

KAUNO TECHNOLOGIJOS UNIVERSITETAS

EGLĖ BUTKEVIČIŪTĖ

EKG SIGNALŲ ANALIZĖ TRENIRUOČIŲ PROCESO
MODELIAVIMUI IR NUOVARGIO VERTINIMO
METODIKOS SUDARYMUI

Daktaro disertacija
Gamtos mokslai, informatika (N 009)

2021, Kaunas

Disertacija rengta 2016–2020 metais Kauno technologijos universiteto Matematikos ir gamtos mokslų fakultete Taikomosios matematikos katedroje. Mokslinius tyrimus rėmė Lietuvos mokslo taryba – gauta stipendija už akademinis pasiekimus (2020 metų pavasario semestre).

Mokslinis vadovas:

Doc. dr. Liepa BIKULČIENĖ (Kauno technologijos universitetas, gamtos mokslai, informatika, N 009).

Interneto svetainės, kurioje skelbiama disertacija, adresas:
<http://ktu.edu>

Redagavo:

Kristina Bačiulienė

TURINYS

ĮVADAS	6
1. LITERATŪROS APŽVALGA.....	10
1.1. Elektriniai gyvybiniai signalai	10
1.1.1. Elektrokardiografija.....	10
1.1.2. Elektroencefalogramos ir elektromiogramos	13
1.1.3. Kompiuterinės ir mobilios technologijos elektrinių signalų apdorojimui	16
1.2. EKG signalų tyrimų metodai.....	19
1.2.1. Širdies ritmo variabilumas.....	19
1.2.2. Signalų tyrimo metodai	22
1.2.3. EKG parametrų paieškos metodika	29
1.3. Sveikatos srityje taikomi klasifikavimo metodai	30
1.4. Surogatiųjų elektrinių signalų simuliacijos	35
1.5. Sveikatos būklės vertinimo sistemos.....	37
1.5.1. Sportuojančių žmonių treniruotės vertinimo būdai	40
1.5.2. Nuovargio vertinimas	42
2. METODIKA	45
2.1. Signalų filtravimo algoritmai	46
2.2. EKG parametrų paieškos algoritmai	50
2.2.1. EKG pikų identifikavimas	51
2.2.2. Kitų EKG parametrų paieška.....	54
2.2.3. Poincare diagramos nuovargio identifikavimui.....	56
2.3. Signalų klasifikavimas	60
2.4. Treniruočių proceso valdymas	62
2.5. Metodų korektiškumo vertinimas ir paklaidos.....	64
2.6. Skyriaus išvados.....	67
3. SIGNALŲ FILTRAVIMO ALGORITMŲ TYRIMAI	68
3.1. Filtravimo parametrų parinkimas naudojant simuliuotus EKG signalus	68
3.2. EKG signalų registravimas filtravimo algoritmų tyrimui	70
3.3. Signalų filtravimo algoritmų palyginimai	72
3.4. EEG duomenų triukšmo simuliacijos naudojant EKG judesio tendencijas	74
3.5. Skyriaus išvados.....	78
4. EKG SIGNALŲ ANALIZĖ NUOVARGIO VERTINIMUI	79
4.1. Atliekami eksperimentai ir EKG signalų registravimas.....	79
4.1.1. EKG signalų registravimas skirtingose aktyvumo būsenose.....	79
4.1.2. Atletų EKG signalų ir R-R intervalų registravimas	80
4.1.3. Skirtingu paros metu atliekami eksperimentai	80
4.1.4. Papildomi eksperimentai	81
4.2. Nuovargio vertinimas naudojant ŠRV analizę	81
4.2.1. R-R intervalų artefaktų pašalinimas	82

4.2.2.	ŠRV tiesinė analizė.....	83
4.2.3.	Nuovargio vertinimas naudojant Poincare diagramas	85
4.3.	EKG signalų klasifikavimas identifikuojant nuovargį	87
4.3.1.	EKG signalo parametrų paieška	88
4.3.2.	Mašininio mokymosi metodų taikymas nuovargiui identifikuoti.....	91
4.4.	Skyriaus išvados	97
IŠVADOS		98
PRAKTINĖ SVARBA		99
LITERATŪRA		100
Priedas 1. BEADS algoritmo paklaidos, priklausomai nuo r parametro reikšmių		115
Priedas 2. BEADS metodu rastų judesio trendų pavyzdžiai		115
Priedas 3. Atliekamų pratimų vizualizacijos		116
Priedas 4. Skirtingų asmenų EKG signalų registravimo skirtingose aktyvumo būsenose protokolas		117
Priedas 5. Poincare diagramos skirtingose būsenose.....		118
Priedas 6. Atletų R-R intervalų sekos ir EKG signalų spektrogramos		120
Priedas 7. Skirtingu paros metu registruotų EKG signalų protokolas		122
Priedas 8. ML metodai, jų parametrai ir aprašymai.....		129
Priedas 9. Tyrimo metu sudaryto RF atskirų DT medžių schemų pavyzdžiai		130

TERMINŲ, ŽENKLŲ, SIMBOLIŲ IR SANTRUMPŲ SĄRAŠAS

EKG – elektrokardiogramos signalas

EEG – elektroencefalogramos signalas

EMG – elektromiogramos signalas

\mathbf{I} – vienetinė matrica

\mathbf{D}_k – k-osios eilės skirtuminė matrica

DBT – diskrečiųjų bangelių transformacijos algoritmas

Trendas – žemo dažnio triukšmas

RMSE – vidutinė kvadratinė paklaida (angl. *root means square error*)

SOA – paslauginė architektūra (angl. *service oriented architecture*)

ŠR – širdies ritmas

ŠRV – širdies ritmo variabilumas (angl. *heart rate variability*, HRV)

IMF – vidinės būsenos funkcijos (angl. *intrinsicmodefunctions*)

EMD – empirinės būsenos išskaidymas (angl. *empiricalmode decomposition*)

MA – slenkančio vidurkio algoritmas (angl. *moving average*)

TEO – Teager energijos operatorius (angl. *teager energy operator*)

MTEO – daugialypis TEO

DFA – betrendė svyravimų analizė (angl. *detrended fluctuation analysis*)

MUAP – motorinio vieneto veiksmų potencialas (angl. *motor unit action potential*)

BAN – kūno srities tinklas (angl. *body area network*)

IoT – daiktų internetas (angl. *internet of things*)

BEADS – bazinės linijos išskyrimas ir signalo nutriukšminimas (angl. *baseline estimation and denoising with sparsity*)

SDRR – standartinis nuokrypis ir standartinės vidurkių paklaidos tarp R-R intervalų (angl. *standart deviation and standart error of means from all R-R intervals*)

T – periodas ($T_0 = 2\pi$)

μ – imties duomenų vidurkis

σ – imties duomenų standartinis nuokrypis

ML – mašininis mokymasis (angl. *machine learning*)

SVM – atraminių vektorių mašinos (angl. *support vector machine*)

KNN – k – artimiausių kaimynų metodas (angl. *k – nearest neighbours*)

DT – sprendimų medis (angl. *decision tree*)

LDA – tiesinė diskriminantinė analizė (angl. *linear discriminant analysis*)

RF – atsitiktinis miškas (angl. *random forest*)

NN – neuroniniai tinklai (angl. *neural networks*)

ROC – kreivė, kuri iliustruoja, kaip keičiasi klasifikatoriaus gebėjimas atskirti kategorijas besikeičiant diskriminantiniam slenksčiui (angl. *receiver operating characteristics curve*)

AUC – plotas po ROC kreive (angl. *area under the ROC curve*)

\mathbb{R} – realiųjų skaičių aibė

T banga – EKG signalo dalis, atsiradusi dėl greitos širdies skilvelių repoliarizacijos

R-R intervalas (arba RR) – EKG signalo parametras, nusakantis trukmę tarp gretimų širdies dūžių. Kitas alternatyvus šio signalo pavadinimas yra ritmograma.

QRS kompleksas – EKG signalo intervalinis parametras, kuris parodo trukmę tarp Q bangos pradžios ir S bangos pabaigos.

IVADAS

Temos aktualumas ir svarba

Išmaniosios technologijos vis populiarėja tarp įvairaus amžiaus žmonių, o tobulėjantys įrenginiai bei besiplėtojanti debesų duomenų saugojimo sistema leidžia daugumą paslaugų vykdyti nuotoliniu būdu.

Sveikatos būklės stebėjimui sporto klubuose, klinikose, darbo vietose ar namuose vis dažniau naudojamos įvairios mobilios aplikacijos, skirtos mėgėjiškai sportuojantiems, atsakingus darbus dirbantiems, vyresnio amžiaus ar specifinių susirgimų turintiems žmonėms, profesionaliems sportininkams ir kt. Elektroninės nuotolinio valdymo sistemos kartais gali pakeisti įprastus sveikatos priežiūros ir stebėsenos metodus. Žmonės vis dažniau ieško informacijos internete apie savo sveikatos būklę, galimus gydymo metodus, rekomendacijas ar dalijasi patirtimi tarpusavyje. Neretai sveikatos stebėjimo sistemoms reikalingi papildomi prietaisai, todėl jų paklausa nuolat auga, tačiau tiek įrenginius, tiek aplikacijas turi būti paprasta naudoti, jie turi būti lengvai suprantami kiekvienam vartotojui. Invaziniai tyrimo metodai tokiu atveju tampa netinkami, todėl elektrinius gyvybinius signalus ir kitus sveikatos duomenis registruojantys neinvaziniai įrenginiai bei juos apdorojanti programinė įranga tampa paklausia.

Elektrokardiogramas pradėta tirti XX a. pradžioje išskiriant pagrindines charakteristikas ir pikus. Iki šiol yra žinoma, kad tai viena pagrindinių širdies ir kraujagyslių anomalijų identifikavimo priemonių. Elektrokardiogramos išpopuliarėjo dėl nesudėtingo ir sąlyginai neinvazinio signalų registravimo proceso, kurio metu širdies elektrinio aktyvumo duomenys perduodami į registravimo įrenginį. Jis paprastai gautus signalus iš karto atvaizduoja grafiškai. Be elektrokardiogramų medicinoje ir diagnostikoje yra registruojami elektroencefalogramos bei elektromiogramos signalai. Žmogaus organizmas yra kompleksinė sistema, todėl pavienių signalų tyrimo neužtenka visos sistemos dinamikai aprašyti. Dėl šios priežasties reikia vertinti žmogaus biosignalų vidinius ir tarpusavio ryšius.

Medicinoje elektriniai signalai paprastai yra registruojami žmogui esant stacionarioje būsenoje, nes norima minimizuoti galimus išorinius triukšmus. Tačiau registruojant įprastinėje aplinkoje retai pavyksta išvengti triukšmų, kurie gali atsirasti dėl kvėpavimo, raumenų susitraukimų, prastų signalo perdavimo kanalų ar nutrūkimų, nepilno elektrodo sąlyčio su oda, mirkčiojimo ir kitų trikdžių. Lietuvos ir užsienio mokslininkai pritaikė bei išplėtojo daugybę signalų filtravimo algoritmų, kurių dėka įvairūs triukšmai gali būti sumažinami nesugadinant pačio elektrinio signalo charakteristikų. Nors stacionariai registruoti signalai vis dar plačiai naudojami diagnostikoje, jie netinkami įvertinti žmogaus organizmo skirtingų sistemų tarpusavio sąveiką bei kitimo dinamiką kasdienės įprastinės veiklos metu.

Žmogui atliekant fizinius ar protinės veiklos pratimus veikia kelios sistemos, taip pat širdies bei kraujagyslių, raumeninė ir nervų sistemos. Vis populiarėjančiais širdies ritmo variabilumo bei elektrokardiogramų parametrų dinaminiais sąsajų tyrimais siekiama rasti sąryšius tarp žmogaus kompleksinės sistemos komponentų. Nors šie tyrimai dažniausiai pagrįsti elektrokardiogramų signalų analize, jie atspindi nepertraukiamus momentinių širdies ritmų svyravimus ir suprantami kaip atsakas į

įvairias fiziologines būsenas ar tam tikras patologines būkles, reguliuojamas autonominės nervų sistemos ar kraujotakos. Nors judesio metu elektrokardiogramų registravimas neatrodo sudėtinga užduotis, tačiau patys signalai yra gerokai triukšmingesni nei fiksuoti stacionariomis sąlygomis. Priklausomai nuo judesio intensyvumo triukšmai tampa nestacionarūs ir standartiniai filtravimo algoritmai nebesugeba signalų apdoroti tinkamai, nepažeisdami svarbiausių charakteristikų. Šiame darbe pasiūlyti elektrinių signalų filtravimo algoritmai geba prisitaikyti prie triukšmo lygio esant skirtingai širdies apkrovai (parenkant skirtingo intensyvumo fizinius pratimus) bei išsaugo pagrindines elektrokardiogramos signalo parametrų reikšmes, reikalingas būklės įvertinimui ir proceso valdymui.

Širdies ritmo variabilumo tyrimai taip pat svarbūs ir fizinio ar fiziologinio nuovargio identifikavimo procese. Fiziologiniu nuovargiu vadinamas bendras nuovargis, apimantis fizinį, protinį ir emocinį žmogaus nuovargį. Fizinis nuovargis ypač aktualus profesionaliai sportuojantiems ar intensyvią atsakingą darbą atliekantiems asmenims. Sportininkai patenka į mažos rizikos grupę dėl tikimybės susirgti širdies ligomis, tačiau, nepastebėjus simptomų laiku, gali atsirasti negrįžtami širdies pažeidimai. Dėl šios priežasties vis daugiau profesionalių sportininkų ir neprofesionaliai sportuojančių žmonių domisi naujausiomis technologijomis, leidžiančiomis stebėti savo sveikatos būklę bei kontroliuoti treniruotės intensyvumą realiu laiku. Tuo tarpu, biuro darbuotojai dažniausiai susiduria su fiziologinio nuovargio problemomis, kurios gali pereiti į lėtinius sveikatos sutrikimus bei turėti ilgalaikių pasekmių. Neretai laiku nepastebėtas nuovargis gali tapti pagrindine nedarbingumo priežastimi. Šio tyrimo metu buvo identifikuojami pagrindiniai elektrokardiogramos parametrai, leidžiantys aptikti fizinį ar fiziologinį nuovargį naudojant širdies ritmo variabilumo analizę ir mašininį mokymą.

Pagrindiniai tyrimai šiame darbe atliekami naudojant elektrokardiogramos signalus, tačiau taip pat parodyta, kad naudoti triukšmų filtravimo algoritmai yra efektyvūs ir kitiems elektriniams signalams. Apdorotiems signalams buvo patobulinti ir pritaikyti elektrokardiogramos parametrų paieškos algoritmai ir, naudojant širdies ritmo variabilumo analizę, parinkti metodai nuovargio vertinimui. Be to, nuovargio identifikavimo metodika ateityje gali būti pritaikyta įvairiose mobiliose aplikacijose ir naudojama darbo metu. Tai leistų sumažinti traumų riziką, mirčių skaičių dėl širdies ir kraujagyslių ligų bei laiku aptikti nuovargio pirmuosius simptomus ir, juos efektyviai pašalinus, padidinti darbingumą.

Tyrimų objektas – elektrokardiogramos signalai, registruoti įvairaus intensyvumo fizinių ir protinių pratimų metu.

Darbo tikslas – apdoroti elektrokardiogramos signalus ir analizuoti jų pokyčius, gautus rezultatus panaudoti treniruočių proceso valdymo modelio ir nuovargio vertinimo metodikos sudarymui.

Darbe sprendžiami uždaviniai:

- Elektrokardiogramos signalus bei jų apdorojimą aprašančios literatūros analizė ir pagrindinių parametrų identifikavimas, siekiant iširti sveikatos būklės vertinimo parametrus.
- Žemo ir aukšto dažnių triukšmų pašalinimo algoritmų apžvalga bei tinkamų metodų parinkimas ir jų pagerinimas.

- EKG signalo parametrų paieškos metodų papildymas įtraukiant į algoritmą T bangos amplitudines bei intervalines vertes.
- Fiziologinio nuovargio vertinimo metodikos sudarymas, realizavimas bei testavimas realiomis sąlygomis.

Darbi naudojami įrenginiai ir programinės priemonės:

- Elektrokardiogramos registruojamos naudojant CardioScout Multi įrenginį (su registravimo dažniu 500 s^{-1}).
- Algoritmų paklaidoms vertinti generuojami elektrokardiogramų signalai naudojant simulatorių CMRR 2.0, kuris generuoja sinusoidę su 150 bpm (dūžių per minutę).
- Visi signalų apdorojimo, EKG parametrų paieškos bei nuovargio vertinimo algoritmai realizuoti naudojant MATLAB_R2015b paketo matematinės ir statistinės analizės funkcijas.
- R-R intervalų filtravimo algoritmai realizuoti naudojant Kubios HRV programinį paketą.

Darbo mokslinis naujumas ir praktinė svarba:

- Tyrimo metu buvo parinkta elektrokardiogramos, registruotos judesio metu, filtravimo algoritmai bei patobulinti atsižvelgiant į pagrindines signalo charakteristikas, jų neiškraipant.
- Suformuota širdies ritmo variabilumo vertinimo metodika fiziniam nuovargiui įvertinti, apimanti duomenų analizę, interpretaciją ir vizualizaciją.
- Sudaryta elektrokardiogramos signalo parametrų paieškos metodika, įtraukiant T piko amplitudines ir intervalines reikšmes. Signalų klasifikavimui pasiūlytos charakteristikos, kurios leidžia įvertinti signalo pokyčius. Metodikos taikomos žmogaus sveikatos būklei vertinti ir stebėti bei nuovargiui identifikuoti.
- Individualizuotos treniruotės valdymo rekomendacijos, vertinimui naudojant duomenis, gautus iš nutriukšmintos elektrokardiogramos.

Ginti pateikiama:

- Trendo pašalinimo algoritmo BEADS modifikacija bioelektriniams signalams apdoroti, įvertinant besikeičiančius filtravimo parametrus, kurie priklauso nuo atliekamo judesio ir treniruotės intensyvumo.
- Papildytas EKG parametrų paieškos algoritmas, įtraukiant tokius parametrus kaip T amplitudė ar T bangos intervalo ilgis.
- Modifikuota treniruočių vertinimo sistema taip, kad signalų apdorojimas bei vartotojui suteikiamas grįžtamasis ryšys vyktų realiu laiku.
- Sudaryta nauja nuovargio vertinimo metodika, kuri geba aptikti įvairias fiziologinio nuovargio rūšis.

Darbo rezultatų aprobavimas:

Disertacijos tema pateikti 5 moksliniai straipsniai, iš kurių 2 mokslinės informacijos instituto duomenų bazės (ISI) leidiniuose, kurios turi citavimo indeksą. Viena publikacija atspausdinta tarptautinėje, kita nacionalinėje leidyklose. Likusios trys publikacijos pristatytos kitų tarptautinių duomenų bazių recenzuojamuose leidiniuose.

Šiame darbe gauti rezultatai buvo pristatyti 6 tarptautinėse konferencijose. Lietuvoje vykusiose tarptautinėse konferencijose: 2017 metais Druskininkuose „Mathematical modeling and analysis: 22nd international conference“, 2018 metais Druskininkuose „10th international workshop on data analysis methods for software systems“, 2019 metais Kaune „Sportininkų rengimo valdymas ir sportininkų darbingumą lemiantys veiksniai: sporto forumas – tarptautinė mokslinė konferencija, skirta Lietuvos sporto universiteto 85-mečiui paminėti“ ir Vilniuje „Information and software technologies: 25th international conference“. Taip pat disertacijoje aprašyti tyrimai pristatyti 2017 metais Graikijoje, Salonikų mieste, „International conference on biomedical and health informatics“ ir Estijoje, Talino mieste, „Sampling theory and applications 2017: 12th international conference“. Pasidalinta patirtimi bei pristatyti tyrimai Porto universitete Portugalijoje 5 dienų stažuotėje „STSM scientific mission“ tema: „ECG signal filtering, analysis and parameter estimation“, kuri buvo finansuojama European Cooperation in Science and Technology (COST).

Disertacijos darbo rezultatai buvo naudojami struktūrinių fondų projekto „EKG signalo filtravimo ir parametrų skaičiavimo tyrimas“ (inočėkiai nr. 01.2.1-MITA-K-824-01-0359) mokslinių tyrimų ir technologinės plėtros įgyvendinimui (2017 09–2018 02). Taip pat plėtojami tyrimai programos EUREKA projekte 11169 „Non-intrusive human fatigue assessment (Fatigue)“ (2018 09 01–2021 08 30). Be to, dalis darbe aprašytų metodų prisidėjo prie „CareWare: Electronics Wearable Sport and Health Solutions“ projekto plėtojamų tyrimų.

Darbo apimtis ir struktūra:

Šią daktaro disertaciją sudaro įvadas, 4 pagrindiniai skyriai, išvados, praktinė svarba, literatūros sąrašas ir publikacijų sąrašas. Darbo apimtis yra 114 puslapių, 55 paveikslų, 26 lentelės ir 181 cituojamų literatūros šaltinių aprašas.

1. LITERATŪROS APŽVALGA

Šiame skyriuje aprašomi elektriniai gyvybiniai signalai, naudojami žmogaus sveikatos, nuovargio ir fizinės būklės vertinimui. Detaliai apibūdinami elektrokardiogramų signalai, jų parametrai bei apdorojimo metodai. Taip pat aprašoma technologija (įrenginiai bei aplikacijos), skirta širdies veiklos sutrikimams aptikti ar žmogaus sveikatos būklei įvertinti.

1.1. Elektriniai gyvybiniai signalai

Elektriniai signalai, tokie kaip elektrokardiogramos (EKG), elektromiogramos (EMG), encefalogramos (EEG), paprastai registruojami kartu su aplinkos triukšmais. Skaitmeninių signalų apdorojimui ir filtravimui yra sukurta ir pritaikyta daugybė metodų, tokių kaip slenkančio vidurkio filtras, eksponentinis glodinimas ar tiesinis Furje glodinimas, bei kiti (Gazi, 2016; Ibrahim, 2012). Chaotiniai signalai paprastai nėra prognozuojami, tačiau tiriant medicininės kilmės signalus galima pastebėti, kad atskiri signalo fragmentai tarpusavyje yra panašūs. Tokiu atveju panašumą galima suprasti taip: bėgant laikui signalo reikšmių vidurkis ir dispersija išlieka beveik nepakitę (Meškauskas, 2017). Pagrindinis signalo filtravimo tikslas yra komponentų išskaidymas į pageidautinas (informatyvias) ir nepageidautinas (triukšmus).

Šiame poskyryje pateiktas širdies veiklos aprašymas bei signalų analizės metodikos. Aprašomas signalų registravimas judesio metu bei pateikiami skirtumai tarp stacionarių ir fizinių pratimų metu registruotų elektrokardiogramų apdorojimo metodų.

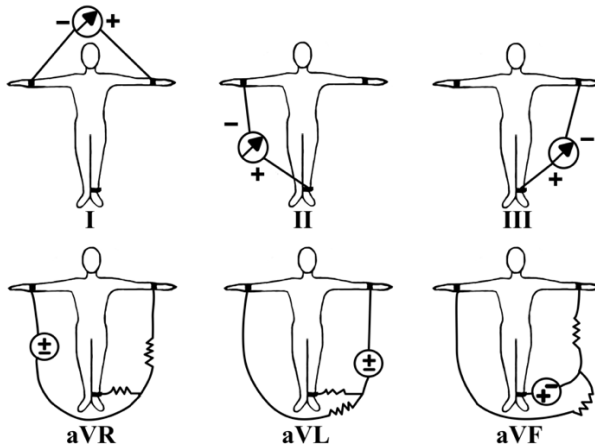
1.1.1. Elektrokardiografija

Elektrokardiografija yra širdies elektrinio aktyvumo signalų registravimas neinvaziniu būdu naudojant su oda besiliečiančius elektrodus. Šis metodas specialiu prietaisu (elektrokardiografu) užrašo širdies ląstelių sukurto suminio elektros lauko potencialo kitimo kreivę – elektrokardiogramą (EKG), pagal kurios charakteristikas sprendžiama apie širdies veiklą. Kiekvienas širdies dūžis yra elektrinis impulsas, kuris susijęs su širdį sudarančių raumeninių skaidulų elektriniu aktyvumu (AlMahamdy & Riley, 2014).

Elektrokardiogramų tyrimai atsirado daugiau nei prieš šimtmetį. Elektrokardiografijos pradininku laikomas Willem Einthoven, kuris 1902 metais naudodamas styginį galvanometrą užregistravo EKG signalą ir susiejo atskirus signalo parametrus (P, Q, R, S ir T raides, žr. 2 pav.) įvairių širdies veiklos nukrypimų nustatymui (Prasad & Varadarajan, 2014). 1924 metais jam buvo įteikta Nobelio premija už elektrokardiografijos išradimą bei vystymą. Jo atradimus širdies ligų diagnostikoje iki šiol taiko kiti mokslininkai.

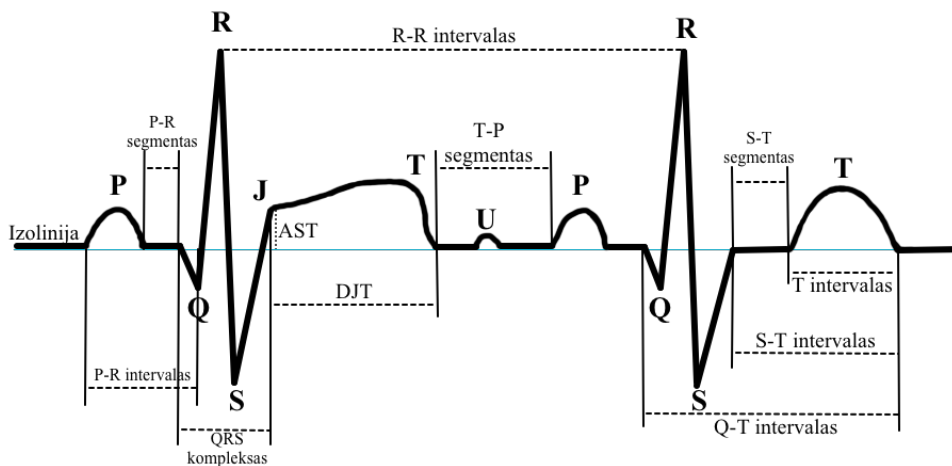
Klasikinėje elektrokardiografijoje dažniausiai registruojama 12 derivacijų (širdies elektrinių impulsų atvaizdavimas laiko skalės atžvilgiu), kurios naudojamos vertinant skirtingų širdies dalių elektrinį aktyvumą ir galimas patologijas. 1913 metais Einthoven pasiūlė standartines tris derivacijas, registruojančias potencialų skirtumus tarp dviejų kūno taškų. Elektrodai pritvirtinami ant dešinės ir kairės rankų, kairės kojos, o ant dešinės kojos prijungiamas įžeminimo laidas. Taip registruojamos trys

galūnių derivacijos (I, II, III) (žr. 1 pav.). Kita trijų derivacijų grupė yra vadinama sustiprintomis unipolinėmis galūnių derivacijomis (aVF, aVL, aVR) (Šmidkaitė, 2017). Bet kuriam šių derivacijų užrašymui naudojami tie patys trys elektrodai, bet matuojamas potencialų skirtumas tarp vieno elektrodo ir vidutinio potencialo tarp kitų dviejų Einthoveno taškų (Ashcleulova et al., 2017). Dažniausiai medicinoje naudojamos šešios krūtininės derivacijos (V1, V2, V3, V4, V5, V6); tyrimams naudojami elektrokardiogramų parametrai vaizduojami V5 derivacijoje (žr. 2 pav.).



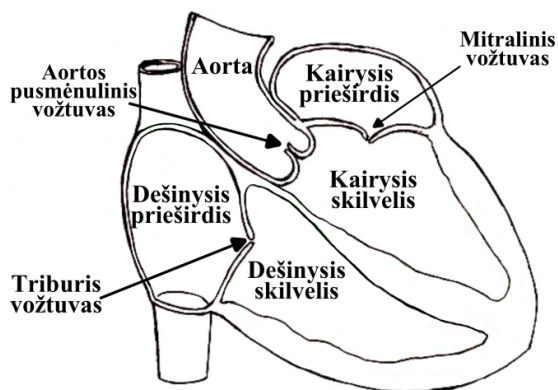
1 pav. Elektrodų išdėstymas EKG registravimui (remiantis Ashcleulova et al., 2017)

Vertinant širdies darbą yra analizuojami tiek intervaliniai (QRS kompleksas, DJT, P-R, S-T segmentai, R-R, P-R, S-T, Q-T intervalai), tiek amplitudiniai (P, Q, R, S, T, U danteliai, AST) elektrokardiogramos parametrai (2 pav.). Paprastai sveikos širdies P-R, S-T bei P-T segmentai yra ant izoelektrinės linijos (0mV), tačiau širdies sutrikimų atveju gali būti tiek aukščiau (pvz., išeminės širdies ligos atveju), tiek žemiau (pvz., miokardo infarkto metu). Parametro JT intervalas (arba kitaip DJT) atspindi širdies medžiagų apykaitą. Mokslininkų nuomone, JT intervalas yra tinkamesnis matavimo matas norint įvertinti skilvelių repoliarizaciją nei QT trukmė (Zareba et al., 2017). Tuo tarpu, ST segmentas apibūdina laiko intervalą tarp skilvelių depoliarizacijos ir repoliarizacijos. Kadangi normaliai ši sritis turi būti horizontali linija (izolinija), tai ST parametro amplitudinės (AST) anomalijos dažniausiai reiškia išeminio miokardo ar infarkto požymius (pakilimai ar nusileidimai) (Kuijt et al., 2017). Pati T banga yra vienas svarbiausių EKG signalo parametru, naudojamu medicinoje ir diagnostikoje. Šio piko amplitudinės ir intervalinės reikšmės gali skirtis priklausomai nuo amžiaus, kūno struktūros, vartojamų vaistų. Tam tikrais atvejais jis gali parodyti kai kurias širdies anomalijas. Padidėjusi T bangos amplitudinė vertė gali reikšti ankstyvą miokardo infarkto būseną. Laiku pastebėjus šiuos pakitimus galima sumažinti infarkto riziką. Kitos ligos, susijusios su T bangos pokyčiais, yra hiperkalemija (nepakankamas kalio kiekis kraujyje) ar plaučių arterijos tromboembolija (Hadjem & Naït-Abdesselam, 2015).



2 pav. EKG signalo V5 derivacija ir jos parametrai

Širdies darbas yra cikliškas. Kardiociklais vadinamas kraujo kelias, prasidedantis nuo širdies, iš kur pumpuojamas į plaučius, grįžta į širdį ir išpumpuojamas į likusį kūną. Kiekvieną ciklą sudaro staigus susitraukimas – sistolė (angl. *systole*), kuri prasideda nerviniame sinusiniame mazge dešiniajame prieširdyje ir suformuoja P dantelį. Toliau tarpkilvelinėje pertvoroje yra prieširdžio skilvelio pluoštas, kuris dalijasi į kairę ir dešinę atšakas ir išsišakoja skilveliuose. Pirmiausia susitraukia prieširdžiai, po to – skilveliai (žr. 3 pav.). Būtent skilvelių susitraukimas suformuoja EKG signalo QRS kompleksą. Po maždaug 150 ms skilveliai repoliarizuojasi ir dėl to atsiranda T dantelis (Gacek & Pedrycz, 2012). Kiekvienas širdies dūžis yra labiausiai sukcentruotas QRS komplekse ir tik labai nedaug energijos atitenka T ar U bangoms, todėl U dantelis gali būti nematomas nuo 50 % iki 75 % visoje registruojamoje elektrokardiogramoje (Prasad & Varadarajan, 2014). Viena pilna širdies veiklos seka pripildant ir pumpuojant kraują yra vadinama širdies ciklu arba širdies dūžiu. Širdies veiklą skirtingų bangų formavimosi metu aprašome 1 lentelėje.



3 pav. Širdies sandara (remiantis Prasad & Varadarajan, 2014)

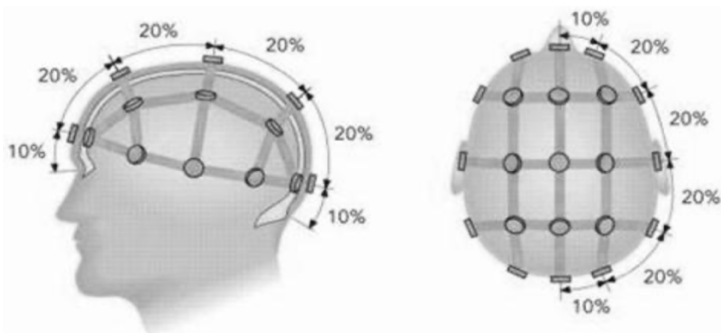
1 lentelė. EKG bangų rūšys ir širdies veikla jų atsiradimo metu

Bangos tipas	Širdies veikla
P – banga	Dešiniojo ir kairiojo prieširdžių depoliarizacija. Gali būti teigiama, neigiama arba dvifazė (Messaoud et al., 2009).
Q – banga	Aktyvuojasi miokardo skilvelio anteroseptalinė dalis.
R – banga	Miokardo skilvelių depoliarizacija.
S – banga	Aktyvuojasi posteriodiafragminė skilvelių dalis.
T – banga	Greita skilvelių repoliarizacija.
U – banga	Susiformavimo priežastis nėra tiksliai žinoma, tačiau atsiranda po T bangos skilvelių repoliarizacijos.

Medicinoje bei diagnostikoje EKG signalai registruojami žmogui esant stacionarioje būsenoje norint išvengti nereikalingų triukšmų, kurie gali trukdyti patologijų indentifikavimui. Signalo perdavimo metu (nuo elektrodo iki atvaizdavimo įrenginio) retai pavyksta išvengti triukšmų, kurie gali atsirasti dėl kvėpavimo, raumenų susitraukimų, prastų signalo perdavimo kanalų ar nutrūkimų, nepilno elektrodo sąlyčio su oda (ypač naudojant daugkartinius elektrodus) bei kitų trikdžių (Edward Jero et al., 2014; Elgendī et al., 2016). EKG signalų apdorojimui ir diagnostikai yra sukurta įvairių metodų ir algoritmų. Vienas populiariausių ir dažniausiai naudojamų yra slenkančio vidurkio algoritmas. Jis gali būti papildytas įtraukiant svorius ar naudojant eksponentinę funkciją (Meškauskas, 2017). Šioje srityje yra atlikta daugybė tyrimų ir papildomų išvalgų, tad geresnių signalų apdorojimo algoritmų paieška nebėra aktuali. Tuo tarpu, judesio metu gauti EKG signalai turi visai kitokio pobūdžio triukšmus, kurių dažniai nėra stacionarūs ir nuolat svyruoja. Dėl to reikalingas atskiras tyrimas tokių signalų apdorojimui.

1.1.2. Elektroencefalogramos ir elektromiogramos

Encefalografija (EEG) yra įrankis registruoti smegenų žievės sukeltą savaiminį elektrinį aktyvumą, naudojant ant galvos odos išdėstytus elektrodus. EEG signalai yra tekančios elektrinės srovės atspindys tarpląstelinėje dalyje, kuri generuojama algebriskai susumuojant žadinančius ar slopinančius postsinapsinius potencialus, atsirandančius ant daugybės žievės neuronų. Vienas matavimo būdų siūlo 6 cm² žievės paviršiaus sinchroniškai aktyvuoti, norint registruoti potencialus nuo galvos odos. Yra pripažinta ir rekomenduotina naudoti tarptautinę 10–20 elektrodų išdėstymo sistemą. Joje 20 elektrodų yra išdėlioti ant galvos odos taip, kad padengtų 10 % ir 20 % galvos perimetro naudojant atpažįstamus kaukolės orientyrus (paviršiaus nelygumus) kaip atskaitos taškus (žr. 4 pav.). Nosis, kaukolės išorinis pakaušio išsikišimas ir du priešakiniai taškai yra keturi paviršiaus žymenys, kuriais yra paremta 10–20 sistema (B. H. Paudel et al., 2012).



4 pav. Tarptautinė 10–20 sistema elektrodų išdėstymui (remtasi B. H. Paudel et al., 2012)

EEG dažniausiai aprašoma naudojant dažnių komponentes, kurios aptinkamos diapazone nuo 1 iki 100 Hz (virpesių periodai nuo 10 iki 1000 ms). Pagal susitarimą šis diapazonas yra išskaidomas į „gamma“ (γ) (>35 Hz), „beta“ (β) (13–35 Hz), „alpha“ (α) (8–13 Hz), „theta“ (θ) (4–8 Hz) ir „delta“ (δ) (1–4 Hz) juostas. Normalaus EEG sužadavimo metu theta ir delta aktyvuojasi retai arba jų iš viso nėra (Miller, 2007). Tyrimuose paprastai yra analizuojami alpha, beta ir gamma virpesiai. Šie signalai plačiai naudojami įvairių sveikatos sutrikimų identifikavimui, kurie dažniausiai susiję su simpatine nervų sistema. EEG atskirų bangų palyginimas pateiktas 2 lentelėje. Šioje lentelėje antrajame stulpelyje nurodyta, kuri smegenų sritis yra atsakinga už atitinkamo virpesių dažnio bangų generavimą, o trečiajame bei ketvirtajame stulpeliuose aprašytos bangų atsiradimo priežastys žmogui esant sveikam ar turint tam tikrų patologinių susirgimų.


2 lentelė. EEG atskirų virpesių juostų palyginimas (remiantis B. H. Paudel et al., 2012)

Rūšis	Vieta	Normaliu atveju	Patologijos
Delta (δ)	Suaugusiems priekinėje dalyje; vaikams galinėje srityje; aukštos amplitudės bangos	Suaugusiems lėto bangų miego metu; kūdikiams rasta atliekant kai kuriuos pasikartojančius pratimus dėmesiui sutelkti	Subkortikaliniai ar difuziniai pažeidimai; metabolinė encefalopatija; hidrocefalija; smegenų vidurio linijos pažeidimai
Theta (θ)	Randama atsitiktinėse vietose	Mažiems vaikams; Vyresniems vaikams ir suaugusiems esant mieguistiems ar susijaudinusiems; tinginiaujant; iššauktų reakcijų slopinimo metu (aktyviai bandant nuslopinti reakciją ar poelgį)	Smegenų subkortikinių struktūrų pažeidimai; metabolinė encefalopatija; smegenų vidurio linijos sutrikimai; tam tikrais atvejais hidrocefalija
Alpha (α)	Galvos galinės srities dalis; iš abiejų pusių; aukštesnė amplitudė	Atsipalaidavus/apmąstant; užmerkus akis; siejama su slopinimo kontroliavimu, kai tikslingai siekiama	Koma

	dominuojančioje pusėje;	nuslopinti atliekamą veiklą skirtingose smegenų vietose	
Beta (β)	Abiejose pusėse simetrinis pasiskirstymas; dažniausiai atsiranda priekinėje dalyje;	Esant budriam / dirbant; aktyvaus, įtempto ar neramaus mąstymo metu; stipraus susikaupimo metu	Nerimo sutrikimo metu; lėtinis stresas
Gamma (γ)	Somatosensorinėje žievėje	Atliekant kryžminį sensorinį apdorojimą (suvokimas derinant du skirtingus pojūčius, tokius kaip garsas ir vaizdas); aktyvuojant trumpąją atmintį lyginant atpažintus objektus, garsus ar lytėjimo pojūčius	Sumažėjęs bangų aktyvumas gali būti siejamas su pažinimo sutrikimais, ypač kai tirama su theta bangų juostomis, tačiau nėra mediciniškai patvirtinta

Analizuojant EEG signalus reikėtų įvertinti galimų triukšmų atsiradimą. Dažniausiai pasitaikantys biologiniai artefaktai yra akių sukelti triukšmai (mirkčiojimas, akių judėjimas, papildoma akių raumenų veikla), EKG (širdies) artefaktai, EMG (raumenų aktyvumo) sukelti triukšmai ir pan. (Miller, 2007).

Daugeliu atveju smegenų veiklos sutrikimai yra diagnozuojami encefalogramomis, kai vizualiai apžiūrimas smegenų veiklos ritmiškumas EEG signaluose. Tačiau ilgos trukmės stebėjimai ir jų vertinimas vizualiai yra labai netikslūs, o laiko skalės EEG parametrų statistinės analizės išvis nepavyksta įgyvendinti. EEG signalo virpesių juostų pavyzdys pateiktas 5 pav.



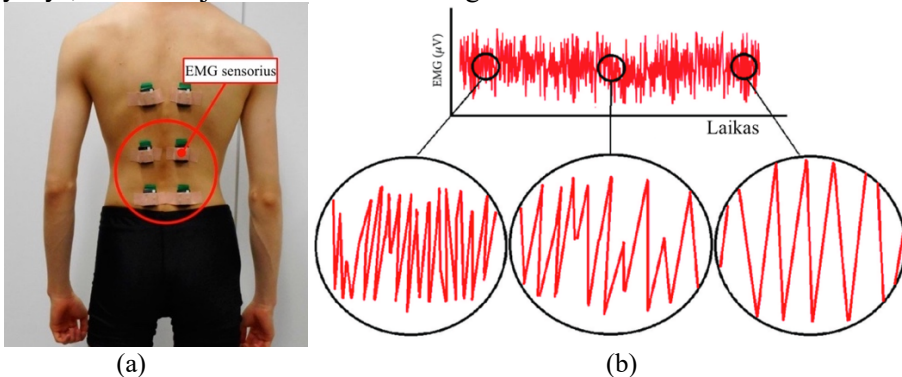
5 pav. EEG atskirų bangų virpesių pavyzdys (remiantis Ma, 2017)

Populiarėjant EEG signalų analizei vis dažniau tikrinami ir elektromiogramos signalai bei jų tarpusavio ryšys. Elektromiografija (EMG) yra diagnostikoje taikoma procedūra, kuri vertina nervų, raumenų bei juos kontroliuojančių nervinių ląstelių (motorinių neuronų) būklę (McCrary et al., 2018). Pacientams, turintiems nervų sistemos pažeidimų, sveikimo procese yra stengiamasi minimizuoti ir / ar kompensuoti susijusius funkcinės būklės pasikeitimus ar negalias. Taigi jei gydytojai,

reabilitologai ar kitas medicinos personalas nori pagerinti paciento funkcionalumą, turi atstatyti arba pakeisti tą neuroninio tinklo dalį, kuri tuo metu yra neveiksni. Dėl šios priežasties diagnostikoje reikia EMG ir EEG signalus analizuoti kompleksiskai (Manolova et al., 2017).

Žmogaus raumenų sistemos pagrindinė funkcija yra suteikti reikalingos jėgos, kai atliekami įvairūs kūno veiksmai. Ši sistema sudaryta iš nervų ir raumenų sistemų, kurios kartu suformuoja neuromuskulinę (nervų-raumenų) sistemą. Raumenų nuovargis gali būti sukeltas dėl kelių skirtingų raumenų pluoštų ar nervų, kurie retkarčiais suklaidina ir nutolina diagnozę nuo realių ligų bei simptomų. Todėl tikslus nuovargio vietos identifikavimas yra svarbiausia užduotis prieš paskiriant atitinkamą gydymą (Q. Wu et al., 2017).

Neinvasinis EMG registravimo būdas dar yra vadinamas S – EMG (angl. *surface electromyography*), kai elektrodai yra išdėstomi ant odos. Paviršinė elektromiografija dengia didelį motorinių vienetų skaičių ir yra fiksuojama taikant superpozicijos principą (De Rocha et al., 2018). Priklausomai nuo kurios raumenų grupės nuovargį norima pamatuoti, jutikliai išdėstomi taip, kad fiksuotų raumenų įsitempimus, pvz., konvejerinio tipo gamyboje paprastai yra statinis stovimas darbas, todėl registruojama šlaunies dvigalvio raumens – kaip stabilizuojančio raumens – elektromiograma, o daugelis ofiso darbuotojų sėdėdami suaktyvina viršutinės galūnės, tačiau didžiausias krūvis tenka nugaros tiesiesiems raumenims. 6 pav. (a) dalyje nuotraukoje matomas elektrodų išdėstymas nugaros srityje, norit pamatuoti nugaros raumenų įsitempimą sėdimo darbo metu. 6 pav. (b) dalyje pateiktas EMG pavyzdys, kai fiksuojamas raumens nuovargis.



