentų požymių, paremtų L1 rodikliu, visų AlexNet modelių tikslumo įverčiai, naudojant testavimo rinkinį

ResNet modelis	Bendras tikslumas	Tikslumas		Jautrumas		F1 tikslumas		Mokymo laikas (s)
		„0“ klasė	„1“ klasė	„0“ klasė	„1“ klasė	„0“ klasė	„1“ klasė	
Pirmas modelis	97,46 %	98,77 %	95,92 %	96,61 %	98,51 %	97,68 %	97,2 %	34 341
Antras modelis	99,07 %	98,81 %	99,4 %	99,52 %	98,51 %	99,16 %	98,86 %	34 893
Trečias modelis	99,08 %	98,81 %	99,43 %	99,55 %	98,51 %	99,17 %	98,87 %	35 236
Ketvirtas modelis	97,77 %	99,07 %	96,24 %	96,87 %	98,88 %	97,96 %	97,54 %	35 864
Penktas modelis	98,98 %	99,25 %	98,65 %	98,9 %	99,08 %	99,08 %	98,86 %	36 581
Šeštas modelis	98,85 %	98,8 %	98,91 %	99,12 %	98,51 %	98,96 %	98,71 %	37 006
Septintas modelis	98,26 %	98,5 %	97,96 %	98,34 %	98,15 %	98,42 %	98,05 %	39 300

Norint gauti optimalius antro Lagranžo rodiklio geriausio modelio rezultatus, mokymas ir validavimas bei testavimas atliekamas dar 4 kartus, o rezultatai vidurkinami. Rezultatai parodyti 62 pav. Vidutinis modelio mokymo laikas 33 225 s (9 h 13 min 45 s). Bendras vidutinis modelio tikslumas 0,99104 (99,104 %), vidutinis „0“ klasės jautrumas 0,99132 (99,132 %), vidutinis „1“ klasės jautrumas 0,99074 (99,074 %), vidutinis „0“ klasės tikslumas 0,99228 (99,228 %), vidutinis „1“ klasės tikslumas 0,9895 (98,95 %), vidutinis F1 „0“ klasės tikslumas 0,99178 (99,178 %), vidutinis F1 „1“ klasės tikslumas 0,9901 (99,01 %).

	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9881	0.9955	0.9917	3741	0	0.9910	0.9929	0.9920	3670
1	0.9943	0.9851	0.9897	3028	1	0.9916	0.9893	0.9904	3089
accuracy			0.9908	6769	accuracy			0.9913	6759
macro avg	0.9912	0.9903	0.9907	6769	macro avg	0.9913	0.9911	0.9912	6759
weighted avg	0.9909	0.9908	0.9908	6769	weighted avg	0.9913	0.9913	0.9913	6759
	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9962	0.9880	0.9921	3671	0	0.9905	0.9924	0.9914	3670
1	0.9857	0.9954	0.9905	3044	1	0.9909	0.9887	0.9898	3089
accuracy			0.9914	6715	accuracy			0.9907	6759
macro avg	0.9909	0.9917	0.9913	6715	macro avg	0.9907	0.9905	0.9906	6759
weighted avg	0.9914	0.9914	0.9914	6715	weighted avg	0.9907	0.9907	0.9907	6759
	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9908	0.9926	0.9917	3670					
1	0.9912	0.9890	0.9901	3089					
accuracy			0.9910	6759					
macro avg	0.9910	0.9908	0.9909	6759					
weighted avg	0.9910	0.9910	0.9910	6759					

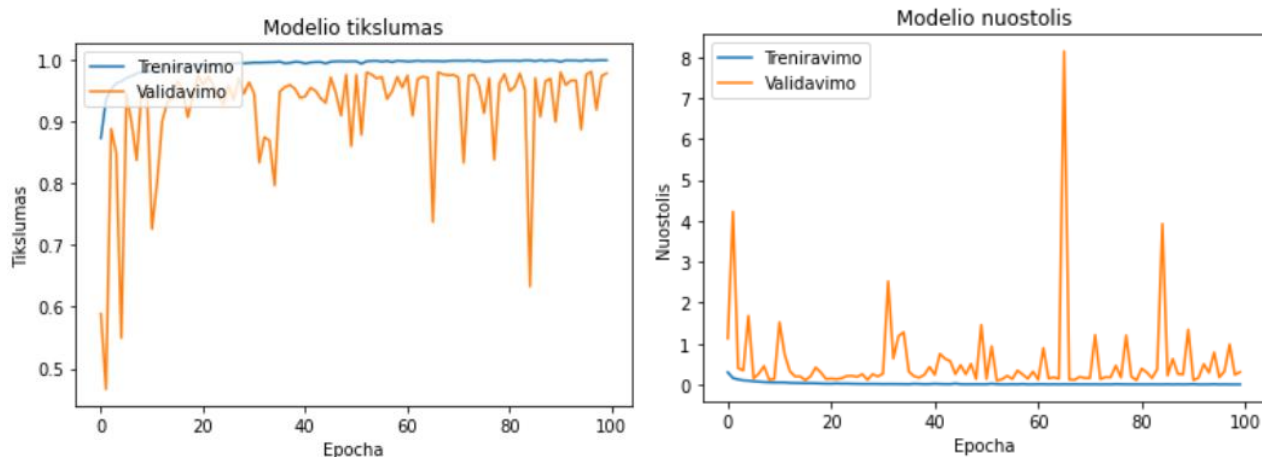
62 pav. EKG segmentų požymių, paremtų L1 rodikliu, geriausio AlexNet modelio penki tikslumo įverčiai, naudojant testavimo rinkinį

3.4.2. Dvimačių požymių, paremtų L2 rodikliu, klasifikavimas

3.4.2.1. Pirmo tinklo modelio rezultatai

Visi paveikslėliai naudojami AlexNet treniravimui ir validavimui paduodami į tinklą originaliu 50x50 dydžio formatu. Modeliui svorių nenustatome, kadangi naudojami atsitiktiniai svoriai. Naudojamas

kompiliatorius su optimizacijos funkcija „Adam“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“. Naudojamas epochų skaičius 100 su 32 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,0001. Modelio mokymas truko 34 232 sekundes (9 h 30 min 32 s). 63 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – mažėjančią. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį.



63 pav. EKG segmentų požymių, paremtų L2, pirmo *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika

Iš 64 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 97,83 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 97,68 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,01 %. Modelis teisingai priskyrė 98,34 % normalaus sinusinio ritmo klasės duomenų bei 97,22 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 98,01 %, o širdies nepakankamumo – 97,61 %.

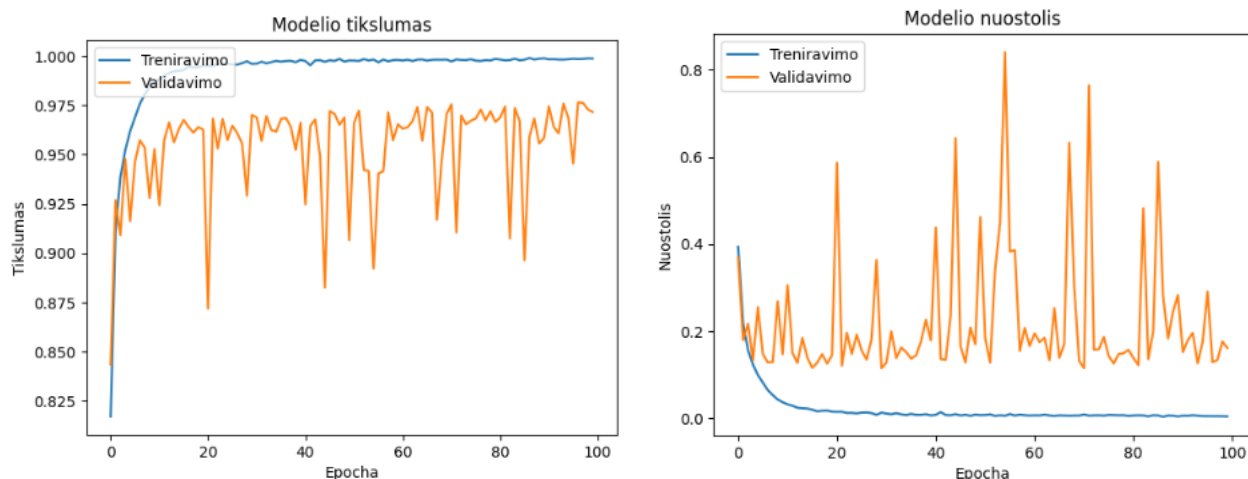
	precision	recall	f1-score	support
0	0.9834	0.9768	0.9801	3710
1	0.9722	0.9801	0.9761	3068
accuracy			0.9783	6778
macro avg	0.9778	0.9785	0.9781	6778
weighted avg	0.9784	0.9783	0.9783	6778

64 pav. EKG segmentų požymių, paremtų L2, pirmo *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.2.2. Antro tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą naudojamas kompiliatorius su optimizacijos funkcija „Adam“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 100 su 32 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,00001. Modelio mokymas truko 34 701 sekundes (9 h 38 min 21 s). Iš 65 pav. grafikų matoma, kad modelis nepersimoko, modelio tikslumo

grafike validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Modelio nuostolio grafike galima matyti nusolio reikšmių nestabilumą, kas rodo, kad modelį reikėtų tobulinti.



65 pav. EKG segmentų požymių, paremtų L2, antro *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika

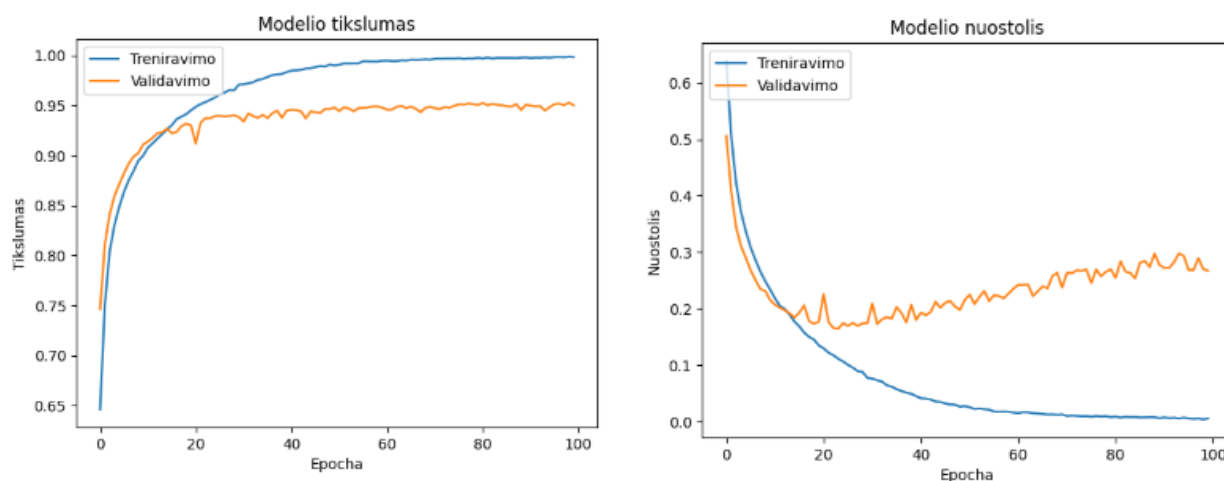
Iš 66 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 97,29 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 96,44 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,31 %. Modelis teisingai priskyrė 98,57 % normalaus sinusinio ritmo klasės duomenų bei 95,81 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 97,49 %, o širdies nepakankamumo – 97,04 %.

	precision	recall	f1-score	support
0	0.9857	0.9644	0.9749	3710
1	0.9581	0.9831	0.9704	3068
accuracy			0.9729	6778
macro avg	0.9719	0.9737	0.9727	6778
weighted avg	0.9732	0.9729	0.9729	6778

66 pav. EKG segmentų požymių, paremtų L2, antro *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.2.3. Trečio tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą naudojamas kompiliatorius su optimizacijos funkcija „Adam“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“. Naudojamas epochų skaičius 100 su 32 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,000001. Modelio mokymas truko 35 732 sekundes (9 h 55 min 32 s). 67 pav. pavaizduota modelio tikslumo ir nuostolio grafikas. Iš nuostolio grafiko galima matyti, kad modelis netinkamas, kadangi didėjant epochų skaičiui, nuostolis taip pat didėja.



67 pav. EKG segmentų požymių, paremtų L2, trečio *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 68 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 95,34 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 95,36 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 95,31 %. Modelis teisingai priskyrė 96,09 % normalaus sinusinio ritmo klasės duomenų bei 94,44 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 95,73 %, o širdies nepakankamumo – 94,87 %.

	precision	recall	f1-score	support
0	0.9609	0.9536	0.9573	3710
1	0.9444	0.9531	0.9487	3068
accuracy			0.9534	6778
macro avg	0.9527	0.9534	0.9530	6778
weighted avg	0.9534	0.9534	0.9534	6778

68 pav. EKG segmentų požymių, paremtų L2, trečio *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.2.4. Ketvirto tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą naudojamas kompiliatorius su optimizacijos funkcija „Adam“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 100 su 16 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,0001. Modelio mokymas truko 35 732 sekundes (9 h 55 min 32 s). 69 pav. pavaizduota modelio tikslumo ir nuostolio grafikas. Iš grafikų matoma, kad modelis nepersimoko, modelio tikslumo grafike validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Modelio nuostolio grafike galima matyti nusolio reikšmių nestabilumą, kas rodo, kad modelį reikėtų tobulinti.