6 pav. (a) Elektrodų išdėstymas registruojant paviršinę nugaros raumenų EMG; (b) EMG pavyzdys vargstančiam raumeniui (paremta Ito et al., 2018)

Šiame darbe buvo tiriami EEG signalai kaip vienas iš galimų elektrinių signalų filtravimo algoritmų panaudojimo būdų, tačiau nenaudojami vertinant fiziologinį nuovargį. Tuo tarpu, EMG signalai naudojami testuose raumenų nuovargiui identifikuoti skirtingo pobūdžio darbo metu. Visgi pagrindinis tyrimo tikslas išlieka EKG signalų apdorojimas ir tyrimas bei nuovargio identifikavimas.

1.1.3. Kompiuterinės ir mobilios technologijos elektrinių signalų apdorojimui

Tobulėjant technologijoms bei signalų registravimo įrenginiams atsiranda vis

didesnė paklausa duomenų apdorojimui ir anomalijų aptikimui realiu laiku. Tam stacionarus EKG registravimas tampa nepatogus, o kartais net neįmanomas. Dėl šios priežasties vis daugiau sportininkų domisi naujausiomis technologijomis bei įrenginiais (pvz., AliveCor (Peritz et al., 2015), CardioCore, Polar, LaPatch (S. Huang et al., 2018), Kaunas – krūvis, Shimmer3 (Sedighi Maman et al., 2017) ir kt.), galinčiais aptikti sutrikimus realiu laiku ir perduoti įspėjimus mobiliaisiais įrenginiais. Jei sveikatos būklės vertinimą būtų galima atlikti realiu laiku bei duomenis perduoti gydytojui internetu, tai paciento būklė būtų stebima nuolat be pasikartojančių apsilankymų gydymo įstaigoje. Tokiu būdu įvairius sveikatos sutrikimus būtų galima pastebėti laiku ir išvengi traumų. Įdiegus automatinį sveikatos vertinimą būtų galima sutaupyti medicininių išlaidų bei sumažėtų gydytojų darbo krūvis. Be to, vis dar yra nemažai šalių, kurios neturi ištobulintos sveikatos sistemos. Pacientų stebėjimas nuotoliniu būdu turėtų teigiamos įtakos tų šalių sveikatos sistemos tobulinimui bei padėtų suteikti tinkamas gydymo paslaugas laiku.

Biomedicinos inžinieriai yra suinteresuoti plėtra paskirstytų kompiuterinių sistemų, kurios leistų registruoti žmonių medicininius duomenis ir juos saugoti žiniatinklio serveriuose (Walker, 2017). Šiuo tikslu nuolat siūlomos ir plėtojamos naujos technologijos, tokios kaip kūno srities tinklas (angl. *body area network*, BAN) ir debesų kompiuterija, susietos su išmaniaisiais įrenginiais (telefonas, planšetė, išmanusis laikrodis). BAN yra nešiojamų kompiuterinių įrenginių belaidis tinklas, kuris šio darbo tyrimuose susideda iš elektrodų, signalų registravimo įrenginio bei išmanaus telefono arba planšetės. Tokių technologijų privalumai yra:

- Duomenys gali būti pasiekiami naudojant bet kokį įrenginį per naršyklę internetu bet kuriuo metu. Vartotojams nebereikia savo kompiuteriuose įsirašinėti daug vietos užimančių programų.
- Debesų kompiuterijos kaina yra gerokai sumažinta atsiradus Amazon EC2 ar Amazon S3, Deelman ir kitiems tiekėjams (Deelman et al., 2008).
- Duomenų apdorojimui ir saugojimui nereikia iš anksto įsigyti daug kompiuterio resursų, nes BAN tinklai yra elastingi ir, tik prireikus daugiau papildomų resursų, jie yra priskiriami (horizontalus mastelio keitimas) (Xia et al., 2013).

Nors debesų kompiuterija vis labiau plėtojama ir tobulinama, iki šiol vienas didžiausių iššūkių yra visapusiškas saugumas.

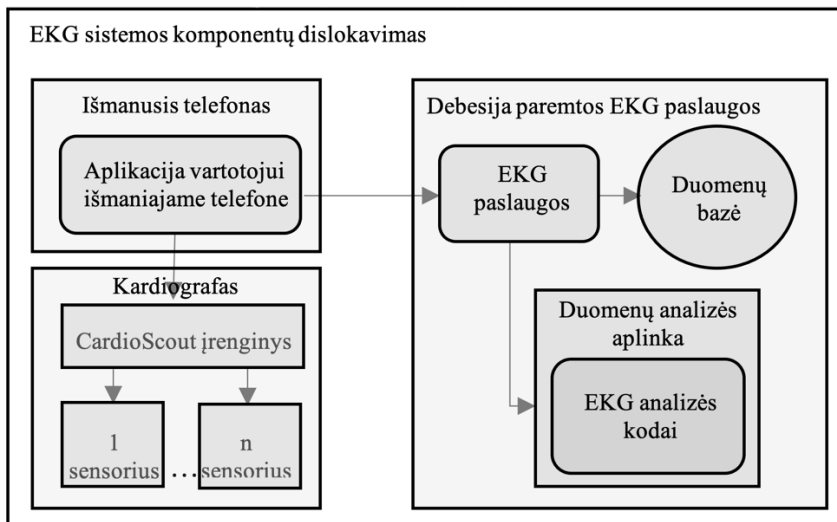
Sveikatos priežiūros centruose, klinikose ar išmanių namų aplinkoje yra populiarios paslauginės architektūros (angl. *serviceoriented architecture*, SOA) sistemos, skirtos sveikatos būklės stebėjimui. Šias sistemas daugiausia naudoja vyresnio amžiaus žmonės, pacientai, sportininkai ir pan. Viena populiariausių struktūrų yra trijų pakopų architektūros nuotolinio sveikatos stebėjimo sistema: belaidis kūno srities tinklas (angl. *wireless body area network*, WBAN), bendravimas ir darbo tinkle sistema bei paslaugų lygmuo. Pavyzdžiui, vienoje tokių sistemų yra nešiojami davikliai, kurie matuoja įvairius fiziologinius parametrus, tokius kaip spaudimas ar kūno temperatūra (Babu et al., 2013). Yra sveikatos priežiūros sistemų, paremtų panašiomis debesų technologijomis panaudojant medicininių duomenų saugyklas. Daiktų interneto (angl. *internet of things*, IoT) integracija į tokias sistemas gali pagerinti sistemų lankstumą, sąveikumą ar sumanumą (Ray, 2015). Įrenginiai,

paremti daiktų internetu (IoT), internete gali būti atpažinti bet kuriuo metu ir bet kur. Prie tokių įrenginių nuotolinio sveikatos stebėjimo sistemos per internetą gali automatiškai prisijungti ir dalintis informacija tarpusavyje ar su sveikatos institucija. Tai labai supaprastina diegimą, nustatymus ir administravimo uždavinius. Be to, yra sukurtos kelios sistemos, siunčiančios automatinis įspėjimus į arčiausią gydymo įstaigą, kai stebimam pacientui stipriai pablogėja sveikata ar įvyksta nelaimė (Miranda et al., 2016).

Sudėtingos sveikatos priežiūros sistemos paprastai nepasiteisina, nes sumažėja saugumas, o jų priežiūrai reikalingi kvalifikuoti informacinių technologijų specialistai, prižiūrintys visas sistemos sudedamąsias dalis. Buvo pasirinkta minimalios architektūros EKG stebėjimo sistema, paremta EKG apdorojimu naudojant debesų technologijas. Ji susideda iš tokių įrenginių:

- Širdies veiklos registravimo įrenginys su sensoriais, įgalintas registruoti žmogaus būklę ir teikti informaciją netoliese esančiam prijungtam įrenginiui.
- Prijungtas įrenginys, kuris surenka sensoriais gautą informaciją ir ją perduoda nuotoliniam kompiuteriui (serveriui).
- Kompiuteris (serveris), kuris gauna informaciją, duomenis saugo, analizuoja ir perduoda grįžtamąjį ryšį vartotojui.

Sistemos schema ir tarpusavio ryšiai pateikti 7 pav.

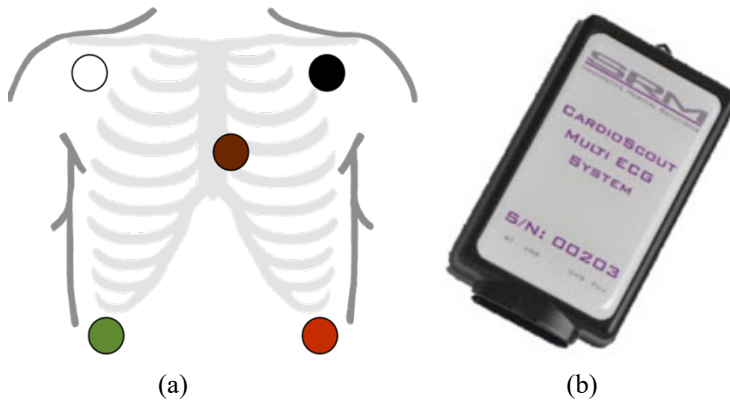


7 pav. Paslauginės architektūros sistemos komponentai

Tyrimai buvo atliekami naudojant signalus, kurie registruoti CardioScout įrenginiu (8 pav. (b)). Naudotas penkių ekranuotų laidų modulis. Elektrodai pagal spalvas aplink krūtinę išdėstyti taip, kad vienu metu būtų galima registruoti 3 derivacijas (8 pav. (a)). Iš jų galima išskaičiuoti dar dvi derivacijas. Tyrimams ir EKG parametrų vertinimui naudojama V5 derivacija, kuri yra pirmoji CardioScout registravimo įrenginyje.

Yra sukurta įvairių mobilių prietaisų EEG signalams registruoti ir analizuoti, tokių kaip Mindwave Mobile 2 (registruoja vieną EEG derivaciją), Bitalino (gali

vienu metu būti registruojami 5 skirtingi elektriniai signalai), Mind media Nexus 10 MKII (EEG registravimas ir programinės įrangos paketas signalų analizei). Vis didėjant tokių įrenginių asortimentui, gerėja ir sveikatos vertinimo sistemos, tačiau šiame darbe nenagrinėjami tokie prietaisai ar jais gauti elektriniai signalai.



8 pav. (a) Elektrodų vietos EKG registravimo metu; (b) CardioScout elektrinių signalų registravimo įrenginys

Ant kūno priklijuoti jutikliai (elektrodai) fiksuoja elektrinius signalus ir laidais perduoda CardioScout įrenginiui, kuris paverčia juos skaitmeniniais signalais ir Bluetooth ryšiu perduoda į mobilųjį telefoną ar planšetę. Gautų duomenų apdorojimui ir analizei EKG signalai perkeliama į kompiuterį ar debesis, kur suformuojamos išvados apie sveikatos būklę, fizinį parengtumą, nuovargį ir pan. Be to, pirminis duomenų apdorojimas bei grįžtamasis ryšys suformuojamas mobiliajame įrenginyje realiu laiku. Tai reikalinga, kad, pavyzdžiui, žmogus galėtų stebėti ir vertinti savo treniruotės intensyvumą.

1.2. EKG signalų tyrimų metodai

1.2.1. Širdies ritmo variabilumas

Širdies ritmo variabilumas (ŠRV) dažniausiai apibūdinamas kaip laiko intervalų tarp širdies dūžių variacijų indikatorius. Jis padeda suprasti, kaip gerai veikia žmogaus širdies kontrolės mechanizmas, bei suteikia galimybę aptikti mažus, bet ankstyvus ženklus apie galimus širdies ir kraujagyslių sutrikimus net žmogui jaučiantis gerai (Karmakar et al., 2015). ŠRV gali būti apibrėžiamas skirtingai, priklausomai nuo tyrimo srities ir naudojamų metodų (tiesiniai, netiesiniai, mišrūs ir pan.). Šiame darbe ŠRV aprašomi pokyčiai tarp vienas po kito einančių širdies tarpdūžinių intervalų, laiko skirtumai tiriami tarp gretimų širdies ciklų. Tai parodo nepertraukiamus momentinių širdies ritmų svyravimus. Šie svyravimai ne atsitiktiniai, o yra kaip atsakas į įvairias fiziologines būsenas ar tam tikras patologines būkles, reguliuojamas vidinės nervų sistemos ar kraujotakos (J. Wu et al., 2013). Tačiau tiek simpatinės, tiek parasimpatinės autonominės nervų sistemos dalys dalyvauja širdies ritmo reguliavimo procese. Suaktyvinta simpatinė nervų sistema didina širdies ritmą, bet kartu mažina ŠRV. Tuo tarpu, veikiant parasimpatinei nervų sistemai širdies ritmas

mažėja, o ŠRV – didėja (Nagaraja et al., 1997). Tokius dėsningumus galima paaiškinti tuo, kad veikiant simpatinei nervų sistemai siaurėja kraujagyslės ir kraujas keliauja iš organų, kurie reikalingi greitam organizmo „gelbėjimuisi“, į organus, kurie atsakingi už intensyvią fizinę veiklą. Parasimpatinė sistema yra atsakinga už „poilsio“ atsaką, atsirandantį kūnui atsipalaidavus. Taip pat ji mažina širdies darbą, mažina kraujospūdį. Organizmui esant pusiausvyroje, tiek simpatinė, tiek parasimpatinė nervų sistemos veikia darniai, o stresinėje situacijoje ar jaučiant nuovargį ryškesnė ir ilgiau veikianti tampa simpatinė dalis (Hristovski & Balagué, 2010).

Nuolat plėtojami laiko eilučių analizės metodai leido atpažinti ir kiekybiškai įvertinti reguliacinių mechanizmų elgseną fiziologinių sistemų kompleksinėje dinamikoje. Širdies dažnio variabilumo analizėje buvo pritaikyti tiesiniai ir netiesiniai metodai su įvairiomis prielaidomis, nuo periodinės elgsenos iki stochastinės laiko eilučių prigimties. Vis daugiau naujų metodų taikoma analizuojant širdies laiko eilutės tarpdūžinius intervalus ir jų tarpusavio ryšį skirtingose laiko skalėse (Mantica et al., 2017). Svarbu suprasti, kad analizei reikšmingas yra ne vien širdies ritmas, bet ir tai, kaip jis kinta. Didelis ŠRV dažniausiai reiškia gerą savijautą ir tinkamą širdies darbą, nes, kuo širdis daugiau dirba, tuo žmogus yra labiau pasiruošęs didesniam fiziniam ar protiniam krūviui. Tuo tarpu, mažas ŠRV gali būti siejamas su ligos simptomais (Monaco et al., 2017). Širdies ritmo variabilumas gali būti matuojamas įvairiais būdais ir įvairiomis metrikomis.

ŠRV pagrįstas R-R intervalų, kurie nustatomi iš elektrokardiogramos signalo, analize. Paprastai širdies variabilumas analizuojamas dvejopai: laiko ir dažnių atžvilgiu. Laiko skalėje gali būti pritaikyti statistinių momentų skaičiavimai, tokie kaip standartinis nuokrypis. Tuo tarpu, dažnių skalėje ŠRV modeliuojamas išryškinant analizei ir diagnostikai reikšmingus dažnius pagal galios spektro tankį (apskaičiuojama iš amplitudžių spektro). Tokie skaičiavimo metodai paprastai apsiriboja signalo laiko ar dažnių skalių tiesinių sistemų įvertinimu. Pastaraisiais metais išpopuliarėjo mišrūs analiziniai metodai bei netiesinės sistemos. Naudojami širdies variabilumo analizės ir vertinimo metodai gali būti suskirstyti į grupes (Germán-Salló & Germán-Salló, 2016):

- *Laiko skalės analizė.* Šios kategorijos metodai R-R intervalų seką traktuoja kaip netvarkingą grupę intervalų (arba intervalų porų) ir pritaiko įvairius metodus, aprašančius tokių duomenų dispersiją. Gretimi normalūs kardiociklai žymimi *RR* ir matuojami sekundėmis (s) arba milisekundėmis (ms). Tokių intervalų seka dar yra vadinama ritmograma. Sveiko žmogaus rimties būsenoje *RR* intervalai gali svyruoti nuo 0,6 s iki 1,2 s. Laiko skalės parametrais gali būti laikomi parametrai, tokie kaip intervalų vidurkis (*MRR* arba *RR*), kvadratinė šaknis iš dispersijos (*SDRR*), vienas po kito einančių gretimų intervalų standartinė paklaida (*SENN*), nuoseklių intervalų porų santykis, kai skiriasi daugiau nei 50 ms (*pNN50%*) (Zangróniz et al., 2018), standartinis nuokrypis atmetus mastelį (*SDSD*) (Torabi Haghighi & Kløve, 2015), kvadratinė šaknis iš vidurkio sumos kvadratinų skirtumų tarp gretimų R-R intervalų (*RMSSD*), *RMSSD* logaritmas (*LnRMSSD*) (Schmitt et al., 2015) ir kt. Visi šie trumpos trukmės variacijos matavimai aprašo aukšto dažnio širdies ritmo variacijas bei turi didelę tarpusavio koreliaciją. Jei analizuojami ilgos trukmės signalai (24 valandų), tai skaičiuojami sudėtingesni statistiniai parametrai (Peng et al., 1995),

kurie gali būti suskirstyti į dvi klases, priklausomai nuo signalų kilmės: (a) momentinio širdies ritmo ir (b) skirtumų tarp R-R intervalų.

Vienas po kito einančių R-R intervalų seka gali būti apibrėžiama taip: RR_1, RR_2, \dots, RR_n , kur n parodo intervalo numerį ir vietą eilutėje (Vollmer, 2015). Pažymėjus N kaip analizuojamų širdies dūžių skaičių, pagrindiniai laiko skalės parametrai aprašomi formulėmis:

1) R-R intervalų vidurkis \overline{RR} :

$$\overline{RR} = \frac{1}{N} \sum_{n=1}^N RR_n. \quad (1)$$

2) Kvadratinė šaknis iš dispersijos (standartinis nuokrypis, SDRR), kuri atspindi visapusiškus (tiek ilgos trukmės, tiek trumpos) pokyčius R-R intervalų eilutėje:

$$SDRR = \sqrt{\frac{1}{N} \sum_{n=1}^N (RR_n - \overline{RR})^2}. \quad (2)$$

3) Gretimų RR intervalų skirtumų standartinis nuokrypis (SDSD):

$$SDSD = \sqrt{\frac{1}{N} \sum_{n=1}^N [(RR_n - RR_{n+1}) - (\overline{RR} - RR_{n+1})]^2}; \quad (3)$$

čia RR_n ir RR_{n+1} yra gretimi R-R intervalai.

4) Standartinio nuokrypio kvadratinis vidurkis (RMSSD):

$$RMSSD = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (RR_{n+1} - RR_n)^2}; \quad (4)$$

5) Variacijos koeficientas CV – tai diskretus indeksas, apskaičiuojamas standartinį nuokrypį padalinus iš vidurkio:

$$CV = \frac{SDRR}{\overline{RR}} \cdot 100\%. \quad (5)$$

Nors ši metodika neretai naudojama ir duoda gerus rezultatus širdies ligų diagnostikoje (miokardo infarkto, aritmijos nustatymui ir kt.), informacija apie EKG signalus yra ribota, nes esanti netiesinė signalo dinamika lieka neįvertinta (Yaghoobi Karimui & Azadi, 2017).

• *Dažnių skalės analizė.* Galios spektro tankio analizė suteikia informacijos apie galios (dispersijos) tvarkingai išdėstytų R-R intervalų dažnių funkcijos pasiskirstymą. ŠRV galios spektro tankis skirstomas į tris pagrindines dažnių juostas: labai žemo dažnio juosta (VLF: 0.0033 – 0.04 Hz), žemo dažnio juosta (LF: žmonėms 0.04 – 0.15 Hz) ir aukšto dažnio juosta (HF: žmonėms 0.16 – 0.4 Hz). Pažymėjimai HF ir LF reiškia analizuojamo signalo atitinkamų dažnių juostų galios vidurkį. Aukšto dažnio svyravimai žymi nervų sistemos moduliacijas. Žemo dažnio svyravimai yra sukelti kintant simpatinei nervų sistemai kartu su barorefleksu mechanizmu (Camm & Lu, 2018). Yra žinoma, kad dažnių skalės indeksai (Ramalho et al., 2017) kiekybiškai aprašo ŠRV ir esant įvairiems patologiniams sutrikimams įgyja mažas reikšmes (X.

Chen et al., 2017; Gautam & Giri, 2016). Neretai rezultatų palyginimui naudojamos normuotos dažnių juostos galios reikšmės. Normavimas atliekamas tokiu būdu:

$$LF_{norm} = \frac{LF}{LF + HF}, \quad HF_{norm} = \frac{HF}{LF + HF}. \quad (6)$$

- *Laiko-dažnio analizė.* Laiko-dažnio analizė parodo laiką, kai pasirodo įvairūs dažniai, dažniausiai skaičiuojant spektrą pastoviam laiko intervale (Verlinde et al., 2001). Vieni populiariausių tokio tipo metodų yra diskrečiosios bangelių transformacijos algoritmas (DWT). Bangelių analizė suteikia informacijos apie skirtingų dažnių komponentų laiko lokalizacijas, kurios yra svarbus įrankis sistemos dinamikos pokyčiams ir struktūrai nustatyti. Ji naudojama diskrečių laiko eilučių signalams apdoroti, tokiems kaip EKG ar R-R intervalų duomenų sekos.

- *Netiesinė analizė.* ŠRV netiesinio matavimo metodai yra paremti ŠRV charakteristikų tarpusavio priklausomybės analize ir kiekybiškai vertina R-R laiko eilutės struktūrą bei sudėtingumą. Paprastai triukšmingi EKG signalai yra nestacionarūs ir netiesiniai. Širdies variabilumo dinamikos analizės metodai yra paremti chaoso ir netiesinių sistemų teorijomis, nes mechanizmai, reguliuojantys širdies ir kraujagyslių sistemas, tikėtina, sąveikauja tarpusavyje netiesiškai (Castaño et al., 2019). Svarbiausi indeksai, aprašantys netiesinę širdies ritmo dinamiką, yra trumpos trukmės fraktalinės eksponentės, kurios nustatomos išanalizavus betrendžius svyravimus (angl. *detrended fluctuation analysis*, DFA), Liapunovo eksponentės, koreliacijos dimensijos ir pan. (Muduli & Mukherjee, 2017). Mokslininkai yra atlikę įvairių tyrimų (Lin et al., 2018) ir pastebėjo, kad ŠRV gali būti aprašomas entropijos indikatoriais. Yra daugybė entropijos skaičiavimo metodų, kurie gali būti naudojami vertinant ŠRV, pavyzdžiui, imties entropija (SampEn), apytikslė entropija (ApEn) ar Kolmogorovo entropija (Fell et al., 2000). Jos naudojamos kaip EKG parametru dinamikos sudėtingumo matas ir gali būti įvardijamos kaip vienas iš įrankių siekiant aptikti širdies ir kraujagyslių sistemos sutrikimus (Orphanidou & Drobnjak, 2017; Zhao et al., 2018). Tačiau entropijos turi keletą esminių trūkumų: stipri priklausomybė nuo nagrinėjamo signalo ilgio, rezultatų nepastovumas ir skaičiavimo paklaidos (Yi et al., 2018). Netiesinei ŠRV analizei priskiriama ir Poincare parametru vertinimas kartu su diagramomis. Platesnis šio metodo aprašymas pateiktas 2.2.3 poskyryje.

ŠRV neretai yra apskaičiuojamas ir įvertinamas naudojant indeksus, tokius kaip Ploto, Porta, Guzik ar nuolydžio indeksai (Karmakar et al., 2015). Jie remiasi duomenų asimetrijos matavimu didėjant atstumui tarp kiekvieno taško ir lygio linijos ar fazės kampo. ŠRV vertinimas naudojant įvairius indeksus yra patogus tuo, kad skaičiavimai paprastai yra nesudėtingi ir nereikalauja daug laiko ar kitų resursų, tačiau jie retai atspindi netiesinę širdies dinamiką. Dėl to indeksai retai naudojami ligų ar širdies veiklos sutrikimų identifikavimui.

1.2.2. Signalų tyrimo metodai

Norint gauti bendrą signalo svyravimų vaizdą, dažnai pirmiausia reikia atlikti dalinį „glodinimą“, t. y. pašalinti nežymius registravimo triukšmus bei atmesti nedidelius signalo svyravimus (osciliacijas).

Algoritmai, skirti signalų apdorojimui, gali būti suskirstyti į veikiančius laiko t srityje ir veikiančius dažnio srityje. Pirmieji algoritmai operuoja tiesiogiai su signalo

reikšmėmis. Antrosios grupės metodai pirmiausiai išskiria signalo spektrą, parodantį, kokių dažnių svyravimai sudaro signalą bei koks yra atskirų dažnių intensyvumas.

Tiesiniai filtravimo metodai, tokie kaip Wiener filtras (Proakis & Manolakis, 1996) ar išskaidymas singulariomis reikšmėmis (angl. *singular value decomposition*, SVD) (Yücelbaş et al., 2018), yra nesudėtingai aprašomi ir pritaikomi, tačiau efektyvumas sumažėja, jei mažame laiko intervale susidaro smailūs kampai ar impulsai. Be to, realūs signalai neretai būna nestacionarūs ir kintantys laike. Taip pat tiesiniai duomenų glodinimo metodai neretai filtruojant suformuoja laiko atsilikimus (Morales et al., 2016). Signalų, tokių kaip EKG, savybės bei cikliškumas išsaugomas naudojant sudėtingesnius filtras, tokius kaip bangelių transformacijos metodas (angl. *discrete wavelet transform*, DWT) ar nepriklausomų komponentų analizė (angl. *independent component analysis*, ICA) (Ziani et al., 2018). Šie algoritmai yra tinkami elektrokardiogramos signalų filtravimui, tačiau sąlyginai sudėtingi realizuoti ir tinkamas EKG parametrų parinkimas gali užtrukti dėl didelio jų kiekio.

Universalūs algoritmai, tokie Butterworth filtras (Jagtap & Uplane, 2012), yra plačiai naudojami medicininių signalų apdorojimui. Jie efektyviai veikia norint sumažinti tiek žemo, tiek aukšto dažnio triukšmus įvairių tipų signalams: didelio greičio video, jėgos platformoms, akselometro signalams ir pan. (Tsuzuki & Ogihara, 2018). Aukšto dažnio Butterworth filtras nepakeičęs praleidžia dažnius, kurie didesni nei apibrėžtas ribinis dažnis f_c . Tuo tarpu, sinusoidės, kurių dažniai yra mažesni nei f_c , yra susilpninamos ir efektyviai pašalinamos iš išvesties signalo. Nors filtravimo poveikis panašus į kitus aukšto dažnio filtras, gali atsirasti netikslumų (pvz., gali pasikeisti laiko skalės parametrų reikšmės) dėl laiko vėlinimo. Apskritai, išvesties signalas yra laikomas tam tikra įvesties signalo pavėlinta, uždelsta versija. Taip yra todėl, kad įprasti aukšto ar žemo dažnio fiksuotos eilės ir ribinio dažnio filtrai uždelsia skirtingų dažnių sinusoides nevienodai. Šis nepageidaujamas, bet kartu neišvengiamas filtravimo reiškinys yra apeinamas naudojant Butterworth filtrą. Tokiu atveju atvirkštine tvarka perfiltruojami jau filtruoti signalai, kur vėlinimas atliekamas atvirkštine tvarka ir duomenys grįžta į pradinę būseną laiko skalės atžvilgiu (Manal & Rose, 2007).

Tarkime, f yra dažnis, o $X(f)$ ir $Y(f)$ žymi dažnių srities įvesties ir išvesties signalus. Tiesinio filtro atveju įvesties ir išvesties signalai aprašomi naudojant perkėlimo funkciją $H(f)$ tokiu būdu:

$$Y(f) = H(f)X(f). \quad (7)$$

Jei $H(f)$ yra žinomas, tai nuo dažnio priklausomas vėlinimas $d(f)$ gali būti apskaičiuotas tokiu būdu:

$$d(f) = -\frac{1}{2\pi} \frac{d}{df} \Phi(H(f)); \quad (8)$$

čia $\Phi(H(f))$ yra $H(f)$ fazė. Analogiškas aukšto dažnio N -tos eilės Butterworth filtras turi perkėlimo funkciją:

$$H_N(f) = \frac{1}{a_0 + a_1(i2\pi f) + \dots + a_N(i2\pi f)^N}; \quad (9)$$

čia $i = \sqrt{-1}$, $a_0 = 1$, o a_1, \dots, a_N yra filtravimo koeficientai. Tada N -tos eilės Butterworth filtro dažnių vėlinimai $d_N(f)$ yra apskaičiuojami cikliškai:

$$d_N(f) = \frac{\sum_{i=0}^{N-1} p_{2i} (2\pi f)^{2i}}{1 + (f/f_c)^{2N}}, \quad (10)$$

$$p_{2i} = \sum_{j=0}^i (-1)^j (2j+1) a_{i-j} a_{i+j+1}; \quad (11)$$

čia a_k yra filtravimo koeficientai, kurie lygūs nuliui, kai $k > N$ (Manal & Rose, 2007).

EKG signalų filtravimui Butterworth metodą naudoja ir Lietuvos mokslininkai (Marozas et al., 2011; Stasiūnas et al., 2012). Neretai šis algoritmas yra prijungiamas prie kitų metodų, kurie paremti neuroniniais tinklais, bangelių transformacijos algoritmais (Liu et al., 2018). Paprastai tokie skaičiavimai trunka labai ilgai EKG triukšmų šalinimo apsimokymo procese ar filtravimo parametrų nustatymo metu.

Stacionarioje būsenoje registruotų EKG signalų filtravimas yra plačiai ištirtas taikant įvairias metodologijas aukšto dažnio triukšmų sumažinimui. Tuo tarpu, judesio metu registruoti medicininiai signalai (EKG, EEG ir EMG) yra labiau užteršti įvairiais aplinkos veiksniais, tokiais kaip elektrodų atlaisvėjimas, nuolatinis raumenų darbas, odos įtempimai ir atpalaidavimai, laidų judėjimas ir pan. Taip pat atsiranda labai stiprūs ir nepastovūs amplitudiniai svyravimai, kurių metu išryškėja nestacionarus žemo dažnio triukšmas – trendas. Dėl šios priežasties įprastiniai signalų apdorojimo metodai tampa neefektyvus arba netikslūs, todėl kyla poreikis taikyti ne vieną, o keletą filtravimo algoritmų (trendo pašalinimui ir aukšto dažnio triukšmų sumažinimui) vienu metu. Kadangi signalai registruojami realiu laiku ir tikimasi gauti grįžtamąjį ryšį iš karto, reikalinga ne tik tinkamai pasirinkti jų apdorojimo metodus, bet ir optimizuoti bei patobulinti taip, kad visi skaičiavimai vyktų be didelių vėlinimų.

Vienas paprasčiausių ir labiausiai naudojamų trendo pašalinimo metodų yra slenkančio vidurkio algoritmas. Esant nežymiems EKG amplitudiniams svyravimams, šis algoritmas be sudėtingų skaičiavimų aptinka ir pašalina nuokrypius nuo izolinijos (Momot, 2009). Šis filtras gali būti aprašomas formule:

$$y(n) = \frac{1}{2N+1} \sum_{i=-N}^N x(n+i); \quad (12)$$

čia $x(n)$ ir $y(n)$ yra įvesties signalas ir išvesties signalas, kuris gaunamas panaudojus slenkančio vidurkio algoritmą; N aprašo imties dydį. Filtruotas signalas $z(n)$ yra randamas tokiu būdu:

$$z(n) = x(n) - y(n). \quad (13)$$

Slenkančio vidurkio algoritmas tinka tada, kai turime nemažai informacijos apie patį EKG signalą bei triukšmus. Esant didesniems bazinės linijos svyravimams, šis metodas daro vis didesnes paklaidas, nes artimų reikšmių vidurkio skaičiavimas pačio signalo nebegali pakoreguoti. Tuo tarpu, pasirinkus platų EKG reikšmių intervalą, suvidurkinamos ir tam tikros signalo dalys, kurios reikalingos parametrų aptikimui, bei prarandama svarbi informacija apie galimas širdies patologijas. Yra sukurta daugybė šio algoritmo patobulinimų, tokių kaip statistinių svorių įvedimas (Hu et al., 2011), slenkstiniai apribojimai (Nguyen et al., 2019), periodiškumo įvertinimas (Lee, 2014) ir kiti. Visgi tam tikrais atvejais šis algoritmas neefektyvus, ypač kai EKG signalo amplitudiniai svyravimai vyksta nuolat ir yra nestacionarūs.

Didelė dalis signalo apdorojimo algoritmų prieš filtravimą atlieka pačio signalo transformaciją. 1807 m. Ž. B. Ž. Furje nustatė, kad bet koki signalą $x(n)$ galima išskaidyti į tam tikrų sinusų ir kosinusų sumą:

$$x(n) = \frac{a_0}{2} + \sum_{k=1}^{\infty} a_k \cos(kn) + \sum_{k=1}^{\infty} b_k \sin(kn), n \in [-\pi; \pi]; \quad (14)$$

čia n yra laikas, k – kampinis dažnis, o koeficientai a_0, a_k, b_k – vadinami Furje koeficientais, kur laisvasis skleidinio narys $\frac{a_0}{2}$ nusako signalo $f(n)$ vidurkį:

$$\frac{1}{2\pi} \int_{-\pi}^{\pi} f(n) dn = \frac{a_0}{2}. \quad (15)$$

Signalo $f(n)$ Furje skleidinio komponentų dariniai, kurie turi vienodą dažnį, yra vadinami harmonikomis, pavyzdžiui, $a_1 \cos n + b_1 \sin n$ – pirmoji harmonika, $a_2 \cos 2n + b_2 \sin 2n$ – antroji harmonika ir t. t. Signalo tyrimas, paremtas jo harmonikų analize, yra vadinamas *spektrine*, arba *Furje, analize*. Toks Furje skleidinio aprašymas tinka tik tada, kai analizuojami signalai yra periodiniai. Praktikoje taip yra retai, todėl laiką n reikia analizuoti kaip kintantį visame stebėjimo intervale, kuris ir yra vienas periodas T , t. y. $n \in [0; T]$ (Šmidaitė, 2017):

$$x(n) = \frac{a_0}{2} + \sum_{k=1}^{\infty} a_k \cos(\omega_0 kn) + \sum_{k=1}^{\infty} b_k \sin(\omega_0 kn); \quad (16)$$

čia $\omega_0 = \frac{2\pi}{T}$. Koeficientai a_k ir b_k randami apskaičiuojant integralus:

$$a_k = \frac{2}{T} \int_0^T f(n) \cos(\omega_0 kn) dn, \quad k = 0, 1, \dots, \quad (17)$$

$$b_k = \frac{2}{T} \int_0^T f(n) \sin(\omega_0 kn) dn, \quad k = 1, 2, \dots \quad (18)$$

Be to, Furje skleidinį taip pat galima apibrėžti kompleksinių funkcijų bazėje:

$$\begin{aligned} x(n) &= c_0 + \sum_{k=1}^{\infty} (c_k - c_{-k}) \cos(\omega_0 kn) + \sum_{k=1}^{\infty} i(c_k - c_{-k}) \sin(\omega_0 kn) \\ &= \sum_{k=-\infty}^{\infty} c_k e^{i\omega_0 kn}; \end{aligned} \quad (19)$$

čia i yra menamasis vienetas, k – signalo kompleksinis spektras (kintantis nuo $-\infty$ iki ∞), c_k – kompleksiniai Furje koeficientai, kurie randami apskaičiuojant integralą (Meškauskas, 2017):

$$c_k = \frac{1}{T} \int_0^T x(n) e^{-i\omega_0 kn} dn; \quad (20)$$

čia $k = 0, \pm 1, \pm 2, \dots$. Kompleksinių Furje koeficientų modulių seka $|c_k|$ dar yra vadinama *amplitudžių spektru*. Jis parodo, kokia yra kiekvienos signalo harmonikos įtaka bendroje komponentų sumoje. Be to, koeficientų argumentų seka

$\arg(c_k)$ vadinama *fazių spektru*, o $|c_k|^2$ – *galios spektru* (Juozapavičius & Meškauskas, 2011).

Praktikoje įprastai analizuojant signalus naudojama diskrečioji Furje transformacija. Tarkime, turime diskretųjį signalą $x_0, \dots, x_j, \dots, x_{p-1}$, tada diskrečiąją Furje transformaciją galima išreikšti:

$$c_k = \frac{1}{p} \sum_{j=0}^{p-1} x_j e^{-i \frac{2\pi}{p} j k}. \quad (21)$$

Išraiška, kuri leidžia iš spektro c_k atkurti skaitmeninį diskretųjį signalą $x_0, \dots, x_j, \dots, x_{p-1}$, dar yra vadinama atvirkštine diskrečiąją Furje transformacija ir gali būti užrašoma tokiu būdu:

$$x_j = \sum_{k=0}^{p-1} c_k e^{i \frac{2\pi}{p} k j}; \quad (22)$$

čia $j = 0, 1, \dots, p - 1$.

Signalų apdorojimui taip pat yra naudojama jungtinė laiko-dažnių analizė. Vienas populiariausių tokių metodų yra bangelių transformacija (angl. *wavelet transform*). Bangelių analizė išskaido laiko eilutę į skirtingų dažnių komponentes ir tada kiekvieną komponentę tiria atskirai atitinkamoje laiko skalėje. Diskrečiųjų bangelių transformacijos algoritmas (DBT) (angl. *discrete wavelet transform*, DWT) yra efektyvus norint išskaidyti signalą į aproksimacijos (žemo dažnio) ir pagrindinius (aukšto dažnio) koeficientus (Shahbakhti, 2015). Metodas paprastai yra sudarytas iš kelių lygių, kuriuose į aukštesnį filtravimo lygį pereina tik gauti aproksimacijos koeficientai (Jenkal et al., 2016). Prieš atliekant signalo išskaidymą būtina apibrėžti pagrindinę (angl. *mother wavelet*) bangelę ir signalo skaidymo lygių skaičių. Pagrindinės bangelės funkcija $\psi_{a,b}(n)$ gali būti aprašoma tokiu būdu:

$$\psi_{a,b}(n) = \frac{1}{\sqrt{a}} \psi\left(\frac{n-b}{a}\right); \quad (23)$$

čia b yra postūmio parametras, o a – mastelio keitimo parametras, n – laikas (Garg et al., 2010). Visos kitos bangelių transformacijos yra pakeisto mastelio pagrindinės bangelės kopijos. Kai $|a| > 1$, mastelis išsitempia ir, priešingai, kai $|a| < 1$ – susispaudžia. Tolydžiuoju atveju bangelių transformacijos funkciją galima užrašyti taip:

$$W_x(a, b) = \int_{-\infty}^{\infty} x(n) \psi_{a,b}(n) dn. \quad (24)$$


Elektriniai signalai registruojami tam tikrais laiko momentais, o diskretiems signalams $x_0, \dots, x_j, \dots, x_{n-1}$ sudaromas diskrečių reikšmių tinklelis (Šmidaitė, 2017). Paprastai yra naudojamas dvejetainis tinklelis (angl. *digital grid*), kai parenkami parametrai $b = 1$ ir $a = 2$ (Giri et al., 2013):

$$\psi_{i,k}(n) = \frac{1}{\sqrt{a^i}} \psi\left(\frac{n - k b a^i}{a^i}\right) = \frac{1}{\sqrt{2^i}} \psi(2^{-i} n - k). \quad (25)$$

Diskrečių bangelių algoritmą galima suskaidyti į tris pagrindines dalis:

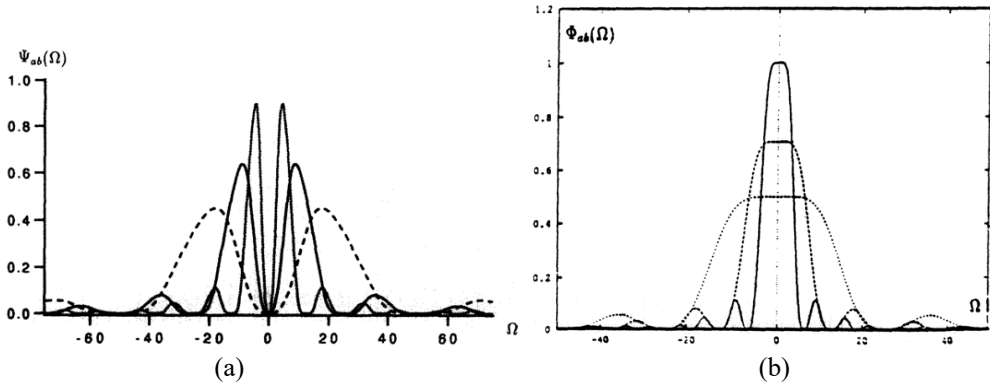
- Atliekama diskrečiųjų bangelių transformacija triukšmingam signalui;

- Tam tikrų slenkstinių funkcijų pagalba dalis bangelių koeficientų yra priskiriami nuliui (pašalinami). Pagrindinė šio proceso idėja yra ta, kad maži bangelių koeficientai laikomi triukšmu, todėl turi būti nufiltruoti nuo pagrindinio signalo koeficientų reikšmių;
- Atliekama atvirkštinė bangelių transformacija, kurios metu filtruotas signalas vėl pakeičiamas į laiko skalės išraišką.



9 pav. Diskrečių bangelių transformacijos algoritmo dalys

Diskrečių bangelių transformacijos algoritmo schema pateikta 9 pav. (S. W. Chen & Chen, 2015). Schemoje y_j yra bangelių koeficientai po transformacijos, y_{tj} – koeficientai, likę po slenkstinių funkcijų panaudojimo ($j \geq t$). Viduriniajame sluoksnyje naudojamos slenkstinės funkcijos gali turėti skirtingus filtravimo koeficientus. 1988 m. Ingrid Daubechies aprašė ortogonalinių funkcijų šeimą (Daubechies & Paul, 1988), kurioje kiekviena grupė turi mastelio keitimo funkcijas, generuojančias skirtingus filtravimo koeficientus. Tos funkcijos ir yra vadinamos bangelėmis. Aukštesnės eilės funkcijos tikslesnės, tačiau kartu reikalauja daugiau skaičiavimo resursų. Vienas iš tokių bangelių pavyzdžių pateiktas 10 pav.



10 pav. Daubechies (6 dažnio juostų): (a) bangelių funkcija ir jos plėtiniai; (b) mastelio keitimo funkcija ir jos plėtiniai, kai $a = 2$ kartu su dažnio atsaku (remiantis Akansu & Haddad, 2001)

Tarkime, norima apibrėžti savybes periodinei funkcijai $H_0(e^{j\omega})$ (periodas $T_0 = 2\pi$) taip, kad begalinė sandauga konverguotų į glodžią funkciją:

$$\Phi(\Omega) = \prod_{k=1}^{\infty} H_0(e^{j\omega/2^k}); \quad (26)$$

čia j yra ortogonalios komponentės eilės numeris, Ω ir ω – dažnio kintamieji, kur ω – diskretaus, o Ω – tolydaus laiko signalų atveju. Be to, $\Omega = \omega$, kai $T_0 = 1$. Tada tinkamas mastelio keitimo funkcijų tvarkingas išdėstymas gali būti apibrėžtas kaip didžiausia laipsnio v reikšmė (Bull, 2014), su kuria tenkinama sąlyga:

$$|\Phi(\Omega)| \leq \frac{c}{(1 + |\Omega|)^{v+1}}, \quad \Omega \in R; \quad (27)$$

čia c yra mastelio keitimo koeficientas. Tai, savo ruožtu, reiškia, kad nykstanti funkcija $\Phi(\Omega)$ apibrėžia taisyklingumą, t. y. glodumą. Sakykime, kad filtravimo funkcija $H_0(z)$ turi L nulių, kai $z = -1$ ir kad tai yra $N - 1$ laipsnio baigtinio impulso atsako filtras (angl. *finite impulse response*). Tada:

$$H_0(z) = \left(\frac{1 + z^{-1}}{2}\right)^L P(z), \quad H_0(1) = 1. \quad (28)$$

Daubechies bangelių funkcijų glodumas didėja tiesiškai kartu su atitinkamu pločiu, t. y. baigtinio impulso atsako filtro ilgiu. Tačiau tiek Daubechies, tiek 1995 metais Lagarias įrodė, kad maksimaliai plokščias sprendinys nepasako, jog bangelė yra glodžiausia (Lagarias & Wang, 1995).