69 pav. EKG segmentų požymių, paremtų L2, ketvirto *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 70 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 95,22 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 95,42 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 94,98 %. Modelis teisingai priskyrė 95,83 % normalaus sinusinio ritmo klasės duomenų bei 94,49 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 95,62 %, o širdies nepakankamumo – 94,73 %.

	precision	recall	f1-score	support
0	0.9583	0.9542	0.9562	3710
1	0.9449	0.9498	0.9473	3068
accuracy			0.9522	6778
macro avg	0.9516	0.9520	0.9518	6778
weighted avg	0.9522	0.9522	0.9522	6778

70 pav. EKG segmentų požymių, paremtų L2, ketvirto *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.2.5. Penkto tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą naudojamas kompiliatorius su optimizacijos funkcija „Adam“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“. Naudojamas epochų skaičius 100 su 16 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,00001. Modelio mokymas truko 36 606 sekundes (10 h 10 min 6 s). 71 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – mažėjančią. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės abėjuose grafikuose nėra nutolusios viena nuo kitos, todėl modelis mokyta pakankamai.



71 pav. EKG segmentų požymių, paremtų L2, penkto *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 72 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 96,86 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 99,22 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 94 %. Modelis teisingai priskyrė 95,24 % normalaus sinusinio ritmo klasės duomenų bei 99 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 97,19 %, o širdies nepakankamumo – 96,44 %.

	precision	recall	f1-score	support
0	0.9524	0.9922	0.9719	3710
1	0.9900	0.9400	0.9644	3068
accuracy			0.9686	6778
macro avg	0.9712	0.9661	0.9681	6778
weighted avg	0.9694	0.9686	0.9685	6778

72 pav. EKG segmentų požymių, paremtų L2, penkto *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.2.6. Šešto tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą naudojamas kompiliatorius su optimizacijos funkcija „Adam“ dėl to, kad iš literatūros apžvalgos, su juo gaunami geriausi rezultatai. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“, kadangi ji tinkama dvejetaini klasei. Naudojamas epochų skaičius 100 su 16 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,000001. Modelio mokymas truko 37 444 sekundes (10 h 24 min 4 s). 73 pav. pavaizduota modelio tikslumo ir nuostolio grafikas. Iš nuostolio grafiko galima matyti, kad modelis netinkamas, kadangi didėjant epochų skaičiui, nuostolis taip pat didėja.



73 pav. EKG segmentų požymių, paremtų L2, šešto *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika

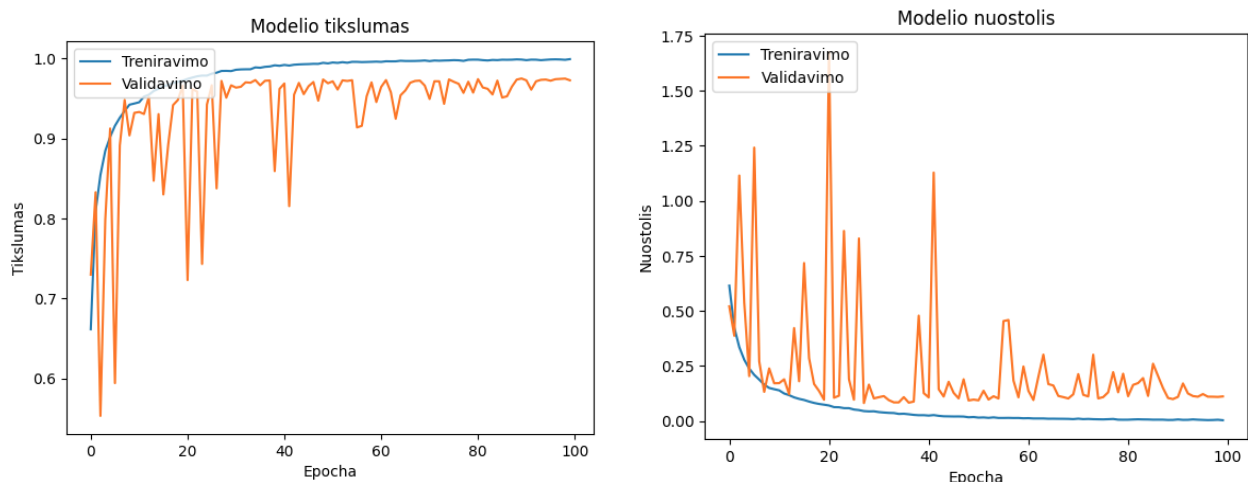
Iš 74 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 98,56 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 98,83 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 98,23 %. Modelis teisingai priskyrė 98,53 % normalaus sinusinio ritmo klasės duomenų bei 98,59 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 98,68 %, o širdies nepakankamumo – 98,41 %.

	precision	recall	f1-score	support
0	0.9853	0.9883	0.9868	3669
1	0.9859	0.9823	0.9841	3055
accuracy			0.9856	6724
macro avg	0.9856	0.9853	0.9854	6724
weighted avg	0.9856	0.9856	0.9856	6724

74 pav. EKG segmentų požymių, paremtų L2, šešto *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.2.7. Septinto tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą naudojamas kompiliatorius su optimizacijos funkcija „SGD“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“. Naudojamas epochų skaičius 100 su 16 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,0001. Modelio mokymas truko 39 312 sekundes (10 h 55 min 12 s). 75 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – mažėjančią. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės abijuose grafikuose nėra nutolusios viena nuo kitos, todėl modelis mokytyas pakankamai.



75 pav. EKG segmentų požymių, paremtų L2, septinto *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika


Iš 76 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 97,39 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 97,82 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 96,87 %. Modelis teisingai priskyrė 97,42 % normalaus sinusinio ritmo klasės duomenų bei 97,35 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 97,62 %, o širdies nepakankamumo – 97,11 %.

	precision	recall	f1-score	support
0	0.9742	0.9782	0.9762	3710
1	0.9735	0.9687	0.9711	3068
accuracy			0.9739	6778
macro avg	0.9738	0.9734	0.9736	6778
weighted avg	0.9739	0.9739	0.9739	6778

76 pav. EKG segmentų požymių, paremtų L2, septinto *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.2.8. Aštunto tinklo modelio rezultatai

Siekiant pagerinti modelio tikslumą naudojamas kompiliatorius su optimizacijos funkcija „SGD“. Naudojama nuostolių funkcija „binary crossentropy“, aktyvacijos funkcija „sigmoid“. Naudojamas epochų skaičius 100 su 16 paveikslėlių padalijimo mokymui parametru. Nustatytas mokymo spartos parametras 0,00001. Modelio mokymas truko 39 561 sekundes (10 h 59 min 21 s). 77 pav. pavaizduota modelio tikslumo ir nuostolio grafikas, iš jų galima matyti, kad modelio mokymosi tikslumas išlaikė augimo tendenciją, o modelio nuostolis – mažėjančią. Iš grafikų matoma, kad modelis nepersimoko, validavimo aibės tikslumas nesikeičia tik svyruoja aplink tą patį dydį. Validavimo ir treniravimo aibės abėjuose grafikuose nėra nutolusios viena nuo kitos, todėl modelis mokyta pakankamai.



77 pav. EKG segmentų požymių, paremtų L2, aštunto *AlexNet* modelio mokymosi tikslumo bei nuostolio per epochą dinamika

Iš 78 pav. rezultatų matoma, kad modelis teisingai suklasifikuoja 96 % dvimačių skaitmeninių vaizdų. Normalaus sinusinio ritmo klasės paveikslukai („0“ klasė) teisingai suklasifikuoti 96,01 % tikslumu, o širdies nepakankamumo klasės („1“ klasės) – 95,99 %. Modelis teisingai priskyrė 96,66 % normalaus sinusinio ritmo klasės duomenų bei 95,22 % širdies nepakankamumo klasės duomenų. Atsižvelgiant į duomenų balansą kiekvienoje klasėje normalaus sinusinio ritmo klasės tikslumas 96,34 %, o širdies nepakankamumo – 95,6 %.

	precision	recall	f1-score	support
0	0.9666	0.9601	0.9634	3710
1	0.9522	0.9599	0.9560	3068
accuracy			0.9600	6778
macro avg	0.9594	0.9600	0.9597	6778
weighted avg	0.9601	0.9600	0.9600	6778

78 pav. EKG segmentų požymių, paremtų L2, aštunto *AlexNet* modelio tikslumo įverčiai, naudojant testavimo rinkinį

3.4.2.9. Geriausias antro Lagranžo rodiklio *AlexNet* modelis

Atlikus skaičiavimus, visi modelių rezultatai matomi 5 lentelėje. Iš rezultatų matoma, kad geriausią bendrą tikslumą pasiekė šeštas modelis. F1 geriausią abiejų klasių tikslumą, kuris apjungia jautrumo ir tikslumo rezultatus pasiekė taip pat pasiekė šeštas modelis, todėl geriausias modelis pirmo Lagranžo rodiklio paveikslėlių klasifikacijai yra šeštas modelis. Geriausio modelio parametrai: padalijimo mokymui parametras 16, mokymosi spartos parametras 0,000001, optimizacijos funkcija „Adam“ bei epochų skaičius 100. Trumpiausiai pirmas modelis, tačiau jo tikslumai buvo žymiai prastesni už šešto modelio.

5 lentelė. EKG segmentų požymių, paremtų L2 rodikliu, visų *AlexNet* modelių tikslumo įverčiai, naudojant testavimo rinkinį

ResNet modelis	Bendras tikslumas	Tikslumas		Jautrumas		F1 tikslumas		Mokymo laikas (s)
		„0“ klasė	„1“ klasė	„0“ klasė	„1“ klasė	„0“ klasė	„1“ klasė	
Pirmas modelis	97,83 %	98,34 %	97,22 %	97,68 %	98,01 %	98,01 %	97,61 %	34 232
Antras modelis	97,29 %	98,57 %	95,81 %	96,44 %	98,31 %	97,49 %	97,04	34 701
Trečias modelis	95,34 %	96,09 %	94,44 %	95,36 %	95,31 %	95,73 %	94,87 %	35 732
Ketvirtas modelis	95,22 %	95,83 %	94,49 %	95,42 %	94,98 %	95,62 %	94,73 %	35 732
Penktas modelis	96,86 %	95,24 %	99 %	99,22 %	94 %	97,19 %	96,44 %	36 606
Šeštas modelis	98,56 %	98,53 %	98,59 %	98,83 %	98,23 %	98,68 %	98,41 %	37 444
Septintas modelis	97,39 %	97,42 %	97,35 %	97,82 %	96,87 %	97,62 %	97,11 %	39 312
Aštuntas modelis	96 %	96,66 %	95,22 %	96,01 %	95,99 %	96,34 %	95,6 %	39 561

Norint gauti optimalius antro Lagranžo rodiklio geriausio modelio rezultatus, mokymas ir validavimas bei testavimas atliekamas dar 4 kartus, o rezultatai vidurkinami. Rezultatai parodyti 79 pav. Vidutinis modelio mokymo laikas 35 596 s (9 h 53 min 16 s). Bendras vidutinis modelio tikslumas 0,98722 (98,722 %), vidutinis „0“ klasės jautrumas 0,9881 (98,81 %), vidutinis „1“ klasės jautrumas 0,98696 (98,696 %), vidutinis „0“ klasės tikslumas 0,9892 (98,92 %), vidutinis „1“ klasės tikslumas 0,98546 (98,546 %), vidutinis F1 „0“ klasės tikslumas 0,98862 (98,862 %), vidutinis F1 „1“ klasės tikslumas 0,98672 (98,672 %).