Mokslininkas Ivan W. Selesnick kartu su kolegomis 2014 metais pasiūlė chromatogramų bazinės linijos nustatymui naudoti vienu metu žemo dažnio filtras ir nutriukšminimą (angl. *baseline estimation and denoising with sparsity*, BEADS) (Ning et al., 2014). Kaip žemo dažnio filtrą jie pasirinko tiesinį ir netiesinį filtravimo būdą, arba kitaip – daugiaskalį bangelių algoritmą, ir jį patobulino įterpdami santykinius dalinius denginius tarp spektro ir pikų. Šį metodų junginį pritaikė chromatogramų bazinės linijos išskyrimui ir triukšmų sumažinimui. Jų pasiūlytas algoritmas remiasi chromatogramos pikų eilutės modeliavimu kaip nedidelės (siauros) sklaidos su jos išvestinėmis forma kartu modeliuojant trendą kaip žemo dažnio signalą. Šis metodas tinka nestacionarių signalų apdorojimui, nes filtravimo metu yra naudojamos baudos funkcijos, kurios yra parenkamos priklausomai nuo analizuojamų duomenų savybių. Keli simetrinių baudos funkcijų pavyzdžiai pateikti 3 lentelėje.

3 lentelė. Simetrinių baudos funkcijų pavyzdžiai ir jų išvestinės

	$\varphi(x)$	$\varphi'(x)$
$\varphi_A(x)$	$ x $	$sign(x)$
$\varphi_B(x)$	$\sqrt{ x ^2 + \varepsilon}$	$\frac{x}{\sqrt{ x ^2 + \varepsilon}}$
$\varphi_C(x)$	$ x - \varepsilon \log(x + \varepsilon)$	$\frac{x}{x + \varepsilon}$

Kadangi judesio metu gauti EKG signalai yra chaotiški ir svyravimai itin ryškūs amplitudės atžvilgiu, bet nėra labai padriki laiko atžvilgiu, tai patį judesį ir nuo jo atsiradusius svyravimus galima laikyti žemo dažnio triukšmu. Šiame darbe EKG signalų bazinės linijos nustatymui buvo pasirinktas BEADS metodas ir patobulintas įvedant papildomą filtravimo parametru nustatymo algoritmą. Į tikslo funkciją BEADS algoritmo parametru dinaminiam parinkimui įterptas rastų QRS intervalų skaičiaus vertinimo algoritmas. Jį naudojant parenkami tokie filtravimo parametrai,

su kuriais po žemo dažnio triukšmo pašalinimo randama daugiausia QRS kompleksų. Tai ypač aktualu, kai analizuojamų signalų amplitudiniai svyravimai yra nestacionarūs ir kiekvienas EKG signalas turi skirtingus filtravimo parametrus.


1.2.3. EKG parametrų paieškos metodika

Klinikinėje diagnostikoje R-R intervalai ir QRS kompleksai yra svarbiausi ir dažniausiai naudojami elektrokardiogramos parametrai. Yra sukurta daug metodų įvairių EKG bangų aptikimui. Vieną pirmųjų metodų 1985 metais pasiūlė mokslininkai J. Pan ir W. Tompkins (Pan & Tompkins, 1985). Jų algoritmas rėmėsi skirtingų dažnių filtrų panaudojimu tam pačiam signalui, kad išryškintų greitos širdies depolarizacijos metu atsiradusius dažnius ir eliminuotų aplinkos trikdžių sukeltą triukšmą. Gautas signalas padidinamas jį keliant kvadratu. Galiausiai naudojami adaptyvūs slenksčiai, kuriais ir nustatomi EKG signalo bangų danteliai bei apskaičiuojamas QRS kompleksas. Mokslininkai teigė, kad jų algoritmas aptiko 99,3 % visų QRS kompleksų teisingai. Kiti panašūs bangų paieškos algoritmai naudoja atitikties filtrus (Xue et al., 1992), neuroninius tinklus (McBride et al., 2011), laiko-dažnio dekompozicijos metodus (Xia et al., 2012), genetinius algoritmus (Gacek & Pedrycz, 2003), paslėptus Markovo modelius (Clifford et al., 2006). Hilberto ilgio ir energijos transformacijos, MODB algoritmai, kurie remiasi kelių signalų išvestinio produkto reikšmėmis, taip pat gali būti naudojami QRS intervalo aptikimui (Köhler et al., 2002). Pastaraisiais metais buvo ištobulinti bangelių transformacijos metodai taip, kad būtų patikimi EKG signalo segmentavimui. Naudojant bangelių transformacijos metodą QRS kompleksas atskiriamas nuo P ar T bangų, triukšmo, bazinės linijos deviacijos ir artefaktų. Taip pat gali būti įvertinamos ir nustatomos įvairios EKG signalo dalys, ypač QRS komplekso, T ar P bangų pradžios vietos (Ghasemi et al., 2010; Sahambi et al., 1997). Daugumai šių metodų reikia didelių skaičiavimo resursų, jie turi nemažus vėlavimus, yra jautrūs triukšmui ar staigiems signalo pokyčiams.

Medicininiai signalai paprastai turi mišrius aplinkos triukšmus, ypač judesio metu. Net sumažinus aukšto ir žemo dažnio triukšmus, signalo amplitudiniai svyravimai gali užgožti EKG parametrų reikšmes. Norint panaudoti registruotą signalą tyrimams ar diagnostikai, reikalingas procesas, kuris dar yra vadinamas „pikų filtravimu“. Jis sudarytas iš veiksmų potencialų aptikimo ir klasifikavimo. Veiksmų potencialų radimui aplinkos triukšme buvo pasiūlyta įvairių kompiuterinio mokymosi algoritmų, kurie remiasi mokymusi su priežiūra (Chandra & Optican, 1997; Wheeler & Heetderks, 1982; S. C. Wu et al., 2015), tačiau jiems dažniausiai reikalinga pradinė informacija apie pačius veiksmo potencialus (sistema turi aproksimuoti funkciją, kuri susieja vektorių su skirtingomis klasėmis, tikrinant kelis funkcijos įvedimo – išvedimo rezultatus). Kadangi dažniausiai apie veiksmo potencialus negalima nieko pasakyti, kol jie nėra surandami, tai akivaizdu, kad realiose sąlygose mokymosi su priežiūra algoritmai turi daug apribojimų.

Mokslininkai Teager 1983 metais, o vėliau 1990 m. Kaiser H. M (Kaiser, 1990) pasiūlė Teager energijos operatoriaus metodą (angl. *teager energy operator*, TEO) kalbų aptikimui įrašuose tirti. Vėliau jis buvo patobulintas į daugialypį TEO (MTEO) (X. Wen et al., 2016). 2006 metais mokslininkai J. H. Choi ir H. K. Jung pasiūlė

neprižiūravimo mokymosi algoritmą, kuris aptiktų veiksmo potencialus ir juos suklasifikuotų. Mokslininkai rėmėsi MTEO atpažinimo algoritmu, tačiau patobulinto įvesdami naują normalizacijos metodą sumažindami sudėtingumą panaudojant imties dydį (Choi et al., 2006).



11 pav. Patobulintas MTEO identifikatorius (remiantis Choi et al., 2006)

Kadangi signalo registravimo dažnis yra pirminė informacija registravimo sistemoje, o ne išskaičiuota naudojant veiksmo potencialus, tai jis gali būti panaudotas neprižiūravimo mokymosi sistemoje. Paprastai norint aptikti pikus taikant MTEO algoritmą reikia apie 6 ar 7 k -TEO operatorių, kad padengtų imties dažnius nuo 10 kHz iki 40 kHz. Tačiau, jei imties dažnis yra žinomas, tik trys k -TEO operatoriai gali pasiekti analogiškus rezultatus. Tai sumažina sistemos sudėtingumą daugiau nei 50 % (Choi et al., 2006). Kad būtų pagerintas algoritmo darbas, buvo susikoncentruota į netikrų signalų (triukšmo) skaičiaus mažinimą. Pavojaus signalas atsiranda tada, kai triukšmas sukelia išėjties pikus aukščiau pasirinkto slenksčio. Tarp kanalų MTEO mažieji k kanalai yra linkę sukelti didelius pikus kaip atsaką į aukšto dažnio triukšmą. Šios problemos sprendimui buvo normalizuoti slenkantys langai naudojant triukšmo vidutines kvadratinės paklaidas (angl. *root means square error*, RMSE), o normalizuoti langų koeficientai apskaičiuojami pagal formulę:

$$\bar{h}_k(i) = \frac{h_k(i)}{\sqrt{3 \sum h_k^2(i) + (\sum h_k(i))^2}}; \quad (29)$$

čia $h_k(i)$ yra i -asis koeficientas judančiame lange, kuris atitinka k -TEO operatorių. Patobulintas J. H. Choi ir H. K. Jung MTEO algoritmas pavaizduotas 11 pav. Šis algoritmas buvo sukurtas nervų sistemos signalams apdoroti bei analizuojamų bangų pikų nustatymui. 2015 metais mokslininkai H. Sedghamiz ir D. Santonocito šį metodą pritaikė ir EMG signalams (Sedghamiz & Santonocito, 2016).

1.3. Sveikatos srityje taikomi klasifikavimo metodai

Sveikatos vertinimui yra taikomi įvairūs klasifikavimo metodai, kurie geba identifikuoti galimas patologijas tiek iš skaitmeninių vaizdų, tiek iš elektrinių gyvybinių signalų. Tradiciniai statistiniai metodai, tokie kaip tiesinė regresija, remiasi konkreto modelio pritaikymu duotai duomenų imčiai. Jie naudojami nustatyti duomenų tarpusavio priklausomybę arba atlikti prognozę. Neretai šie uždaviniai atliekami vienas po kito tam pačiam uždaviniui. Nors vienas iš pagrindinių tikslų tokio tipo metoduose yra atlikti prognozę, nėra atliekamas testavimas ir rezultatai aprašo tik tą duomenų imtį. Tokiu būdu nevertinamas prognozės tikslumas, bet tiriamas modelio kintamųjų patikimumas bei suderinamumas. Tuo tarpu, mašininio mokymo metodai

sugeba mokytis iš duomenų ir pateikia modelį, kuriuo atliekamos prognozės turint bet kokią duomenų imtį. Tiesinės regresijos atveju mašininio mokymo algoritmai atlieka pakartotines prognozes tikrindami sudarytą modelį su testavimo duomenų imtimi. Tradicinių ir mašininio mokymo metodų veikimo schemas pateiktos 12 pav.



12 pav. Tradicinių ir mašininio mokymo metodų schemas (remiantis Wiens & Shenoy, 2018)

Pažangios technologijos, tokios kaip socialinė žiniasklaida, išmanieji telefonai, nešiojami ir neurovaizdiniai įrenginiai, leido mokslininkams ir klinikų gydytojams surinkti didelį kiekį duomenų apie įvairius sveikatos fiziologinius ir protinius pacientų sutrikimus (M. Chen et al., 2014). Vis daugėjant duomenų kiekiui, atsirado veiksmingi metodai jiems apdoroti ir analizuoti – mašininis mokymasis (angl. *machine learning*, ML). ML apima pažangių statistinių ir tikimybinių metodų panaudojimą konstruojant sistemas, kurios gali automatiškai mokytis iš pateiktų duomenų. Mašininis mokymasis suteikia reikšmingą naudą daugybei sričių, įskaitant dirbtinį intelektą, kompiuterinę regą, kalbos atpažinimą ar natūralios kalbos apdorojimą. Tai leidžia mokslininkams ir programuotojams išgauti svarbios informacijos iš duomenų rinkinių, įtraukti asmeninius pastebėjimus ir plėtoti bei tobulinti intelektualias sistemas (Jordan & Mitchell, 2015). Sveikatos srityse, tokiose kaip bioinformatika, ML yra labai naudingas, nes atlieka greitą ir kokybišką analizę kompleksiniams duomenims (Luo et al., 2016). Tokia analitinė metodika taip pat yra naudojama ir plėtojama sveikatos sutrikimams tirti, gerinant pacientų savijautą bei didinant supratimą apie fiziologinę būklę ir jos kontroliavimą.

ML algoritmai gali būti išskaidyti į tris pagrindines grupes: 1) prižiūrimo mokymosi, 2) neprižiūrimo mokymosi, 3) dalinai prižiūrimo mokymosi (žr. 4 lent.). Prižiūrimo mokymosi atveju yra žinomos duomenų klasės ir jos naudojamos apmokant modelį, kuris gali prognozuoti kategorijas naujiems duomenims. Pavyzdžiui, klasifikuojant elektroninius laiškus kaip šlamštą remiantis ankstesniais laišku anotavimais (Bi et al., 2019). Tuo tarpu, neprižiūrimo mokymosi algoritmai naudoja duomenų klasterizavimo technikas, kad nustatytų naujas įžvalgas. Pavyzdžiui, iš internetinių forumų pokalbių sudarinėjami tematikų žemėlapiai (Teague & Shatte, 2018). Dalinai prižiūrimo mokymosi technika plėtoja modelius, kurie paremti duomenų su klasėmis ir be jų kombinacija (Gibson et al., 2013). Tokia metodika yra naudinga norint pagerinti mokymosi su priežiūra modelius naudojant neanotuotus duomenis, nes tam tikrais atvejais duomenų su anotacijomis yra nedaug arba jie brangūs. Praktikoje dirbant su ML reikėtų atkreipti dėmesį, kad nėra vienos metodikos, kuri labiausiai tiktų bet kuriai problemai, todėl rekomenduojama išbandyti

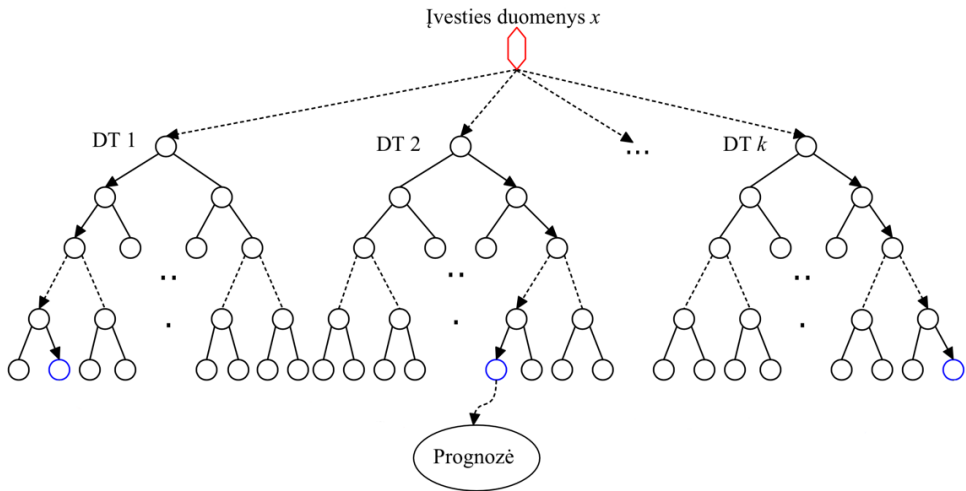
įvairias technikas prieš nustatant, kuris algoritmas veikia geriausiai konkrečiai duomenų imčiai ar užduočiai (Shatte et al., 2019).

4 lentelė. ML algoritmų kategorijos, dažniausiai naudojami modeliai ir taikymų pavyzdžiai sveikatos srityje (Ayar & Sabamoniri, 2018; Celin & Vasanth, 2018; Shatte et al., 2019)

Kategorija	Priziūrimas mokymasis	Neprižiūrimas mokymasis	Dalinai prižiūrimas mokymasis
Aprašymas	Mokymasis iš duomenų su žinomomis kategorijomis tam, kad būtų galima prognozuoti nepažymėtus įvesties duomenis (Bi et al., 2019)	Mokymasis iš duomenų, kurie neturi iš anksto apibrėžtų kategorijų tam, kad diferencijuotų duomenis į grupes arba norint surasti bendrus duomenų rinkinių požymius (Bi et al., 2019)	Mokymasis tiek iš duomenų su kategorijomis (paprastai nedidelis kiekis duomenų visos imties atžvilgiu), tiek be jų tam, kad išspręstų prižiūrimo ar neprižiūrimo mokymosi uždavinį (Teague & Shatte, 2018).
Populiarūs modeliai	Atraminų vektorių mašinos (angl. <i>support vector machine</i> , SVM), k – artimiausių kaimynų metodas (angl. <i>k – nearest neighbours</i> , KNN), atsitiktinis miškas (angl. <i>random forest</i>), naivus Bajesas (angl. <i>naive Bayes</i> , NB), logistinė regresija, sprendimų priėmimo medis (angl. <i>decision tree</i> , DT)	K – vidurkių klasterizavimas, hierarchinis klasterizavimas, paslėptas Markovo modelis, tiesinė diskriminantų analizė (angl. <i>linear discriminant analysis</i> , LDA), neuroniniai tinklai (angl. <i>neural networks</i> , NN)	Savęs apmokymo, mišrūs modeliai, bendras mokymas, grafiniu atvaizdavimu paremti metodai, dalinai prižiūrimas SVM
Taikymų pavyzdžiai	Prognozuojant pacientų riziką susirgti tam tikromis ligomis remiantis jų istoriniais medicininiais duomenimis (pvz., (Khalilia et al., 2011) naudoja atsitiktinio miško metodą)	Išgaunant informacijos apie šalutinį vaistų poveikį tiriant nestruktūrizuotas socialinių tinklų žinutes (pvz., Nikfarjam et al., 2015) taikymai naudojant gimtosios kalbos apdorojimo metodus)	Identifikuojant svarbią informaciją (pvz., diagnozė) iš nestruktūrizuoto teksto, kuris yra pateiktas elektroniniuose sveikatos įrašuose (pvz., Z. Wang et al., 2012), taikymai kuriant klasifikatorių turint duomenų su žymenimis pavyzdžių)

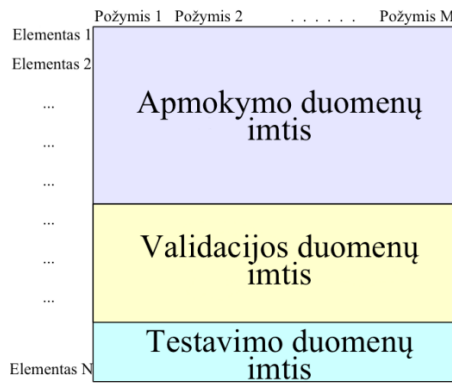
Medicinoje ir diagnostikoje mašininio mokymosi algoritmai taikomi tiriant biologinius elektrinius signalus (EKG, EEG, EMG), įvairius skaitmeninius vaizdus (gautus kompiuteriniu tomografu, magnetinio rezonanso aparatu, rentgeno aparatu ir pan.) ar anketinius duomenis. Priklausomai nuo duomenų kiekio ar turimos informacijos apie pačią duomenų imtį tyrimams pasirenkama algoritmų kategorija ar kelios iš jų ir testuojama, su kuriuo metodu geriausiai pavyksta sukurti duomenis aprašantį modelį. Prie mašininio mokymo algoritmų reikėtų paminėti ir išvestinius metodus. Vienas populiariausių yra atsitiktinis miškas (angl. *random forest*, RF), kurį sudaro atskiri DT. Atsitiktinis miškas gali būti sudarytas ir atskirų DT modelių, kurie yra apmokomi vienu metu naudojant atsitiktines duomenų imtis (angl. *bagged trees*). Tuo tarpu, nuoseklų atsitiktinį mišką sudaro atskiri DT modeliai, kurie apmokomi

vienas po kito taip, kad naujasis mokytoji iš prieš tai buvusio klaidų (angl. *boosted trees*). Dažniausiai šio tipo algoritmai turi didesnę mazgų skaičių (Spanakis et al., 2016). RF algoritmo duomenų klasifikavimo schema pateikta 13 pav.



13 pav. Atsitiktinio miško modelio klasifikavimo schema (remiantis Y. Zhou ir Qiu, 2018)

Klasifikavimo uždaviniuose mašininio mokymosi algoritams paprastai duomenys yra išskaidomi į tris dalis: modelio apmokymui, validavimui ir testavimui (žr. 14 pav.). Kai jau apmokytam modeliui yra paduodamos validacijos ar testavimo duomenų imtys, reikalinga kokia nors statistika jo darbo įvertinimui (Chicco, 2017).



14 pav. Duomenų imties išskaidymas mašininio mokymosi metodams

Sprendžiant standartinę prižiūrimo mokymosi dviejų klasių problemą kiekvienam elementui iš validavimo (arba testavimo) imties priskiriama teigiama arba neigiama klasė (dažniausiai 0 arba 1). Mašininio mokymosi algoritmas apmoko modelį atskirti šias dvi klases pagal pateiktus duomenis. Pabaigoje atliekama prognozė kiekvienam elementui iš testavimo duomenų imties. Tada remiantis gautomis prognozėmis algoritmas priskiria elementus vienai iš kategorijų, kurios pateiktos 5 lent.

5 lentelė. ML elementų, gautų atlikus prognozę, kategorijos (Bowes et al., 2014)

Pavadinimas	Pažymėjimas	Aprašymas
Teisinga neigiama (angl. <i>true negative</i>)	TN	Elementas prognozuojant priskiriamas kaip neteisingas ir iš tikrųjų yra neteisingas
Teisinga teigiama (angl. <i>true positive</i>)	TP	Elementas prognozuojant priskiriamas kaip teisingas ir iš tikrųjų yra teisingas
Neteisinga teigiama (angl. <i>false positive</i>)	FP	Elementas prognozuojant priskiriamas kaip klaidingas, o iš tikrųjų yra teisingas
Neteisinga neigiama (angl. <i>positive</i>)	FN	Elementas prognozuojant priskiriamas kaip teisingas, o iš tikrųjų yra neteisingas

Jei ML algoritmą testuojant / validuojant gaunama daug elementų iš kategorijų TP arba TN, tai reiškia, kad algoritmas sugeba teisingai klasifikuoti kaip teigiamą reikšmę turinčius elementus, kurie iš tikrųjų buvo teigiami validavimo duomenų imtyje (TP), arba kaip neigiamus, kurie turėjo neigiamą reikšmę validavimo imtyje (TN). Analogiškai, jei gaunama daug FP elementų, tai reiškia, kad metodas neteisingai suklasifikavo kaip teigiamus elementus, kurie iš tikrųjų buvo neigiami validavimo imtyje. Visų kategorijų lentelė dar yra vadinama maišaties matrica (angl. *confusion matrix*). Norint suprasti, kaip gerai atlieka prognozes gautas algoritmas bendru atveju, galima apskaičiuoti populiarių statistikų reikšmes, tokias kaip $tikslumas_{bendras}$ arba $F1_{\text{įvertis}}$, kurių geriausia galima įgyti reikšmė yra 0, o blogiausia 1. Kitos dažniausiai naudojamos statistikos mašininio mokymosi modeliui įvertinti pateiktos 6 lent.

$$tikslumas_{bendras} = \frac{TP + TN}{TP + TN + FP + FN}; \quad (30)$$

$$F1_{\text{įvertis}} = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \quad (31)$$

6 lentelė. Statistikos bendram ML algoritmų įvertinimui (Bowes et al., 2014; Chicco, 2017; Mastoi et al., 2018)

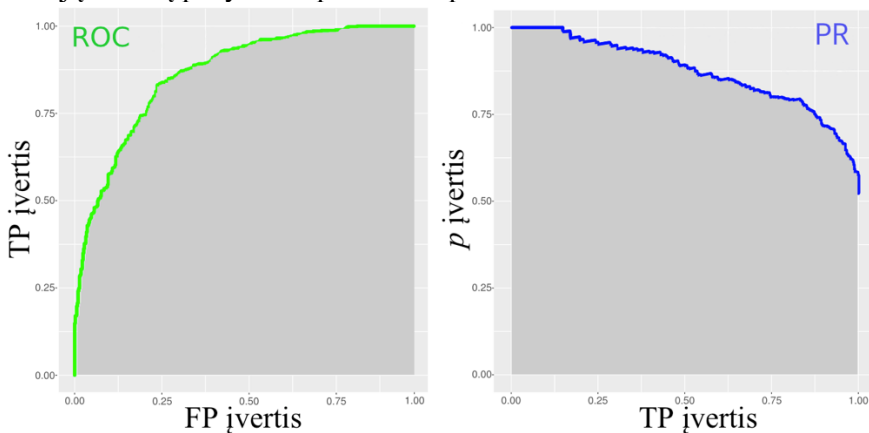
Pavadinimas	Pažymėjimas	Formulė
Paklaidų įvertis (angl. <i>error rate</i>)	<i>er</i>	$\frac{FP + FN}{TP + TN + FP + FN}$
Klaidingai atmesta (angl. <i>recall</i>) / jautrumas / tikimybė nustatyti (angl. <i>probability of detection</i>)	<i>r</i> arba <i>pd</i>	$\frac{TP}{TP + FN}$
Specifiškumas (angl. <i>specificity</i>)	<i>spec</i>	$\frac{TN}{TN + FP}$
I tipo klaidos įvertis, tikimybė apie galimą klaidą (angl. <i>probability of false alarm</i>)	<i>t1</i> arba <i>pf</i>	$\frac{FP}{TN + FP}$
Preciziškumas (angl. <i>precision</i>) arba klaidingai priimta	<i>p</i>	$\frac{TP}{TP + FP}$
II rūšies klaidos įvertis	<i>t2</i>	$\frac{FN}{FN + TP}$

Nors $tikslumas_{bendras}$ ir $F1_{\text{įvertis}}$ yra plačiai naudojamos statistikos, abi tam

tikrais atvejais gali būti neteisingai interpretuojamos, nes nesugeba visiškai įvertinti visų paklaidų tipų. Ypač tai aktualu medicinos ir sveikatos duomenų tyrimuose, nes paprastai yra daug duomenų apie sveikus žmones ir palyginus nedaug – apie sergančius pacientus. Siekiant išvengti tokių interpretavimo klaidų naudojamas Matthews koreliacijos koeficientas (angl. *Matthews correlation coefficient*, *MCC*), kuris įgyja blogiausią reikšmę, kai $MCC = -1$ ir geriausią, kai $MCC = 1$.

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP) \cdot (TP + FN) \cdot (TN + FP) \cdot (TN + FN)}} \quad (32)$$

Kadangi visų skaičiavimų pabaigoje bus žinomi tikrų reikšmių vektoriai kiekvienai klasei FN, TN, FP, TP, tai, norint atlikti kokybinį įvertinimą, galima pasirinkti vieną iš dviejų kreivių: ROC kreivė (angl. *receiver operating characteristics curve*) arba tikslumo-jautrumo kreivė (angl. *precision-recall curve*, PR). Abiejų kreivių pavyzdžiai pateikti 15 pav.



15 pav. ML algoritmo gauti ROC ir PR kreivių pavyzdžiai (remiantis Chicco, 2017)

Šiame darbe ML algoritmų palyginimui naudojamos charakteristikos: $tikslumas_{bendras}$, $F1_{įvertis}$ ir MCC . 1960 metais Jacob Cohen išsiaiškino (Cohen et al., 1960), kad tikėtina, jog yra tam tikras tikslumo lygis prognozuojamiems duomenims, kai galima sakyti, jog modelis nebesugeba prognozuoti teisingai ir atsakymas tampa panašus į spėjimą. Jis iškėlė hipotezę, kad tam tikras spėjimų skaičius gali sutapti su teisingu atsakymu ir patikimumo statistika paaiškintų tą atsitiktinę atitiktį. Jis išplėtojo $kappa$ statistiką kaip įrankį reguliuojant atsitiktinės atitikties faktorių (McHugh, 2012). Ši statistika apskaičiuojama pagal formulę:


$$kappa = \frac{tikslumas_{bendras} - d}{1 - d}; \quad (33)$$

čia d yra klaidos pasirodymo dažnis (žr. 6 lent.). Jei $kappa > 0,75$, tai $kappa$ laikomas labai geru. Nuo 0,4 iki 0,75 laikomas pakankamu ir $kappa < 0,4$ yra vertinimas kaip silpnas.

1.4. Surogatinų elektrinių signalų simuliacija

Surogatiniai duomenys remiasi laiko eilučių duomenimis, kurie sukonstruojami naudojant tinkamai apibrėžtus modelius atkuriant signalo spektrą (Maiwald et al.,

2008) ar originalių duomenų įvairias statistines savybes (Prichard & Theiler, 1994). Surogatiniai duomenys gali būti naudojami norit papildyti jau esamus duomenis, kuriant modelius struktūrų atpažinimui, kurių nėra realiuose signaluose, tobulinant ir analizuojant esamus metodus ar gerinant laiko eilučių prognozavimą bei klasifikavimą (Schreiber & Schmitz, 2000). Tokie duomenys gali būti sukurti įvairiais būdais, pvz., statistinio apdorojimo proceso metu, kai naudojant tam tikrus modelio ar sistemos apribojimus atsitiktinai generuojami duomenys (Schreiber & Schmitz, 2000), arba naudojant atsitiktines fazes ir imant duotos periodogramos atvirkštinę greitąją Furje transformaciją (angl. *fast Furje transform*, FFT). Šiame darbe surogatinių duomenų generavimui buvo pasiūlyta empiriniais duomenimis pagrįsta technika, kurioje naudojamos vidinės būsenos funkcijos (angl. *intrinsic mode functions*, IMF), išvestos iš empirinės būsenos išskaidymo (angl. *empirical mode decomposition*, EMD) (N. E. Huang, 2001). IMF apibrėžia ortogonalų funkcijų rinkinį su amplitudiniais ir dažnių svyravimais, kurie turi fizinę prasmę. Yra sukurta daugybė EMD variacijų ir plėtinių, tokių kaip slankaus sverto (angl. *weighted sliding*) EMD, baigtinis jungtinis (angl. *complete ensemble*) EMD su adaptyviu triukšmu. Jie buvo pasiūlyti norint išvengti pagrindinių EMD trikdžių, pvz., būsenos sumaišymo ar ribinių problemų. Žinoma, tokie patobulinimai algoritmą padaro sudėtingesnę ir reikalauja daugiau skaičiavimo resursų.



16 pav. Judesio signalo pavyzdys (paryškinta juoda) ir jo surogatai

Šiame darbe nėra svarbi būsenos sumaišymo problema, nes yra sudedamos visos mišrios IMF, o bet kuri iš jų reiškia naują surogatinį signalą. Tuo tarpu, ribinių reikšmių problema gali būti išsprendžiama tiesiog sutrumpinus surogatinį signalą. Tolimesniems tyrimams buvo pasirinktas klasikinis EMD metodas, kurio elgsena yra gerai ištirta. EMD taikymuose gautų ortogonalų IMF funkcijų signalai $x(t)$ gali būti rekonstruoti tokiu būdu:

$$x(t) = \sum_{i=1}^n IMF_i(t) + E(t); \quad (34)$$

čia E yra paklaidos, n – IMF funkcijų skaičius. Matricinėje formoje surogatinės duomenų eilutės sugeneruojamos kaip atsitiktinių svorių IMF sumos:

$$\tilde{\mathbf{X}} = n \cdot \frac{\mathbf{S}}{\sum_{i=1}^n S_i} \cdot \mathbf{IMF} + \mathbf{E}; \quad (35)$$

čia $\tilde{\mathbf{X}}$ yra surogatinis signalas vektorinėje formoje (formato $[1 \times n]$), \mathbf{S} – tolygiai pasiskirsčiusių atsitiktinių dydžių S_i ($i = \overline{1, n}$) vektorius, \mathbf{E} – atsitiktinis triukšmas (formato $[1 \times n]$). Sugeneruoto judesio signalo pavyzdys yra pateiktas 16 pav., kuriame surogatiniai signalai vaizduojami šalia nurodyto judesio signalo.

1.5. Sveikatos būklės vertinimo sistemos

Elektrokardiografija gali parodyti naudingos informacijos apie širdies ciklo ar sveikatos būseną. Taip pat EKG yra plačiai naudojamas metodas pacientų fizinės ir protinės sveikatos būklės stebėjimui bei vertinimui (Fontana et al., 2019).

Sveikatos stebėjimui sporto klubuose, klinikose, darbo vietose ar namuose vis dažniau naudojamos įvairios mobilios aplikacijos, skirtos vyresnio amžiaus žmonėms, pacientams, sportininkams ir kt. Elektroninės nuotolinio valdymo sistemos kartais gali pakeisti įprastus sveikatos priežiūros metodus. Daiktų internetu (IoT) paremtos sistemos išmaniose sveikatos stebėjimo sistemose gali apjungti ir dalintis informacija tarpusavyje internetu automatiškai. Kasmet nedidelės kainos elektrokardiogramas ir širdies variabilumą registruojantys įrenginiai vis dažniau naudojami vartotojų rinkoje. Daugybė duomenų vienu metu gali būti surinkta naudojant IoT, išmaniuosius nešiojamus įrenginius ir panaudota e – sveikatos ir geros sveikatos aplikacijose, tokiose kaip, darbo vietos ergonomikai (Maskeliunas & Damasevicius, 2016), epilepsijos priepuolių nustatymui (Vandecasteele et al., 2017), nuolatiniam lėtinių ligų stebėjimui (C. Wen et al., 2008), aktyvumo atpažinimui (Damaševičius et al., 2016), depresijos stebėjimui (Grzegorowski et al., 2017) bei nuovargio identifikavimui (Damaševičius, 2016).

Nors surinkti duomenys gali būti naudingi vertinant žmogaus būklę, reikia efektyvių skaičiavimo algoritmų norint gauti vertingos informacijos realiu laiku. Paprastai naudotojas nori gauti grįžtamąjį ryšį apie savo būklę ir prognozes iš karto. Be to, labai svarbu, kad e – sveikatos aplikacijos automatiškai sietų profesionalius ekspertus būklei įvertinti, fiziologinius duomenis analizuoti ir programos vartotojus. Išmaniųjų technologijų sąsajos, modeliavimo ir duomenų gavybos integracijos turi būti patogios ir efektyvios. Norint įvertinti žmogaus sveikatos būklę, reikia stebėti jo individualias kasdienes veiklas, o analizuoti realiu laiku visus svarbiausius signalus visą dieną iki šiol yra sudėtinga užduotis.

Yra sukurta daugybė įrenginių bei aplikacijų, integruotų išmaniuosiuose telefonuose, kurios skirtos įvertinti sveikatos būklę, stebėti cukraus lygį kraujyje, gerinti nervinės sistemos veiklą ar net įvertina streso lygį. Dauguma yra orientuotos į specifines sritis ar tam tikrų sutrikimų turinčius pacientus. Keletas tokių pavyzdžių yra HealthTap, Dosecast, Glucose Buddy, PCR Tracker, Parkinson Diary, Baby Connect ir kt. (žr. 7 lent.). Dauguma šių aplikacijų remiasi suvestais vartotojo

duomenimis, gydytojų rekomendacijomis, žingsnių skaičiavimu ar tiesiog yra kasdieniai patarimai tiek pasitelkiant video medžiagą, tiek tekstinę informaciją. Pagrindinis tokių aplikacijų trūkumas yra tas, kad jos nėra pritaikytos individualiam vartotojui bei labai nežymiai atsižvelgia į dabartinę sveikatos būklę (pvz., kūno masės indeksą ar amžių). Dažniausiai signalų registravimo ar sveikatos vertinimo įrenginiai turi savo mobilias aplikacijas, kurios leidžia paprasčiau interpretuoti gautus rezultatus. Pvz., AliveCor EKG registravimo įrenginio (Peritz et al., 2015) technologija buvo pritaikyta naujausiuose Apple Watch įrenginiuose. Šia aplikacija ne tik fiksuojami EKG signalai, bet ir pateikiamos individualios rekomendacijos vartotojui. Kartu su kita Apple produkcija šie laikrodžiai išpopuliarėjo sveikatos vertinimo srityje, nes yra draugiški vartotojui, nereikia pirkti vienkartinį elektrodų, kiekvieną kartą juos klijuoti ant kūno. Taip pat patogiu, kad įrenginys yra daugiafunkcis ir vienu metu gali būti ne tik laikrodis, žingsniamatis, EKG signalų registratorius, bet ir kaip telefonas. Tai ypač aktualu sportuojantiems žmonėms, kurie treniruotės metu su savimi nesinešioja kitų įrenginių. AliveCor technologija registruoja EKG signalus ir ima iš galūnių derivacijų (abiejų rankų) gautus impulsus (žr. 1 pav.). Pagrindinis tokios sistemos trūkumas yra tas, kad EKG registravimas gali būti atliekamas tik žmogui nejudant, du pirštus prispaudus prie įrenginio, todėl nuolatinis sveikatos stebėjimas ir vertinimas nedaromas. Kitos populiarios aplikacijos, naudojančios iPhone išmaniojo telefono galinę kamerą ar išmanųjį laikrodį, yra Welltory, HRV4Training, Elite HRV ir kt. Jos turi aplinką, draugišką vartotojui, bei leidžia stebėti sveikatos pakitimus, tačiau sudėtinga spręsti apie matavimų tikslumą, nes nėra priėjimo prie pačių ŠRV matavimų ir matomi tik rezultatai rekomendacijų pavidalu.

7 lentelė. Mobilios aplikacijos sveikatos vertinimui (remiantis Serenity, 2020; Silva et al., 2015; Yousaf et al., 2019)

Pavadinimas	Sritis	Aprašymas
Symple Symptom Tracker	Sveikatos stebėjimui	Savijautos, miego stebėjimas informaciją suvedant pačiam vartotojui
HealthTap	Diagnozei	Klausimynas apie sveikatą. Parenkama diagnozė arba susiekama su gydytoju (už tam tikrą įkainį)
Healow	Sveikatos stebėjimui	Aplikacija jungianti pacientą ir gydytoją-fiziologą, kurioje suvedami ir atnaujinami sveikatos duomenys, vizitacijų priminimai ir kt.
HealthTap	Diagnozei	Gydytojų atsakymai į sveikatos klausimus, patarimai
Doctor on Demand	Diagnozei	Galima užsiregistruoti pas gydytoją ar susiekti vaizdu esant kokiems nors sveikatos pablogėjimams. Galima tik anglų kalba.
Digital Pharmacist	Diagnozei, vaistų dozavimui	Gydytojų ir vaistininkų konsultacija dėl medikamentų, priminimai ir pan.
iTriage	Diagnozei	Informacija apie simptomus, ligas, medikamentus, procedūras ir kt.
Dosecast	Vaistų dozavimui	Priminimas apie vaistų vartojimą, didelis medikamentų pasirinkimas
Daily Carb	Diabeto	Padedą stebėti ir skaičiuoti suvartotą maistą, riebalus,

	valdymui	angliavandenius, vandens kiekį, galima suvesti duomenis apie insulino kiekį kraujyje, pulsą, spaudimą ir pan.
Glucose Buddy	Diabeto valdymui	Galima suvesti duomenis apie insulino kiekį kraujyje, angliavandenių suvartojimą ir kt.
Live OCD Free	Fiziologiniams sutrikimams	Kompulsinio sutrikimo pacientams, simptomams mažinti
Elevate:Brain Training	Fiziologiniams sutrikimams	Gerina susikaupimą, matematinius ir kalbėjimo gebėjimus, atmintį ir pan.
T2 Mood Tracker	Fiziologiniams sutrikimams	Naudoja 6 skirtingas nuotaikos būsenas stebint vartotojo būseną bei nuotaiką.
Constant Therapy	Fiziologiniams bei elgsenos sutrikimams	Parenka individualius pratimus, kuriuos galima atlikti namuose, atitinka klinikinę pažintinę kalbos terapiją.
Pain Rating Scales	Fiziologiniams sutrikimams	Naudojama, kad atpažintų demencijos sutrikimą turinčių vartotojų skausmą.
CogniCare	Sveikatos stebėjimui	Simptomų stebėjimui bei registravimui dimensijos sutrikimą turinčių vartotojų.
Office-Fit	Fiziniam skausmui mažinti	Parenkami pratimai esant skausmui, atsiradusiam dėl darbo pobūdžio ar streso.
WebMD Pain Coach	Fiziniam skausmui mažinti	Padeda suderinti kasdienes veiklas su chroniniu skausmu, esančiu kaklo, nugaros srityse arba fibromialgija, migrena ir pan.
PCR Tracker	Vėžio gydymui	Sveikatos stebėjimui sergant leukemija, laboratorijos rezultatų stebėjimui. Teikiamos rekomendacijos ir video medžiaga.
SkinKeeper	Vėžio gydymui	Padeda sekti odos pasikeitimus, šeimoje esančius vėžio rizikos faktorius vartotojui ir jo gydytojui.
Noteness	Nervinei sistemai	Išsėtinės sklerozės pacientams padeda vesti dienoraštį, stebėti injekcijas.
Parkinson Diary	Nervinei sistemai	Parkinsono liga sergantiems pacientams padeda sekti simptomus.
Young Epilepsy	Nervinei sistemai	Skirta epilepsija sergančiam jaunimui bei jų tėvams. Pateikiama vaizdinė medžiaga simptomams sekti bei kontroliuoti.
Baby Connect	Vaiko priežiūrai	Vaiko auginimo patarimai, dienotvarkė, medicininiai duomenys, priminimai ir pan.
Apple Health	ŠRV	Naudojant Apple išmanųjį laikrodį registruoja SDRR duomenis ir teikia informaciją apie nuovargį.
Welltory	ŠRV	Rodo ŠVR apskaičiuotą galutinį rezultatą, įvertina energingumą ir streso lygį. Gali būti naudojama su iPhone galine kamera arba išoriniu pulsomatavimo įrenginiu.
HRV4Training	ŠRV	Gali būti naudojama su iPhone galine kamera arba išoriniu pulso matavimo įrenginiu. Rekomendacijas apie treniuotę pradeda rodyti tik po 30 dienų.
Elite HRV	ŠRV	Gali būti naudojamas su išoriniu pulso matavimo įrenginiu. Naudojama kvėpavimo pratimų lavinimui


		bei grupinėms treniruotėms.
SweetBeat HRV	ŠRV	Reikalingas specialus diržas, kuris dedamas ant krūtinės. Naudojama ŠRV stebėjimui.
Gyroscope	ŠRV	Neatlieka jokių papildomų skaičiavimų. Galima pačiam užpildyti SDRR parodymus, užregistruotus kitų įrenginių.
HRV Score	ŠRV	Naudojama kartu su Apple išmaniuoju laikrodžiu. ŠRV įvertinimui reikalingi tikslūs duomenys.

Lietuvoje viena pirmųjų ritmogramas pradėjo analizuoti profesorė Marija Danguolė Žemaitytė, kuri tyrė širdies ritmo autonominės reguliacijos ir kraujotakos ypatumus funkcinų mėginių metu sveikiems ir turintiems širdies sutrikimų. Taip pat analizavo ŠRV miego metu, modeliavo žmogaus širdies veiklą bei tyrė galimus aritmijos požymius (Žemaitytė et al., 1984). Profesorius Adolfas Laimutis Telksnys kartu su kitais Vilniaus universiteto mokslininkais pradėjo tirti elektrokardiogramų ir ritmogramų signalų perdavimą nedideliu atstumu į mobiliuosius Android tipo įrenginius (Miežinis ir Telksnys, 2013). Jie pasiūlė schemą, kaip duomenys turi būti perduodami, filtruojami bei analizuojami diagnostikos tikslais.