	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9964	0.9796	0.9879	3671	0	0.9871	0.9927	0.9899	3694
1	0.9759	0.9957	0.9857	3044	1	0.9911	0.9843	0.9877	3049
accuracy			0.9869	6715	accuracy			0.9889	6743
macro avg	0.9861	0.9876	0.9868	6715	macro avg	0.9891	0.9885	0.9888	6743
weighted avg	0.9871	0.9869	0.9869	6715	weighted avg	0.9889	0.9889	0.9889	6743
	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9869	0.9937	0.9903	3791	0	0.9857	0.9881	0.9869	3710
1	0.9920	0.9834	0.9877	3018	1	0.9856	0.9827	0.9842	3068
accuracy			0.9891	6809	accuracy			0.9857	6778
macro avg	0.9894	0.9886	0.9890	6809	macro avg	0.9857	0.9854	0.9856	6778
weighted avg	0.9892	0.9891	0.9891	6809	weighted avg	0.9857	0.9857	0.9857	6778
	precision	recall	f1-score	support		precision	recall	f1-score	support
0	0.9844	0.9919	0.9881	3566					
1	0.9902	0.9812	0.9856	2974					
accuracy			0.9870	6540					
macro avg	0.9873	0.9865	0.9869	6540					
weighted avg	0.9870	0.9870	0.9870	6540					

79 pav. EKG segmentų požymių, paremtų L2 rodikliu, geriausio *AlexNet* modelio penki tikslumo įverčiai, naudojant testavimo rinkinį

3.5. Mašininio mokymo metodų rezultatų palyginimas

Geriausios dirbtinių neuroninių tinklų *ResNet* ir *AlexNet* architektūrų modeliai dvimačiams skaitmeniniams vaizdams, paremtiems Lagranžo pirmu ir antru rodikliais, kartu su suvidurkintais

tikslumo įverčiais pavaizduoti 6 lentelėje. Geriausias modelis, pasiekiantis didžiausią bendrą tikslumą (99,198 %), tikslumą bei F1 tikslumą, tiek širdies nepakankamumo, tiek normalaus sinusinio ritmo klasei, yra *ResNet* architektūros modelis, klasifikuotas dvimačiais skaitmeniniais vaizdais, paremtais pirmu Lagranžo rodikliu. Modeliui nustatyti parametrai: padalijimo mokymui parametras 16, optimizacijos funkcija „Adam“ bei epochų skaičius 30. Tiek *ResNet*, tiek *AlexNet* architektūrų modeliai, geriau klasifikavo pirmu Lagranžo rodikliu paremtus dvimačius skaitmeninius vaizdus, tačiau antru Lagranžo rodikliu paremti dvimačiai skaitmeniniai vaizdai taip pat pasiekė aukštą klasifikavimo tikslumą abejomis dirbtinių neuroninių tinklų architektūromis. Atsižvelgiant į tikslumą įverčius pirmas Lagranžo rodiklis yra pranašesnis už antrą Lagranžo rodiklį, norint klasifikuoti širdies nepakankamumo ir normalaus sinusinio ritmo klases.

6 lentelė. Pirmu ir antru Lagranžo rodikliu paremtų dvimačių skaitmeninių vaizdų klasifikavimo dirbtiniais neuroniniais tinklais geriausių *AlexNet* ir *ResNet* architektūrų modelių tikslumo įverčiai

Duomenys	Modelis	Bendras tikslumas	Tikslumas		Jautrumas		F1 tikslumas	
			„0“ klasė	„1“ klasė	„0“ klasė	„1“ klasė	„0“ klasė	„1“ klasė
L1 skaitmeninių vaizdų	<i>ResNet</i>	99,198 %	99,288 %	99,086 %	99,226 %	99,154 %	99,26 %	99,122 %
L2 skaitmeninių vaizdų	<i>ResNet</i>	98,616 %	98,792 %	98,43 %	98,678 %	98,546 %	98,732 %	98,52 %
L1 skaitmeninių vaizdų	<i>AlexNet</i>	99,104 %	99,132 %	99,074 %	99,228 %	98,95 %	99,178 %	99,01 %
L2 skaitmeninių vaizdų	<i>AlexNet</i>	98,722 %	98,81 %	98,696 %	98,92 %	98,546 %	98,862 %	98,672 %

Kiekvienas modelio mokymosi laikas buvo skirtingas. *ResNet* modelio vidutinis mokymo laikas su pirmu Lagranžo rodikliu paremtais vaizdais 10 h 43 min 34 s, o su antru Lagranžo rodikliu paremtais vaizdais – 12 h 25 min 23 s. *AlexNet* modelio vidutinis mokymo laikas su pirmu Lagranžo rodikliu paremtais vaizdais 9 h 13 min 45 s, o su antru Lagranžo rodikliu paremtais vaizdais – 9 h 53 min 16 s. Jei realiuose taikymuose būtų aktualus dažnas tinklo mokymas, svarbus trumpesnis mokymosi laikas, optimalus sprendimas būtų naudoti geriausią *AlexNet* architektūros modelį su pirmu Lagranžo rodikliu paremtais skaitmeniniais vaizdais, kadangi tokio tinklo modelis mokosi 1h 29 min 49 s trumpiau nei geriausias modelis bei pasiekiamas bendras tikslumas yra mažesnis tik 0,094 %. Jeigu tinklo mokymas nėra dažnas, tai rekomenduojama naudoti geriausią projekte išskirtą modelį, kuris pasiekia aukščiausią tikslumą.

Išvados

1. Atlikus literatūros apžvalgą pastebėta, kad mašininis mokymas yra dažnai taikomas metodas širdies nepakankamumo EKG analizei, dėl pasiekiamo aukšto klasifikavimo tikslumo. Širdies nepakankamumui iš EKG signalų prognozuoti, naudojamos gilių neuroninių tinklų *AlexNet*, *GoogLeNet* ir *ResNet* architektūros, hibridiniai mašininio mokymo metodai, naudojant tolydžiąją bangelių transformaciją bei filtrų bankus, sprendimų medžių, atraminių vektorių mašinų bei atsitiktinių miškų modeliai. Iš literatūros apžvalgos matoma, kad Lagranžo rodiklių taikymas EKG analizėje yra naujumas.
2. Iš EKG duomenų segmentų apskaičiuojant pirmą ir antrą Lagranžo rodiklius, sukonstruoti dvimačiai požymiai, iš jų formuojamos matricos ir jos traktuojamos kaip dvimačiai skaitmeniniai vaizdai. Gauti skaitmeniniai vaizdai turi vizualių skirtumų tarp nagrinėtų klasių.
3. Rstudio programa realizuotas dvimačio požymio išskyrimas iš „Physionet“ duomenų bazės svetainės „BIDMC širdies nepakankamumo“ ir „MIT-BIH normalaus sinusinio ritmo“ duomenų bazių elektrokardiogramos segmentų. Iš atlikto tyrimo nustatyta, kad toks požymio išskyrimo būdas yra efektyvus, pasiekiantis aukštą klasifikavimo tikslumą, nustatant širdies nepakankamumo bei normalaus sinusinio ritmo klases.
4. Dvimačiams skaitmeniniams vaizdams klasifikuoti naudotos dirbtinių neuroninių tinklų *ResNet* ir *AlexNet* architektūros. Pirmu Lagranžo rodikliu paremti dvimačiai skaitmeniniai vaizdai yra efektyvesni nei paremti antru Lagranžo rodikliu, pasiekiantys aukštesnį klasifikavimo tikslumą. *ResNet* modeliai tokių vaizdų klasifikavimui yra labiau tinkami nei *AlexNet*. Aukščiausias klasifikavimo tikslumas gautas *ResNet* modelį, mokant su pirmu Lagranžo rodikliu, paremtais dvimačiais skaitmeniniais vaizdais. Suvidurkintas šio modelio testavimo duomenų bendras tikslumas yra 99,198 %.
5. Realių EKG segmentų aukšto tikslumo klasifikavimo rezultatai parodo, kad pasiūlytas dvimačių skaitmeninių vaizdų konstravimo algoritmas gali būti taikomas praktikoje.

Literatūros sąrašas

1. SVEIKAS.LT: *Širdies nepakankamumas. Simptomai, priežastys, eiga ir gydymas* [interaktyvus]. 2011 [žiūrėta 2023-03-20 d.]. Prieiga per: https://ligos.sveikas.lt/lt/ligos/sirdies_ir_kraujagysliu_ligos/sirdies_nepakankamumas
2. QUIZLET: *Didysis kraujo apytakos ratas* [interaktyvus]. 2023 [žiūrėta 2023-03-20 d.]. Prieiga per: <https://quizlet.com/474701674/didysis-kraujo-apytakos-ratas-diagram>
3. HFSA: *Heart Failure Facts & Information* [interaktyvus]. 2020 [žiūrėta 2023-03-20 d.]. Prieiga per: <https://quizlet.com/474701674/didysis-kraujo-apytakos-ratas-diagram>
4. MEDICINOS DIAGNOSTIKOS IR GYDYMO CENTRAS: *Širdies nepakankamumas, arba kai širdis pavargsta* [interaktyvus]. 2014 [žiūrėta 2023-03-20 d.]. Prieiga per: <https://www.medcentras.lt/straipsniai/kardiologija-sirdies-ligos/sirdies-nepakankamumas-arba-kai-sirdis-pavargsta>
5. VISUOMENĖS SVEIKATA: *Širdies nepakankamumas Lietuvoje – sunki, bet valdoma liga* [pdf]. 2017 [žiūrėta 2023-03-20 d.]. Prieiga per: [https://www.hi.lt/uploads/pdf/visuomenes%20sveikata/2017.2%20\(77\)/VS%202017%20\(7\)%20RED%20Sirdies%20nepakankamumas.pdf](https://www.hi.lt/uploads/pdf/visuomenes%20sveikata/2017.2%20(77)/VS%202017%20(7)%20RED%20Sirdies%20nepakankamumas.pdf)
6. ANDRIUS LIDEIKIS: *Kas yra Elektrokardiograma?* [interaktyvus]. 2021 [žiūrėta 2023-03-20 d.]. Prieiga per: <https://sirdiesritmas.lt/blogs/straipsniai/kas-yra-elektrokardiograma>
7. CRISTIANO ANTONINO. *Ką Rodo P, T, U Bangos, QRS Kompleksas Ir ST Segmentas* [interaktyvus]. 2022. Prieiga per: <https://www.emergency-live.com/lt/health-and-safety/ecg-what-p-t-u-waves-the-qrs-complex-and-the-st-segment-indicate>
8. KARAYE KM, SANI MU. *Electrocardiographic abnormalities in patients with heart failure.* *Cardiovasc J Afr.* 2008, 19(1):22-5. PMID: 18320082; PMCID: PMC3975312.
9. Sudestna NAHAK, Akanksha PATHAK ir Goutam SAHA. *Evaluation of handcrafted features and learned representations for the classification of arrhythmia and congestive heart failure in ECG, Biomedical Signal Processing and Control*, 2023, 79 (2), 104230. ISSN 1746-8094. Prieiga per: doi:[10.1016/j.bspc.2022.104230](https://doi.org/10.1016/j.bspc.2022.104230).
10. V. JAHMUNAH ir E.Y.K. NG AND TAN RU SAN ir U. RAJENDRA ACHARYA. *Automated detection of coronary artery disease, myocardial infarction and congestive heart failure using GaborCNN model with ECG signals. Computers in Biology and Medicine*, 2021, 134, 104457. ISSN 0010-4825. Prieiga per: doi:[10.1016/j.combiomed.2021.104457](https://doi.org/10.1016/j.combiomed.2021.104457).
11. AHMED S. ELTRASS ir MAZHAR B. TAYEL AND ABEER I. AMMAR. *A new automated CNN deep learning approach for identification of ECG congestive heart failure and arrhythmia using constant-Q non-stationary Gabor transform. Biomedical Signal Processing and Control.* 2021, 65, 102326. ISSN 1746-8094. Prieiga per: doi:[10.1016/j.bspc.2020.102326](https://doi.org/10.1016/j.bspc.2020.102326).
12. R.K. TRIPATHY ir MARIO R.A. PATERNINA AND JUAN G. ARRIETA AND ALEJANDRO ZAMORA-MÉNDEZ ir GANESH R. NAIK. *Automated detection of congestive heart failure from electrocardiogram signal using Stockwell transform and hybrid classification scheme. Computer Methods and Programs in Biomedicine.* 2019, 173, 53-65. ISSN 0169-2607. Prieiga per: doi:[10.1016/j.cmpb.2019.03.008](https://doi.org/10.1016/j.cmpb.2019.03.008)
13. VIDYA K. SUDARSHAN, U.RAJENDRA ACHARYA, SHU LIH OH, MUHAMMAD ADAM, JEN HONG TAN, CHUA KUANG CHUA, KOK POO CHUA ir RU SAN TAN. *Automated diagnosis of congestive heart failure using dual tree complex wavelet transform and statistical features extracted from 2s of ECG signals. Computers in Biology and Medicine.* 2017, 83, 48-58. ISSN 0010-4825. Prieiga per: doi:[10.1016/j.combiomed.2017.01.019](https://doi.org/10.1016/j.combiomed.2017.01.019)