Tobulėjant EKG signalų registravimo įrenginiams, sukuriama ir daugiau mobiliųjų aplikacijų, kurių pagalba registruojami ne tik pulsas, žingsnių skaičius, EKG signalai, bet ir deguonies įsisavinimas, kūno temperatūra, kvėpavimo dažnis ir pan. Neretai tokie įrenginiai yra brangūs, pritaikyti specifinėms žmonių grupėms, atliekančioms atsakingą darbą (pvz., ugniagesiams, išminuotojams, kariams ir pan.) ir sunkiai prieinami įprastiems vartotojams.

1.5.1. Sportuojančių žmonių treniruotės vertinimo būdai

Žmogaus organizmas yra kompleksinė sistema, kurios atskiros dalys sąveikauja tarpusavyje. Galima išskirti tris pagrindines dalis: griaučiai ir raumenys, širdies ir kraujagyslių bei nervų sistema. Kelių žmogaus organizmo sistemų sąryšių modelis yra vaizduojamas 17 pav., kuriame funkciniai elementai pažymėti: Pe – periferinė sistema; Re – reguliuojanti sistema (smegenys), Ts – tiekimo / aprūpinimo sistema (širdies, kraujagyslių). Sąryšiai nusakomi naudojant šiuos parametrus: pulsas (ŠR), JT intervalas, sistolinis (S) ir diastolinis (D) arterinio kraujo spaudimas, o pažymėjimas Δ nusako atitinkamo parametro pokytį (Aseriskyte et al., 2005).



17 pav. Žmogaus funkcinės būklės vertinimo modelis

17 pav. vaizduojama žmogaus funkcinės būklės vertinimo apibendrinta sistema yra

supaprastinta, vertinant tik širdies ir kraujagyslių funkcijas. Šis modelis gali būti papildytas parametrais, tokiais kaip įkvėptas oro tūris per minutę, suvartoto deguonies tūris per minutę ar tam tikrų EKG parametrų amplitudiniai pokyčiai (Poderys et al., 2015; Šmidkaitė, 2017; Vainoras, 1996).

Žmogaus organizmo būklės analizę galima atlikti keliais skirtingais būdais. Vertinant atskiras organizmo sistemas ir neatsižvelgiant į bet kokias tarpusavio sąveikas, analizuojamas vienas biologinis signalas. Norint įvertinti kelių žmogaus organizmo sistemų būklę, turi būti tiriamos sistemų tarpusavio dinaminės sąsajos bei kitimas viena kitos atžvilgiu. Tokiu atveju analizuojami mažiausiai du biologiniai signalai ir vertinamas jų tarpusavio ryšys. Tarkime, kad duoti du vienu metu registruoti skaitmeniniai signalai y_1, y_2, \dots ir z_1, z_2, \dots . Paėmus po tris abiejų signalų taškus, galima suformuoti sąryšių matricą \mathbf{X}_n :

$$\mathbf{X}_n = \begin{bmatrix} y_n & y_{n-1} - z_{n-1} \\ y_{n+1} - z_{n+1} & z_n \end{bmatrix}; \quad (36)$$

čia $n = 1, 2, \dots$. Apskaičiavus šios matricos diskriminantą D_n gauname:

$$D_n = (y_n - z_n)^2 + 4(y_{n-1} - z_{n-1})(y_{n+1} - z_{n+1}). \quad (37)$$

Būtent diskriminantai, o ne organizmo sistemų sąryšio matrica, yra plačiai naudojami tiek sveikų žmonių, tiek sergančių širdies ligomis funkcinės būklės vertinime (Venskaitytė, 2011). Taip pat diskriminantai gali parodyti žmogaus kūno funkcinius ypatumus ar sportininkų širdies adaptacijos greitį padidėjus fiziniam krūviui (Berskiene et al., 2009; Bikulciene et al., 2011; Muntianaite-Dulkinienė et al., 2009).

Diskriminantai skaičiuojami naudojant EKG signalus, kai parenkamos tam tikros charakteristikos, atsirandančios tarp R-R intervalų ir QRS kompleksų. Jie yra itin svarbūs kuriant treniruočių labiau personalizuotas sistemas (Venskaityte et al., 2009). Parinkus $y_n = RR_n$, o $z_n = QRS_n$ diskriminantas D yra apskaičiuojamas pagal (38) formulę. Analogiškai randami kitų sistemų parametrų diskriminantai. Šis parametras yra labai jautrus bet kokiems EKG signalo pokyčiams, todėl yra plačiai naudojamas įvairiuose streso testuose (Maharaj & Alonso, 2014). Tam tikrais atvejais QRS kompleksas, T, P bangos gali neparodyti jokių sveikatos būklės pasikeitimų. Tuo tarpu, diskriminantas identifikuoja net mažiausius pokyčius EKG signaluose. E. Venskaitytė diskriminantus naudojo EKG signalo parametrinėms dinaminėms sąsajoms identifikuoti ir pritaikė atletų fizinės būklės vertinimui naudojant krūvio mėginio testus (Venskaitytė, 2011). Venskaitytė sujungė diskriminantų analizę kartu su įprastais fizinės būklės vertinimo metodais, tokiais kaip R-R ir JT parametrų santykinė analizė, širdies susitraukimo dažnio stebėjimas ir kt. (Venskaityte et al., 2009).

Norint nustatyti tiriamo proceso bendros kaitos kryptį, galima atlikti visų trijų dinaminių sąsajų vertinimą susumuojant visas diskriminantų reikšmes D_n . Naudojant kompleksiško profilio, aprašytą (Bar-yam, 2002), suminis diskriminantas gali būti užrašomas tokiu būdu:

$$D_{suminis} = D_{RR_QRS} + D_{RR_JT} + D_{QRS_JT}; \quad (38)$$

čia D_{RR_QRS} yra diskriminantas tarp R-R intervalų ir QRS kompleksų, kuris apibūdina širdies ir viso organizmo tarpusavio sąsają, D_{RR_JT} – diskriminantas tarp R-R ir JT intervalų, kuris aprašo organizmo metabolinės ir reguliacinės sistemų sąsajas, D_{QRS_JT} – diskriminantas tarp QRS kompleksų ir JT intervalų, kuris nusako širdies metabolinę

ir valdymo sistemų sąsajas.

Populiarėjant sveikai gyvensenai ir tobulėjant išmaniosioms technologijoms, vis daugiau žmonių linkę stebėti savo fizinį aktyvumą, sveikatos būklę ir tuo pačiu vertinti organizmo pokyčius bei reakcijas į fizinio krūvio padidėjimą, klimato pokyčius, laiko zonos skirtumus ir pan. Yra sukurta daugybė aplikacijų, integruotų išmaniuosiuose telefonuose bei laikrodžiuose, kurios skirtos stebėti fizinį aktyvumą, skaičiuoti kalorijas, gerinti mitybą. Vienos populiariausių yra Fitocracy, Couch to 5K, Fooducate, Fitbit Coach, MyFitnessPal ir kt., kurias galima parsisiųsti į savo mobiliuosius įrenginius nemokamai arba už tam tikrą vienkartinį ar mėnesinį mokestį (žr. 8 lent.) (www.mobileappdaily.com/ ir <https://www.healthline.com/health/mental-health/top-healthy-lifestyle-iphone-android-apps>). Vis daugiau kineziterapijos specialistų ar trenerių platina vardines programėles, kuriose teikia rekomendacijas sveikesnei gyvensenai, svorio metimui ar kūno linijų tobulinimui. Nors didelis pasirinkimas patinka vartotojams, čia atsiranda didelė problema dėl trenerių kompetencijų ir tinkamo sporto plano sudarymo. Neretai pradedantys sportuoti, o kartais net sportuojantys profesionaliai nežino apie esančias laikysenos, raumenų tinkamo funkcionavimo judesio metu ir panašias problemas.

8 lentelė. Populiariausios mobilios aplikacijos sportui ir mitybai

Pavadinimas	Sritis	Aprašymas
MyFitnessPal	Sportui ir mitybai	Padedą sekti svorio pasikeitimus, mitybą, žingsnius. Galima pažymėti atliktus pratimus, gauti rekomendacijų ir motyvacijos iš bendruomenės.
Charity Miles	Sportui	Registruojamas žingsnių skaičius, nubėgtas ar dviračiu nuvažiuotas atstumas.
Shop Well: Better Food Choices	Mitybai	Padedą paprasčiau sureguliuoti mitybą ir pasirinkti tinkamus maisto produktus.
Fabulous: Self Care	Motyvacijai	Motyvuoja sveikai maitintis, teikia rekomendacijas geresniam miegui ar savijautai.
Couch to 5K	Sportui	Skirta pradedantiems bėgioti.
Fooducate	Mitybai	Sveikesnei mitybai, svorio metimui.
Fitbit Coach	Sportui ir mitybai	Padedą sudaryti mitybos planą, vedamos treniruotės su vaizdine medžiaga.
Fitocracy	Sportui ir mitybai	Padedą sudaryti mitybos planą, vedamos treniruotės su vaizdine medžiaga.

Šiame darbe aprašomas modelis įvertina tiek žmogaus kompleksinę sistemą, naudojant EKG signalų dviejų parametrų sekas, išreikštas per diskriminantus (*QRS* ir *RR*), tiek atskirų sistemų pokyčius (*QRS* kompleksų, *JT* intervalų ir širdies ritmo pokyčius). Be to, tinkamam EKG signalų apdorojimui ir duomenų perdavimui yra detalizuojama galima mobilių aplikacijų sąryšio su įrenginiais ir vartotoju schema, leidžianti užtikrinti duomenų bei rezultatų korektiškumą.

1.5.2. Nuovargio vertinimas

Žmonės labai dažnai patiria nuovargį, kuris atsiranda po sunkios fizinės veiklos, užsitęsios nemigos, stresinių situacijų ar ūmių ligos simptomų. Paprastai po tam tikro poilsio periodo ar pasveikus jis sumažėja. Tačiau nuovargis gali tęstis ilgesnį

laiko tarpą ir pabloginti sveikimo procesą, poilsio kokybę, bendravimo sugebėjimus ir pan. Be to, nuovargis yra laikomas vienu labiausiai pasitaikančių lėtinių širdies ir kraujagyslių, neurologinių ar imunologinių ligų sukėlėjų (Cumming et al., 2016). Nuovargio atsiradimo procesas iš esmės yra neištirtas. Pavyzdžiui, nuovargio ir kitų somatinių pojūčių, tokių kaip skausmas ar dusulys, atsiradimo priežastis gali būti fiziologinė ar neurobiologinė (Lenaert et al., 2018).

Kadangi žmogus didelę savo gyvenimo laiko dalį praleidžia darbe, neretai nuovargio atsiradimo priežastimi yra laikoma darbo aplinka ir trukmė. Nuovargis darbo vietoje yra daugialypė konstrukcija, kuri mažina darbuotojo atliekamos veiklos efektyvumą. Jis atsiranda dėl užsitęsios veiklos ir yra siejamas su psichologiniais, sociologiniais ir aplinkos veiksniais (Barker & Nussbaum, 2011). Iš profesinės sveikatos ir saugumo pusės, nuovargis turi būti suvaldytas tiek pasirodžius ryškiems trumpalaikiams simptomams, tiek ilgajame laikotarpyje. Profesinis nuovargis atsiranda tiek dėl darbo metu esančio fizinio krūvio, tiek dėl protinio. Gamybos srityje fizinis nuovargis yra labai reikšmingas, nes gali sukelti diskomfortą, pabloginti judėjimo galimybes, sumažinti pajėgumą (Sedighi Maman et al., 2017). Atsiradusį nuovargį pastebėti sunku, todėl jau nuo 1997 metų pradėta svarstyti apie galimas technologijas, kaip jį identifikuoti ir sumažinti (Decade & Bonato, 2010). Iki šių dienų yra ištobulinta įvairiausių technologijų nuo nešiojamų išmaniųjų įrenginių, kurie fiksuoja širdies pulsą ar EKG signalus, iki sudėtingų jutiklių tinklo (įskaitant judesio, video, radijo dažnio identifikatorius (angl. *radio-frequency identification*, RFID) ir slėgio jutiklius. Kadangi paprastai įrenginiai, naudojančys kameras, yra brangūs, užima daug vietos ir reikalauja nemažai laiko resursų duomenų registravimui bei apdorojimui, nešiojami įrenginiai tampa vis populiariesni dėl savo kainos ir patogumo (F. Wang et al., 2018).

Nuovargio rūšys gali būti įvairios: sensorinis, protinis, emocinis ir kt., bet dažniausiai yra nustatomas bendras nuovargis, kuris taip pat yra suprantamas kaip laikinas darbingumo sumažėjimas (Jason et al., 2010). Yra nagrinėta daugybė fizinio nuovargio atsiradimo teorijų. Viena jų buvo paremta periferiniais pokyčiais, kai, nepriklausomai nuo centrinės nervų sistemos reguliacijos, sumažėja skeleto raumenų kontaktiškumas dėl susikaupusių metabolitų. Manoma, kad dėl nepakankamos dirbančių raumenų kraujo cirkuliacijos atsiranda raumenų anaerobiozė, kuri gali sąlygoti miokardo išemiją (Hill et al., 1924). Dėl laktato kaupimosi atsipalaiduoja raumenys ir pratimas nutraukiamas priverstinai. Venskaitytė savo darbe aprašė ir kitas nuovargio atsiradimo teorijas, kurios remiasi tiek biocheminiais veiksniais, tiek kompleksinėmis sistemomis ir kt. (Venskaitytė, 2011).

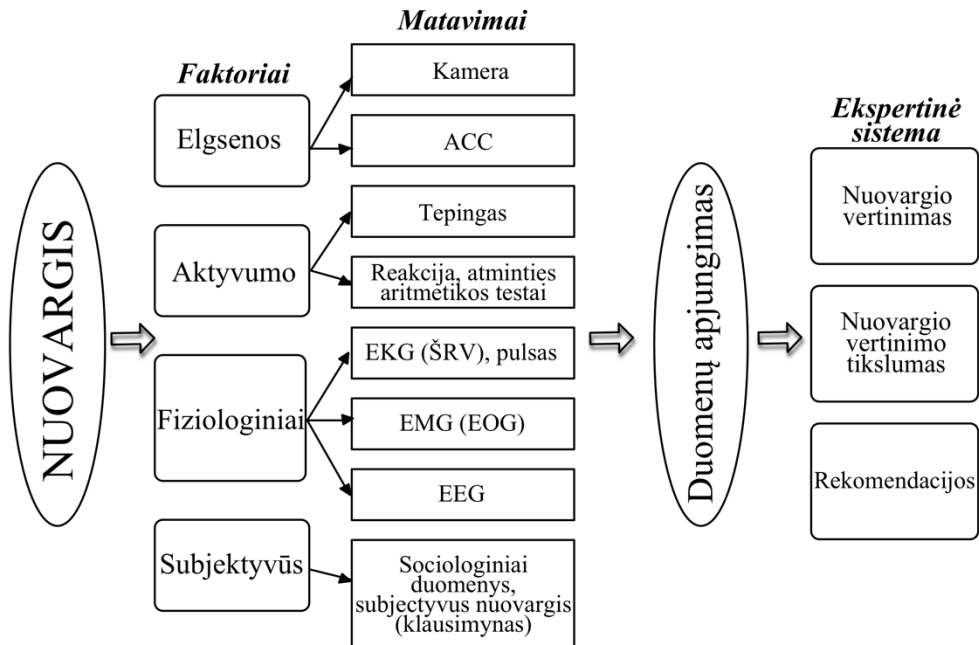
Kadangi šiuolaikiniai nešiojami įrenginiai neretai fiksuoja EKG signalus, tai vienas iš svarbiausių nuovargio vertinimo parametrų tampa širdies ritmo variabilumas (ŠRV). Pastaraisiais metais šio parametro tyrimai labai išpopuliarėjo. ŠRV ypatingas tuo, kad greiti svyravimai gali tiesiogiai sietis su simpatine nervų sistema. Tai parodo, kad signalo suformuota sistemos struktūra nebūtinai yra tiesinė, bet taip pat turi savyje netiesinių operacijų (Taouli & Bereksi-Reguig, 2012). Literatūroje taip pat galima rasti kitų netiesinių nuovargio identifikavimo ir vertinimo metodų, tokių kaip pagrindinių komponenčių analizė (angl. *principal component analysis*, PCA) (Fatima et al., 2020), neuroniniai tinklai (Ed-Doughmi et al., 2020), neraiškiosios logikos

metodai (angl. *fuzzy logic*) (Azim et al., 2014), faktorinė analizė (Weinstein et al., 2017) ir kt. Kaip netiesinis metodas vertinant ŠRV ir identifikuojant nuovargį buvo pasirinktas Poincare metodas naudojant R-R intervalų reikšmes.

Tam tikrais atvejais ŠRV analizės neužtenka, todėl nuovargio vertinimui gali būti naudojami ir kiti EKG parametrai. Tokiu atveju kaip netiesinis tyrimo metodas gali būti PCA algoritmas. Principinių komponentių metodas yra vienas populiariausių daugiamačių duomenų analizės būdų, nes jo pagrindą sudaro įvairios dimensijos mažinimo ir triukšmo filtravimo metodikos. Daugiamačiai duomenys gali būti laikomi didelės dimensijos vektorinės erdvės elementu, tarkime \mathbb{R}^p . Pirminis PCA algoritmo tikslas yra rasti elementų su didžiausia sklaida kryptis, kurios yra ortogonalios ir geriausiai nusako duomenis p – dimensijos erdvėje (Martín-Clemente & Zarzoso, 2018). Paprastai, pagrindinis tikslas pasiekiamas radus duomenų projekcijos ieškoma kryptimi didžiausią kvadratų sumą. Taip pat kelios geriausiai tinkančios kryptys (arba kitaip – pagrindinės ašys) gali būti apskaičiuotos pakartotinai sprendžiant optimizavimo uždavinį su apribojimu, kad n -oji pagrindinė ašis turi būti statmena prieš tai buvusiai $(n - 1)$ -ajai. Poerdvis $V \subset \mathbb{R}^p$, generuojamos ortogonalų bazinių vektorių, kurie nurodo pagrindines kryptis, yra vadinamas signalo poerdviu (svarbi sąvoka daugiamačių signalų apdorojimo procese) (Martín-Clemente & Zarzoso, 2018). Tarkime, kad turime N duomenų taškų $\{x_1, x_1, \dots, x_N\}$, kurių kiekvieno dimensija yra p , kiekvienas x_i yra atsitiktinis vektorius su vidurkiu nulis. Tada šis vektorius gali būti perrašytas į $(p \times N)$ dydžio matricinį pavidalą $\mathbf{X} = [x_1, x_1, \dots, x_N]$. Apibrėžkime, kad $\mathbf{w} \in \mathbb{R}^p$, kur $\|\mathbf{w}\|_2 = 1$ ir nusako projekcijos kryptį. PCA algoritmo tikslas yra rasti atsitiktinį kintamąjį $y = \mathbf{w}^T \mathbf{X}$ su didžiausia empirine dispersija. Sviurių vektorius \mathbf{w} gaunamas, sprendžia tokį uždavinį matricinėje formoje:

$$\max_{\|\mathbf{w}\|_2=1} \|\mathbf{w}^T \mathbf{X}\|_2. \quad (39)$$

Radus pagrindines komponentes, dalis jų gali būti pašalintos kaip nereikšmingos. Tokiu būdu sumažinama pradinio signalo dimensija taip, kad būtų išlaikoma kiek įmanoma tikslesnė informacija apie pradinis kintamuosius. Be to, gautos naujos signalą aprašančios pagrindinės komponentės yra tarpusavyje nepriklausomos (Zhang, 2018).

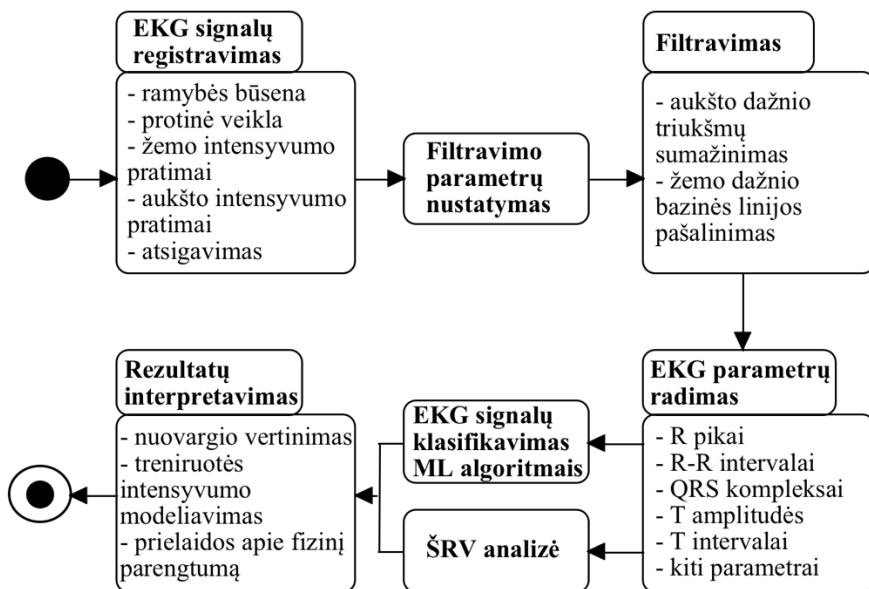


18 pav. Matuojami rodikliai ir nuovargio vertinimo algoritmo struktūra

Nuovargis paprastai vertinamas kompleksiskai tiriant įvairius fiziologinius ir protinės veiklos parametrus bei analizuojant gautų testų rezultatus. Vykdomame tarptautiniame projekte „Non-intrusive human fatigue assessment (Fatigue)“ Lietuvos partneriai labiau akcentuoja fizinio nuovargio rodiklius, Latvijos partneriai – protinės veiklos. Bendrai fiksuojami duomenys ir naudojami testai pateikiami 18 pav. Kamera, akcelometrija, protinės veiklos testai, pulsas, širdies susitraukimo dažnio variabilumas (ŠSD), akių raumenų susitraukimų vertinimas, encefalogramos bus vertinami Latvijos partnerių, o Teping (sportuojančių asmenų funkcinės būklės vertinimo testas), EKG, ŠSD variabilumas, EMG nugaros raumenims, subjektyvūs testai realizuojami Lietuvoje.

2. METODIKA

Fizinio krūvio metu registruoti EKG signalai yra labai triukšmingi, todėl jų interpretavimui ar žmogaus fiziologinei būklei įvertinti reikalingas tinkamas signalų apdorojimas. Šiame skyriuje aprašomi metodai ir algoritmai skirti elektrokardiogramose registruotų triukšmų sumažinimui, EKG parametrų radimui bei tam tikrų EKG signalų klasifikavimui.



19 pav. EKG signalų apdorojimo schema

Filtravimo parametru nustatymo dalis (žr. 19 pav.) yra svarbus uždavinys EKG signalų apdorojimo tyrime. Signalas paprastai yra užterštas įvairiais aplinkos, duomenų perdavimo metu atsiradusiais tiek žemo, tiek aukšto dažnio triukšmais. Judesio metu registruotuose EKG signaluose tokių triukšmų yra itin gausu, todėl paprasti algoritmai, kurie nereikalauja didelių skaičiavimo resursų (tokie kaip slenkančio vidurkio metodas, Butterworth filtras ir pan.), nebesugeba tinkamai filtruoti duomenų ir paruošti jų tolimesniems skaičiavimams ar diagnostikai. Tuo tarpu, sudėtingesni metodai susideda iš įvairių parametru, kurių parinkimas atima daug laiko ir neretai reikalauja atskiro tyrimo. Šiame darbe pasiūlytos kelios išeitys: (a) sudarytas algoritmas, kuris įvertina filtravimo parametru reikšmes priklausomai nuo QRS intervalų skaičiaus; (b) EKG signalų klasifikavimas naudojant mašininį mokymą.

2.1. Signalų filtravimo algoritmai

Judesio metu registruotas triukšmingas EKG signalas gali būti modeliuojamastokiu būdu:

$$y(n) = x(n) + v(n) + w(n), \quad n = 1, \dots, N; \quad (40)$$

čia x yra švarus žemo dažnio signalas, w – stacionarus Gauso baltasis triukšmas, v – atsitiktinis žemo dažnio signalo darinys (trends), o N – signalo ilgis.

Tyrimams pasirinktas diskrečiųjų bangelių transformacijos algoritmas aukšto dažnio triukšmų sumažinimui. Metodo trūkumai, privalumai bei filtravimo parametru parinkimo metodika aprašyti 3 skyriuje.

Žemo dažnio triukšmas neretai vadinamas trendu. Kol tiriamasis guli stacionarioje pozicijoje (įprastas EKG ar EEG registravimas medicinoje), EKG signalai yra išsidėstę vienoje horizontalioje tiesėje – izolinijoje (žr. 2 pav.). N taškų

signalas gali būti aprašomas kaip vektorius:

$$\mathbf{x} = [x_1, x_2, \dots, x_N]^T; \quad (41)$$

čia T reiškia matricos transponavimo funkciją. Tyrimui buvo pasirinktas ir patobulintas BEADS algoritmas. Bazinės linijos išskyrimas įprastai yra atliekamas naudojant slenkančio vidurkio algoritmą, nes jis nereikalauja išankstinio signalo paruošimo, neturi savyje papildomų filtravimo parametrų reikšmių, kurias būtina nustatyti prieš signalų apdorojimą, bei veikia greitai, nenaudodamas daug skaičiavimo resursų. Efektyvumui įvertinti pradinėje tyrimų dalyje buvo palyginti abu algoritmai.

BEADS algoritmas: šis žemo dažnio filtras aprašomas naudojant skirtumines matricas bei iteraciniu būdu minimizuojant tikslo funkciją $G(\mathbf{x})$.

Pirmiausia apibrėžkime skirtumines matricas, kai pirmos eilės skirtuminė matrica \mathbf{D}_1 yra užrašoma taip:

$$\mathbf{D}_1 := \begin{bmatrix} -1 & 1 & & & \\ & -1 & 1 & & \\ & & \ddots & \ddots & \\ & & & -1 & 1 \end{bmatrix}. \quad (42)$$

N taškų signalo \mathbf{x} pirmos eilės skirtumas yra užrašomas $\mathbf{D}\mathbf{x}$, kai \mathbf{D}_1 matricos dydis yra $(N - 1) \times N$. Analogiškai antros eilės skirtuminė matrica (formato $(N - 2) \times N$) apibrėžiama tokiu būdu:

$$\mathbf{D}_2 := \begin{bmatrix} -1 & 2 & -1 & & & \\ & -1 & 2 & -1 & & \\ & & \ddots & \ddots & \ddots & \\ & & & -1 & 2 & -1 \end{bmatrix}. \quad (43)$$

Apibendrintai, k eilės skirtuminis operatorius, kurio dydis $(N - k) \times N$, yra apibrėžiamas kaip \mathbf{D}_k . Tolimesniems išvedimams patogiu apibrėžti ir vienetinę matricą \mathbf{I} kaip nulinės eilės skirtuminę matricą $\mathbf{D}_0 := \mathbf{I}$ ($k = 0$), kuri yra kvadratinė $(N \times N)$ dydžio matrica (Selesnick et al., 2014). Ieškant triukšmingo signalo bazinės linijos sprendžiamas trijų dalių optimizavimo uždavinys: žemo dažnio triukšmo atskyrimas naudojant aukšto dažnio filtrą, asimetrinės baudos funkcijos apibrėžimas ir simetrinės funkcijos įvedimas.

Priklausomai nuo pačio analizuojamo signalo struktūros gali būti naudojamos skirtingos baudos funkcijos: tiek simetrinės (žr. 3 lent.), tiek asimetrinės. Asimetrinė baudos funkcija reikalinga tada, kai žinoma ar spėjama, jog ieškomas signalas $\mathbf{x} = [x_1, x_2, \dots, x_N]^T$ turi didesnes teigiamas reikšmes negu neigiamas ir atvirkščiai. Taip skirtingai bauduojamos teigiamos ir neigiamos signalo dalys. Šiame darbe ieškomas judesio trendas yra kintantis signalas, kuris paprastai stipriai skiriasi teigiamoje ir neigiamoje dalyse izolinijos atžvilgiu, todėl yra svarbu į algoritmą įtraukti asimetrinę baudos funkciją. Ją pažymėkime $\theta(x, r)$, kai r yra asimetrijos parametras:

$$\theta(x, r) = \begin{cases} x, & x \geq 0; \\ -rx, & x < 0. \end{cases} \quad (44)$$

Apsibrėžiame antros eilės daugianarį $\theta_\varepsilon(x, r)$ (išvedimą žr. Ning et al., 2014), kuris yra tolydžiai diferencijuojama funkcijos $\theta(x, r)$ aproksimacija ir užrašomas tokiu būdu:

$$\theta_\varepsilon(x, r) = \begin{cases} x, & x > \varepsilon \\ \frac{1+r}{4\varepsilon}x^2 + \varepsilon\frac{1+r}{4} + \frac{1-r}{2}x, & |x| \leq \varepsilon \\ -rx, & x < -\varepsilon \end{cases} \quad (45)$$

čia $\varepsilon > 0$ yra nedidelė konstanta. Asimetrinei baudos funkcijai apibrėžiamo ($N \times N$) dydžio įstrižainę matricą $\mathbf{\Gamma}(\mathbf{v})$, kurios įstrižainėje esančius elementus galima užrašyti tokiu būdu:

$$[\mathbf{\Gamma}(\mathbf{v})]_{n,n} = \begin{cases} \frac{1+r}{4|v_n|}, & |v_n| \geq \varepsilon \\ \frac{1+r}{4\varepsilon}; & |v_n| \leq \varepsilon \end{cases} \quad (46)$$

čia $\mathbf{v} = [v_1, v_2, \dots, v_N]$. Analogiškai, simetrinei baudos funkcijai apibrėžiamo ($N \times N$) dydžio įstrižainę matricą $\mathbf{\Lambda}(\mathbf{v})$, kurios pagrindinės įstrižainės elementai išreiškiami tokiu būdu:

$$[\mathbf{\Lambda}(\mathbf{v})]_{n,n} = \frac{\varphi'(v_n)}{v_n}; \quad (47)$$

čia funkcijos φ ir jų išvestinės φ' yra aprašytos 3 lent. Simetrinės baudos funkcijos reikalingos, kai ieškomas signalas \mathbf{x} ar jo išvestinės $\mathbf{D}_i\mathbf{x}$ yra teigiamos arba neigiamos su vienoda tikimybe (arba ši informacija nėra žinoma). Iki šiol aprašytos baudos funkcijos yra labiau naudojamos ekstremumų filtravimui, tačiau taip pat EKG signalui reikalingas aukšto dažnio filtras, kuris praleidžia pro save tokius signalus, kurie yra aukščiau pasirinkto dažnio barjero ir palieka visą likusį signalą. Aukštesnės eilės tokio tipo aukšto dažnio filtras gali būti užrašomas naudojant perkėlimo funkciją:

$$H(z) = \frac{(-z + 2 - z^{-1})^d}{(-z + 2 - z^{-1})^d + \alpha(z + 2 + z^{-1})^d}; \quad (48)$$

čia α ir d yra teigiami dydžiai, o $d \in \mathbf{Z}$ nurodo, kelintos eilės matrica yra aprašoma (filtravimo eilė). Matricinėje formoje aukšto dažnio filtras \mathbf{H} užrašomas tokiu būdu:

$$\mathbf{H} = \mathbf{A}^{-1}\mathbf{B}; \quad (49)$$

čia \mathbf{B} yra skirtuminė matrica D_k (šiuo atveju D_2 , žr. (43), kurios dydis $(N - 2d) \times N$, o \mathbf{A} simetrinė kvadratinė matrica, kurios dydis $(N - 2d) \times (N - 2d)$ ir kurioje esantys elementai yra vadinami filtravimo koeficientais. Jie randami iteraciniu būdu minimizuojant tikslo funkciją $G(\mathbf{x})$. Vektoriaus \mathbf{x} normas apibrėžiame tokiu būdu:

$$\|\mathbf{x}\|_1 = \sum_{n=0}^{N-1} |x_n|, \quad \|\mathbf{x}\|_2^2 = \sum_{n=0}^{N-1} |x_n|^2. \quad (50)$$

Pažymėjus, kad $\mathbf{y} = [y_0, y_1, \dots, y_{N-1}]^T$ yra triukšmingas EKG signalas, filtravimo uždavinys įtraukiant visas tris algoritmo dalis gali būti aprašomas tokiu būdu:

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{H}(\mathbf{y} - \mathbf{x})\|_2^2 + \lambda_0 \sum_{n=0}^{N-1} \theta(x_n, r) + \sum_{i=1}^M \lambda_i \sum_{n=0}^{N_i-1} \varphi([\mathbf{D}_i\mathbf{x}]_n) \right\}; \quad (51)$$

čia λ_i yra algoritmo reguliacijos parametrai, \mathbf{D}_i yra i – tosios eilės diferencialinis

(skirtuminis) operatorius, o M nurodo naudojamų simetrinių baudos funkcijų skaičių (šiam darbe $M = 3$). Tada pačią tikslo funkciją $G(\mathbf{x})$ galima aprašyti taip:

$$G(\mathbf{x}) = \frac{1}{2} \|\mathbf{H}(\mathbf{y} - \mathbf{x})\|_2^2 + \lambda_0 \mathbf{x}^T [\boldsymbol{\Gamma}(\mathbf{x})] \mathbf{x} + \lambda_0 \mathbf{b}^T \mathbf{x} + \sum_{i=0}^M \left[\frac{\lambda_i}{2} (\mathbf{D}_i \mathbf{x})^T [\boldsymbol{\Lambda}(\mathbf{D}_i \mathbf{x})] (\mathbf{D}_i \mathbf{x}) \right], \quad (52)$$

čia \mathbf{b} yra vektorius (formato $(1 \times N)$), kurio visi elementai yra vienodi:

$$[\mathbf{b}]_n = \frac{1-r}{2}. \quad (53)$$

Be to, remiantis komutatyvumo savybe tiesinėms, stacionarių laiko eilučių sistemoms, aukšto dažnio filtras matricinėje formoje gali būti užrašomas minimizuojant tikslo funkciją $G(\mathbf{x})$ vektoriaus \mathbf{x} atžvilgiu (Ning et al., 2014). Gauname išraišką:

$$\hat{\mathbf{x}} = \left(\mathbf{H}^T \mathbf{H} + 2\lambda_0 \boldsymbol{\Gamma}(\mathbf{x}) + \sum_{i=0}^M \lambda_i \mathbf{D}_i^T [\boldsymbol{\Lambda}(\mathbf{D}_i \mathbf{x})] \mathbf{D}_i \right)^{-1} \mathbf{H}^T \mathbf{H} \mathbf{y} = \mathbf{A} \mathbf{Q}^{-1} \mathbf{B}^T \mathbf{B} \mathbf{A}^{-1} \mathbf{y}; \quad (54)$$

čia $\mathbf{Q} = \mathbf{B}^T \mathbf{B} + \mathbf{A}^T (\sum_{i=0}^M \lambda_i \mathbf{D}_i^T [\boldsymbol{\Lambda}(\mathbf{D}_i \mathbf{x})] \mathbf{D}_i) \mathbf{A}$. BEADS algoritmo pseudo kodas pateiktas 20 pav.

BEADS algoritmas tikslo funkcijos minimizavimui

Įvestis: triukšmingas EKG signalas \mathbf{y} , asimetrijos koeficientas $r \geq 1$, matricos \mathbf{A} ir \mathbf{B} , regularizacijos parametrai λ_i , $i = 1, \dots, M$; ε – nedidelis teigiamas skaičius (konstanta)

Išvestis: filtruotas signalas \mathbf{x} , tikslo funkcijos reikšmė \mathbf{f}

PRADŽIA

$$[\mathbf{b}]_n = \frac{1-r}{2};$$

$$\mathbf{d} = \mathbf{B}^T \mathbf{B} \mathbf{A}^{-1} \mathbf{y} - \lambda_0 \mathbf{A}^T \mathbf{b};$$

$$\mathbf{x} = \mathbf{y};$$

kartoti tol, kol \mathbf{f} konverguoja

jei $|\mathbf{v}_n| \geq \varepsilon$, tai

$$[\boldsymbol{\Gamma}]_{n,n} = \frac{1+r}{4|\mathbf{x}_n|};$$

jei $|\mathbf{v}_n| \leq \varepsilon$, tai

$$[\boldsymbol{\Gamma}]_{n,n} = \frac{1+r}{4\varepsilon};$$

kiekvienai i nuo 0 iki M

$$[\boldsymbol{\Lambda}]_{i,n,n} = \frac{\varphi'([\mathbf{D}_i \mathbf{x}]_n)}{[\mathbf{D}_i \mathbf{x}]_n};$$

$$\mathbf{M} = 2\lambda_0 \boldsymbol{\Gamma};$$

kiekvienai i nuo 0 iki M

$$\mathbf{M} = \mathbf{M} + \lambda_i \mathbf{D}_i^T \boldsymbol{\Lambda}_i \mathbf{D}_i;$$

$$\mathbf{Q} = \mathbf{B}^T \mathbf{B} + \mathbf{A}^T \mathbf{M} \mathbf{A};$$

$$\mathbf{x} = \mathbf{A} \mathbf{Q}^{-1} \mathbf{d};$$

$$\mathbf{f} = \mathbf{y} - \mathbf{x} - \mathbf{B} \mathbf{A}^{-1} (\mathbf{y} - \mathbf{x});$$

PABAIGA

20 pav. BEADS algoritmas tikslo funkcijos minimizavimui

Algoritmas perskaičiuoja visas EKG parametrų reikšmes tol, kol randama kitimo linija – trendas su mažiausiomis paklaidomis. Sudėtinga iš anksto nuspėti, kokius filtro parametrus ar baudos funkcijas parinkti turint nedaug pirminės informacijos apie patį signalą. Elektrokardiogramos pasižymi tuo, kad turi aiškiai matomų periodiškai atsikartojančių parametrų rinkinį – QRS kompleksą (žr. 2 pav.), kuris yra vienas svarbiausių parametrų medicinoje ir diagnostikoje. Tam, kad optimizavimo uždavinys būtų orientuotas į EKG signalų filtravimą ir parametrų lokalių ekstremumų paiešką, į BEADS filtrą įterptas algoritmas, kurio pseudo kodas pateiktas 21 pav. Pagrindinis algoritmo tikslas yra apskaičiuoti BEADS filtro parametrų reikšmes randant maksimalų QRS intervalų skaičių.

BEADS algoritmo modifikacijos parametrų paieškos automatizavimui

Įvestis: judesio metu registruotas triukšmingas EKG signalas

Išvestis: BEADS filtro parametrų vertės

PRADŽIA

kiekvienam BEADS filtro parametrai atlikti

geriausia_reikšmė = 0;

maksimalus_rastas_QRS_kiekis = 0;

kiekvienai *parametro_reikšmė* atlikti

išskirti žemo dažnio triukšmą EKG signalui naudojant BEADS metodą;

rasti *R*, *Q* ir *S* pikus;

j = 1;

kiekvienam *i* nuo 1 iki didžiausia_reikšmė(ilgis(*R*), ilgis(*Q*), ilgis(*S*)) atlikti

jei *Q(i)* arba *R(i)* arba *S(i)* yra tuščia

i = *i* + 1;

priešingu atveju

QRS(j) = apskaičiuojamas QRS kompleksas;

j = *j* + 1;

jei *maksimalus_rastas_QRS_kiekis* < ilgis(*QRS*)

maksimalus_rastas_QRS_kiekis = ilgis(*QRS*);

geriausia_reikšmė = *parametro_reikšmė*;

PABAIGA

21 pav. BEADS algoritmo modifikacijos parametrų paieškos automatizavimui

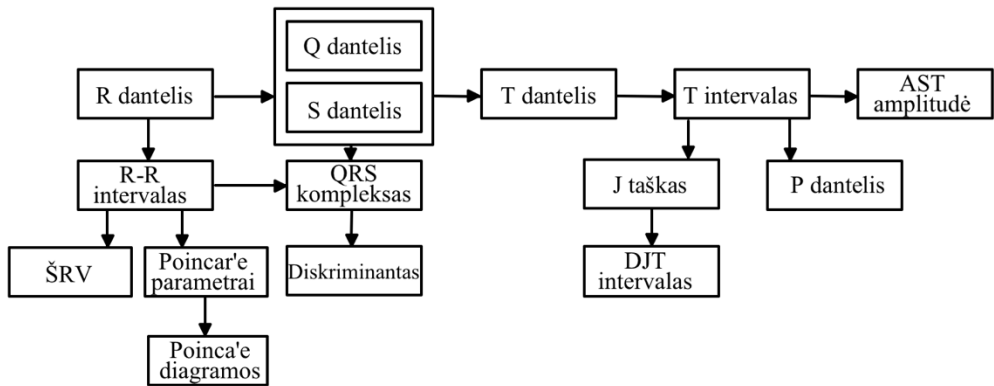
QRS komplekso ir kitų EKG parametrų paieškos algoritmai aprašomi 2.2 skyriuje.

Aukšto dažnio triukšmai sumažinti naudojant DWT algoritmą. Tinkamam filtravimo parametrų parinkimui atlikta papildoma analizė (žr. 3.1 skyrių).

2.2. EKG parametrų paieškos algoritmai

Elektrokardiogramos signalas yra cikliškas ir jame aiškiai išsiskiria tam tikros bangos, jų pikai bei trukmės. Kai kuriuos EKG parametrus, tokius kaip *R* pikas, *R-R* intervalas, *Q*, *S*, *T* pikai galima apskaičiuoti taikant atitinkamus algoritmus iš pačio signalo. Paprastai algoritmai remiasi išvestinių skaičiavimu ir nereikalauja daug skaičiavimo resursų. Parametrai, tokie kaip *AST*, *DJT*, taip pat yra randami tiesiogiai iš EKG signalo, tačiau jų reikšmių neretai nepavyksta identifikuoti dėl signalo svyravimų net registruojant stacionarioje būsenoje. Išvestiniai parametrai, tokie kaip diskriminantai, širdies variabilumas, randami naudojant atskirus metodus, kuriems reikalingi jau apskaičiuoti EKG signalo tiesioginiai parametrai. Elektrokardiogramos

parametrai ieškomi pažingsniui, vienas po kito, pradedant nuo ryškiausių ir lengviausiai apskaičiuojamų iki išvestinių (žr. 22 pav.).



22 pav. EKG parametų paieškos algoritmų seka

22 pav. esančioje schemoje ŠRV dalis siejasi su Poincare parametų paieška. Čia norima išskirti kitus ŠRV parametrus ir analizės metodus, kurie smulkiau aprašyti 1.2.1 poskyryje. Yra ir daugiau tiesioginių EKG parametų (žr. 2 pav.), tačiau norit juos apskaičiuoti, reikalingas signalo glodinimas, kurio metu gali būti prarasta dalis svarbios informacijos, reikalingos sveikatos vertinimui.

2.2.1. EKG pikų identifikavimas

Kadangi EKG signalai yra triukšmingi, kai registruojami judesio metu, o diagnostikai EKG parametų įvertinimas turi vykti realiu laiku, tai reikalingas greitai ir pakankamai tiksliai veikiantis šių parametų paieškos algoritmas. Dauguma EKG parametų paieškos algoritmų (tokių kaip Pan Tompkins ar atitikties filtrai) remiasi signalų transformacija išryškinant amplitudines reikšmes ir slenkstinių funkcijų pritaikymu išskiriant konkrečius EKG parametrus (dažniausiai Q, R, S bangas). Itin triukšmingame signale, kai žemo dažnio triukšmo variacijos yra didesnės nei pačio EKG signalo, slenkstinių funkcijų panaudojimas tampa neefektyvus. Net ir pašalinus judesio metu atsiradusius trendus (pagerinus signalą) vis vien jo amplitudinės vertės gali skirtis priklausomai nuo atliekamo judesio intensyvumo, skirtingų raumenų darbo ir pan. Be to, Q ar S bangos vienu metu būti ryškios (didelis pokytis nuo izolinijos), o kitu – amplitudiniai pokyčiai nuo izolinijos labai nedideli ar net artimi nuliui. Vadinasi, kiekvieną kartą, kai tiriamas naujas EKG signalas, reikėtų parinkti tik jam tinkamą slenkstinę funkciją ir vis vien nebūtų galima užtikrinti, kad rastas EKG parametras, o ne triukšmo sukelta osciliacija. Dėl šių priežasčių šiame darbe buvo pasirinktas MTEO algoritmas, kuris remiasi veiksmų potencialų identifikavimu ir jų klasifikavimu (žr. 1.2.3). Jam pritaikyta papildoma normalizacija, kuri sumažina algoritmo kompleksumą ir padeda EKG parametrus nustatyti realiu laiku. Šis algoritmas ir jo patobulinimai aprašomi šiame poskyryje. Pikų aptikimo modelis susideda iš trijų dalių: signalo pagerinimas ir rekonstrukcija, MTEO skaičiavimai, statistinio slenkščio nustatymas.