14. ANKIT A. BHURANE, MANISH SHARMA, RU SAN-TAN ir U. RAJENDRA ACHARYA. An efficient detection of congestive heart failure using frequency localized filter banks for the diagnosis with ECG signals. *Cognitive Systems Research*. 2019, 55, 82-94. ISSN 1389-0417. Prieiga per: doi:[10.1016/j.cogsys.2018.12.017](https://doi.org/10.1016/j.cogsys.2018.12.017)
15. OLANREWAJU, RASHIDAH FUNKE, IBRAHIM, S. NOORJANNAH, ASNAWI, ANI LIZA ir ALTAF, HUNAIN. Classification of ECG signals for detection of arrhythmia and congestive heart failure based on continuous wavelet transform and deep neural networks. *Indonesian Journal of Electrical Engineering and Computer Science*. 2021, 22(3), 1520–1528. Prieiga per: doi:[10.11591/ijeecs.v22.i3.pp1520-1528](https://doi.org/10.11591/ijeecs.v22.i3.pp1520-1528)
16. EVANTHIA TRIPOLITI. Estimation of New York Heart Association class in Heart Failure Patients Based on Machine Learning Techniques. *Zenodo*. 2017. Prieiga per: doi:[10.5281/zenodo.1311685](https://doi.org/10.5281/zenodo.1311685)
17. *MACHINE LEARNING: Overview of GAN Structure* [interaktyvus]. 2022 [žiūrėta 2023-04-10 d.]. Prieiga per: https://developers.google.com/machine-learning/gan/gan_structure
18. AHMET ÇINAR AND SEDA ARSLAN TUNCER. Classification of normal sinus rhythm, abnormal arrhythmia and congestive heart failure ECG signals using LSTM and hybrid CNN-SVM deep neural networks. *Computer Methods in Biomechanics and Biomedical Engineering*. 2021, 24(2), 203-214. Prieiga per: doi:[10.1080/10255842.2020.1821192](https://doi.org/10.1080/10255842.2020.1821192)
19. GRÜN Dimitri, RUDOLPH Felix, GUMPFER Nils, HANNIG Jennifer, ELSNER Laura K., VON JEINSEN Beatrice, HAMM Christian W., RIETH Andreas, GUCKERT Michael ir KELLER Till. Identifying Heart Failure in ECG Data With Artificial Intelligence—A Meta-Analysis. *Frontiers in Digital Health*. 2021, 2. ISSN 2673-253X. Prieiga per: doi:[10.3389/fdgth.2020.584555](https://doi.org/10.3389/fdgth.2020.584555)
20. ACHARYA, U. RAJENDRA, FUJITA, HAMIDO, OH, SHU LIH, HAGIWARA, YUKI, TAN, JEN HONG, ADAM, MUHAMMAD, TAN, RU SAN. Deep convolutional neural network for the automated diagnosis of congestive heart failure using ECG signals. *Applied Intelligence*. 2019, 49, 16-27. ISSN 1573-7497. Prieiga per: doi: [10.1007/s10489-018-1179-1](https://doi.org/10.1007/s10489-018-1179-1)
21. ZERINA MASETIC AND ABDULHAMIT SUBASI. Congestive heart failure detection using random forest classifier. *Computer Methods and Programs in Biomedicine*. 2016, 130, 54-64. ISSN 0169-2607. Prieiga per: doi:[10.1016/j.cmpb.2016.03.020](https://doi.org/10.1016/j.cmpb.2016.03.020)
22. AKBILGIC Oguz, BUTLER Liam, KARABAYIR Ibrahim, CHANG Patricia P, KITZMAN Dalane W, ALONSO Alvaro, CHEN LIN Y ir SOLIMAN Elsayed Z. ECG-AI: electrocardiographic artificial intelligence model for prediction of heart failure. *European Heart Journal - Digital Health*. 2021, 2(4), 626-634. ISSN 2634-3916. Prieiga per: doi:[10.1093/ehjdh/ztab080](https://doi.org/10.1093/ehjdh/ztab080)
23. G. G. N. GEWEID, M. A. ABDALLAH. A New Automatic Identification Method of Heart Failure Using Improved Support Vector Machine Based on Duality Optimization Technique. *IEEE Access*. 2019, 7, 149595-149611. Prieiga per: doi:[10.1109/ACCESS.2019.2945527](https://doi.org/10.1109/ACCESS.2019.2945527).
24. LI D, TAO Y, ZHAO J, WU H. Classification of Congestive Heart Failure from ECG Segments with a Multi-Scale Residual Network. *Symmetry*. 2020, 12(12). Prieiga per: doi:[10.3390/sym12122019](https://doi.org/10.3390/sym12122019)
25. Zerina MAŠETIC, Abdulhamit SUBASI. Detection of congestive heart failures using C4.5 Decision Tree. *Southeast Europe Journal of Soft Computing*. 2013, 2(2), ISSN 2233-1859. Prieiga per: doi:[10.21533/scjournal.v2i2.32](https://doi.org/10.21533/scjournal.v2i2.32)
26. SAWZA SAADI SAEED, RAGHAD ZUHAIR YOUSIF. A Slantlet based Statistical Features Extraction for Classification of Normal, Arrhythmia, and Congestive Heart Failure

- in Electrocardiogram. *UHD Journal of Science and Technology*. 2021, 5(1), 71-81. Prieiga per: doi:[10.21928/uhdjst.v5n1y2021.pp71-81](https://doi.org/10.21928/uhdjst.v5n1y2021.pp71-81)
27. YUE ZHANG AND MING XIA. Application of Deep Neural Network for Congestive Heart Failure Detection Using ECG Signals. *Journal of Physics: Conference Series*. 2020, 1642. Prieiga per: doi: [10.1088/1742-6596/1642/1/012021](https://doi.org/10.1088/1742-6596/1642/1/012021)
 28. MIHAELA PORUMB, ERNESTO IADANZA, SEBASTIANO MASSARO, LEANDRO PECCHIA. A convolutional neural network approach to detect congestive heart failure. *Biomedical Signal Processing and Control*. 2020, 55, 101597, ISSN 1746-8094. Prieiga per: doi:[10.1016/j.bspc.2019.101597](https://doi.org/10.1016/j.bspc.2019.101597).
 29. KOOLE, M.A.C., KAUW, D., WINTER, M.M. ET AL. First real-world experience with mobile health telemonitoring in adult patients with congenital heart disease. *Neth Heart J*. 2019, 27, 30–37. Prieiga per: doi:[10.1007/s12471-018-1201-6](https://doi.org/10.1007/s12471-018-1201-6)
 30. S. KRISHNAKUMAR., M. YASODHA., J. VERONICA PRIYADHARSHINI., J. BETHANNEY JANNEY., S. DIVAKARAN AND V. LUMEN CHRISTY. Detection of Arrhythmia and Congestive Heart Failure Through Classification of ECG Signals Using Deep Learning Neural Network. *2021 International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation (ICAECA)*, Coimbatore, India. 2021, 1-7. Prieiga per: doi:[10.1109/ICAECA52838.2021.9675703](https://doi.org/10.1109/ICAECA52838.2021.9675703).
 31. İnan GÜLER and Elif Derya ÜBEYLI'. ECG beat classifier designed by combined neural network model. *Pattern Recognition*. 2005, 38(2), 199-208, ISSN 0031-3203. Prieiga per: doi:[10.1016/j.patcog.2004.06.009](https://doi.org/10.1016/j.patcog.2004.06.009).
 32. SEBASTIANO RAFFA AND GIANMARIO MERISIO AND FRANCESCO TOPPUTO. Finding regions of bounded motion in binary asteroid environment using Lagrangian descriptors. *Communications in Nonlinear Science and Numerical Simulation*. 2023, 121, 107198. ISSN 1007-5704. Prieiga per: doi:[10.1016/j.cnsns.2023.107198](https://doi.org/10.1016/j.cnsns.2023.107198).
 33. M.LANDAUSKAS, M.RAGULSKIS. Clustering of ECG segments for patients before sudden cardiac death based on Lagrange descriptors. *Vibroengineering Procedia*. 2019, 26, 78-83 ISSN 2538-8479. Prieiga per: doi:[10.21595/vp.2019.21007](https://doi.org/10.21595/vp.2019.21007).
 34. JUNGINGER Andrej and HERNANDEZ Rigoberto. Lagrangian descriptors in dissipative systems. *Phys. Chem. Chem. Phys.* 2016, 18, 30282-30287, ISSN 44. Prieiga per: doi:[10.1039/C6CP02532C](https://doi.org/10.1039/C6CP02532C).
 35. Carlo, Gabriel G. and Borondo, F. Lagrangian descriptors for open maps. *Phys. Rev. E*. 2020, 101(2), 022208. Prieiga per: doi:[10.1103/PhysRevE.101.022208](https://doi.org/10.1103/PhysRevE.101.022208).
 36. ANA M. MANCHO AND STEPHEN WIGGINS AND JEZABEL CURBELO AND CAROLINA MENDOZA. LAGRANGIAN DESCRIPTORS: A method for revealing phase space structures of general time dependent dynamical systems. *Communications in Nonlinear Science and Numerical Simulation*. 2013, 18(12), 3530-3557. Prieiga per: doi:[10.1016/j.cnsns.2013.05.002](https://doi.org/10.1016/j.cnsns.2013.05.002).
 37. DAQUIN, JÉRÔME AND REMI, PEDENON-ORLANDUCCI AND AGAOGLOU, MAKRINA AND GARCIA-SANCHEZ, GUILLERMO AND MANCHO, ANA MARIA. Global Dynamics Visualisation from Lagrangian Descriptors. Applications to Discrete and Continuous Systems. *SSRN*. 2022, 37. Prieiga per: doi:[10.2139/ssrn.4175901](https://doi.org/10.2139/ssrn.4175901).
 38. FRANCISCO BALIBREA-INIESTA, CARLOS LOPESINO, STEPHEN WIGGINS, AND ANA M. MANCHO. Lagrangian Descriptors for Stochastic Differential Equations: A Tool for Revealing the Phase Portrait of Stochastic Dynamical Systems. *International Journal of Bifurcation and Chaos*. 2016, 26(13), 1630036. Prieiga per: doi:[10.1142/S0218127416300366](https://doi.org/10.1142/S0218127416300366)

39. J MONTES and F REVUELTA and F BORONDO. Lagrangian descriptors and regular motion. *Communications in Nonlinear Science and Numerical Simulation*. 2021, 102, 105860. ISSN 1007-5704. Prieiga per: doi:[10.1016/j.cnsns.2021.105860](https://doi.org/10.1016/j.cnsns.2021.105860).
40. GARCÍA-GARRIDO, VÍCTOR J. AND STEPHEN WIGGINS. Lagrangian descriptors and the action integral of classical mechanics. *Physica D: Nonlinear Phenomena*. 2022. Prieiga per: doi:[10.1016/j.physd.2022.133206](https://doi.org/10.1016/j.physd.2022.133206).
41. BIDMC Congestive Heart Failure Database. *PhysioNet*. [interaktyvus]. 2000 [žiūrėta 2023-02-20 d.]. Prieiga per: physionet.org/content/chfdb/1.0.0/.
42. MIT-BIH Normal Sinus Rhythm Database. *PhysioNet*. [interaktyvus]. 1999 [žiūrėta 2023-02-20 d.]. Prieiga per: physionet.org/content/nsrdb/1.0.0/.
43. Ana M. MANCHO, Stephen WIGGINS, Jezabel CURBELO, Carolina MENDOZA. Lagrangian descriptors: A method for revealing phase space structures of general time dependent dynamical systems. *Communications in Nonlinear Science and Numerical Simulation*, 2013, 18(12), 3530-3557, ISSN 1007-5704. Prieiga per: doi:[10.1016/j.cnsns.2013.05.002](https://doi.org/10.1016/j.cnsns.2013.05.002).
44. IBM: *What is machine learning?* [interaktyvus]. [žiūrėta 2023-03-20 d.]. Prieiga per: <https://www.ibm.com/topics/machine-learning>.
45. AL WIKI: *Accuracy and Loss*. [interaktyvus]. [žiūrėta 2023-03-18]. Prieiga per: <https://machine-learning.paperspace.com/wiki/accuracy-and-loss>.
46. TARANG SHAH: *About Train, Validation and Test Sets in Machine Learning*. [interaktyvus]. 2017 [žiūrėta 2023-03-18]. Prieiga per: <https://towardsdatascience.com/train-validation-and-test-sets-72cb40cba9e7>
47. GEEKSFORGEEEKS: *Intuition of Adam Optimizer*. [interaktyvus] 2020 [žiūrėta 2023-02-18]. Prieiga per: <https://www.geeksforgeeks.org/intuition-of-adam-optimizer/>.
48. IBM: *What are neural networks?* [interaktyvus]. [žiūrėta 2023-02-20 d.]. Prieiga per: <https://www.ibm.com/topics/neural-networks>.
49. DEEPCHECKS GLOSSARY *ResNet*. [interaktyvus]. 2023 [žiūrėta 2023-02-20 d.]. Prieiga per: <https://deepchecks.com/glossary/resnet/>.
50. ELBERT ALFREDO TJOA, I PUTU YOWAN NUGRAHA SUPARTA, RITA MAGDALENA, NOR KUMALASARI CP. The use of CLAHE for improving an accuracy of CNN architecture for detecting pneumonia. *SHS Web Conf*. 2022, 139, 03026. Prieiga per: doi:[10.1051/shsconf/202213903026](https://doi.org/10.1051/shsconf/202213903026)