1. *Signalų apdorojimas.* EKG signalas filtruojamas taikant aukšto dažnio filtrą ir normalizuojamas su žemo dažnio filtru. Taip sumažinamas triukšmingumas.

2. *MTEO skaičiavimai.* Motorinio vieneto veiksmų potencialai (angl. *motor unit action potentials*, MUAP) paprastai turi aukštas amplitudes ir momentinius dažnius. Naudojant Teager energijos operatorių (angl. *teager energy operator*, TEO), kuris yra laiko-dažnio tyrimo metodas, galima nustatyti MUAP pasirodymo laiką. TEO gali būti apibrėžtas formule:

$$\omega(x(nT)) = x^2(nT) - x(nT - T)x(nT + T); \quad (55)$$

čia $x(nT)$ yra originalus (pradinis) EKG signalas su $n = 1, 2, \dots, N$, kai N yra signalo duomenų skaičius, o T yra imties dažnis. Daugialypėje k – TEO versijoje $x(nT - T)x(nT + T)$ yra pakeistas į $x(nT - kT)x(nT + kT)$, kai k yra sutartinis parametras, dar vadinamas vėlinimo parametru. Taip pat k – TEO gali būti priderintas prie labiau specifinių dažnių, todėl šis metodas yra patogus įrankis, kai norima sumažinti skaičiavimų sudėtingumą bei neprarasti efektyvumo lyginant su kitais laiko-dažnio metodais. Šiuo atveju k – TEO yra apibrėžiamas taip:

$$Y_k(nT) = x^2(nT) - x(nT - kT)x(nT + kT); \quad (56)$$

čia k pasirinkimas priklauso nuo ieškomų pikų periodiškumo. Didinant k reikšmę identifikatorius tampa mažiau jautrus aukštiesiems dažniams bei labiau jautrus žemiems dažniams. Galutinis MTEO $t(nT)$ rezultatas yra apskaičiuojamas pagal (57) formulę.

$$t(nT) = \max\{\hat{Y}_1(nT), \hat{Y}_2(nT), \dots, \hat{Y}_k(nT)\}; \quad (57)$$

čia $\hat{Y}_k(nT)$ yra $Y_k(nT)$ po suglodinimo naudojant Hamming langą, kurio dydis $4k + 1$ (Drake & Callaghan, 2006) ir normalizuotas naudojant kvadratinę dispersiją k skalėje.

3. *Statistinis slenkstis.* Ši dalis yra naudojama nustatyti MUAP pasirodymo laiką $t(nT)$ signale. Tyrime taikytas statistinis metodas, kuris panašus į Nenadic ir Burdick (Nenadic & Burdick, 2005) pasiūlytą. Pirmiausia $\forall n$ apsibrėžiama dvilypė hipotezė, kur H_0 , kai nėra MUAP ir H_1 – jis yra:

$$\begin{cases} H_0: t(nT) = G(nT), \\ H_1: t(nT) = s(nT) + G(nT); \end{cases} \quad (58)$$

čia $s(nT)$ yra su MUAP gautas signalas, o $G(nT)$ – atsitiktinio Gauso triukšmo seka. Kadangi atsitiktinio kintamojo $t(nT)$ mediana yra mažiau jautri išorės veiksniams nei dispersija, tai $t(nT)$ standartinis nuokrypis gali būti įvertintas kaip jo absoliutaus nuokrypio mediana:

$$\hat{\sigma} = \text{MEDIANA}\{|t(T) - \mu|, \dots, |t(NT) - \mu|\}; \quad (59)$$

čia μ yra imties vidurkis. Toliau yra pasirenkamas medianinis slenkstis TH_1 .

$$TH_1 = \hat{\sigma}\sqrt{2 \ln N}. \quad (60)$$

Taigi, $t(nT)$ yra palyginamas su slenkščiu TH_1 ir išskaidomas į segmentus $t^G(nT)$ – triukšmas ir $t^S(nT)$ – signalas:

$$\begin{cases} t^G(nT) := \{t(nT) \leq TH_1\} \\ t^S(nT) := \frac{t(nT)}{t^G(nT)} \end{cases} \quad (61)$$

Dvilypės hipotezės apriorinės tikimybės ($P(H_0)$ ir $P(H_1)$) yra apskaičiuojamos pagal formulę:

$$P(H_0) = \frac{\|t^G(n)\|_1}{N};$$

$$P(H_1) = \frac{\|t^S(n)\|_1}{N};$$
(62)

čia $\| \cdot \|_1$ yra apskaičiuojamas pagal (50) formulę. Sprendimų priėmimo slenkstis TH_2 , naudojamas apriorinėms tikimybės įvertinti, yra apibrėžiamas tokiu būdu:

$$TH_2 = \frac{\eta}{2} + \frac{\hat{\sigma}^2}{\eta} \left(C + \ln \frac{P(H_0)}{P(H_1)} \right);$$
(63)

čia η yra $t(n)$ absoliučios reikšmės imties vidurkis; C – vartotojo pasirinkta konstanta, kuri nusako aptikimo algoritmo jautrumą. Po testavimo sugeneruojamas signalas su MUAP imtimis:

$$MUAP(nT) := \{t(nT) \geq TH_2\}.$$
(64)

Išskiriant šiuos slenkstinius taškus stipriai pagreitėja modelio parinkimo procedūros tikslumas (Sedghamiz & Santonocito, 2016). EKG signalo Q, R, S pikų skaičiavimo algoritmas pateiktas 23 pav.

k- TEO Q, R, S pikų skaičiavimo algoritmas

Įvestis: *EKG* – filtruotas elektrokardiogramos signalas; C – vartotojo pasirinkta konstanta; **dažnis** – signalo registravimo dažnis

Išvestis: *Q, R, S* pikai

PRADŽIA

$N = \text{EKG ilgis};$

$L = 2 \cdot \text{dažnis};$

kiekvienam i nuo 4 iki $N - 3$ atlikti

$M(1) = (EKG(i))^2 - (EKG(i-1) \cdot EKG(i+1));$

$M(2) = (EKG(i))^2 - (EKG(i-2) \cdot EKG(i+2));$

$M(3) = (EKG(i))^2 - (EKG(i-3) \cdot EKG(i+3));$

$MTEO(i) = \text{didžiausia_reikšmė}(M(1), M(2), M(3));$

$STD = \text{standartinis_nuokrypis}(MTEO(1), MTEO(2), \dots, MTEO(L));$

$TH0 = C \cdot STD \cdot (2 \ln L)^2;$

$TH1 = TH0;$

kiekvienam i nuo 4 iki $N - 3$ atlikti

jei $MTEO(i-2) < MTEO(i-1)$ ir $MTEO(i-1) > MTEO(i)$, tai

jei $MTEO(i-1) \geq TH1$, tai

$MUAP = MTEO(i-1);$

$triukšmas = 0,125 \cdot MTEO(i-1) + 0,875 \cdot \text{triukšmas};$

$TH1 = \text{triukšmas} + 0,3 \cdot (MUAP - \text{triukšmas});$

$TH2 = C \cdot TH1;$

jei $MTEO(i-1) \geq TH2$, tai

$RR_{intervalas}(j) = MTEO(i-1);$

$j = j + 1;$

kiekvienam k nuo 1 iki j atlikti

$R(k) = \text{randamas R dantelis};$

$Q(k) = \text{randamas Q dantelis};$

$S(k) = \text{randamas S dantelis};$

PABAIGA

23 pav. *k*- TEO Q, R, S pikų skaičiavimo algoritmas

Elektrokardiogramos V5 derivacijoje Q ir S pikai paprastai įgyja neigiamas reikšmes izolinijos atžvilgiu. Neretai Q pikas yra labai neryškus ar net lygus 0. Tuo tarpu, R ir S bangos turi didelius nuokrypius nuo izolinijos. QRS kompleksas yra intervalinis EKG parametras, kuris tęsiasi nuo Q bangos pradžios iki S bangos pabaigos.

2.2.2. Kitų EKG parametrų paieška

Tyrimams naudojami EKG parametrai neapsiriboja R-R intervalų ar Q, R, S pikų identifikavimu. Analizei bei diagnostikai reikalingos T parametro amplitudinės reikšmės ir T intervalas, kuris parodo T bangos trukmę nuo pradžios iki pabaigos. Surasti šias EKG parametrų reikšmes pasiūlytas algoritmas, kuris remiasi kritinių reikšmių bei ekstremumų skaičiavimu (24 pav.). Algoritmas susideda iš trijų pagrindinių dalių:

1) *T bangos piko identifikavimas.* Iš 2 pav. pavaizduotos elektrokardiogramos signalo galima pastebėti, kad T banga yra tarp S ir Q bangų pikų ir turi didžiausią amplitudinę reikšmę šiame intervale. Vadinasi, T pikai gali būti apskaičiuojami pagal formulę:

$$T(n) = \max_{i=S(n):Q(n+1)} \{f(i)\}; \quad (65)$$

čia $S(n)$, $Q(n)$ yra S ir Q bangų vieta EKG signale f .

2) *T bangos pradžios ir pabaigos radimas.* T banga prasideda ten, kur EKG signalas nuo izolinijos pakeičia kryptį ir reikšmės pradeda didėti. Pradžia yra šiek tiek toliau nei baigiasi S banga, bet dar nepasiekus T piko. Nors ir filtruotas EKG signalas, bet vis dar turi nedidelius reikšmių svyravimus, kurie sudaro lokalius minimumus bei maksimumus. $T(n)$ bangos pradžios kritiniai taškai randami lygtimi:

$$\frac{\Delta f(i)}{\Delta i} = 0; i \in (S(n) + C \cdot fs: T(n)); \quad (66)$$

čia C yra konstanta, o fs yra EKG signalo registravimo dažnis. T bangos pradžia laikoma mažiausia lokalaus ekstremumo reikšmės pozicija.

$$T_{pr}(n) = \min_{i=1:N} \{K_i(n)\}; \quad (67)$$

čia N yra lokalių ekstremumų skaičius, K_i yra ekstremumų reikšmės. Analogiškai apskaičiuojama ir T bangos pabaiga, tik ekstremumai ieškomi nuo T bangos piko iki kitos Q bangos pradžios.

$$\frac{\Delta f(i)}{\Delta i} = 0; i \in (T(n): Q(n+1) - C \cdot fs); \quad (68)$$

$$T_{pb}(n) = \min_{i=1:N} \{K_i(n)\}. \quad (69)$$

3) *T intervalo apskaičiavimas.* Turint T bangos pradžios ir pabaigos pozicijas EKG signale nesudėtinga apskaičiuoti T intervalo ilgį pagal formulę:

$$T_{int}(n) = T_{pb}(n) - T_{pr}(n). \quad (70)$$

T intervalo skaičiavimo algoritmas

Įvestis: filtruotas EKG signalas; C – vartotojo pasirinkta konstanta; Q, R, S pikai; *dažnis* – signalo registravimo dažnis

Išvestis: $T_intervalas$, $T_amplitudė$

PRADŽIA

$N = S$ pikų skaičius

kiekvienam i nuo 1 iki N atlikti

$T_pozicija(i) =$ didžiausia EKG reikšmės vieta nuo $S(i) + C \cdot dažnis$ iki $Q(i + 1)$;

$T_amplitudė(i) = EKG(T_pozicija(i))$;

$pradžios_ekstremumai =$ EKG ekstremumai intervale nuo $S(i) + 2C \cdot dažnis$ iki $T(i)$;

$pabaigos_ekstremumai =$ EKG ekstremumai intervale nuo $T(i)$ iki $Q(i + 1)$;

$pradžios_Esk =$ pradžios ekstremumų skaičius;

$pabaigos_Esk =$ pabaigos ekstremumų skaičius;

jei pradžios_ekstremumai yra tuščia, tai

$T_pradžia(i) = (S(i) + T(i))/2$;

priešingu atveju

$T_pradžia(i) =$ mažiausios pradžios ekstremumų reikšmės vieta;

jei pabaigos_ekstremumai yra tuščia, tai

$T_pabaiga(i) = (T(i) + Q(i + 1))/2$;

priešingu atveju

$T_pabaiga(i) =$ mažiausios pabaigos ekstremumų reikšmės vieta;

$T_intervalas(i) = T_pabaiga(i) - T_pradžia(i)$;

PABAIGA

24 pav. T intervalo skaičiavimo algoritmas

Žinant Q, S, S, T pikų pozicijas nesudėtingai galima apskaičiuoti QT bei ST intervalus. QT randamas iš T bangos pabaigos atėmus Q bandos pradžios poziciją. Analogiškai su ST – iš T bangos pabaigos pozicijos atimama S bangos pradžios taškas.

Radus R pikus, QRS kompleksus, T intervalus, galima taikyti algoritmus ieškant DJT bei AST parametrų reikšmių ir skaičiuojant diskriminantus. J taškas yra perlinkio taškas ten, kur baigiasi S banga prieš prasidedant T bangai (žr. 2 pav.). Paprastai, J taškas sutampa su S bangos pabaiga, tačiau esant širdies patologijai jis gali sutapti su T bangos pradžia arba turėti visai kitą poziciją (tarp S bangos pabaigos ir T bangos pradžios). Šiam perlinkio taškui įvertinti naudojamos antros eilės išvestinės ir yra randamas lygtimi:

$$\frac{\Delta^2 f(x)}{\Delta x^2} = 0. \quad (71)$$

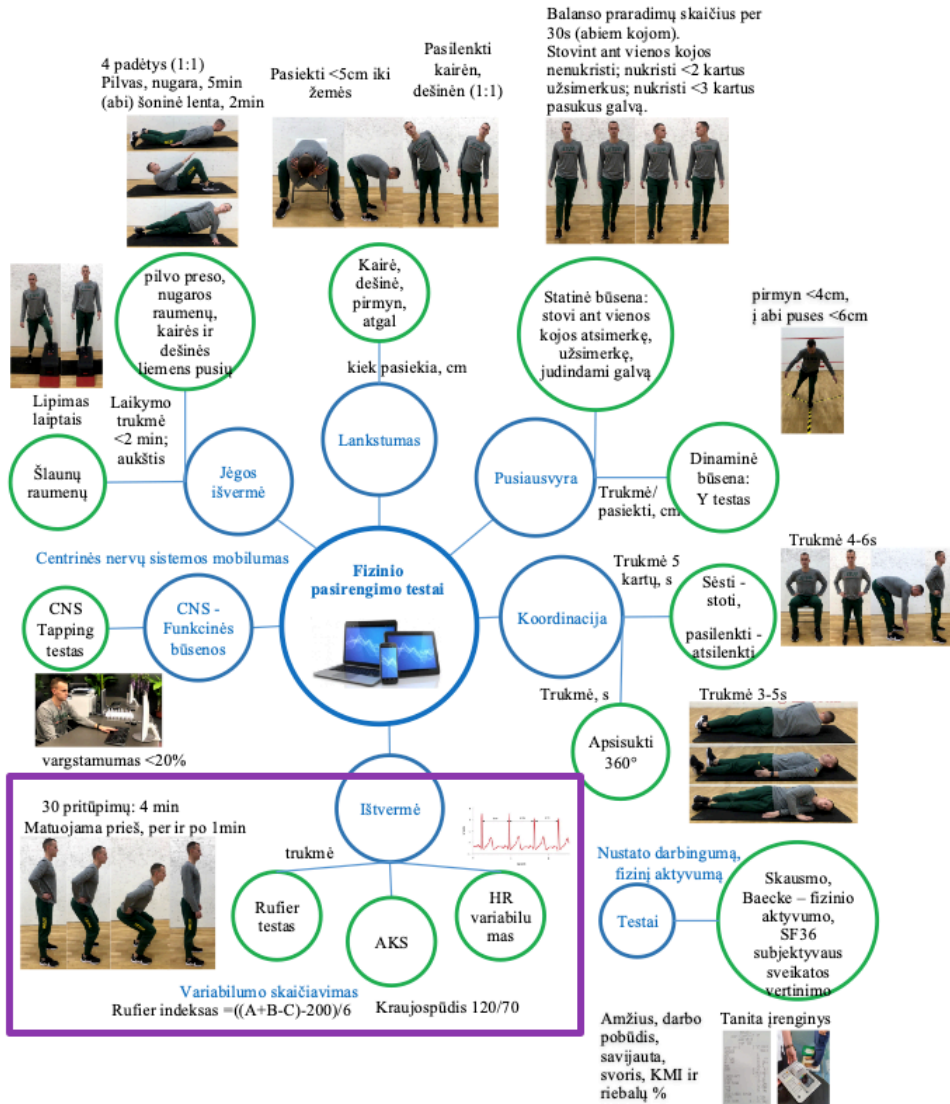
DJT intervalas randamas apskaičiavus intervalą nuo J taško iki T bangos pabaigos. AST yra amplitudinis EKG parametras, kuriuo ieškomas atstumas nuo izolinijos iki S bangos pabaigos taško. Jei žmogaus širdies veikla yra gera, tai $AST = 0$. Priešingu atveju gali įgyti tiek teigiamą, tiek neigiamą reikšmes. P dantelis randamas ne visada, ypač, kai elektrokardiograma registruojama judesio metu. Šiam pikui rasti ieškoma didžiausia amplitudinė reikšmė tarp T bangos pabaigos ir Q bangos pradžios.

Vienas iš populiariausių EKG išvestinių parametrų yra diskriminantai, kurie aprašo $R-R$ intervalų ir QRS kompleksų svyravimus ir yra labai svarbūs individualizuotos sveikatos vertinimo sistemos kūrimui (Venskaityte et al., 2009). EKG analizėje pasirinktas diskriminantų vertinimas išreikštas formule:

$$D(RR - QRS)_n = (RR_n - QRS_n)^2 + 4(RR_{n-1} - QRS_{n-1})(RR_{n+1} - QRS_{n+1}); \quad (72)$$

čia RR yra trukmė tarp R pikų, n – širdies ciklo numeris. Šis parametras yra labai jautrus bet kokiems EKG signalo pasikeitimams ar svyravimams ir plačiai naudojamas vertinant sveikatos būklę sportininkų stresinio testo metu. Gali būti taip, kad QRS kompleksai, T pikai nerodo jokių reikšmingų pokyčių, tuo tarpu, diskriminantų reikšmės gali stipriai tarpusavyje skirtis.

2.2.3. Poincare diagramos nuovargio identifikavimui




25 pav. Projekto „Non-intrusive human fatigue assessment (Fatigue)“ vykdymo schema

ŠRV yra svarbi dalis sveikatos būklės vertinimo procese. Vykdomos programos EUREKA projekte „Non-intrusive human fatigue assessment (Fatigue)“ (žr. 25 pav.)

tiriamos nuovargio atsiradimo priežastys, paplitimas darbo aplinkoje bei vertinamas darbuotojų fizinis pasirengimas. 25 pav. schemoje pavaizduotos visos tiriamos sritys ir atliekami testai. Svarbi dalis (schemoje apvesta stačiakampiu) yra ŠRV vertinimas ir ištvėmės bei nuovargio tyrimas, kurios metu naudojami tiesiniai ir netiesiniai analiziniai metodai, tokie kaip Poincare diagramos.

Populiarėjantis Poincare diagramų vaizdavimo būdas širdies periodų duomenims suteikia naujų įžvalgų apie širdies ir kraujagyslių dinamikos mechanizmus (Platiša et al., 2019). Poincare parametrų skaičiavimas nesudėtingas ir daug resursų nereikalaujantis procesas. Parametrai siejasi su taškinės diagramos duomenų pasiskirstymu ir dispersija. Tyrimo metu pastebėta, kad Poincare diagrama gali būti kaip vienas iš būdų nuovargio identifikavimui ar užkertant kelią traumoms dėl per didelio krūvio treniruotės metu. Atitinkami dažnių sritys požymiai gali suteikti informacijos apie kokios nors ligos skirtingų būklių ar sveikatos individualius skirtumus (Vollmer, 2015). Poincare vaizdavimas naudojamas tiek analizuojant trumpos trukmės signalus, tiek ilgos. Ši metodika taikoma keliais skirtingais būdais: vizualiai, kai žmogus tiesiog žiūrėdamas į brėžinius gali pastebėti struktūrą, arba kiekybinis, kai apskaičiuojamos įvairios Poincare parametrų reikšmės, atspindinčios Poincare brėžinyje esančią informaciją.



26 pav. Poincare diagrama ir jos parametrai (remtasi Piskorski & Guzik, 2005)

Paprastai Poincare grafikuose parodomas sąryšis tarp R-R intervalų, kur RR_i vaizduojami x ašyje, o RR_{i+1} – y ašyje (Kubičková et al., 2016). Atvaizdavus grafiškai šiuos intervalus gaunama kreivė, kurios forma yra pailgas taškinės diagramos debesis (žr. 26 pav.), išsidėstęs apie ryšio liniją ir panašus į elipsę. Elipsės mažoji ašis yra statmena ryšio linijai ir reiškia standartinį nuokrypį $SD1$. Šis parametras aprašo trumpo laikotarpio svyravimus, t. y. greitus ŠRV svyravimus. Tuo tarpu, didžioji ašis $SD2$ parodo ilgo laikotarpio svyravimus (Platiša et al., 2019). $\forall i =$

1, 2, ..., n - 1, kai n yra RR intervalų skaičius, įsivedame pažymėjimus:

$$x_{1i} = \frac{RR_{i+1} - RR_i}{\sqrt{2}}, \quad x_{2i} = \frac{RR_{i+1} + RR_i}{\sqrt{2}}. \quad (73)$$

Taip pat elipsė pasukama kryptimi, sutampančia su ryšio linija, t. y. kampų $\varphi = \frac{\pi}{4}$.

Galutinė vektorių x_1, x_2 išraiška yra:

$$\begin{bmatrix} x_{1i} \\ x_{2i} \end{bmatrix} = \begin{bmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{bmatrix} \begin{bmatrix} x_{1i} \\ x_{2i} \end{bmatrix}. \quad (74)$$

Poincare parametrų reikšmės dabar gali būti apskaičiuojamos:

$$SD1 = \sqrt{Var(x_1)}, \quad SD2 = \sqrt{Var(x_2)}; \quad (75)$$

čia $Var(x)$ yra vektoriaus x dispersija. Elipsės centras yra RR_i, RR_{i+1} vidurkių vektorius $(\overline{RR}_i, \overline{RR}_{i+1})$. Be to, $SDRR$ parametras apibrėžia bendrą variabilumą, kuris randamas naudojant Poincare elipsės ašų dydžius:

$$SDRR = \frac{SD1}{SD2}. \quad (76)$$

$SDRR$ gali būti naudojamas kaip nuovargio identifikavimo matas (Zhong et al., 2018). Kuo didesnė reikšmė, tuo širdies variabilumas yra didesnis ir žmogaus širdis geba labiau prisitaikyti prie fizinio krūvio. Kai įgyjamos nedidelės reikšmės, širdis dirba tolygiai (dažniausiai intensyviai) ir jaučiamas fizinis nuovargis. Intensyvios treniruotės metu tai yra įprastas reiškinys, tačiau sveiko žmogaus širdis paprastai atsistato netrukus po fizinės veiklos (S. Chen et al., 2020). Fizinio nuovargio nustatymas naudojant Poincare diagramas yra atliekamas stebint Poincare diagramų formą, parametrus ($SD1, SD2$ ir $SDRR$) ir jų pokyčius (S. Chen et al., 2020).

Poincare diagramų ŠRV tyrimui elektrokardiogramos signalų R-R intervalai turi būti tinkamai apskaičiuoti. Neretai registruojant šiuos intervalus pasitaiko klaidų, o jų korekcijai reikalingi papildomi algoritmai, tokie kaip procentinis, standartinio nuokrypio ar medianinis filtras. Eksperimentinio tyrimo metu paaiškėjo, kad dažniausiai susiduriame su dviejų tipų R-R intervalų sekos artefaktais, t. y. pirmos rūšies klaida: nustatytas R pikas, nors jo nebuvo; antros rūšies klaida: nerasta / praleista R parametro reikšmė, nors ji buvo. Buvo naudojami trys klaidų aptikimo metodai, kurie artefaktus panaikina naudojant splineų interpoliacijas. Kiekviena iš šių funkcijų yra efektyvi skirtingose situacijose. Medianinis filtras atsitiktiniam kintamajam x , kurio ilgis n , o slenkstis τ , gali būti aprašomas tokia funkcija:

$$M(n) = \frac{|x(n) - med(x)|}{1.483 \cdot med\{|x(n) - med(x)|\}}; \quad (77)$$

čia $med(\cdot)$ reiškia medianą. Jei $M(n) \geq \tau$, tai nebuvo pirmos rūšies klaidos. Priešingu atveju – ji buvo. Analogiškai apibrėžiamas standartinio nuokrypio filtras:

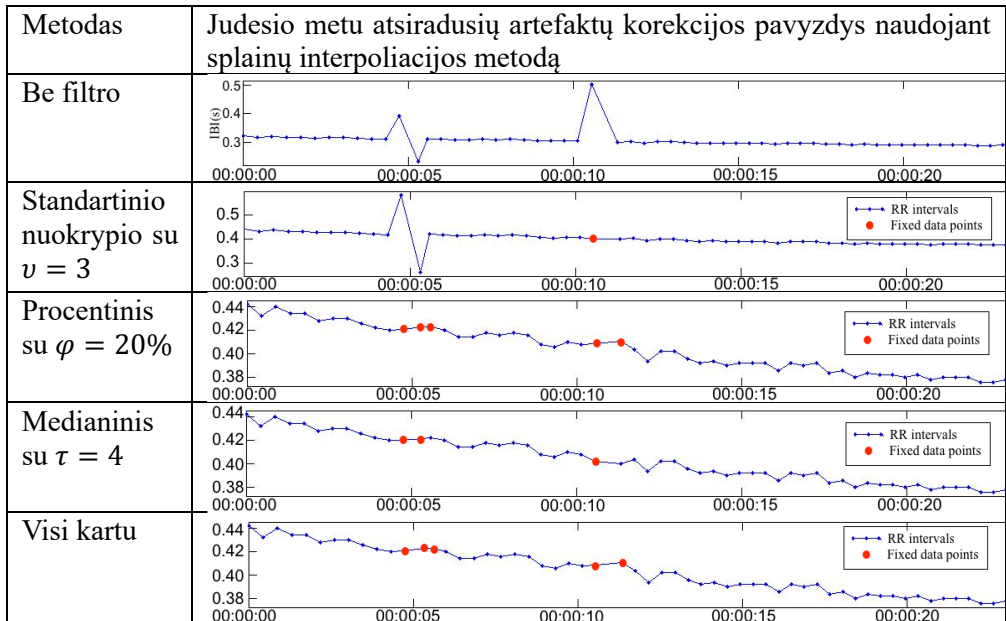
$$S(n) = \sqrt{\frac{1}{n} \sum_{i=1}^n (x(i) - \bar{x})^2}; \quad (78)$$

čia \bar{x} yra imties duomenų vidurkis. Jei paimsime slenkstį v , tai $S(n) \geq v$ reiškia pirmos arba antros rūšies klaidą (G. Zhou et al., 2019). Trečiasis artefaktų šalinimo filtras yra vadinamas procentiniu, kuris aprašomas formule:

$$P(n) = \frac{x(n) - \bar{x}}{\bar{x}} \cdot 100\%. \quad (79)$$

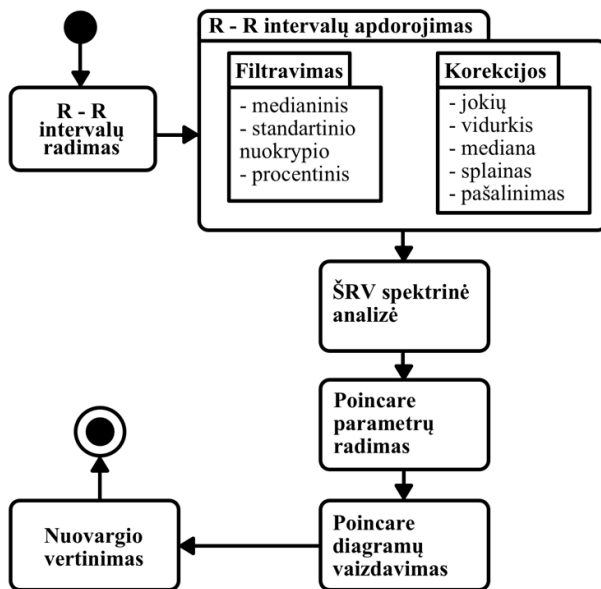
Pažymėję slenkstį φ raide, gauname: jei $P(n) \geq \varphi$, tai įvyko antros rūšies klaida. Tuo tarpu, jei $P(n) \leq -\varphi$, tai yra pirmos rūšies klaida. Šis filtras gerai aptinka staigius R-R intervalų pokyčius nuo vidurkio \bar{x} . Nustačius pirmos arba antros rūšies klaidas, reikia jas ištaisyti. Naudojama įvairių metodų, tačiau populiariausi yra: gretimų reikšmių vidurkis, mediana, splainas ar tiesiog nereikalingos reikšmės pašalinimas. R-R intervalų sekos apdorojimo pavyzdžiai prie skirtingų klaidų aptikimo algoritmų pateikti 9 lent., kurioje $\nu = 3$, $\varphi = 20\%$ ir $\tau = 4$. Klaidų korekcijai naudojamas splainų interpoliacijos metodas.

9 lentelė. Artefaktų korekcijos pavyzdys R-R intervaluose



Atlikus R-R intervalų duomenų filtravimą gali būti naudojami ŠRV vertinimo algoritmai (tokie kaip Poincare) bei atliekamas nuovargio vertinimas pagal gautus rezultatus. R-R intervalų apdorojimo bei ŠRV analizės schema pateikta 27 pav.

Nors Poincare tyrimo metodas populiarius įvairių širdies patologijų identifikavimo procesuose, nuovargio vertinimas yra nauja pritaikymo sritis. 27 pav. pavaizduota metodika taip pat gali būti taikoma žmogaus fizinio parengtumo vertinimui ar kitose panašiose sveikatos vertinimo srityse. Poincare diagramos leidžia stebėti ne tik ŠRV parametrų reikšmes, bet ir jų pokyčius plokštumoje.

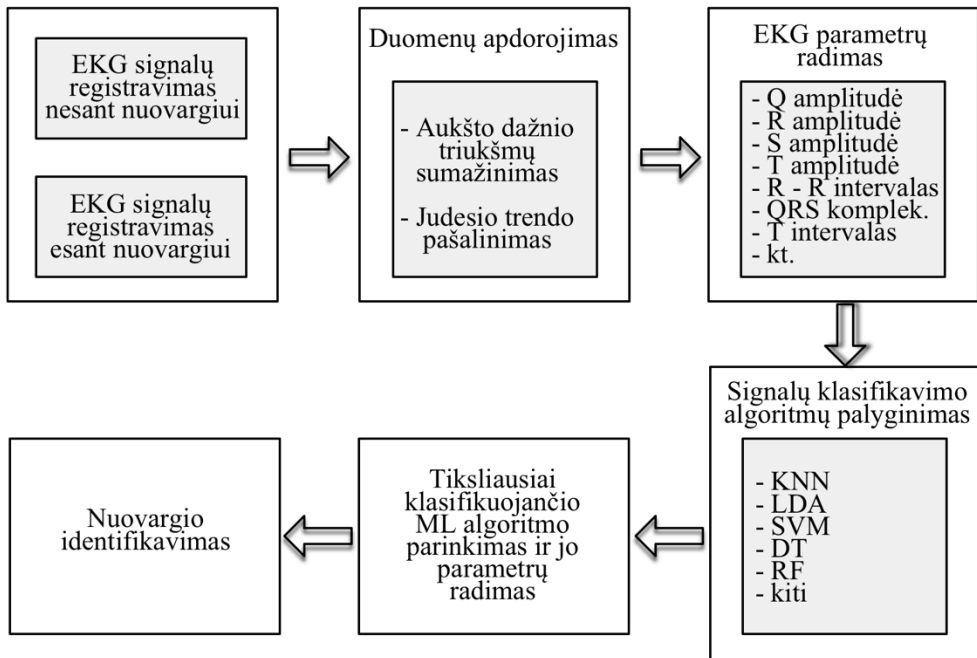


27 pav. ŠRV apskaičiavimo ir vertinimo schema

2.3. Signalų klasifikavimas

Standartinį signalų klasifikavimo algoritmą sudaro dvi pagrindinės dalys: pirminė signalo transformacija ir pats klasifikavimas. Pirminis transformacijos procesas naudojamas norint išgauti specifinių požymių iš pirminio signalo ir sumažinti jo dimensiją, kad klasifikavimas būtų atliekamas kuo efektyviau. Šio proceso pabaigoje prarandama dalis informacijos apie patį signalą, kuri yra traktuojama, kaip nereikalinga klasifikavimui (Wei et al., 2018). Elektrokardiogramų klasifikavimas į skirtingas patologijų kategorijas yra sudėtingas signalo struktūrų atpažinimo uždavinys, todėl paprastai naudojami ne vienas, bet keletas algoritmų skirtingiems tikslams pasiekti (Shao et al., 2018). Daugybė medicininės paskirties paslaugų sričių, tokių kaip medicininiai testai, vaistų dozavimas, sąryšiai tarp klinikos ir diagnostikos duomenų, naudoja duomenų gavybos metodologijas. Dėl didėjančio duomenų kiekio, signalų klasifikavimo ir sistemų automatizavimo procesai vis populiarėja medicinoje ir didėja paklausa tarp pacientų.

Analogiškas EKG signalų klasifikavimo uždavinys gali būti formuluojamas ir nuovargio vertinimo procese. Šiuo atveju analizuojamas ne vientisas EKG signalas ar tam tikri jo išskaidymai, o skirtingu paros metu registruoti signalai. Nuovargis paprastai jaučiamas po intensyvios fizinės veiklos ar dienos eigoje (ypač vakare). Fizinį nuovargį nustatyti gerokai paprasčiau, nes po intensyvios fizinės veiklos ar jos metu širdies ritmas yra padidėjęs. Tuo tarpu, ryškių EKG signalo parametrų skirtumų, esant ar nesant fiziologiniam nuovargiui, pastebėti sudėtinga. Šiame darbe pasiūlytas nuovargio identifikavimo procesas pavaizduotas 28 pav.



28 pav. EKG signalų klasifikavimo schema

28 pav. schemoje „Signalų klasifikavimo algoritmų palyginimo“ dalyje nurodyti mašininio mokymosi algoritmai (KNN, DT, SVM ir kt.) turi skirtingus sudėtingumo lygius, gali būti modifikuoti priklausomai nuo uždavinio sudėtingumo arba net įjungti į bendrą klasifikavimo metodą. Jų formavimo procesas priklauso nuo teisingų požymių skaičiaus pasirinkimo, todėl prieš klasifikavimą būtina atmesti nereikšmingus ar turinčius didelę tarpusavio koreliaciją kintamuosius (Shao et al., 2018). Duomenų analizėje ir prognozavime yra išplėtotas ir aprašytas ne vienas RF algoritmas. Šiame darbe papildomai aprašytas atsitiktinio miško modelis, kuris pateiktas kaip pavyzdys nuovargio nustatymo procese. Įvertinami įvairūs modelio hiperparametrai, tokie kaip didžiausias galimas medžio aukštis, mazguose esantis minimalus elementų skaičius, DT medžių skaičius ir pan.

Atskiro sprendimų medžio procedūrą sudaro trys dalys:

1. Įvedami visi duomenys į pagrindinį mazgą.
2. Duomenys padalinami į mazgus taip, kad būtų minimizuotas Gini koeficientas. Neretai geriausiam skaidymui parinkti yra apskaičiuojama entropija.
3. Kartojamas 1 ir 2 žingsniai kiekvienam išskaidymo mazgui tol, kol pasiekiamas norimas tikslumas arba kol pasiekimas apibrėžtas maksimalus gylis.

Jei pažymėsime, jog yra n duomenų mazge t ir kiekviename mazge yra c klasių, tai duomenų, priklausančių klasei i , santykis $p(i|t)$ apibrėžiamas tokiu būdu:

$$p(i|t) = \frac{n_i}{n}; \quad (80)$$

čia t nurodo mazgo numerį, i – klasės numerį, o n_i – duomenų kiekį klasėje i . Gini koeficientas I_G kiekvienam mazgui tada aprašomas tokiu būdu (Oeda & Chieda, 2019):

$$I_G(t) = 1 - \sum_{i=1}^c p(i|t)^2. \quad (81)$$

Mašininio mokymo algoritmams, sprendžiant klasifikavimo uždavinį, duomenų rinkiniai yra išskaidomi į dvi grupes, skirtas apmokymui ir testavimui. Paprastai, turint didesnę duomenų imtį, gaunamas didesnis klasifikavimo tikslumas, tačiau nebūtinai. Tam tikrais atvejais duomenys nėra informatyvūs, o mašininio mokymo algoritmai duomenis suskirsto į kategorijas nekorektiškai (Pu et al., 2018).

Neretai mašininio mokymosi algoritmai apsimokymo procese gali per daug prisitaikyti prie duomenų imties, t. y. persimokyti (angl. *over-fitting*). Tada naujoms duomenų imtims prognozės gaunamos su didesnėmis paklaidomis. Siekiant išvengti šių trūkumų, įvedama duomenų kryžminė validacija (angl. *cross-validation*). Tai apsaugo nuo persimokymo, išskaidant duomenų rinkinius į grupes ir įvertinant kiekvienos grupės klasifikavimo ar prognozavimo tikslumą.

2.4. Treniruočių proceso valdymas

Populiarijant sveikai gyvensenai vis daugiau žmonių sportuoja. Sportuojant profesionaliai kyla paklausa įvairių mobilių aplikacijų, kurios padėtų reguliuoti treniruotės intensyvumą arba stebėti ir sekėti treniruotės planą. Žinoma, norint išvengti širdies veiklos sutrikimų dėl per didelio krūvio, biologiniai rodikliai tampa vieni iš pagrindinių indikatorių, lemiančių pratimų intensyvumo parinkimą. Be to, profesionaliai sportuojantys siekia pagerinti savo fizinę būklę ir ištvermingumą, todėl modelis, leidžiantis stebėti sveikatos būklę realiu laiku, gali įspėti ne tik, kad reikia mažinti treniruotės krūvį, bet ir pasiūlyti ją suintensyvinti.

Šiame darbe realus laikas apibrėžiamas kaip 10 sekundžių laiko intervalas, per kurį registruojami EKG signalai ir įvertinami parametrai apskaičiuojant jų vidurkį. Treniruotės sesijos modelis gali būti aprašomas penkiomis pagrindinėmis dalimis: trukmė, širdies ritmas, QRS kompleksai, DJT intervalai, diskriminantai.

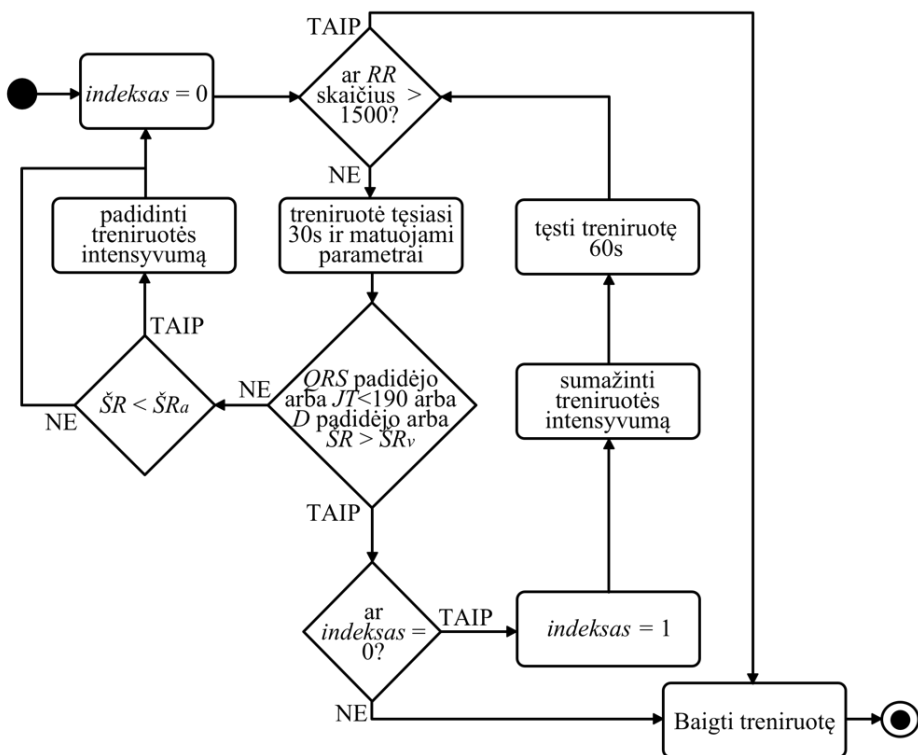
Trukmė. Treniruotės trukmė priklauso nuo R-R intervalų skaičiaus. Rekomenduojama, kad treniruotė neviršytų 1 500 R-R intervalų skaičiaus (Hulke & Phatak, 2011).

Širdies ritmas (ŠR). Matuojamas dūžių skaičiumi per minutę. Viršutinė ir apatinė širdies ritmo ribos apibrėžiamos pagal formules:

$$\check{S}R_a = \left((220 - A) - \check{S}R_p \right) \cdot 0,5 + \check{S}R_p, \quad (82)$$

$$\check{S}R_v = \left((220 - A) - \check{S}R_p \right) \cdot 0,85 + \check{S}R_p, \quad (83)$$

čia $\check{S}R_a$ yra širdies ritmo apatinė riba, $\check{S}R_v$ – viršutinė riba, $\check{S}R_p$ – širdies ritmas prieš treniruotę, A – treniruotę atliekančio asmens amžius (Poderys et al., 2010). Jei širdies ritmas mažesnis nei $\check{S}R_a$, tai treniruotės intensyvumas turėtų būti padidintas. Taip pat, jei $\check{S}R$ yra didesnis nei $\check{S}R_v$, tai reikėtų sumažinti širdies apkrovą ir parinkti lengvesnius pratimus arba treniruotę sustabdyti.



29 pav. Treniruotės sprendimų priėmimo algoritmo schema

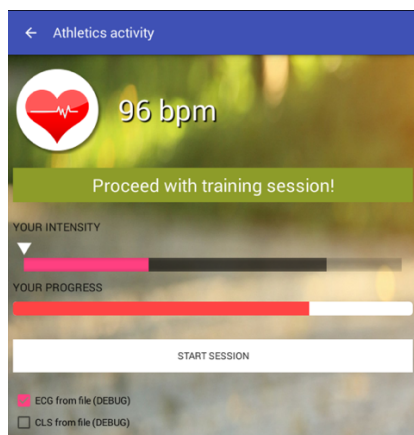
ŠR vertinimas taip pat plačiai naudojamas sprendimų priėmimo algoritmuose įvairių rūšių treniruotėms vertinti, tokioms kaip grupinės treniruotės (Vehkaoja et al., 2008). Tačiau paprastai tokios sistemos nėra personalizuotos ir turėtų būti patobulintos.

QRS kompleksas. Jei per 30 s *QRS* padidėja 5 %, tai treniruotės intensyvumas turėtų būti sumažintas. Po to 60 s šis parametras yra nevertinamas. Jei per kitas 30 s *QRS* vis dar didėja, treniruotė stabdoma.

JT intervalas. Jei *JT* trukmė yra trumpesnė nei 190 ms, treniruotės intensyvumas turi būti sumažintas ir kitas 60 s šis parametras nevertinamas. Jei po šio laiko *JT* vis dar mažesnis nei 190 ms, tai treniruotė turėtų būti sustabdyta.

Diskriminantas (D). Diskriminantų reikšmės vertinamos panašiai kaip ir *QRS* kompleksų: jei per paskutines 30 s *D* padidėjo 10 %, tai treniruotės intensyvumas sumažinamas ir matuojamas vėl tik po 60 s. Jei po to per kitas 30 s jis vėl padidėja, tai treniruotė turi būti stabdoma.

Jei EKG parametrai yra stabilūs (*QRS* ir *D* nedidėja) arba nepasiekia kritinių reikšmių, treniruotės intensyvumas turėtų išlikti panašus. Priešingu atveju intensyvumas turėtų būti padidintas, sumažintas arba treniruotė sustabdyta (Gobinath Aroganam, 2019).



30 pav. CareWare mobilios aplikacijos vaizdas

Schematiškai treniruotės intensyvumo parinkimo modelis pavaizduotas 29 pav. Čia kintamasis „indeksas“ yra naudojamas norit apibrėžti pirmąją ar antrąją EKG parametro kritinę reikšmę. Algoritmo pradžioje, šis parametras yra lygus nuliui ir, prieš sumažinant treniruotės intensyvumą, priskiriama reikšmė 1. Tada atitinkamas parametras 60 s yra nevertinamas, po to treniruotė stabdoma, jei parametras vis dar rodo kritinę sveikatos būklę. Priešingu atveju parametro „indeksas“ reikšmė priskiriama 0 ir treniruotė tęsiama mažesniu intensyvumu. Šio algoritmo tikslas yra aptikti fiziologinės būsenos pokyčius ir parinkti tinkamą pratimų intensyvumą, priklausomai nuo vidinių ir išorinių faktorių (prisitaikant prie geografinių klimato ar laiko pokyčių, įvertinant nuovargį ir kt.). Projekto CareWare – „Electronic Wearable Sport and Health Solutions“ vykdymo metu bendradarbiaujant su įvairių sričių mokslininkais, buvo sukurta mobili aplikacija (žr. 30 pav.), kurioje teikiamos rekomendacijos apie treniruotės intensyvumą ir galimą fizinį aktyvumą. Aplikacijoje vertinimas atliekamas registruojant EKG signalus ir vertinant parametru reikšmes.

2.5. Metodų korektiškumo vertinimas ir paklaidos

Gautų rezultatų vertinimas yra svarbus žingsnis norit parodyti, kiek patikimi ir tikslūs pasiūlyti metodai. Paskutinėje algoritmu analizės proceso dalyje apskaičiuojami tam tikri elgsenos indeksai tarp rekonstruotų ir žinomų pradinių reikšmių. Metodų tikslumas šiame darbe vertinamas naudojant Pearsono koreliacijos koeficientą, kuris parodo stiprumą ir kryptį tiesinės koreliacijos tarp dviejų kintamųjų:

$$R^2 = \frac{[\sum(x_i - \bar{x})(y_i - \bar{y})]^2}{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}; \quad (84)$$

čia x_i, y_i yra atskirų imčių taškai su indeksu i , o \bar{x}, \bar{y} – atitinkamų imčių reikšmių vidurkiai. Šiame darbe naudojamas koreliacijos koeficientas signalų spektrų tarpusavio priklausomybei įvertinti, kuris aprašomas formule:

$$R_{Sp}^2 = \frac{[\sum(S_f(x) - \bar{S}(x))(S_f(y) - \bar{S}(y))]^2}{\sum(S_f(x) - \bar{S}(x))^2 \sum(S_f(y) - \bar{S}(y))^2}; \quad (85)$$

čia $S_f(x), S_f(y)$ yra amplitudinės signalų x ir y spektro reikšmės (matuojamos dB),

kurių dažnis f . Atitinkamai, $\bar{S}(x)$ ir $\bar{S}(y)$ yra signalų x ir y spektrų vidutinės reikšmės.

Tiesinis ryšys tarp dviejų atsitiktinių kintamųjų reikšmių bus tuo stipresnis, kuo $|R|$ yra arčiau 1. Jei $R > 0$, tai didėjant vieno atsitiktinio dydžio reikšmėms, kito reikšmės taip pat tiesiškai didėja. Analogiškai, jei $R < 0$, tai didėjant vieno atsitiktinio dydžio reikšmėms, kito – tiesiškai mažėja. Jei $R = 0$, tai tiesinio ryšio nėra. Evans 1995 metais pasiūlė (Evans, 1995) Pearsono koreliacijos stiprumo koeficientą R išskaidyti pagal jo absoliutinės reikšmės vertę:

0,00 – 0,19 „labai silpnas“

0,20 – 0,39 „silpnas“

0,40 – 0,59 „vidutinis“

0,60 – 0,79 „stiprus“

0,80 – 1,00 „labai stiprus“

Tarkime, kad koreliacijos koeficientas R yra nežinomas. Tada, norint atsakyti į klausimą, ar analizuojami du dydžiai yra priklausomi, tikrinama nulinė hipotezė apie populiacijos Pearsono koeficiento lygybę nuliui:

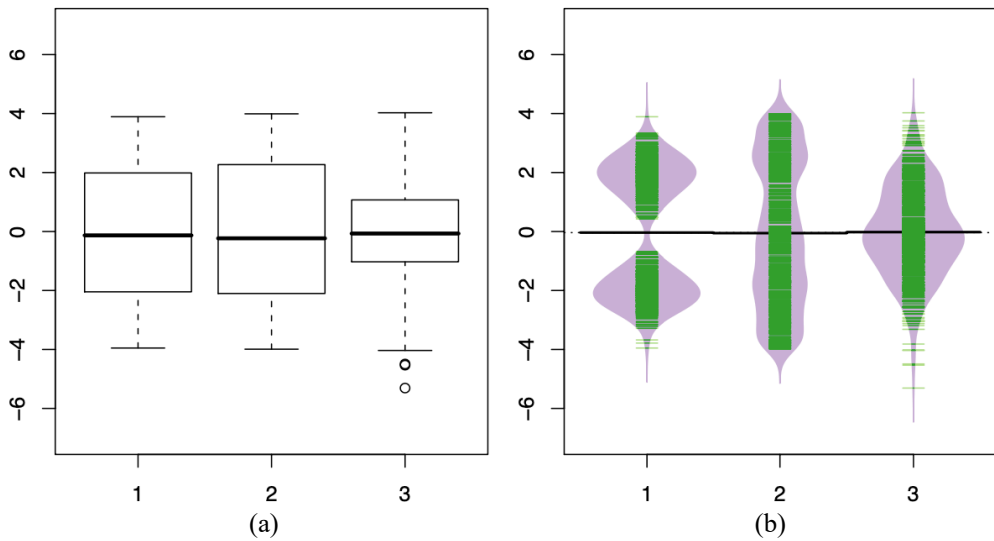
$$H_0: \rho = 0, \quad H_a: \rho \neq 0. \quad (86)$$

Šiai hipotezei patikrinti yra naudojama Stjudento statistika (arba t – testas):

$$t = \frac{R}{\sqrt{1 + R^2}} \sqrt{n - 2}, \quad t \sim St(n - 2); \quad (87)$$

čia n yra imties dydis. Jei H_0 yra atmetama, tai tarp x ir y yra statistiškai reikšmingas tiesinis ryšys, kurio stiprumas gali svyruoti nuo labai silpno iki funkcinio ryšio (kai ρ artimas ± 1).

Koreliacijos koeficiento statistinis įvertinimas dažniausiai naudojamas ne skaičiavimų patikimumui tikrinti, o skirtingų duomenų imčių pasiskirstymui nustatyti. Šiame darbe ši statistika ypač aktuali klasifikuojant EKG signalus. Pats duomenų pasiskirstymas išryškinant pagrindines statistikas (vidurkį, dispersiją, medianą ir pan.) dažniausiai atvaizduojamas naudojant stačiakampes diagramas, tačiau jos turi keletą pagrindinių trūkumų: sudėtinga suprasti ne matematikams ir matoma ne visa naudinga informacija apie duomenų imtį. Taip pat yra daug kitų duomenų atvaizdavimo būdų, tokių kaip stulpelinė, branduolinio tankio, sklaidos diagramos ir kt. Dauguma jų nėra labai patogios, norint palyginti kelias skirtingas duomenų imtis. Šiame darbe pasiūlytas metodas yra pupelių diagrama (angl. *beans plot*), kurioje išryškėja viena ar kelios „pupos“ formos duomenų serijos. Kiekviena pupa sudaryta iš duomenų tankio kontūro, kuris yra veidrodinis daugiakampio formos atspindys. Toje dalyje, kurioje yra daugiausia duomenų, pupelė storiausia, o kur duomenų mažiau – ji susitraukia. Be to, viduje vaizduojama vienmatė sklaidos diagrama, kuri pažymėta skirtingos spalvos linijomis (žr. 31 pav. (b) (Kampstra, 2008). Tai užtikrina duomenų tankio informacijos atvaizdavimą. Aiškūs skirtumai tarp stačiakampės ir pupelių diagramų matomi 31 pav. Palyginus abiejų tipų diagramas matyti, kad duomenų imtį daug informatyviau atvaizduoja pupelių diagramos.



31 pav. (a) Stačiakampių diagramų pavyzdžiai, (b) pupelių diagramų pavyzdžiai (remiantis Kampstra, 2008)

Kelios skirtingos spalvos pupelių diagramoje gali trukdyti, kai norima palyginti daugiau duomenų imčių, todėl šiame darbe buvo atlikti patobulinimai: išimta vienmatė sklaidos diagrama (juostos centrinėje dalyje) ir įvestas spalvų gradientas, kuris ir parodo duomenų sklaidą (kuo šviesesnė dalis, tuo didesnė duomenų sankaupa). Be to, įvedami papildomi duomenų imčių pasiskirstymų pažymėjimai: pažymėtas pupelę sudarančių duomenų vidurkis ir bendros duomenų imties vidurkis.

Norint įvertinti, ar tam tikros Poincare parametrų reikšmės (šiam darbe parametro *SDRR*) turi vienodą pasiskirtymą atliekant skirtingus fizinius pratimus, Sjudento statistika nebetinka. Tam buvo parinktas Friedman testas, kuris nereikalauja, jog imtis būtų iš tos pačios populiacijos. Keliama nulinė hipotezė, kad stulpeliuose esantys duomenys yra pasiskirstę vienodai ir alternatyvi hipotezė, kad pasiskirstymas nėra vienodas. Friedmano statistika F_T aprašoma tokiu būdu:

$$\frac{12 \sum_{j=1}^k P_j^2}{\Lambda} - \frac{3\Lambda}{T} \sim \chi_{k-1}^2; \quad (88)$$

čia $\Lambda = Tk(k+1)$, t – laiko periodai ($t = 1 \dots T$), k – analizuojamų laiko eilučių skaičius ir P_j – j -ojo stulpelio laipsnių suma (Gray, 2020). Friedmano testas neretai naudojamas EKG signalų klasifikavimo procese įtraukiant gautus rezultatus į mašininį mokymą (Zeytinoğlu et al., 2013).

ŠRV tiesinių parametrų analizėje vizualiam rezultatų palyginimui pritaikytas duomenų standartizavimas (angl. *z-score normalization*), kur parametrų reikšmės perskaičiuojamos tokiu būdu:

$$x' = \frac{x - \mu}{\sigma}; \quad (89)$$

čia μ yra x duomenų vidurkis, o σ – dispersija. Gautos normuotos imties duomenų vidurkis yra lygus 0, o dispersija lygi 1. Taip pat tokiu būdu normuoti duomenys buvo naudojami EKG signalų klasifikavime ir nuovargio identifikavimo procese.

2.6. Skyriaus išvados

Judesio metu registruotiems elektrokardiogramos signalams standartiniai ir plačiai naudojami žemo dažnio triukšmų pašalinimo algoritmai netinka. Dėl judesio, raumenų susitraukimų, judančių laidų ar kitų trikdžių žemo dažnio triukšmas yra nestacionarus ir neretai užgožia patį EKG signalą. Tokiems judesio artefaktams pašalinti buvo naudojamas BEADS algoritmas, kuris sugeba tinkamai identifikuoti tendą ir ją eliminuoti nepažeidžiant pačio signalo charakteristikų. Šis metodas susideda iš aukšto dažnio filtro, simetrinių ir asimetrinių baudos funkcijų (51). BEADS algoritmas iteraciniu būdu minimizuoja tikslo funkciją (52) ir perkelia EKG signalą izolinijos atžvilgiu. Kadangi judesio metu atsiradę triukšmai gali stipriai varijuoti, o BEADS algoritmas turi nemažai parametrų (tokių kaip ribinis dažnis, asimetrijos parametras, reguliaciniai parametrai ir pan.), tikėtina, jog skirtingiems pratimams gali netikti tos pačios parametrų reikšmės.

Šiame darbe pristatoma ir aprašoma reikšminga BEADS algoritmo modifikacija, skirta judesio metu registruotiems EKG signalams filtruoti (žr. 21 pav.). Dėl šio patobulinimo algoritmo parametrai geba prisitaikyti prie skirtingų judesio triukšmų ir sėkmingai juos eliminuoja. Modifikacija remiasi QRS kompleksų skaičiaus nustatymu: kuo daugiau QRS kompleksų pavyksta rasti, tuo atitinkamo BEADS algoritmo parametro reikšmė yra tinkamesnė. Žinoma, reikėtų atkreipti dėmesį, kad ši sąlyga gali būti tenkinama tik tada, kai analizuojamas iš anksto apibrėžtas BEADS algoritmo parametrų reikšmių intervalas (pavyzdžiui, ribinio dažnio reikšmės gali kisti tik intervale $[0,01; 0,2]$). Taip išvengiama galimų EKG signalo iškraipymų.

Q, R, S bangų bei QRS komplekso paieška atliekama naudojant k – TEO metodą (žr. 23 pav.), kuris susideda iš dviejų pagrindinių dalių: trijų MTEO reikšmių radimo pagal (56) formulę ir statistinio slenksčio įvertinimo. Šiuo algoritmu galima tiksliai nustatyti norimo MUAP pasirodymo laiką. Tokiu būdu nustatomi Q, R ir S bangų parodymo laikai bei jų amplitudinės vertės. Turint šias reikšmes, galima apskaičiuoti QRS kompleksą.

Fiziologinio nuovargio vertinimo procese šių EKG parametrų nepakanka. Tam buvo pasiūlytas k – TEO algoritmo papildymas, kuriuo galima apskaičiuoti T dantelio pasirodymo laiką bei jo trukmę. Jis remiasi kritinių reikšmių radimu (žr. 24 pav.) žinant apytikslę vietą tarp QRS kompleksų. Papildymas susideda iš trijų pagrindinių dalių:

- T bangos piko identifikavimas
- T bangos pradžios iš pabaigos taško radimas
- T intervalo (trukmės) apskaičiavimas
- Kitų EKG parametrų radimas (QT ir ST)

Pasiūlyta tiesinė ir netiesinė ŠRV tyrimų metodika, kuria galima nustatyti fizinį nuovargį treniruotės metu ar iš karto po jos. Išvestiniai EKG parametrai randami naudojant tiesioginius signalo parametrus. Pavyzdžiui, šiame tyrime naudojami ŠRV parametrai ar Poincare diagramos yra randamos naudojant tik R-R intervalų reikšmes. Taip pat sudaryta fiziologinio nuovargio vertinimo metodika, kuri apima įvairių EKG signalo parametrų reikšmes (QRS kompleksas, T intervalas ir kt.).


3. SIGNALŲ FILTRAVIMO ALGORITMŲ TYRIMAI

3.1. Filtravimo parametrų parinkimas naudojant simuliuotus EKG signalus

Tiek algoritmų parinkimui, tiek jų parametrų nustatymui buvo sugeneruotas EKG signalas naudojant simulatorių CMRR 2.0, kuriame nėra jokio pašalinio triukšmo ir kuris vaizduoja teorinę sveikos širdies darbą atitinkančią elektrokardiogramą. Simulatorius generuoja EKG signalo sinusoidę su 150 bpm (dūžių per minutę). Prie šio signalo pridėdami žemo ir aukšto dažnių triukšmai: aukšto dažnio triukšmas – atsitiktinis Gauso baltasis triukšmas su vidurkiu 10; žemo dažnio triukšmas – sinusoidė, aprašoma formule:

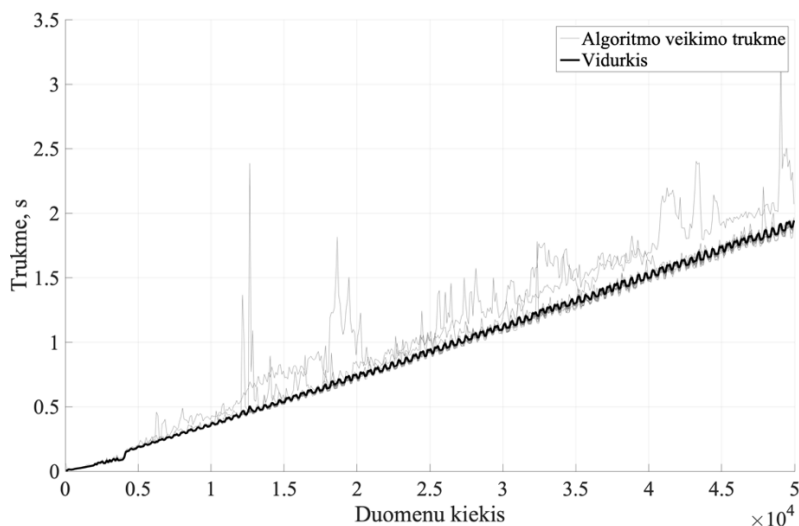
$$f(t) = 0,3 \cdot \sin(0,9 \cdot \pi \cdot t) + 0,001 \cdot d, \quad (90)$$

čia d yra atsitiktinis dydis su standartiniu normaliuoju pasiskirstymu. Simuliuoto ir su triukšmu signalo pavyzdys pateiktas 32 pav. EKG laiko eilutės matavimai pateikti milisekundėmis (ms), kad rezultatus būtų galima palyginti su Cardioscout registravimo įrenginiu (8 pav. (b), kuris signalus registruoja kas 2 ms.



32 pav. Su simulatoriumi sugeneruotas EKG signalas (kas 2 ms) su triukšmu

Be BEADS algoritmo parametrų paieškos labai svarbu įvertinti ir pačio algoritmo sudėtingumą. Tai ypač aktualu, kai norima, jog duomenų apdorojimas būtų atliktas realiu laiku. BEADS algoritmo vykdymo laiko priklausomybė nuo N duomenų taškų pateikta 33 pav. Buvo sugeneruotos skirtingos EKG laiko eilutės su atsitiktiniais triukšmais (iš viso 50 vnt.) ir paduodant BEADS skirtingą duomenų kiekį apskaičiuojamas algoritmo veikimo laikas (sekundėmis). Galima pastebėti, kad tam tikrais atvejais algoritmo veikimo trukmė yra didesnė nei 3 s. Tokie svyravimai galėjo įvykti todėl, kad BEADS algoritmas vis perskaičiuoja filtravimo koeficientus tol, kol pasiekiami pakankamai maža tikslo funkcijos reikšmė. Skaičiavimuose ieškomos atvirkštinės matricos, kurias priklausomai nuo duomenų reikšmių ne visada yra lengva ir greitai apskaičiuoti (kai determinantas arti nulio). Nepaisant kai kurių svyravimų, algoritmo vykdymo laiko vidurkis turi tiesinę priklausomybę nuo duomenų kiekio (33 pav. paryškinta linija), o tai rodo gerą algoritmo veikimą ir tinkamumą realių duomenų apdorojimo procese.



33 pav. BEADS algoritmo sudėtingumas

EKG signalai nėra simetriniai laiko ašies (Ox) atžvilgiu, todėl svarbu įvertinti BEADS algoritmo asimetrinę baudos funkciją ir parinkti tinkamą asimetrijos koeficientą r ($r \in \mathbb{Z}^+$). Tyrimo su simuliuotais duomenimis metu (vertinant vidutines kvadratinės paklaidas tarp pradinio simuliuoto ir filtruoto EKG signalų) pastebėta, kad r kintant nuo 1 iki 5 RMSE paklaidos yra labai nedidelės ir vidutiniškai siekia vos 0,076. Didesnės reikšmės prastina rezultatą ir eksponentiškai didina paklaidas (žr. Priedas1 priede). Tolimesniems tyrimams pasirinkta asimetrijos koeficiento reikšmė $r = 2$.

10 lentelė. DBT algoritmo RMSE paklaidos ir skaičiavimo trukmė prie skirtingų Daubechies bangelių


Daubechies	Trukmė, s	RMSE	Daubechies	Trukmė, s	RMSE
'db1'	0,168	0,1025	'db13'	0,212	0,0879
'db2'	0,138	0,0935	'db14'	0,229	0,0878
'db3'	0,172	0,0909	'db15'	0,235	0,0878
'db4'	0,163	0,0898	'db16'	0,229	0,0878
'db5'	0,166	0,0892	'db17'	0,254	0,0878
'db6'	0,166	0,0888	'db18'	0,266	0,0877
'db7'	0,179	0,0885	'db19'	0,248	0,0877
'db8'	0,173	0,0883	'db20'	0,309	0,0877
'db9'	0,179	0,0882	'db21'	0,295	0,0877
'db10'	0,194	0,0881	'db22'	0,294	0,0877
'db11'	0,213	0,0880	'db23'	0,300	0,0876
'db12'	0,223	0,0879	'db24'	0,311	0,0876

Aukšto dažnio triukšmų sumažinimui buvo naudojamas trijų lygių diskrečiųjų bangelių transformacijos algoritmas, kuriame slenkstinės funkcijos parinktos iš Daubechies funkcijų šeimos – bangelių. Tyrime pasirinktos 5 000 EKG signalo taškų (trukmė 10 s), kurie naudojami nustatyti tinkamiausius Daubechies filtravimo

koeficientus tiek vidutinių kvadratinų paklaidų, tiek skaičiavimo trukmės atžvilgiu. Kadangi simuliuotame EKG signale aukšto dažnio triukšmas yra atsitiktinis Gauso baltasis triukšmas, tai buvo paimti 100 skirtingų simuliutų EKG signalų, kuriuose jau pašalintas žemo dažnio trendas naudojant BEADS algoritimą. Gauti rezultatai pateikti 10 lent.

Nors ryškių skirtumų nei laiko, nei vidutinės kvadratinės paklaidos atžvilgiu nėra, galima pastebėti, kad DBT algoritmas duoda geriausias rezultatus su bangelių funkcijomis „db11“ ir „db12“. Vidutinės kvadratinės paklaidos yra labai panašios kaip ir aukštesnių eilių Daubechies koeficientų ir didinant Daubechies koeficientų eilę, RMSE beveik nesikeičia. Analizuojant didesnius duomenų srautus algoritmo trukmė taip pat didėtų, todėl kiekviena, net ir nedidelė sekundės dalis, yra svarbi realaus laiko analizės procese. Taip pat reikėtų atkreipti dėmesį į tai, kad buvo skaičiuojama su MacBook Pro, kuris turi 8 GB operatyviosios atminties, 2,9 GHz dviejų branduolių i5 procesorių. Tikėtina, kad išmaniajame telefone ar laikrodyje skaičiavimai užtruks ilgiau.

Kaip atrodo simuluotas EKG signalas po aukšto ir žemo dažnių triukšmų pašalinimo pavaizduota 34 pav. Čia žemo dažnio triukšmas buvo pašalintas naudojant BEADS algoritimą su asimetrijos koeficientu $r = 2$, o aukšto dažnio triukšmas sumažintas naudojant DWT algoritimą su Daubeches „db11“ bangelėmis.



34 pav. Simuliuto EKG signalo filtravimo pavyzdys: (a) simuluotas signalas ir BEADS algoritmo rastas trendas; (b) po trendo nuėmimo; (c) po filtravimo naudojant DWT algoritimą

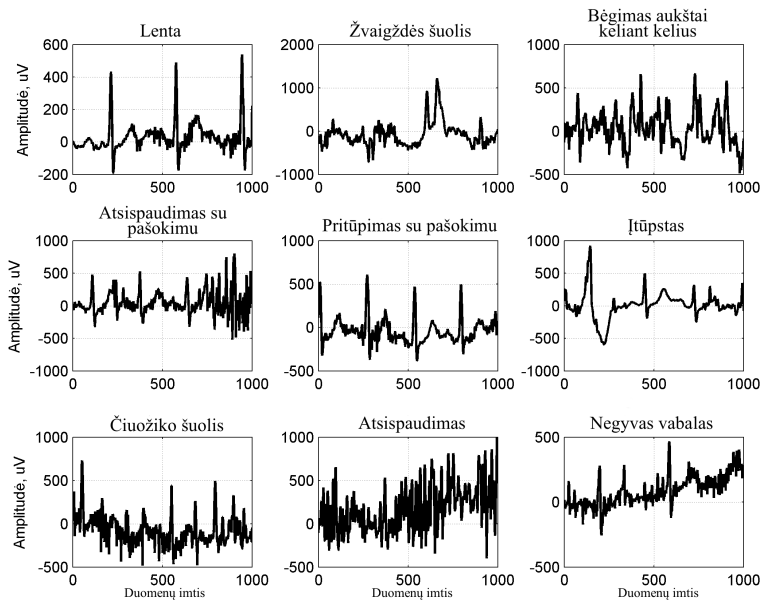
3.2. EKG signalų registravimas filtravimo algoritmų tyrimui

EKG signalų registravimui naudojamas CardioScout Multi įrenginys (su registravimo dažniu 500 s^{-1}). EKG signalai paimti žmogui vaikstant ir atliekant 10 skirtingų pratimų rinkinį, kurie sudaro pagrindinių funkcinių pratimų treniruotę (Haff & Nimphius, 2012). Šis rinkinys susideda iš trijų statinių pratimų: lenta, šoninė lenta kairės ir dešinės pusių (dirbančios raumenų grupės: centrinės, pečių, nugaros), dviejų kardiopratiimų: žvaigždės šuoliai, bėgimas aukštai keliant kelius (dirbančios raumenų

grupės: rankos, kojos), šeši dinaminiai pratimai: negyvas vabalas (dirbančios raumenų grupės: centrinė, pečių mobilumo, klubų lankstumo), atsispaudimas su pašokimu (dirba visos raumenų grupės), itūpstai, pritūpimai su pašokimu, čiuožiko šuoliai (dirbančios raumenų grupės: kojos, sėdmenys) ir prisispaudimai (dirbančios raumenų grupės: centrinė, nugaros, krūtinės). Kiekvienas pratimas buvo atliekamas 1 minutę. Visi atliekami pratimai pavaizduoti 35 pav. Registruotų EKG signalų pavyzdžiai pateikti 36 pav. Čia matyti, kad registruoti EKG signalai turi įvairius amplitudinius svyravimus bei formas, nes buvo paveikti skirtingų žemo ir aukšto dažnio triukšmų (skirtingų pratimų filmuotos medžiagos nuorodos pateiktos Priedas 3 priede).



35 pav. Atliekamų skirtingų bazinių pratimų vizualizacija



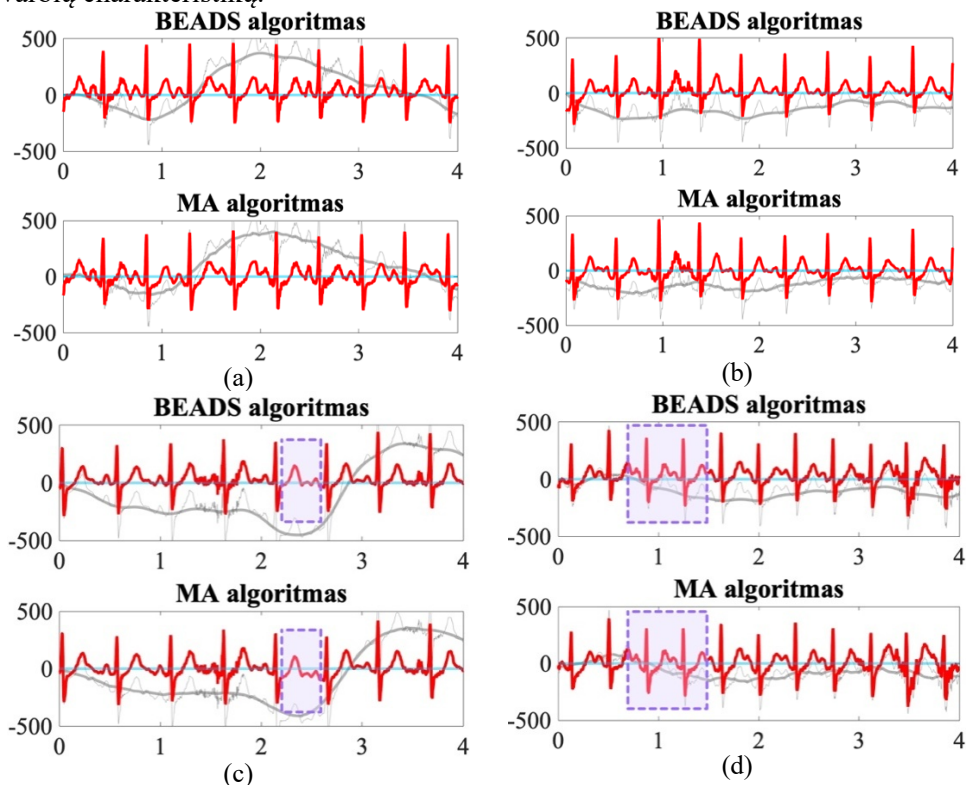
36 pav. Registruoti EKG signalų pavyzdžiai atliekant skirtingus fizinius pratimus

3.3. Signalų filtravimo algoritmų palyginimai

Ieškant tinkamiausio filtro judesio trendui pašalinti, buvo ištirti ir išbandyti įvairūs metodai, tokie kaip Butterworth filtras, Wiener filtras, DWT metodas ir daug kitų. Pagrindinė problema, su kuria susiduria standartiniai filtrai, yra ta, kad tam tikros EKG signalo dalys yra suglodinamos ir prarandamos tikrosios amplitudinės signalo parametrų vertės. Kai kurie (tokie kaip Wiener filtras) netiksliai identifikuoja nestacionarų trendą ir signalas tampa išdarytas izolinijos atžvilgiu. Tuo tarpu, metodai, tokie kaip MA ar BEADS, geba prisitaikyti prie analizuojamo signalo ir atskirti judesio trendą neprarandant EKG pagrindinių charakteristikų. Nors algoritmai atrodytų veikia panašiu tikslumu, slenkančio vidurkio metodas ne visada geba prisitaikyti prie staigių signalo pokyčių ar atsižvelgti į izolinijos padėtį.

37 pav. yra pateikti prie skirtingų pratimų registruotų EKG signalų BEADS ir MA filtrų palyginimai. Kol pratimai yra paprasti, be staigių judesio pokyčių (pritūpimai, įtūpstai – (a) ir (b) dalys), judesio trendo linija (paryškinta pilka) randama labai panaši. Galima pastebėti tam tikrus neatitikimus, tačiau jie neturėtų turėti didelės įtakos EKG parametrų paieškos procese. Tuo tarpu, (c) dalyje matomi aiškūs MA algoritmo trūkumai, kai dalis EKG signalo parametrų persikelia žemiau izolinijos ir tokiu būdu pakeičia net savo amplitudinės reikšmės ženklą. Tokius parametrus identifikuoti ir interpretuoti sveikatos vertinimo procese tampa gerokai sunkiau. Dar ryškesni MA ir BEADS algoritmų skirtumai matomi intensyvių pratimų metu, kai EKG signalai gerokai triukšmingesni (pvz., pritūpimas su pašokimu – 37 pav. (d) dalis). Čia neatitikimų atsiranda ne tik vienoje širdies ciklo dalyje, bet ir visoje eilutėje. Beveik visas QRS kompleksas (išskyrus R piką) atsiduria žemiau izolinijos.

Taip sutrumpėja T bangos intervalo ilgis bei prarandama kitų elektrokardiogramai svarbių charakteristikų.



37 pav. BEADS ir MA algoritmų judesio trendo pašalinimo pavyzdžiai (a) atliekant pritūpimus; (b) įtūpstai atgal; (c) atsistojimai iš sėdimos padėties; (d) pritūpimas su pašokimu. Ryškiai raudona linija yra filtruotas EKG signalas, mėlyna – izolinija, pastorinta pilka – judesio trendas

11 lentelė. Rastų QRS skaičius BEADS ir MA algoritmų filtruotiems duomenims

Nr.	Atliekamų pratimų tipas	BEADS, QRS skaičius per min.	MA, QRS skaičius per min.
1	pritūpimai ir įtūpstai	119	118
2	pritūpimai ir įtūpstai	124	124
3	įtūpstai	138	138
4	kardiopratinimai	147	142
5	kardiopratinimai	150	147
6	kardiopratinimai	153	143

Palyginamoji analizė taip pat pateikta 11 lent., kurioje parodyta, kiek QRS kompleksų randama prie skirtingų pratimų, kai judesio trendas pašalinamas naudojant BEADS ir MA filtrus. Čia pastebimos panašios tendencijos kaip ir 37 pav. Kol pratimai yra mažo intensyvumo, EKG signalas yra filtruojamas panašiu tikslumu ir QRS kompleksų radimui didelės įtakos neturi. Atliekant didesnio intensyvumo kardiopratinimus, prarandama gerokai daugiau informacijos apie EKG signalą. Tam

tikrais atvejais skirtumas yra net 10 QRS kompleksų per minutę. Analogiškai lieka neįvertintos ir kitos EKG charakteristikos, nes signalų parametų paieškos algoritmai remiasi QRS kompleksų nustatymu. Be to, reikėtų atsižvelgti, kad MA vėlinimo lango ilgis buvo pasirinktas 0,5 s, o vėlinimo atstatymui 0,25 s (t. y. pusė vėlinimo lango ilgio). Daugiau BEADS algoritmo EKG signalų filtravimo pavyzdžių žr. Priedas 2 priede.

3.4. EEG duomenų triukšmo simuliavimas naudojant EKG judesio tendrus

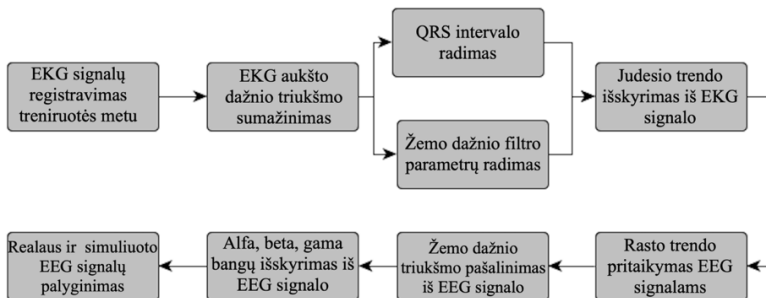
Šiame darbe naudojamos metodikos schema (žr. 38 pav.) susideda iš 5 dedamųjų, kurioje kiekviena aprašoma detalai:

- 1) Signalų registravimas: EKG ir EEG signalai registruojami atliekant įvairius fizinius pratimus pagal paslauginės architektūros (SOA) metodiką, skirtą žmogaus fiziologinių signalų stebėjimui (7 pav.).
- 2) BEADS algoritmo filtravimo parametų parinkimas (ribinio dažnio) naudojant triukšmingus EKG signalus ir į tikslo funkcijos minimizavimą įtraukiant rastų QRS kompleksų skaičių.
- 3) Judesio signalo (trendo) išskyrimas naudojant BEADS filtravimo algoritmą.
- 4) Generuojami judesius nusakantys surogatiniai signalai naudojant vidinės būsenos funkcijas (IMF), kurios atsiranda iš empirinio būsenų išskaidymo (EMD).
- 5) Pašalinamas dėl judėjimo atsiradęs triukšmas iš EEG signalo.



38 pav. Naudojamos sistemos komponentų paslauginė architektūra

Pasiūlyto metodo srautinė diagrama pavaizduota 39 pav., kuriame aprašomas pritaiktų metodų eiliškumas: 1) EKG aukšto dažnio triukšmų sumažinimas; 2) trendo išskyrimas iš EKG signalo; 3) bazinės linijos pritaikymas EEG signalams; 4) žemo dažnio juostos išskyrimas iš EEG signalo; 5) rezultatų palyginimas. Prieš ieškant bazinės linijos EKG signaluose buvo atlikta papildoma normalizuoto ribinio dažnio paieškos analizė.




39 pav. Naudojamų metodų eiliškumo schema

Ieškant tinkamiausių filtravimo parametų buvo įvestas QRS kompleksų paieškos algoritmas. Tikslo funkcijos optimizavimo procese ieškomas QRS

kompleksų skaičius. Turima omenyje, kad kuo daugiau QRS kompleksų pavyksta aptikti filtruotame EKG signale, tuo geresnė parinkta filtravimo parametro reikšmė.

Kiekvienas atliekamas fizinis pratimas formuoja savitus EKG amplitudinius svyravimus, nes dirba skirtingi raumenys ir pratimų intensyvumas yra nevienodas. Todėl kiekvienu atveju gaunama skirtinga normalizuoto ribinio dažnio f_c reikšmė. Apskritai, geriausi filtravimo rezultatai (didžiausias QRS skaičius) gaunami, kai $f_c < 0.1$ (žr. 40 pav.). Kai kurie pratimai (tokie kaip lenta, šoninės lentos) atliekami beveik stacionarioje būsenoje, todėl jų geriausias rastas normalizuotas dažnis yra labai mažas ($f_c < 0.02$), o rasto judesio trendo svyravimai nežymūs. Tuo tarpu, kardiopratiniai (tokie kaip bėgimas aukštai keliant kelius ar čiuožiko šuoliai) turi didelius trendus ir yra labiau paveikti aukšto dažnio triukšmų. Dėl šios priežasties QRS nustatymas tampa sudėtingesne užduotimi, o f_c reikšmės yra labiau svyruojančios (žr. 40 pav.).




40 pav. Normalizuoti ribiniai dažniai skirtingiems fiziniams pratimams, skirti QRS kompleksų skaičiaus radimui judesio triukšmu užterštiems EKG signalams

EKG signalo apdorojimo ir trendo nustatymo procese QRS kompleksų radimas yra atliekamas kiekviename žingsnyje. Šiame darbe teigiama, kad kuo daugiau QRS kompleksų pavyko aptikti, tuo geresni filtravimo rezultatai gaunami. Reikėtų atkreipti dėmesį, kad QRS kompleksas yra laikomas rastu tik tada, kai pavyksta nustatyti visų trijų (Q, R ir S) bangų vietas laiko eilutėje. Taip išvengiama neteisingo EKG parametrų identifikavimo ir interpretavimo itin triukšmingame signale. Cikliška kartojant algoritmą (žr. 21 pav.) randama geriausia BEADS filtro normalizuoto ribinio dažnio f_c reikšmė. Būtent šis filtravimo parametras yra labai svarbus nustatant ir pašalinant judesio signalą. Pavyzdys, kaip QRS kompleksų skaičius priklauso nuo f_c parametro reikšmių pateiktas 40 pav.

Fizinių pratimų metu registruotų EKG signalų filtravimui buvo naudojami du algoritmai: diskrečių bangelių transformacijos (DWT) algoritmas aukšto dažnio triukšmų sumažinimui ir BEADS metodas – judesio trendo išskyrimui ir pašalinimui. Pastebėta, kad „Nėgyvo vabalo“ pratimas turi didelį ir išskirtinai stipriai svyruojantį trendą. Šio pratimo registruoto signalo pavyzdys pateiktas 41 pav.

Po EKG signalo apdorojimo ir visų judesio trendų išskyrimo kitas žingsnis – bazinės linijos pritaikymas EEG signalams. Nauji, simuliuoti EEG signalai buvo sudaryti iš dviejų komponentų: originalių EEG signalų (iš <https://physionet.org/>) ir surogatinių judesio signalų, kurie sugeneruoti iš originalių judesio signalų (išskirtų iš EKG naudojant BEADS algoritmą). Toks dirbtinis fizinių pratimų trendo uždejimas suteikia galimybę dirbti su triukšmingais EEG signalais, pažiūrėti ir ištestuoti turimus

algoritmus triukšmų pašalinimui fizinės treniruotės metu. Žinoma, EEG signalai yra itin jautrūs bet kokiems fiziologinės veiklos pokyčiams: raumenų susitraukimui, kalbėjimui ar net mirkčiojimui, todėl nėra galimybės algoritmus testuoti EEG signalais realiomis sąlygomis. Šiuo metu nėra sukurta tokia technologija ar įrenginys, kuris galėtų tinkamai registruoti EEG signalus judesio metu. Dėl šios priežasties tyrimo metu buvo simuliuojami EEG signalai naudojant EKG signalų judesio tendrus. Nors laiko skalės EEG parametrų tyrimas neturi prasmės dėl itin didelio jautrumo, dažnių skalės charakteristikos naudojamos vertinant BEADS filtro galimą pritaikymą kitiems biosignalams (tokiems kaip EEG).




41 pav. (a) Dėl judesio atsiradusių triukšmų užterštas EKG signalo pavyzdys; (b) EKG signalas po trendo pašalinimo; (c) išskirtas judesio signalas

Spektrinis Pearsono koreliacijos koeficientas (85) formulė) buvo apskaičiuotas tarp originalių ir simuliuotų EEG signalų (po trendo pašalinimo) spektrų (žr. 12 lent.). Geresniam palyginimui buvo atskirtos alpha, beta, gamma bangos ir apskaičiuota jų spektrų koreliacija. 12 lentelėje $spkor_{sig}$ parodo originalių ir po trendo pašalinimo EEG signalų spektrų koreliaciją. Tuo tarpu, $spkor_{alpha}$, $spkor_{beta}$, $spkor_{gamma}$ atitinkamai reiškia spektrų koreliacijas tarp alpha (8–15 Hz), beta (16–31 Hz) ir gamma (≥ 32 Hz) EEG signalo bangų. Atitinkamai, f_c parodo geriausią rastą ribinį dažnį, kuris naudojamas EEG signalų filtravime. Spektrų koreliacijos koeficientai (žr. 12 lent.) parodo, kad pasiūlyta metodika neiškreipia EEG signalų spektrinių charakteristikų. Taip pat, pašalinus judesio tendą, signalas lieka panašus į pradinį registruotą signalą. Geriausios koreliacijos nustatytos, kai asmuo atliko „Žvaigždės šuolio“ ir „Pritūpimo su pašokimu“ pratimus. Rezultatai gauti prie atitinkamų 0,010 ir 0,031 normalizuotų dažnių reikšmių. Aukštesni dažniai veda į mažesnes Pearsono koreliacijos reikšmes (žr. įtūpstų pratimą 12 lent.). Tokiems rezultatams įtakos galėjo

turėti trendo pašalinimo metu atsiradę signalo iškraipymai. Kuo didesnis judesio dažnis, tuo signalas yra labiau pažeidžiamas jį pašalinant, nes EEG signalą daugiausia sudaro aukštų dažnių bangos.

12 lentelė. Spektrų koreliacija tarp originalaus EEG signalo ir simuliuoto EEG signalo po to, kai buvo pašalintas judesio trendas

Pratimas	$spkor_{sig}$	$spkor_{alpha}$	$spkor_{beta}$	$spkor_{gamma}$	f_c
Lenta	0,895	0,908	0,929	0,931	0,083
Šoninė lenta (kairė)	0,900	0,948	0,958	0,962	0,002
Šoninė lenta (dešinė)	0,907	0,954	0,963	0,963	0,003
Negyvas vabalas	0,923	0,920	0,954	0,963	0,010
Žvaigždės šuolis	0,930	0,962	0,974	0,964	0,028
Bėgimas aukštai keliant kelius	0,914	0,930	0,969	0,966	0,010
Atsispaudimas su šuoliu	0,902	0,924	0,957	0,950	0,062
Pritūpimas su pašokimu	0,928	0,958	0,972	0,960	0,031
Įtūpstas	0,836	0,849	0,871	0,869	0,167
Čiuožiko šuolis	0,920	0,867	0,942	0,949	0,023
Atsispaudimas	0,923	0,916	0,960	0,963	0,062



42 pav. Pearsono koreliacijos tarp judesio signalo ir EEG signalo po trendo pašalinimo

Judesio signalo pašalinimo procese kaip efektyvumo matas taip pat naudojamas Pearsono koreliacijos koeficientas (84) formulė) tarp judesio signalo ir EEG signalo po trendo pašalinimo. Rezultatai gauti prie skirtingų fizinių pratimų pateikti 42 pav. Stačiakampė diagrama parodo, kad yra nedidelė koreliacija tarp judesio signalo ir

EEG signalo po trendo pašalinimo. Tai parodo, kad signalų atskyrimas nepažeidžia signalo dažnių skalės charakteristikų, kurios yra svarbios sveikatos vertinimo procese.

3.5. Skyriaus išvados

Stacionariai registruotų EKG signalų filtravimui pakanka nesudėtingų metodų, tokių kaip slenkančio vidurkio algoritmas (MA) ar diskrečioji Furje transformacija. Paprastai tokiems signalams užtenka vieno filtro tiek aukšto dažnio, tiek žemo dažnio triukšmams pašalinti. Tuo tarpu, judesio metu registruoti signalai turi nestacionarų triukšmą ir įprasti metodai susiduria su bent viena iš dviejų problemų:

1) dėl kintamo dažnio triukšmo nesugeba jo pakankamai sumažinti, kad išryškėtų pagrindinės EKG signalo charakteristikos (atitinkami parametrai);

2) parenkamas per platus pašalinamų dažnių intervalų spektras, o tai lemia, kad prarandama dalis informacijos apie patį signalą.

Daugelis nesudėtingų metodų neatsižvelgia į laiko skalės vėlinimus ar suglodina signalą taip, kad amplitudinė EKG parametrų reikšmių analizė praranda prasmę. Esant nedidelio intensyvumo fiziniams pratimams, slenkančio vidurkio algoritmas veikia pakankamai greitai, yra nesudėtingai įgyvendinamas ir skaičiuoja panašiu tikslumu kaip ir pasiūlytas BEADS metodas. Tačiau atliekant sudėtingesnius judesius, kurių metu raumenys susitraukinėja greičiau ir širdies darbas svyruoja stipriau, MA nebesugeba tinkamai aptikti žemo dažnio triukšmo ir EKG signalą atstatyti ties izolinija. Dalis amplitudinių signalo parametrų net pakeičia savo ženklą.

Kadangi tiek žemo, tiek aukšto dažnio triukšmai svyruoja priklausomai nuo pratimo pobūdžio bei treniruotės intensyvumo, tai darbe naudojami du filtrai: BEADS algoritmas parinktas aptikti ir pašalinti trendą, o DWT metodas – aukšto dažnio triukšmams sumažinti. Nors BEADS algoritmas yra sudėtingesnis nei MA, jo sudėtingumas yra tiesiškai priklausomas nuo duomenų kiekio, todėl galima sakyti, kad yra tinkamas realaus laiko skaičiavimams atlikti. Tyrimo metu paaiškėjo, kad šis filtravimo metodas taip pat gali būti naudojamas EEG signalams apdoroti ir neiškraipo jo spektrinių charakteristikų.

4. EKG SIGNALŲ ANALIZĖ NUOVARGIO VERTINIMUI

Šiame skyriuje aprašomi atlikti eksperimentai, skirti žmogaus fiziologiniam nuovargiui nustatyti bei fizinei būklei įvertinti. Tyrimo metu parinkti ir palyginti skirtingi nuovargio nustatymo metodai. Taip pat apskaičiuotos EKG signalų ir jų parametrų statistikos. Detaliai aprašyta metodika, kaip sudarytas ML modelis nuovargiui identifikuoti.

4.1. Atliekami eksperimentai ir EKG signalų registravimas

Kaip ir 3.2 skyriuje, EKG signalų registravimui naudojamas CardioScout Multi įrenginys (su registravimo dažniu 500 s^{-1}). Atletų duomenys gauti po apdorojimo su Kaunas – Krūvis programa, kai išskiriami R-R intervalai bei atvaizduojamos spektrogramos.

4.1.1. EKG signalų registravimas skirtingose aktyvumo būsenose

Šio tyrimo eksperimentuose dalyvavo 5 skirtingo fizinio parengtumo asmenys, kurių amžius 25–30 metų. Visi dalyviai atliko tuos pačius fizinius pratimus ir IQ testus prie kompiuterio. Detalus tyrimo protokolas pateiktas Priedas 4 priede. Kiekvienas dalyvis yra pažymėtas atitinkamai Asm1, Asm2 ir t. t. Kiekvieno asmens tiriamos būsenos aprašytos 13 lentelėje.

13 lentelė. Aktyvumo būsenų EKG signalų registravimas

Būsenos pav.	Būsenos aprašymas
S1	Ramybės būsena atsistojus
S2	Protinė veikla (testų sprendimai prie kompiuterio) atsisėdus
S3	Ramybės būsena atsisėdus
S4	Atliekami fiziniai pratimai
S5	Atsigavimas atsistojus
S6	Atsigavimas atsisėdus

Tyrimui išskirti 8 fiziniai pratimai (4 žemo intensyvumo ir 4 aukšto intensyvumo). Atliekami pratimai ir jų kiekis aprašyti 14 lentelėje. Šiuo atveju nėra vertinamas laikas treniruotės metu. Priklausomai nuo žmogaus fiziologijos ir fizinio parengtumo pratimai gali būti atliekami greičiau arba lėčiau.

14 lentelė. Treniruotės metu atliekami fiziniai pratimai ir jų kiekis

Nr.	Pratimo pavadinimas	Intensyvumas	Kiekis
1	Pritūpimai	mažas	15 vnt
2	Atsistojimai iš sėdimos padėties	mažas	15 vnt
3	Įtūpstai atgal	mažas	po 8 vnt kiekviena koja
4	Įtūpstai į šoną	mažas	po 8 vnt kiekviena koja
5	Bėgimas aukštai keliant kelius	didelis	po 8 vnt kiekviena koja
6	Pašokimas iš pritūpimo	didelis	15 vnt
7	„Žvaigždės šuolis“	didelis	15 vnt
8	„Čiuožėjo šuolis“	didelis	po 8 vnt kiekviena koja

Taikant eksperimentą, aprašytą 14 lentelėje, ir duomenų priklausomybę nuo treniruotės intensyvumo reikėtų atkreipti dėmesį į žmogaus fizinį parengtumą.

4.1.2. Atletų EKG signalų ir R-R intervalų registravimas

Atletų treniruotės protokolas buvo sudarytas iš penkių dalių: ramybės būseną (prieš treniruotę), žemo intensyvumo pratimai, poilsis, aukšto intensyvumo pratimai ir atsigavimas. Čia būsenos išsidėsčiusios tokiu eiliškumu: B1 – ramybė, kuri registruojama prieš prasidedant treniruotei; B2 – atliekant mažo intensyvumo pratimus (pritūpimai); B3 – poilsis po pirmųjų pratimų; B4 – atliekant aukšto intensyvumo pratimus (pritūpimai su šuoliu); B5 – atsigavimas po visos treniruotės. Būsenų eiliškumas su trukmėmis pateikti 15 lentelėje.

15 lentelė. Treniruotės metu atliekami fiziniai pratimai ir jų trukmė

Būsenos pav.	Aprašymas	Trukmė
B1	Ramybė prieš treniruotę	1 min
B2	Mažo intensyvumo pratimai	1 min
B3	Poilsis	1 min 30 sek
B4	Aukšto intensyvumo pratimai	30 sek
B5	Atsigavimas	3 min

Šiuo atveju EKG yra registruojama nepertraukiamai ir visos būsenos eina viena po kitos (be pertraukų). 6 atletai yra gero fizinio parengtumo ir 19–23 metų amžiaus. Iš viso registruojamo EKG signalo trukmė yra apie 6 min. 30 sek.

4.1.3. Skirtingu paros metu atliekami eksperimentai

Tiesinei ŠRV analizei bei nuovargio nustatymo tyrimui naudojamos elektrokardiogramos buvo registruojamos skirtingu paros metu, tiek prieš treniruotę, tiek po jos. Tyrimams buvo naudojami 60 skirtingų dienų elektrokardiogramų duomenys (60 sek. trukmės). Du kartus per dieną (ryte ir vakare) atliekami skirtingi fiziniai pratimai (4 mažo intensyvumo: pritūpimai, atsistojimai iš sėdimos padėties, įtūpstai atgal ir įtūpstai į šoną ir 4 didelio intensyvumo: bėgimas aukštai keliant kelius, pritūpimas su pašokimu, „Žvaigždės šuolis“, „Čiuožiko šuolis“). Visi pratimai atliekami iš eilės (po 15–16 kartų) padarant po 15 sekundžių pertrauką tarp kiekvienos serijos. Atliekami tie patys pratimai, kurie aprašyti 4.1.1 skyriuje 14 lent. Bendra treniruotės trukmė neregistruojama, bet trunka apie 6 min. EKG signalų registravimo būsenos ir jų aprašymai pateikti 16 lent.

16 lentelė. Skirtingu paros metu registruojamos elektrokardiogramos

Būsenos pav.	Aprašymas	Trukmė
A1	Ryte prieš treniruotę	60 sek.
A2	Ryte po treniruotės	60 sek.
A3	Vakare prieš treniruotę	60 sek.
A4	Vakare po treniruotės	60 sek.

Išsami informacija apie tiriamuosius asmenis, jų fiziologinį nuovargį bei dienos veiklas yra pateikta Priedas 7 priede. Pastaba: šioje dalyje svarbiausi duomenys yra

EKG signalai, registruoti būsenose, kurios aprašytos 16 lent. Treniruotės metu registruotos elektrokardiogramos nėra naudojamos ar analizuojamos šiame darbe.

4.1.4. Papildomi eksperimentai

Iš elektrokardiogramos signalo fizinio nuovargio atsiradimo momentą pastebėti yra sunku. Taikomi įvairūs matematiniai metodai (šiam darbe aprašytos ir realizuotos tiesinė ir netiesinė ŠRV analizės), tačiau dažniausiai nuovargis nustatomas eksperimentų metu stebint ŠRV parametrų pokyčius. Tam buvo atliktas papildomas eksperimentas, kai keturi skirtingo intensyvumo pratimai buvo atliekami vienas po kito su 15 sek. pertraukomis. Kiekvienas pratimas buvo atliekamas 13 sesijų po mažiausiai 10 kartų arba ne trumpiau nei 60 sek. Savijauta skirstoma į tris kategorijas: NF – nėra nuovargio; JF – jaučiamas nedidelis nuovargis; DN – jaučiamas didelis nuovargis. Tiriamojo asmens savijauta kiekvienos sesijos metu atliekant skirtingus pratimus aprašyti 17 lent.

17 lentelė. Pratimų sesijos ir tiriamo asmens savijauta (nuovargis)

Pav.	„Čiuožiko šuolis“		„Negyvas vabalas“		Pritūpimas		Ėjimas	
	Sesij. nr.	Kiekis (vnt)	Savijauta	Kiekis (vnt)	Savijauta	Kiekis (vnt)	Savijauta	Laikas (sek)
1	14	NF	12	NF	10	NF	60	NF
2	14	NF	12	JF	10	NF	62	NF
3	14	NF	12	JF	10	NF	60	NF
4	12	NF	12	JF	10	JF	62	NF
5	12	JF	10	JF	10	JF	63	NF
6	10	JF	10	JF	10	JF	60	NF
7	12	JF	10	JF	10	JF	60	NF
8	12	JF	10	JF	10	JF	61	NF
9	12	JF	10	JF	10	DN	60	NF
10	10	DN	10	JF	10	DN	63	JF
11	10	DN	10	JF	10	DN	60	JF
12	10	DN	10	DN	10	DN	60	JF
13	10	DN	10	DN	10	DN	60	JF

Taip pat EKG signalai registruoti įvairiose kitose būsenose, pvz., be sustojimo ir greitai keičiant fizinius pratimus bei jų intensyvumą. Nors duomenų kiekis yra didesnis nei aprašytas šiame darbe, papildomų išvalgų apie filtravimo algoritmų parinkimą, nuovargį, tiriamųjų savijautą, fizinį parengtumą ir pan. nustatyti nepavyko. Todėl šiame darbe kitos duomenų imtys nėra aprašytos.


4.2. Nuovargio vertinimas naudojant ŠRV analizę

Prieš skaičiuojant ŠRV ir vertinant nuovargį svarbu tinkamai apdoroti R-R intervalų sekas. 2.2.3 poskyryje aprašomi galimi artefaktai (trūkstanta arba perteklinė reikšmės) ir jų pašalinimo metodai (medianinis, standartinio nuokrypio ir procentinis filtrai). Šio tyrimo metu buvo naudojami dviejų tipų eksperimentiniai duomenys: ilgos treniruotės sesija kelių skirtingų atletų, įvertinant poilsio ir atsigavimo periodus, bei daug vienas po kito registruojamų trumpų pratimų R-R intervalai. Skaičiavimai

atliekami naudojant Kubios HRV (<https://www.kubios.com/hrv-premium/>) duomenų apdorojimo programą.

4.2.1. R-R intervalų artefaktų pašalinimas

Kaip buvo minėta ankstesniuose skyriuose, ŠRV analizė remiasi R-R intervalų paieška ir jų tyrimu. Prieš duomenis naudojant įžvalgoms apie žmogaus fizinį parengtumą ar fizinį nuovargį, atsiradusį treniruotės metu, svarbu, kad R-R intervalai būtų tiksliai apskaičiuoti, t. y. nebūtų artefaktų (galimus artefaktų aprašymus žr. 2.2.3 skyr.). Šiame skyriuje analizuojami atletų duomenys (aprašymas pateiktas 4.1.2 skyr.). 43 pav. pateiktas pavyzdys, kaip atrodo treniruotės metu EKG signalo spektrograma ir R-R intervalų seka skirtingose būsenose (daugiau pavyzdžių pateikta Priedas 6 priede). Nesunku pastebėti, kad daugiausia artefaktų atsiranda tada, kai atliekami aukšto intensyvumo fiziniai pratimai, o mažiausiai – ramybės būsenoje arba atsigavimo metu. Taip yra todėl, kad skiriasi elektrokardiogramos triukšmo lygis, kuris aiškiai matomas ir iš spektrogramos. Triukšmas daugiausia atsiranda dėl raumenų susitraukimų, elektrodų atlaisvėjimo ir pan. Be to, iš 43 pav. (a) dalies matomi aiškūs R-R intervalų svyravimai. Kuo sudėtingesnis atliekamas pratimas, tuo įgyjamos mažesnės intervalų reikšmės, kas parodo, kad širdis dirba stipriau ir greičiau. Dažniausiai širdis į apkrovą sureaguoja ne iš karto, todėl galima pastebėti, kad R-R intervalų kreivė pradeda judėti žemyn ne iš karto. Tuo tarpu, po aukšto intensyvumo pratimų atsigavimas trunka ilgiau, kol širdis sugrįžta į pradinę būseną.



43 pav. R-R intervalai treniruotės metu skirtingose būsenose: (a) R-R intervalų artefaktų pašalinimo pavyzdys, (b) EKG spektrograma skirtingose būsenose.

R-R intervalų artefaktų pašalinimo metodų parinkimo tyrime buvo naudojami atletų treniruotės duomenys. Gautų rezultatų pavyzdžiai pateikti 18 lent. (šeši sportininkai, kurie identifikuojami pagal raides nuo A iki F). Atletai (vienas po kito be pertraukos) atliko pritūpimus kaip žemo intensyvumo pratimus ir pritūpimus su šuoliu

– aukšto intensyvumo. Filtravimo rezultatai gauti vertinant visą treniruotės trukmę (visas 5 būsenas). Tyrime buvo naudojami visi R-R intervalų klaidų aptikimo algoritmai bei spline interpoliacijos metodas tų klaidų ištaisymui. Pastebėta, kad naudojant visų trijų artefaktų aptikimo metodų junginį aptinkama ir ištaisoma daugiausia klaidų. Panašu, kad iš analizuojamų trijų metodų daugiausia klaidų aptinka procentinė funkcija, kuri neretu atveju sugeba aptikti tiek pat artefaktų, kiek ir visų funkcijų junginys. Dėl šios priežasties tolimesniuose skaičiavimuose buvo pasirinktas tik šis metodas.

18 lentelė. R-R intervalų ir rastų artefaktų skaičius

Atletas	R-R skaičius	Standartinio nuokrypio filtras (artefaktų skaičius)	Procentinis filtras (artefaktų skaičius)	Medianinis filtras (artefaktų skaičius)	Visų trijų filtrų junginys (artefaktų skaičius)
A	697	10	61	17	63
B	735	4	34	4	34
C	812	2	44	0	44
D	879	11	36	14	36
E	756	14	59	15	60
F	877	1	10	0	10


4.2.2. ŠRV tiesinė analizė

Tiesiniai širdies ritmo variabilumo parametrai aprašyti 1.2.1 poskyryje, kuriame išskiriamos dvi pagrindinės grupės: laiko skalės ir dažnių skalės parametrai.

Šiame tyrime naudojami duomenys aprašyti 4.1.3 skyr. Gautoms elektrokardiogramoms buvo rasti R-R intervalai bei apskaičiuoti tiesiniai ŠRV parametrai. Taip pat atliktas duomenų normavimas pagal (89) formulę. Gautų standartizuotų tiesinių ŠRV parametų pasiskirstymų pupelių diagramos pateiktos 44 pav. Šiose diagramose stačiakampiai žymi konkrečią pupelę sudarančių duomenų vidurkį, o pliusas vaizduoja bendros duomenų imties vidurkį.

Iš 44 pav. diagramų nesunku pastebėti, kad bet kurio ŠRV parametro reikšmių pasiskirstymas labai skiriasi tarp būsenų A1 ir A2 bei A3 ir A4, t. y. nuovargį identifikuoti treniruotės metu ar po jos yra nesudėtinga. Tuo tarpu, dienos nuovargis (tarp būsenų A1 ir A3) išryškėja labai nežymiai, todėl reikalinga papildoma analizė. Būsenose A1 ir A3 ŠRV parametų statistikos ir koreliacijos pateiktos 19 lent. Lentelėje μ žymi reikšmių vidurkį, o σ – standartinį nuokrypį.

Iš 19 lentelėje gautų rezultatų galima spręsti, jog nėra statistškai reikšmingos koreliacijos tarp būsenų A1 ir A3 tiesinių ŠRV parametų reikšmių (išskyrus vidurkį \overline{RR}), nes $p > 0,05 = \alpha$. Galima daryti išvadą, kad naudojant tiesinius ŠRV parametrus galima identifikuoti momentinį fizinį nuovargį, tačiau norint nustatyti fiziologinį nuovargį informacijos nepakanka. Tam reikalingi tolimesni tyrimai ir sudėtingesnės metodikos.




44 pav. Pupelių diagramos tiesiniams ŠRV parametrams skirtingose būsenose (A1, A2, A3, A4)

19 lentelė. Būsenų A1 ir A3 ŠRV parametrų statistikos

ŠRV param.	Matavimo vnt.	A1 ($\mu \pm \sigma$)	A3 ($\mu \pm \sigma$)	p reikšmė (dvipusė su $\alpha = 0,05$)	Pearsono koreliacijos koeficientas
\overline{RR}	sekundė	0,8502±0,0747	0,8763±0,0926	0,0000	0,5898
$SDRR$	sekundė	0,0867±0,0495	0,0994±0,0610	0,1083	-0,2094
$RMSSD$	sekundė	0,0530±0,0342	0,0597±0,0406	0,4844	-0,0920
$SDSD$	sekundė	0,0742±0,0402	0,0829±0,0488	0,1075	-0,2099
CV	%	10,3524±6,235	11,3603±6,939	0,0643	-0,2403
LF_{norm}	-	0,7585±0,1748	0,7092±0,2386	0,2685	0,1452
HF_{norm}	-	0,2415±0,1748	0,2908±0,2386	0,2685	0,1452

4.2.3. Nuovargio vertinimas naudojant Poincare diagramas

Ankstesniuose poskyriuose buvo parodyta, kad R-R intervalų filtravimo metodų parinkimas turi įtakos dažnių ir laiko skalės tiesinės ŠRV analizės rezultatams. Siekiant išvengti rezultatų interpretavimo klaidų, netiesinėje Poincare analizėje naudojami jau filtruoti R-R intervalų duomenys.



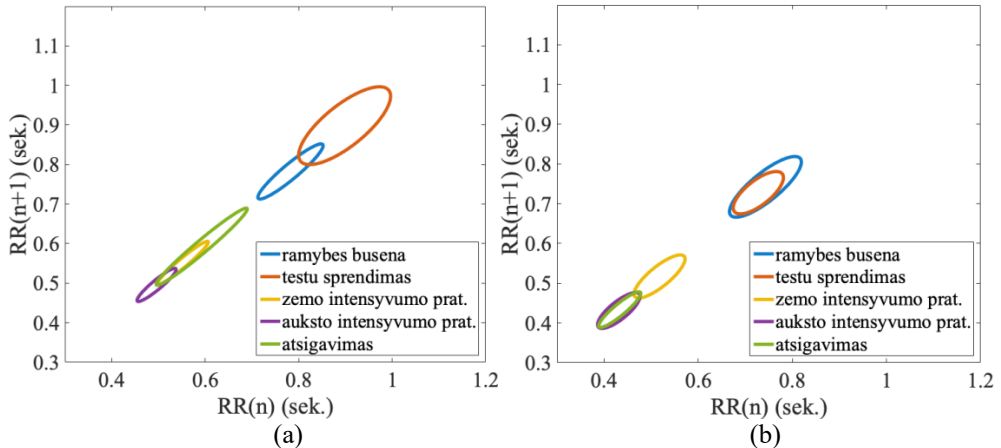
45 pav. Poincare diagramos pavyzdys poilsio metu

Poincare diagramos pavyzdys pateiktas 45 pav., kuriame vaizduojamas širdies variabilumas treniruotės metu (šiuo konkrečiu atveju vaizduojami duomenys poilsio būsenos metu). Treniruotės intensyvumas gali būti matomas brėžinyje iš elipsės pozicijos, formos ir duomenų išsibarstymo. Kuo gaunama apvalesnė (plokštesnė) elipsė, tuo širdies variabilumas yra mažesnis, o tai gali būti prastesnės širdies būsenos rodiklis. Parametrai $SD1$ ir $SD2$ nurodo elipsės formą ir R-R intervalų išsibarstymą. 20 lent. aprašoma širdies variabilumo pokyčiai skirtingose treniruotės būsenose (B1, B2, B3, B4, B5). Matuojami parametrai išreikšti sekundėmis. Būseną B1 parodo gerą širdies darbą, kai duomenų sklaida yra didelė. Tai reiškia, kad širdies variabilumas yra

didelis. Panašūs rezultatai matosi ir būsenose B3 ir B5. Tuo tarpu, B2 ir B4 būsenos parodo ribotą širdies variabilumą, o tuo pačiu ir sunkesnį širdies darbą. Poilsio metu pastebimas greitas širdies atsigavimas, o *SDRR* padidėjo ir pasiekė net geresnę reikšmę nei ji buvo prieš treniruotę ($SDRR_1 = 0,086 < 0,142 = SDRR_3$). Tai reiškia, kad po nedidelio intensyvumo pratimų ŠRV grįžo į pradinę būseną. Tačiau po visos treniruotės (atsigavimo metu) *SDRR* parametro reikšmė sumažėjo ir širdies veikla sunkiai atsistatinėjo į pradinę būseną. Toks reiškinys gali būti interpretuojamas kaip nuovargis (žr. 2.2.3).

20 lentelė. Poincare parametrai skirtingose treniruotės būsenose

Būsena	Treniruotės intensyvumas	<i>SD1</i>	<i>SD2</i>	<i>SDRR</i>	<i>RMSSD</i>
B1	Ramybė prieš treniruotę	0,010	0,111	0,086	0,015
B2	Žemo intensyvumo pratimai	0,006	0,064	0,087	0,008
B3	Poilsis	0,017	0,116	0,142	0,024
B4	Aukšto intensyvumo pratimai	0,007	0,088	0,078	0,011
B5	Atsigavimas	0,009	0,131	0,065	0,011



46 pav. Skirtingų būsenų Poincare elipsių pavyzdžiai: (a) reguliariai sportuojančio asmens, (b) asmens, ilgą laiką neturėjusio intensyvios fizinės veiklos

Naudojant netiesinę ŠRV analizę Poincare diagramų pagalba galima atlikti papildomų įžvalgų apie žmogaus fizinį parengtumą, širdies sugebėjimą prisitaikyti prie krūvio intensyvumo ir pan. 46 pav. pateikti keli pavyzdžiai, kur (a) dalyje yra pavaizduotos Poincare elipsės skirtingose būsenose profesionaliai sportuojančio žmogaus, o (b) dalyje – ilgą laiką nesportavusio asmens. Iš diagramų matyti, kad atsiradus net ir nedideliame fiziniam krūviui (atliekant nedidelio intensyvumo fizinius pratimus), nesportuojančio žmogaus elipsės vieta labai greitai pasikeitė, nes staiga sutrumpėjo R-R intervalai. Galima sakyti, kad tai parodo, jog ŠRV yra nedidelis ir širdis nesugeba greitai prisitaikyti prie krūvio. Taip pat per 3 atsigavimo minutes nesportuojančio žmogaus atsigavimo elipsė nepakeitė padėties ir širdis dirbo taip pat, kaip ir atliekant aukšto intensyvumo pratimus. Tuo tarpu, aiškiai matyti, kad reguliariai sportuojančio atsigavimo kreivė, nors ir nepasiekia pradinės (ramybės

būsenos) padėties, pastebimas laipsniškas grįžimas, nes elipsė pakyla į viršų ir yra labai plokščia. Remiantis šiais pastebėjimais galima daryti išvadą, kad ŠRV analizė naudojant Poincare diagramas yra tinkama žmogaus fiziniam parengtumui vertinti (daugiau pavyzdžių žr. Priedas 5 priede).

Norint nustatyti, kaip nuovargis turi įtakos *SDRR* parametro reikšmėms, turėtų būti analizuojami ilgos trukmės EKG signalai ir po R-R intervalų išskyrimo turėtų būti atlikta palyginamoji analizė. Norint tokius duomenis registruoti ir apdoroti reikalingi dideli kompiuterio resursai. Šiame tyrime buvo pasirinkta registruoti trumpus EKG signalus, kai tas pats asmuo tą pačią dieną atliko pratimus vieną po kito (skirtingos sesijos). Kiekvienas pratimas buvo atliekamas 13 sesijų po mažiausiai 10 kartų. *SDRR* parametro svyravimai matomi 21 lentelėje. Kuo mažesnio intensyvumo yra pratimas, tuo įgyjama didesnė *SDRR* parametro reikšmė. Be to, atliekant didelio intensyvumo pratimus, šis parametras turi mažesnę sklaidą (žr. 21 lent.). Naudojant Friedmano testą keliami nulinė hipotezė, kad stulpeliuose esančių duomenų pasiskirstymas yra vienodas ir priešingu atveju – pasiskirstymas nėra vienodas. Šiame tyrimo pavyzdyje skirtingų pratimų *SDRR* parametrai buvo imami kaip skirtingi stulpeliai ir gauta $p < 0.001$ reikšmė leidžia atmesti nulinę hipotezę. Šie rezultatai parodo, kad yra statistiškai reikšmingas skirtumas tarp *SDRR* parametrų reikšmių prie skirtingų fizinių pratimų. Toks statistinis interpretavimas kartu su duomenų imties parinkimo metodais gali būti naudojamas mašininio apsimokymo analizėje kuriant skirtingų pratimų klasifikatorių (Beritelli et al., 2018; Lobo et al., 2016).

21 lentelė. Poincare ir nuovargio parametrų statistinė analizė

Statistika	<i>SDRR</i> reikšmės prie skirtingų pratimų			
	„Negyvas vabalas“	„Čiuožėjo šuolis“	Pritūpimas	Ėjimas
Vidurkis	0,129	0,051	0,062	0,170
Stand. nuokrypis	0,029	0,010	0,025	0,039
p reikšmė	<0,001 (Friedman testas)			
Pirma sesija	0,127	0,040	0,138	0,239
Paskutinė sesija	0,109	0,043	0,052	0,141

Suprantama, nuovargis atsiranda fizinės treniruotės pabaigoje. Kuo intensyvesni pratimai atliekami, tuo nuovargis didesnis ir tuo pačiu apskaičiuojamos mažesnės *SDRR* parametro reikšmės. Pavyzdžiui, vaikščiojant *SDRR* mažėjo lėtai ir šiek tiek užtruko, kol buvo pradedamas jausti nuovargis, bet taip ir nepasiekė pratimų „Negyvas vabalas“ ar „Čiuožėjo šuolis“ parametro reikšmių. 21 lent. galima pastebėti, kad didesnio intensyvumo pratimai paskatina greitesnį nuovargio atsiradimą. Atliekant pratimą „Čiuožėjo šuolis“ *SDRR* parametro reikšmė buvo nedidelė nuo pradžių. Nors apskaičiuota nedidelė variacija, parametro reikšmė niekada nepasiekė tokių reikšmių, kaip „Vaikščiojimo“ pratimo metu. Šie pastebėjimai yra akivaizdūs ir aiškūs dėl pačios žmogaus fiziologijos. Šis tyrimas parodė, kad Poincare metodas tinkamas fiziniam nuovargiui tirti ir analizuoti.


4.3. EKG signalų klasifikavimas identifikuojant nuovargį

Iki šiol tirti ŠRV parametrai ir jų statistinės charakteristikos nepakankamai gerai sugebėjo nustatyti fiziologinį nuovargį, nors fizinis nuovargis buvo pastebimas tiek

palyginus Poincare parametrų reikšmes, tiek vizualiai iš Poincare diagramų. Panašu, kad tolesniam tyrimui ir signalų klasifikavimui ŠRV parametrų neužtenka, todėl šio skyriaus pirmoje dalyje buvo rasti papildomi EKG parametrai bei įvertintos jų statistinės charakteristikos visos imties atžvilgiu. Kitose dalyse atlikta signalų analizė prie skirtingų būsenų A1, A2, A3 ir A4 (būsenų aprašymus žr. 4.2.2 poskyryje). Klasifikavimo uždavinys formuojamas tik naudojant EKG signalus, registruotus ryte ir vakare (būsenos A1 ir A3). Analizuojant 60 dienų elektrokardiogramas iš viso gauti 8 271 matavimai, tarp kurių 4 195 matavimai yra būsenos A1 ir 4 076 – būsenos A3. Atskirų EKG parametrų duomenys sunormuoti naudojant (89) formulę. Visi skaičiavimai atliekami naudojant MATLAB R2015b programą.

4.3.1. EKG signalo parametrų paieška


Kaip ir buvo minėta metodologinėje šio darbo dalyje, prieš ieškant EKG parametrų reikšmių, duomenys yra filtruojami naudojant du skirtingus filtrus: DWT aukštos dažnio triukšmų sumažinimui ir BEADS – judesio trendo pašalinimui. Naudojant MTEO algoritmą (žr. 2.2.1 skyr.) buvo apskaičiuotos Q, R, S bangų amplitudės bei rasti QRS kompleksai ir R-R intervalai. Klasifikavimo, arba kitaip – fiziologinio nuovargio identifikavimo, uždavinyje maksimaliam tikslumui pasiekti šių parametrų neužtenka. Tam buvo pasiūlyti MTEO algoritmo papildymai (žr. 2.2.2 skyr.), kurie skirti T bangos amplitudinėms ir intervalinėms reikšmėms apskaičiuoti. Klasifikavimo uždaviniui spręsti buvo pasirinkti tokie EKG parametrai: Q, R, S ir T bangų amplitudinės reikšmės (pažymėtos Qa , Sa , Ra , Ta), R-R (pažymėta RR) ir QRS komplekso intervalų ilgiai (pažymėta QRS), S – T ir D – T intervalai (atitinkamai pažymėti ST ir DT) bei T bangos trukmė (pažymėta $Tint$). Rastų signalo parametrų pavyzdys filtruotame EKG signale pateiktas 47 pav.



47 pav. EKG parametrų paieškos pavyzdys


48 pav. pavaizduoti gautų EKG signalo parametrų pasiskirstymai būsenų A1 ir A3 bei tarpusavio parametrų sklaidos diagramos. Iš šių brėžinių galima pastebėti, kad duomenys turi nemažai išskirčių, todėl anksčiau naudotos pupelių diagramos nebetinka, nes vizualiai atrodo mažos ir tampa neinformatyvios (t. y. sudėtinga palyginti tarpusavyje). Akivaizdu, kad kai kurie EKG parametrai yra labiau koncentruoti ir jų sklaida nedidelė (pvz., Q, S amplitudės ar QRS kompleksų ilgiai), o didesne sklaida pasižymi tokie parametrai, kaip R amplitudė ar R-R intervalas.

Panašu, kad būsenų A1 ir A3 duomenų imtyse tam tikrų parametrų reikšmės labai persidengia. Nemažas persidengimas pastebimas ir iš R-R intervalų histogramos. Tikėtina, kad dėl šios priežasties, ankstesni nuovargio identifikavimo būdai netiko, nes nesugebėjo aptikti reikšmingų skirtumų tarp šių būsenų vertinant tik ŠRV parametrų reikšmes.



48 pav. EKG parametrų histogramos ir tarpusavio duomenų sklaidos diagramos

Duomenų klasifikavimo uždaviniuose labai svarbu tinkamai parinkti analizuojamus signalo parametrus. Kad nuovargio identifikavimo algoritmai dirbtų greičiau, paprastai atmetamos tos charakteristikos, kurios stipriai koreliuoja su kitais parametrais. Dėl šios priežasties apskaičiuoti Pearsono koreliacijos koeficientai bendros duomenų imties (t.y. A1 ir A3 kartu) kiekvienai EKG parametrų porai (žr. 49 pav.). Tiesinę duomenų tarpusavio priklausomybę buvo galima pastebėti ir iš 48 pav. (pvz., vizualiai tai aiškiai matosi tarp parametrų QT ir ST). Nors dalis duomenų turėjo silpną ar vidutinio lygio (žr. 2.5 skyr.) koreliaciją (žr. 49 pav.), kaip ir buvo galima tikėtis, QT ir ST yra tiesiškai priklausomi (Pearsono koreliacijos koeficientas siekia net 0,98), todėl bent vienas iš šių parametrų turės būti pašalintas iš galutinio klasifikavimo modelio. Taip pat galima pastebėti stiprų tiesinį ryšį tarp $Tint$ ir QT ar ST parametrų reikšmių (Pearsono koreliacijos koeficientas $>0,8$). Kol kas sudėtinga pasakyti, kurie parametrai turi didesnę reikšmę klasifikavimo uždavinyje, o kuriuos galima pašalinti. Norint neprarasti skaičiavimo tikslumo, pradiniam klasifikavimo etape buvo naudojamos visos rastos EKG charakteristikos (9 EKG parametrai).



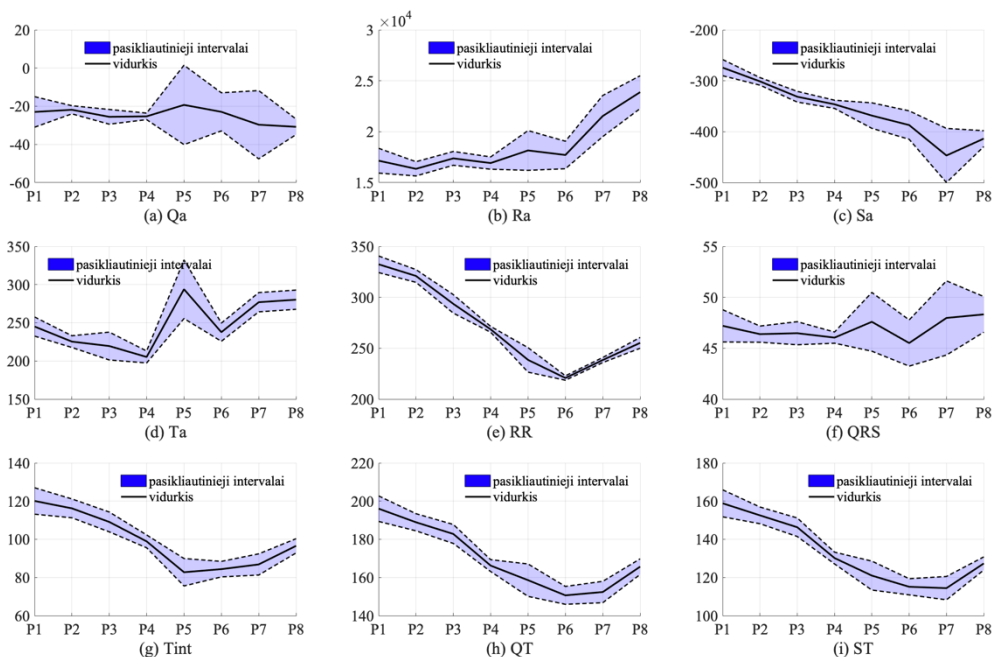
49 pav. EKG parametrų Pearsono koreliacijos koeficientai

Be to, šio tyrimo metu atlikta papildoma analizė, susijusi su nuovargiu pačios treniruotės metu. Buvo atliekami 8 skirtingi fiziniai pratimai (po 15 arba 16 kartų, priklausomai nuo pobūdžio) tarp jų padarant po 15 s pertrauką. Gautų EKG parametrų duomenų pagrindinės statistinės charakteristikos (vidurkis ir standartinis nuokrypis) pateiktos 22 lent., kurioje P1, P2, ..., P8 žymi skirtingus pratimus (P1 – pritūpimai, P2 – atsistojimai iš sėdimos padėties, P3 – įtūpstai atgal, P4 – įtūpstai į šoną, P5 – bėgimas aukštai keliant kelius, P6 – pašokimas su pritūpimu, P7 – „Žvaigždės šuolis“, P8 – „Čiuožiko šuolis“, vizualizacijas žr. 35 pav.). 22 lent. Galima matyti širdies darbą skirtingų pratimų metu (pvz., RR intervalų vidutinės trukmės pokyčiai parodo, kaip greitai plaka žmogaus širdis). Analogiški rezultatai yra pavaizduoti ir 50 pav.

22 lentelė. EKG parametrų reikšmių vidurkiai ir dispersijos prie skirtingų fizinių pratimų vienos treniruotės metu

Pratimas	Qa ($\mu \pm \sigma$)	Ra ($\mu \pm \sigma$)	Sa ($\mu \pm \sigma$)	Ta ($\mu \pm \sigma$)	RR ($\mu \pm \sigma$)	QRS ($\mu \pm \sigma$)	Tint ($\mu \pm \sigma$)	Ciklų skaičius
P1	-16,76 ±12,92	5248,6 ±957,07	-81,12 ±28,98	87,57 ±40,23	0,51 ±0,05	0,09 ±0,01	0,2 ±0,07	51 per 27,07sek.
P2	-11,43 ±35,9	4691,52 ±928,19	-80,54 ±39,51	126,5 ±26,19	0,48 ±0,03	0,09 ±0,02	0,2 ±0,03	63 per 31,4sek.
P3	-14,31 ±9,56	4617,4 ±952,04	-103,87 ±29,41	129,43 ±27,09	0,45 ±0,02	0,09 ±0,01	0,18 ±0,04	64 per 30,16sek.
P4	-14,75 ±11,73	5142,71 ±1045,8	-108,89 ±32,09	143,28 ±31,25	0,44 ±0,02	0,09 ±0,01	0,17 ±0,03	87 per 40,04sek.
P5	-9,40 ±52,84	5658,53 ±2357,51	-191,48 ±91,93	200,84 ±63,6	0,43 ±0,02	0,10 ±0,03	0,14 ±0,04	31 per 14,66sek.

P6	1,96 ±57,02	7556,39 ±2022,41	-152,96 ±73,71	168,48 ±56,25	0,38 ±0,02	0,10 ±0,03	0,12 ±0,04	60 per 23,8sek.
P7	-47,03 ±183,57	7239,91 ±2682,82	-196,16 ±173,8	220,54 ±100,89	0,38 ±0,05	0,11 ±0,03	0,12 ±0,06	33 per 14sek.
P8	-37,32 ±102,38	6725,88 ±2293,03	-168,7 ±97,33	206,98 ±71,76	0,39 ±0,01	0,09 ±0,02	0,12 ±0,04	48 per 20sek.



50 pav. EKG parametrų statistikų pavyzdys skirtingų fizinių pratimų metu

50 pav. galima matyti, kad didesnio intensyvumo pratimų (P5, P6, P5 ir P8) metu apskaičiuoti parametrai *Qa* ir *QRS* turi didesnę sklaidą, nors vidurkiai išlieka panašūs kaip ir žemo intensyvumo fizinių pratimų metu (P1, P2, P3 ir P4). Taip pat matomas intervalinių (*RR*, *Tint*, *QT*, *ST*) parametrų reikšmių mažėjimas beveik visos treniruotės metu, kas gali rodyti vis didėjantį krūvį ir greitėjantį širdies darbą. P7 ir P8 pratimai, nors ir intensyvūs, panašiu, kad nėra labai sudėtingi ir nereikalauja didelių pastangų juos atliekančiam žmogui šiame pavyzdyje (intervalinių parametrų reikšmės padidėja). Reikėtų atkreipti dėmesį, kad šiame paveiksle pateiktas tik vieno žmogaus EKG parametrų statistikų pavyzdys skirtingų fizinių pratimų metu. Priklausomai nuo fiziologijos ar fizinio parengtumo EKG parametrų kitimo tendencijos gali svyruoti.

4.3.2. Mašininio mokymosi metodų taikymas nuovargiui identifikuoti

Ankstesniuose skyriuose buvo analizuojamas momentinis fizinis nuovargis, kuris atsiranda treniruotės metu arba iš karto po jos. Buvo nustatyta, kad tokiam uždaviniui spręsti pakanka tiesinės ŠRV analizės, o naudojant netiesinę ŠRV analizę galima atlikti papildomų pastebėjimų apie tiriamojo asmens fizinį parengtumą, širdies gebėjimą prisitaikyti prie fizinės apkrovos. Tuo tarpu, bendro ar fiziologinio


nuovargio identifikavimas yra daug sudėtingesnis uždavinys ir vien ŠRV analizės nebeužtenka.

4.1.3 skyr. aprašytų eksperimentų tiriamos būsenos A1 ir A3 nusako asmens savijautą ryte ir vakare. Paprastai, bendras ar fiziologinis nuovargis atsiranda po dienos darbų vakare, tad galima daryti prielaidą, kad A1 būseną nusako tiriamojo savijautą, kai nuovargio nėra, o A3 – kai yra nuovargis. 23 lent. pateikti būsenų A1 ir A3 EKG parametrų Pearsono koreliacijos koeficientai. Galima pastebėti, kad nėra stiprios koreliacijos analizuojant visus aprašytus EKG parametrus tarp atskirų būsenų. Preliminariai galima tikėtis, kad naudojant visus EKG parametrus bus gautas geriausias klasifikavimo modelis. Klasifikavimui į A1 ir A3 duomenų grupes buvo naudojami ML algoritmai.

23 lentelė. Pearsono koreliacijos koeficientai tarp būsenų A1 ir A3 EKG parametrų

Būsena	Qa	Ra	Sa	Ta	RR	QRS	$Tint$	QT	ST
A1 ir A3	0,242	0,071	0,180	0,293	0,354	0,276	0,190	0,376	0,323

Šiame darbe buvo tiriami įvairūs mašininio mokymosi algoritmai su skirtingais sudėtingumo lygiais bei įvairiomis hiperparametrų reikšmėmis. 51 pav. ir 24 lent. pateikta keletas iš jų. 51 pav. vaizduojamos ML algoritmų tikslumų stačiakampės diagramos, atlikus 100 pakartotinių apmokymų tai pačiai duomenų imčiai. Visais atvejais kryžminei validacijai pasirinktas duomenų imties išskaidymas į grupes (70 % apmokymui ir 30 % testavimui) ir apskaičiuotos metodų tikslumo bendros charakteristikos: $tikslumas_{validacijos}$ (išreikštas procentais), $F1_{vertis}$, MCC . Tyrimo metu gauti metodų parametrai pateikti Priedas 8 priede. Pradiniam individualiam (vieno žmogaus) nuovargio vertinimo modeliui sudaryti naudojami visi ankstesniuose skyriuose aprašyti EKG parametrai (9 charakteristikos). Šioje tyrimų dalyje nebuvo analizuojami bei testuojami neprižiūrimo mokymosi algoritmai (tokie kaip NN ar klasterizavimas), nes EKG signalai registruoti ryte ar vakare yra atskirti atitinkamais pažymėjimais, t. y. tiksliai galima pasakyti, kurie matavimai turėtų rodyti nuovargį, o kurie ne. Dėl to šiuo atveju, neprižiūrimo mokymosi metodus naudoti yra netikslinga.




51 pav. Skirtingų ML algoritmų tikslumų stačiakampės diagramos

24 lentelė. Skirtingų mašininio mokymosi algoritmų vidutiniai tikslumai


Metodas	$tikslumas_{validacijos} \cdot 100 \%$	$F1_{\text{vertis}}$	MCC
KNN	94,19 %	0,94	0,87
LDA	76,82 %	0,75	0,46
Kvadratinis SVM	90,89 %	0,91	0,82
DT	92,31 %	0,92	0,83
RF (nuoseklus)	95,08 %	0,95	0,90

24 lent. ir 51 pav. rodo, kad klasifikavimas į A1 ir A3 duomenų grupes (būsenas) geriausiai atliekamas sudarant sprendimų medžių modelį (DT), artimiausių kaimynų modelį (KNN) ar atsitiktinį mišką (RF). Didžiausias tikslumas buvo pasiektas su RF, kur atskirų medžių skaičius yra 30, o maksimalus išskaidymų skaičius 20. Visais atvejais naudojama 10 kartų kryžminė validacija. Atsižvelgiant į 24 lentelėje aprašytus rezultatus detalesnei analizei buvo pasirinktas atsitiktinis miškas (RF), kurio apskaičiuotas validacijos tikslumas vidutiniškai lygus 95 %.

Atsitiktinis miškas (RF) yra metodas, susidedantis iš tam tikro skaičiaus atskirų sprendimų medžių (DT). Kiekviename medyje visi mazgai turi apibrėžtas sąlygas, kurios nurodo, pagal kokias ypatybes duomenys išskaidomi į du atskirus rinkinius. Panašaus atsako reikšmės patenka į tą patį duomenų rinkinį. Atitinkamo požymio svarba yra apskaičiuojama stebint, kaip kiekvienas kintamasis (šiuo atveju EKG parametras) sumažina entropiją medyje.



(a)



(b)

52 pav. Svarbiausių EKG parametų nustatymas klasifikuojant būsenas A1 ir A3: (a) EKG parametrai ir RF modelio tikslumas; (b) RF modelio kaupiamojo tikslumo kreivė

Pasirinkus tikslumo slenkstį 0,80 išskirti keturi pagrindiniai EKG signalo parametrai *Sa*, *Ra*, *Ta* ir *QT*, kurie laikomi svarbiausiais klasifikuojant A1 ir A3 būsenas (t. y. identifikuojant nuovargį). Šie EKG parametrai naudojami tolimesniame RF modelio sudaryme kaip įvesties duomenys. Taip pat, remiantis šia informacija, galima teigti, kad T banga yra reikšminga charakteristika fiziologinio nuovargio identifikavimo procese.

Kaip ir dauguma ML algoritmų, taip ir RF turi nemažai parametų, kurių reikšmės reikia apibrėžti iš anksto. Nėra vienos bendros taisyklės, kuri nuspręstų,

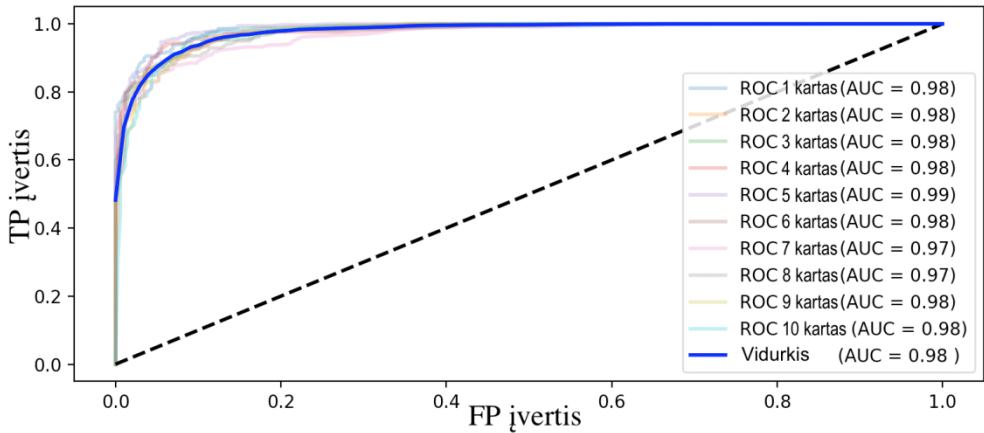
kuris parametru rinkinys yra labiausiai tinkantis analizuojamiems duomenims. Tam, kad nereikėtų atlikti daugybės testavimų prie skirtingų klasifikatoriaus parametru reikšmių, buvo sudaryta atsitiktinė tinklelio paieška (atsitiktinai parenkamos parametru reikšmių kombinacijos fiksuotą skaičių kartų). Šiuo atveju buvo iteruojama 1 000 kartų naudojant mokymosi duomenų imtį ir ieškoma klasifikatoriaus parametro reikšmių, su kuriomis randama didžiausia vertės funkcijos reikšmė (tikslumas arba teisingų prognozių skaičiaus ir įvesties duomenų skaičiaus santykis). Rastos RF klasifikatoriaus parametru reikšmės pateiktos 25 lent.

25 lentelė. Geriausios rastos RF modelio parametru reikšmės

Parametras	Reikšmė
'maks_gylis' – didžiausias galimas vieno medžio aukštis	7
'min_elementu_sk' – mazgai, turintys mažiau elementų nėra išskaidomi	40
'maks_pozymiu' – apibrėžia didžiausią skaičių charakteristikų, kurios aprašo kiekvieną išskaidymą	2
'min_elementu_lape' – mažiausias galimas lapo elementu skaičius	7
'n_medziu' – RF modelio medziu skaičius	40
'mokymosi_ivertis' – nustato kiekvieno naujai pridedamo medžio įtaką galutiniam rezultatui	0.15

Sudaromas atsitiktinio miško modelis naudojant 25 lentelėje nurodytas parametru reikšmes. Gautas modelio vidutinis tikslumas 0,945.

Modelio apmokymui naudojama k – kartų kryžminė validacija. Šiuo metodu duomenys suskirstomi į k skirtingų, bet vienodo dydžio pogrupių. Po to kiekvienas pogrupis naudojamas testavimo etape. Likę pogrupiai kombinuojami mokymo etape klasifikatoriaus mokymuisi. Turima omenyje, kad naudojama ta pati mokymuisi skirta duomenų imtis, kuri k kartų papildomai išskaidoma į mokymosi ir testavimo duomenų imtis. Būsenų A1 ir A3 klasifikavimui naudojama 10-ties kartų kryžminė validacija RF modeliui. Kryžminės validacijos rezultatus patogiau atvaizduoti atskiramis ROC kreivėmis (kiekvienam k atskirai) bei, apskaičiavus reikšmių vidurkius, atvaizduojama vidurkių ROC kreivė. Naudojant šias kreives plokštumoje atvaizduojami TP įverčiai y ašyje (arba pd , reiškia, kad teisingai suklasifikuotos būsenos A3 reikšmės) ir FP įverčiai x ašyje (arba pf , t. y. prognozuojama būseną A3, o iš tiesų buvo A1) skirtinguose diskriminantinių sprendimų priėmimo lenksčiuose. Gauti rezultatai pateikti 53 pav. Čia AUC yra plotas po ROC kreive. Šis plotas aprašo tikimybę, kad klasifikatorius priskirs atsitiktinai pasirinktą A3 klasės element geriau nei atsitiktinai pasirinktą klasės A1 elementą.




53 pav. 10 kartų kryžminė validacija RF modeliui.

Remiantis 53 pav. gautais validacijos rezultatais galime teigti, kad tikėtinas klasifikavimo tikslumas yra apie 98 %. Turint sudarytą RF modelį galima pareiti prie testavimo. Tam buvo palikta 30 % pradinės duomenų imties. Modelio vertinimui buvo pasirinktos šios charakteristikos: preciziškumas (p), jautrumas (pd) ir $F1_{i\text{vertis}}$ (išraiškas žr. 6 lent.). Testavimo rezultatai pateikti 26 lent.

26 lentelė. Sudaryto RF modelio testavimo rezultatai


Klasė	Preciziškumas, p	Jautrumas, pd	$F1_{i\text{vertis}}$	Imties dydis
A1	0,94	0,95	0,95	1498
A3	0,95	0,94	0,94	1435

Gautas modelio testavimo tikslumas yra 0,945, kuris yra šiek tiek mažesnis nei tikėtasi (validacijos tikslumas buvo apie 98 %), tačiau modelis pakankamai gerai geba klasifikuoti ir atskirti tiek A1, tiek A3 būsenas. Šie rezultatai taip pat pateikti maišaties matricoje (žr. 54 pav.).



54 pav. Būsenų A1 ir A3 maišaties matrica

Slenkstis preciziškumui p įvertinti skiriasi nuo slenksčio jautrumui pd įvertinti. ROC ir P-R kreivės testavimo duomenims pateiktos 55 pav. Kiekvienas šių kreivių taškas nusako maišaties matricos vertes prie skirtingų sprendimo priėmimo slenksčių. Jei ROC kreivėje pasirinktame slenksčių vertę mažesnę, gausime pd įverčio didesnę reikšmę, t. y. A3 klasės elementai bus klasifikuojami tiksliau, tačiau tai tuo pačiu sumažins A1 klasės klasifikavimo tikslumą.



55 pav. RF modelio testavimas: (a) ROC kreivė, (b) P-R kreivė

Atsitiktinės imties faktorius yra vienas iš svarbiausių įverčių tiriant modelio tinkamumą. Buvo apskaičiuotas $kappa = 0,886$, kuris reiškia, kad modelio patikimumas yra „labai geras“ (žr. 1.3 skyr.). Galima daryti išvadą, kad gautas modelis pakankamai gerai prognozuoja tiek A1, tiek A3 būsenas, t. y. geba iš EKG signalo parametrų reikšmių nustatyti, ar žmogus turi nuovargiui būdingų charakteristikų, ar ne. Sudarytas RF modelis susideda iš 40 sprendimų medžių, kurių aukštis ne didesnis nei 7. Keli pavyzdžiai pateikti Priedas 9 priede.

Interpretuojant rezultatus bei gautas paklaidas, reikėtų atsižvelgti ir į analizuojamus duomenis, kai EKG signalai buvo registruoti ryte ir vakare nepriklausomai nuo to, ar žmogus jautė nuovargį, ar ne (protokolą apie žmogaus savijautą bei dienos užimtumą žr. Priedas 7 priede).

Tyrimo metu buvo sudaryti klasifikavimo modeliai prieš tai analizuojamiems duomenims pritaikius PCA algoritmą, tačiau gautas tikslumas buvo gerokai mažesnis, palyginus su šiame skyriuje aptartais modeliais. Tikėtina, kad tai turėjo įtakos naudotų EKG parametrų nedidelė tarpusavio priklausomybė (žr. 49 pav.). Be to, detaliau ištyrus kai kuriuos kitus ML metodus (tokius kaip KNN, DT), galima tikėtis panašių klasifikavimo rezultatų.

4.4. Skyriaus išvados

Kintamoje veikloje registruotų fiziologinių signalų artefaktų aptikimas ir korekcija yra svarbus uždavinys analizei ir supratimui, kaip veikia žmogaus kūnas. Šiame darbe aprašomas naujas būdas identifikuoti ir apdoroti signale atsiradusius artefaktus R-R intervalų eilutės duomenims, kurie gali būti naudojami fiziniam nuovargiui identifikuoti.

Šiame darbe tiriamas nuovargis yra išskaidomas į du atskirus tipus: fizinis, atsiradęs intensyvios treniruotės metu, ir fiziologinis, kuris fiksuojamas dienos pabaigoje ar po sudėtingų užduočių atlikimo prie kompiuterio. Lyginant EKG signalus prieš treniruotę ir iš karto po jos, kai kurie pasiūlyti tiesiniai ŠRV parametrai (tokie kaip \overline{RR} , $SDRR$, $SDSD$, CV) išryškino momentinį fizinį nuovargį. Tuo tarpu, nėra statistiškai reikšmingo skirtumo tarp ŠRV tiesinių parametrų, apskaičiuotų ryte ir vakare. Labai tikėtina, kad tam turėjo įtakos persidengiančios skirtingų būsenų RR intervalų reikšmės (žr. 48 pav.).

Netiesinis ŠRV analizės metodas naudojant Poincare diagramas ne tik identifikuoja fizinį nuovargį, tačiau ir leidžia daryti tam tikras prielaidas apie žmogaus fizinį parengtumą ir širdies veiklos galimus sutrikimus. Stebint RR intervalų pokyčius skirtingose būsenose (atliekant skirtingus fizinius pratimus) ir elipsės formą bei poziciją ($RR(n)$, $RR(n+1)$) koordinačių plokštumoje galima išskaidyti pratimus pagal jų intensyvumą. Taip pat pastebėta, kad parametras $SDRR$ yra pakankamai informatyvus nusakant nuovargio pasirodymo greitį. Kuo intensyvesnis pratimas atliekamas, tuo parametro $SDRR$ reikšmė yra mažesnė (pvz., pirmą kartą atliekant „Ėjimo“ pratimą $SDRR_{\text{ėjimas}} = 0,239$, o pirmą kartą atliekant „Čiuožiko šuolį“ – $SDRR_{\text{čiuož.šuoł.}} = 0,040$).

Kadangi ŠRV analizė apsiriboja tiesiniais ar netiesiniais RR intervalų pokyčiais, tai bendrą viso kūno ar fiziologinį nuovargį identifikuoti sunku. Tam buvo atlikta papildoma analizė, kurioje įvertinti ir kiti EKG parametrai (tokie kaip Q, R, S, T amplitudės, QRS kompleksas, T intervalas, QT, ST). Buvo nustatyta, kad iš visų tirtų ML metodų geriausiai bendrą nuovargį identifikuoja atsitiktinis miškas (RF). Naudojant KNN ar DT modelius gautas tikslumas taip pat buvo neblogas (>90%).

Detalesniam tyrimui pasirinktas RF modelis, kuris naudojamas individualiam nuovargio identifikavimo uždaviniui. Tyrimo metu paaiškėjo, kad geriausiai būsenas A1 ir A3 (ryte ir vakare prieš treniruotę) aprašo keturi EKG parametrai: Sa , Ra , Ta , QT , todėl kiti parametrai buvo nenaudojami sudarant galutinį RF modelį. Nustatyta, kad RF hiperparametrų reikšmės, pateiktos 25 lent., didesniu nei 94 % tikslumu geba identifikuoti nuovargį. Šioje dalyje išryškėja T bangos svarba nuovargio vertinimo procese. Net du iš keturių parametrų susiję su T banga (Ta ir QT) įtraukti į galutinį A1 ir A3 klasifikavimo uždavinį ir yra reikšmingi identifikuojant fiziologinį nuovargį, atsiradusį dienos pabaigoje.

IŠVADOS

1. Judesio metu registruoti EKG signalai yra triukšmingi dėl atsiradusių įvairių trikdžių (tokių kaip elektrodo sąlyčio su oda, laidų judėjimo ir pan.) ir pačio judesio pobūdžio. Tyrimo metu nustatyta, kad vieno bendro filtravimo algoritmo tokiems signalams apdoroti nepakanka. Šiame darbe pasiūlyta naudoti dviejų metodų derinį: modifikuotą BEADS algoritmą – žemo dažnio triukšmams (judesio artefaktams) pašalinti ir DWT – aukšto dažnio triukšmams sumažinti.
2. Šiame darbe aprašyta BEADS algoritmo modifikacija skirta judesio metu registruotiems EKG signalams filtruoti. Dėl šio patobulinimo, algoritmo parametrai (tokie kaip f_c) geba prisitaikyti prie skirtingų judesio triukšmų ir sėkmingai juos eliminuoja nepažeidžiant pagrindinių signalo parametrų. Tyrimo metu paaiškėjo, kad alternatyvūs algoritmai, tokie kaip slenkančio vidurkio filtras, kai kurias EKG signalo dalis iškraipo (pvz., T banga atsiduria žemiau izolinijos), o tai apsunkina tolesnę EKG parametrų paiešką. Be to, naudojant modifikuotą BEADS algoritmą neiškraipomos pagrindinės biologinių elektrinių signalų (EKG, EEG, EMG) laiko ar dažnių skalių charakteristikos.
3. Palyginus kelis filtravimo metodus buvo parinktas DWT algoritmas EKG signalo aukšto dažnio triukšmams sumažinti. Naudojant šį algoritmą simuliuotiems EKG signalams su Daubeches „db11“ bangelėmis pašalinami aukšto dažnio triukšmai ir gaunama RMSE paklaida lygi 0,088.
4. EKG parametrų paieškos k – TEO algoritmas papildytas T bangos apskaičiavimu ir rastos kitų EKG parametrų (Ta , $Tint$, QT ar ST) reikšmės. Kadangi šio signalo forma bei parametrų eiliškumas žinomas, papildymai remiasi ekstremumų nustatymu ir nereikalauja didelių skaičiavimo resursų (reikalingų duomenų apdorojimui realiu laiku) bei randa parametrus triukšmingame signale.
5. Atlikus papildomus eksperimentus sudarytas ir aprašytas treniruotės intensyvumo valdymo modelis, leidžiantis sportuojančiam išvengti širdies veiklos sutrikimų, traumų ir pasiekti maksimalių rezultatų (įvertinus QRS , $\dot{S}R$, JT ir kt.). Šis algoritmas įdiegtas į Careware mobilią aplikaciją ir kartu su CardioScout Multi įrenginiu naudojamas profesionaliai sportuojančių žmonių treniruotės metu.
6. Pasiūlyta tiesinė ir netiesinė ŠRV metodika geba identifikuoti fizinių nuovargių treniruotės metu ar po jos. Priklausomai nuo pratimo intensyvumo keičiasi Poincare elipsės forma bei pozicija. Nors sudėtinga išskirti konkrečias parametrų reikšmes, lemiančias nuovargį, tyrimo metu nustatyta, kad Poincare elipsės postūmis žemyn reiškia padidėjusį širdies darbą. Lėtas elipsės atsistatymas į pradinę poziciją gali rodyti stiprų fizinių nuovargių arba prastą fizinių parengtumą.
7. Palyginus įvairius mašininio mokymo metodus ir įvertinus jų tikslumą, pasirinktas atsitiktinio miško algoritmas kaip geriausiai tinkantis fiziologinio nuovargio identifikavimui (tikslumas apie 95 %). Tyrimo metu paaiškėjo, kad geriausiai nuovargį aprašo keturi EKG signalo parametrai: Sa , Ra , Ta , QT . Nustatyta, kad atsitiktinio miško klasifikatorius individualiam nuovargiui identifikuoti susideda iš 40 skirtingų sprendimų medžių, kurių kiekvieno aukštis ne didesnis nei 7.

PRAKTINĖ SVARBA

1. Dalis algoritmų panaudota tarptautiniame projekte ITEA2 Careware – „Electronics Wearable Sport and Health Solutions“ 13034 plėtojamų tyrimų – judesio EKG filtravimas, prisidėta prie treniruotės algoritmo formavimo.
2. Disertacijoje aprašyti tyrimai naudojami programos EUREKA projekte 11169 „Non-intrusive human fatigue assessment (Fatigue)“. Pagrindinis indėlis yra nuovargio vertinimas naudojant ŠRV analizę, klasifikavimas pagal EKG parametrus.
3. Filtravimo algoritmai buvo naudojami struktūrinių fondų projekto „EKG signalo filtravimo ir parametrų skaičiavimo tyrimas“ (inočekiai nr. 01.2.1-MITA-K-824-01-0359) mokslinių tyrimų ir technologinės plėtros įgyvendinimui. Paruošti signalų apdorojimo algoritmai perrašyti iš MATLAB programos į C++.
4. 2021 metų vasarį prasidėjęs naujas projektas Eureka ITEA3 19008 INNO4HEALT (*Stimulate continuous monitoring in personal and physical health*), kuriame naudojamos sportininkų psichofiziologinės būklės vertinimas pagal ŠRV.

LITERATŪRA

1. Akansu, A. N., & Haddad, R. A. (2001). *Multiresolution Signal Decomposition: Transforms, Subbands, and Wavelets* (Bell Communications Research) Hsing, T. Russell
2. AlMahamdy, M., & Riley, H. B. (2014). Performance study of different denoising methods for ECG signals. *Procedia Computer Science*, 37, 325–332. <https://doi.org/10.1016/j.procs.2014.08.048>
3. Aseriskyte, D., Berskiene, K., Korsakas, S., Navickas, Z., Vainoras, A., & Gargasas, L. (2005). Information dimension of the heart function parameters during stress test. *Computers in Cardiology*, 32, 491–493. <https://doi.org/10.1109/CIC.2005.1588144>
4. Ashcleulova, T. V., Kovalyova, O. M., & Demydenko, A. V. (2017). Electrocardiographic Method of Cardiac Function Examination, Technique of ECG Registration and Reading.
5. Ayar, M., & Sabamoniri, S. (2018). An ECG-based feature selection and heartbeat classification model using a hybrid heuristic algorithm. *Informatics in Medicine Unlocked*, 13(May), 167–175. <https://doi.org/10.1016/j.imu.2018.06.002>
6. Azim, T., Jaffar, M. A., & Mirza, A. M. (2014). Fully automated real time fatigue detection of drivers through Fuzzy Expert Systems. *Applied Soft Computing Journal*, 18, 25–38. <https://doi.org/10.1016/j.asoc.2014.01.020>
7. Babu, S., Chandini, M., Lavanya, P., Ganapathy, K., & Vaidehi, V. (2013). Cloud-enabled remote health monitoring system. *2013 International Conference on Recent Trends in Information Technology, ICRTIT 2013*, 702–707. <https://doi.org/10.1109/ICRTIT.2013.6844286>
8. Bar-yam, Y. (2002). Complexity Rising: From Human Beings to Human Civilization, a Complexity Profile 1. *Encyclopedia of Life Support Systems*, 01(December), 1–33. <http://www.necsi.edu/projects/yaneer/Civilization.html>
9. Barker, L. M., & Nussbaum, M. A. (2011). The effects of fatigue on performance in simulated nursing work. *Ergonomics*, 54(9), 815–829. <https://doi.org/10.1080/00140139.2011.597878>
10. Beritelli, F., Capizzi, G., Lo Sciuto, G., Napoli, C., & Woźniak, M. (2018). A novel training method to preserve generalization of RBPNN classifiers applied to ECG signals diagnosis. *Neural Networks*, 108, 331–338. <https://doi.org/10.1016/j.neunet.2018.08.023>
11. Berskiene, K., Lukosevicius, A., Jarusevicius, G., Jurkonis, V., Navickas, Z., Vainoras, A., & Daunoraviciene, A. (2009). Analysis of dynamical interrelations of electrocardiogram parameters. *Elektronika Ir Elektrotechnika*, 7(7), 95–98. <https://doi.org/10.5755/j01.eee.95.7.10055>
12. Bi, Q., Goodman, K. E., Kaminsky, J., & Lessler, J. (2019). What is machine learning? A primer for the epidemiologist. *American Journal of Epidemiology*, 188(12), 2222–2239. <https://doi.org/10.1093/aje/kwz189>
13. Bikulciene, L., Navickas, N., Smidtaite, R., Berskiene, K., Vainoras, A. (2011) The measure of ECG complexity by matrix analysis. *Journal of Applied Electromagnetism*, 13(1), 1–9.
14. Bowes, D., Hall, T., & Gray, D. (2014). DConfusion: A technique to allow cross study performance evaluation of fault prediction studies. *Automated Software Engineering*,

- 21(2), 287–313. <https://doi.org/10.1007/s10515-013-0129-8>
15. Bull, D. R. (2014). *Communicating Pictures: A Course in Image and Video Coding*
 16. Camm, A. J., & Lu, T. (2018). ESC CardioMed - the new electronic ESC Textbook of Cardiovascular Medicine. *European Journal of Preventive Cardiology*, 25(14), 1563–1566. <https://doi.org/10.1177/2047487318791111>
 17. Castaño, F. A., Hernández, A. M., & Soto-Romero, G. (2019). Assessment of artifacts reduction and denoising techniques in Electrocardiographic signals using Ensemble Average-based method. *Computer Methods and Programs in Biomedicine*, 182. <https://doi.org/10.1016/j.cmpb.2019.105034>
 18. Celin, S., & Vasanth, K. (2018). ECG Signal Classification Using Various Machine Learning Techniques. *Journal of Medical Systems*, 42(12), 1–11. <https://doi.org/10.1007/s10916-018-1083-6>
 19. Chandra, R., & Optican, L. M. (1997). Detection, classification, and superposition resolution of action potentials in multiunit single-channel recordings by an on-line real-time neural network. *IEEE Transactions on Biomedical Engineering*, 44(5), 403–412. <https://doi.org/10.1109/10.568916>
 20. Chen, M., Mao, S., & Liu, Y. (2014). Big data: A survey. *Mobile Networks and Applications*, 19(2), 171–209. <https://doi.org/10.1007/s11036-013-0489-0>
 21. Chen, S. W., & Chen, Y. H. (2015). Hardware design and implementation of a wavelet de-noising procedure for medical signal preprocessing. *Sensors (Switzerland)*, 15(10), 26396–26414. <https://doi.org/10.3390/s151026396>
 22. Chen, S., Xu, K., Zheng, X., Li, J., Fan, B., Yao, X., & Li, Z. (2020). Linear and nonlinear analyses of normal and fatigue heart rate variability signals for miners in high-altitude and cold areas. *Computer Methods and Programs in Biomedicine*, 196. <https://doi.org/10.1016/j.cmpb.2020.105667>
 23. Chen, X., Yang, R., Ge, L., Luo, J., & Lv, R. (2017). L’hypnose dans le traitement de la dépression majeure: une analyse de la variabilité du rythme cardiaque. *International Journal of Clinical and Experimental Hypnosis*, 65(1), 52–63. <https://doi.org/10.1080/00207144.2017.1246873>
 24. Chicco, D. (2017). Ten quick tips for machine learning in computational biology. *BioData Mining*, 10(1), 1–17. <https://doi.org/10.1186/s13040-017-0155-3>
 25. Choi, J. H., Jung, H. K., & Kim, T. (2006). A new action potential detector using the MTEO and its effects on spike sorting systems at low signal-to-noise ratios. *IEEE Transactions on Biomedical Engineering*, 53(4), 738–746. <https://doi.org/10.1109/TBME.2006.870239>
 26. Clifford, G. D., Azuaje, F., & McSharry, P. E. (2006). *Advanced Methods and Tools for ECG Data Analysis 1st ed.*
 27. Cohen, J., Yofe, J., & Davies, A. M. (1960). Family morbidity. A suggested method of measurement. *British Journal of Preventive & Social Medicine*, 14(1), 39–43. <https://doi.org/10.1136/jech.14.1.39>
 28. Cumming, T. B., Packer, M., Kramer, S. F., & English, C. (2016). The prevalence of fatigue after stroke: A systematic review and meta-analysis. *International Journal of Stroke*, 11(9), 968–977. <https://doi.org/10.1177/1747493016669861>

29. Damasevicius, R. (2016). Analysis of Keystroke Dynamics for Fatigue Recognition. *CEUR Workshop Proceedings, 1603*(July), 1–8. <https://doi.org/10.1007/978-3-319-62404-4>
30. Damaševičius, R., Vasiljevas, M., Šalkevičius, J., & Woźniak, M. (2016). Human activity recognition in AAL environments using random projections. *Computational and Mathematical Methods in Medicine, 2016*. <https://doi.org/10.1155/2016/4073584>
31. Daubechies, I., & Paul, T. (1988). Time-frequency localisation operators-a geometric phase space approach: II. The use of dilations. *Inverse Problems, 4*(3), 661–680. <https://doi.org/10.1088/0266-5611/4/3/009>
32. De Rocha, V. A., Do Carmo, J. C., & Assis De Nascimento, F. O. (2018). Weighted-Cumulated S-EMG Muscle Fatigue Estimator. *IEEE Journal of Biomedical and Health Informatics, 22*(6), 1854–1862. <https://doi.org/10.1109/JBHI.2017.2783849>
33. Decade, A., & Bonato, P. (2010). From Enabling Technology to Clinical Applications. *IEEE Engineering in Medicine and Biology Magazine: The Quarterly Magazine of the Engineering in Medicine & Biology Society, June*, 25–36.
34. Deelman, E., Singh, G., Livny, M., Berriman, B., & Good, J. (2008). The cost of doing science on the cloud: The montage example. *2008 SC—International Conference for High Performance Computing, Networking, Storage and Analysis, SC 2008, November*. <https://doi.org/10.1109/SC.2008.5217932>
35. Drake, J. D. M., & Callaghan, J. P. (2006). Elimination of electrocardiogram contamination from electromyogram signals: An evaluation of currently used removal techniques. *Journal of Electromyography and Kinesiology, 16*(2), 175–187. <https://doi.org/10.1016/j.jelekin.2005.07.003>
36. Ed-Doughmi, Y., Idrissi, N., & Hbali, Y. (2020). Real-time system for driver fatigue detection based on a recurrent neuronal network. *Journal of Imaging, 6*(3). <https://doi.org/10.3390/jimaging6030008>
37. Edward Jero, S., Ramu, P., & Ramakrishnan, S. (2014). Discrete Wavelet Transform and Singular Value Decomposition Based ECG Steganography for Secured Patient Information Transmission. *Journal of Medical Systems, 38*(10). <https://doi.org/10.1007/s10916-014-0132-z>
38. Elgendi, M., Meo, M., & Abbott, D. (2016). A proof-of-concept study: Simple and effective detection of p and t waves in arrhythmic ECG signals. *Bioengineering, 3*(4). <https://doi.org/10.3390/bioengineering3040026>
39. Evans, J. D. (1995). *Straightforward statistics for the behavioral sciences*. Brooks/Cole Publishing Company.
40. Fatima, B., Shahid, A. R., Ziauddin, S., Safi, A. A., & Ramzan, H. (2020). Driver Fatigue Detection Using Viola Jones and Principal Component Analysis. *Applied Artificial Intelligence, 34*(6), 456–483. <https://doi.org/10.1080/08839514.2020.1723875>
41. Fell, J., Mann, K., Röschke, J., & Gopinathan, M. S. (2000). Nonlinear analysis of continuous ECG during sleep I. Reconstruction. *Biological Cybernetics, 82*(6), 477–483. <https://doi.org/10.1007/s004220050600>
42. Fontana, P., Martins, N. R. A., Camenzind, M., Boesch, M., Baty, F., Schoch, O. D., Brutsche, M. H., Rossi, R. M., & Annaheim, S. (2019). Applicability of a textile ECG-

- belt for unattended sleep apnoea monitoring in a home setting. *Sensors (Switzerland)*, 19(15), 1–9. <https://doi.org/10.3390/s19153367>
43. Gacek, A., & Pedrycz, W. (2003). *A Genetic Segmentation of ECG Signals*. 50(10), 1203–1208.
 44. Gacek, A., & Pedrycz, W. (2012). *ECG Signal Processing, Classification and Interpretation: A Comprehensive Framework of Computational Intelligence* (G. (Institute of M. T. Adam, Equipment), & U. of A. Witold, Pedrycz (Computer, Department of Electrical and Engineering Alberta (eds.)). <https://doi.org/10.1007/978-0-85729-868-3>
 45. Garg, G., Singh, V., Gupta, J. R. P., & Mittal, A. P. (2010). Optimal algorithm for ECG denoising using Discrete Wavelet Transforms. *2010 IEEE International Conference on Computational Intelligence and Computing Research, ICCIC 2010, 2*, 577–580. <https://doi.org/10.1109/ICCIC.2010.5705839>
 46. Gautam, D. D., & Giri, V. K. (2016). Analysis of HRV signal for disease diagnosis. *11th International Conference on Industrial and Information Systems, ICIIS 2016 - Conference Proceedings, 2018-Janua*, 639–643. <https://doi.org/10.1109/ICIINFS.2016.8263017>
 47. Gazi, O. (2016). Understanding Digital Signal Processing. In *Springer* (Vol. 13). <https://doi.org/10.1007/978-3-642-11130-3>
 48. Germán-Salló, Z., & Germán-Salló, M. (2016). Non-linear Methods in HRV Analysis. *Procedia Technology*, 22, 645–651. <https://doi.org/10.1016/j.protcy.2016.01.134>
 49. Ghasemi, M., Ghaffari, A., SadAbadi, H., & Golbayani, H. (2010). QT interval measurement using RMED curve; a novel approach based on wavelet techniques. *Computer Methods in Biomechanics and Biomedical Engineering*, 13(6), 857–864. <https://doi.org/10.1080/10255841003664719>
 50. Gibson, B. R., Rogers, T. T., & Zhu, X. (2013). Human Semi-Supervised Learning. *Topics in Cognitive Science*, 5(1), 132–172. <https://doi.org/10.1111/tops.12010>
 51. Giri, D., Rajendra Acharya, U., Martis, R. J., Vinitha Sree, S., Lim, T. C., Ahamed, T., & Suri, J. S. (2013). Automated diagnosis of Coronary Artery Disease affected patients using LDA, PCA, ICA and Discrete Wavelet Transform. *Knowledge-Based Systems*, 37, 274–282. <https://doi.org/10.1016/j.knosys.2012.08.011>
 52. Gobinath Aroganam, N. M. and D. H. *. (2019). Consumer Sport Applications. *Sensors*, 19, 1–26. <https://doi.org/10.3390/s19091983>
 53. Gray, D. (2020). An international housing market in the British Isles: Evidence from business and medium-term cycles using a Friedman test. *Urban Studies*, 57(2), 307–322. <https://doi.org/10.1177/0042098019839886>
 54. Grzegorowski, M., Janusz, A., Sl, D., & Stawicki, S. (2017). *Depression Behavior Detection Model Based on Participation in Serious Games*. c, 526–539. <https://doi.org/10.1007/978-3-319-60840-2>
 55. Hadjem, M., & Naït-Abdesselam, F. (2015). An ECG T-wave anomalies detection using a lightweight classification model for wireless body sensors. *2015 IEEE International Conference on Communication Workshop, ICCW 2015*, 278–283. <https://doi.org/10.1109/ICCW.2015.7247191>
 56. Haff, G. G., & Nimphius, S. (2012). Training principles for power. *Strength and Conditioning Journal*, 34(6), 2–12. <https://doi.org/10.1519/SSC.0b013e31826db467>

57. Hill, A. V., Long, C. N. H., & Lupton, H. (1924). Muscular Exercise, Lactic Acid and the Supply and Utilisation of Oxygen. *Proceedings of the Royal Society of London. Series B, Containing Papers of a Biological Character*, 97((682)), 155–176.
58. Hristovski, R., & Balagué, N. (2010). Fatigue-induced spontaneous termination point - Nonequilibrium phase transitions and critical behavior in quasi-isometric exertion. *Human Movement Science*, 29(4), 483–493. <https://doi.org/10.1016/j.humov.2010.05.004>
59. Hu, X., Xiao, Z., & Zhang, N. (2011). Removal of baseline wander from ECG signal based on a statistical weighted moving average filter. *Journal of Zhejiang University: Science C*, 12(5), 397–403. <https://doi.org/10.1631/jzus.C1010311>
60. Huang, N. E. (2001). Review of Empirical Mode Decomposition. *Proc. SPIE*, 4391(March 2001), 71–80. <https://doi.org/10.1117/12.421232>
61. Huang, S., Li, J., Zhang, P., & Zhang, W. (2018). Detection of mental fatigue state with wearable ECG devices. *International Journal of Medical Informatics*, 119(May), 39–46. <https://doi.org/10.1016/j.ijmedinf.2018.08.010>
62. Hulke, S., & Phatak, M. (2011). Cardiac adaptation to endurance training in young adult. *Chronicles of Young Scientists*, 2(2), 103. <https://doi.org/10.4103/2229-5186.82973>
63. Ibrahim, D. (2012). Teaching Digital Signal Processing. *Procedia - Social and Behavioral Sciences*, 46, 4441–4445. <https://doi.org/10.1016/j.sbspro.2012.06.271>
64. Ito, T., Ayusawa, K., Yoshida, E., & Kobayashi, H. (2018). Evaluation of active wearable assistive devices with human posture reproduction using a humanoid robot. *Advanced Robotics*, 32(12), 635–645. <https://doi.org/10.1080/01691864.2018.1490200>
65. Jagtap, S. K., & Uplane, M. D. (2012). The impact of digital filtering to ECG analysis: Butterworth filter application. *Proceedings – 2012 International Conference on Communication, Information and Computing Technology, ICCICT 2012*, 1–6. <https://doi.org/10.1109/ICCICT.2012.6398145>
66. Jason, L. A., Boulton, A., Porter, N. S., Jessen, T., Njoku, M. G., & Friedberg, F. (2010). Classification of myalgic encephalomyelitis/chronic fatigue syndrome by types of fatigue. *Behavioral Medicine*, 36(1), 24–31. <https://doi.org/10.1080/08964280903521370>
67. Jenkal, W., Latif, R., Toumanari, A., Dliou, A., El B'Charri, O., & Maoulainine, F. M. R. (2016). An efficient algorithm of ECG signal denoising using the adaptive dual threshold filter and the discrete wavelet transform. *Biocybernetics and Biomedical Engineering*, 36(3), 499–508. <https://doi.org/10.1016/j.bbe.2016.04.001>
68. Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Artificial Intelligence*, 349(6245).
69. Juozapavičius, A., & Meškauskas, T. (2011). *Vaizdų ir signalų analizė ir apdorojimas*. VU Matematikos ir informatikos fakultetas.
70. Kaiser, F. J. (1990). On a simple algorithm to calculate the “energy” of a signal. *IEEE Xplore*, 1910(10), 381–384.
71. Kampstra, P. (2008). Beanplot: A Boxplot Alternative for Visual Comparison of Distributions. *Journal of Statistical Software*, 28(November), 1–9. <papers3://publication/uuid/692988CE-7E10-498E-96EC-E7A0CE3620A3>
72. Karmakar, C. K., Khandoker, A. H., & Palaniswami, M. (2015). Phase asymmetry of heart rate variability signal. *Physiological Measurement*, 36(2), 303–314.

- <https://doi.org/10.1088/0967-3334/36/2/303>
73. Khalilia, M., Chakraborty, S., & Popescu, M. (2011). Predicting disease risks from highly imbalanced data using random forest. *BMC Medical Informatics and Decision Making*, *11*(1). <https://doi.org/10.1186/1472-6947-11-51>
 74. Köhler, B. U., Hennig, C., & Orglmeister, R. (2002). The principles of software QRS detection. *IEEE Engineering in Medicine and Biology Magazine*, *21*(1), 42–57. <https://doi.org/10.1109/51.993193>
 75. Kubičková, A., Kozumplík, J., Nováková, Z., Plachý, M., Jurák, P., Lipoldová, J. (2016). Heart rate variability analysed by Poincaré plot in patients with metabolic syndrome. *Journ. of Electrocardiol.* *49*(1), 23–28. <https://doi.org/10.1016/j.jelectrocard.2015.11.004>
 76. Kuijt, W. J., Green, C. L., Verouden, N. J. W., Haeck, J. D. E., Tzivoni, D., Koch, K. T., Stone, G. W., Lansky, A. J., Broderick, S., Tijssen, J. G. P., de Winter, R. J., Roe, M. T., & Krucoff, M. W. (2017). What is the best ST-segment recovery parameter to predict clinical outcome and myocardial infarct size? *Journal of Electrocardiology*, *50*(6), 952–959. <https://doi.org/10.1016/j.jelectrocard.2017.04.009>
 77. Lagarias, J. C., & Wang, Y. (1995). Wavelet Bases in R². *The Journal of Fourier Analysis and Applications*, *2*(1), 1–14.
 78. Lee, J. (2014). Motion artifacts reduction from PPG using cyclic moving average filter. *Technology and Health Care*, *22*(3), 409–417. <https://doi.org/10.3233/THC-140798>
 79. Lenaert, B., Jansen, R., & van Heugten, C. M. (2018). You make me tired: An experimental test of the role of interpersonal operant conditioning in fatigue. *Behaviour Research and Therapy*, *103*(February), 12–17. <https://doi.org/10.1016/j.brat.2018.01.006>
 80. Lin, C. T., Nascimben, M., King, J. T., & Wang, Y. K. (2018). Task-related EEG and HRV entropy factors under different real-world fatigue scenarios. *Neurocomputing*, *311*, 24–31. <https://doi.org/10.1016/j.neucom.2018.05.043>
 81. Liu, M., Hao, H. Q., Xiong, P., Lin, F., Hou, Z. G., & Liu, X. (2018). Constructing a Guided Filter by Exploiting the Butterworth Filter for ECG Signal Enhancement. *Journal of Medical and Biological Engineering*, *38*(6), 980–992. <https://doi.org/10.1007/s40846-017-0350-1>
 82. Lobo, J. L., Ser, J. Del, De Simone, F., Presta, R., Collina, S., & Moravek, Z. (2016). Cognitive workload classification using eye-tracking and EEG data. *Proceedings of the International Conference on Human-Computer Interaction in Aerospace, HCI-Aero 2016, November 2017*. <https://doi.org/10.1145/2950112.2964585>
 83. Luo, J., Wu, M., Gopukumar, D., & Zhao, Y. (2016). Big Data Application in Biomedical Research and Health Care: A Literature Review. *Biomedical Informatics Insights*, *8*, BII.S31559. <https://doi.org/10.4137/bii.s31559>
 84. Ma, J. Z. G. (2017). Plasma Brain Dynamics (PBD): A Mechanism for EEG Waves Under Human Consciousness. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, *9947 LNCS*(2), 324–333. https://doi.org/10.1007/978-3-319-46687-3_36
 85. Maharaj, E. A., & Alonso, A. M. (2014). Discriminant analysis of multivariate time series: Application to diagnosis based on ECG signals. *Computational Statistics and Data Analysis*, *70*, 67–87. <https://doi.org/10.1016/j.csda.2013.09.006>

86. Maiwald, T., Mammen, E., Nandi, S., & Timmer, J. (2008). Mathematical Methods in Signal Processing and Digital Image Analysis. *Mathematical Methods in Signal Processing and Digital Image Analysis, December 2007*, 41–74. <https://doi.org/10.1007/978-3-540-75632-3>
87. Manal, K., & Rose, W. (2007). A general solution for the time delay introduced by a low-pass Butterworth digital filter: An application to musculoskeletal modeling. *Journal of Biomechanics*, 40(3), 678–681. <https://doi.org/10.1016/j.jbiomech.2006.02.001>
88. Manolova, A., Tsenov, G., Lazarova, V., & Neshov, N. (2017). Combined EEG and EMG fatigue measurement framework with application to hybrid brain-computer interface. *2016 IEEE International Black Sea Conference on Communications and Networking, BlackSeaCom 2016*, 1–5. <https://doi.org/10.1109/BlackSeaCom.2016.7901569>
89. Mantica, G., Stoop, R., & Stramaglia, S. (2017). Preface. *Springer Proceedings in Physics, 191*(March), vii. <https://doi.org/10.1007/978-3-319-47810-4>
90. Marozas, V., Petrenas, A., Daukantas, S., & Lukosevicius, A. (2011). A comparison of conductive textile-based and silver/silver chloride gel electrodes in exercise electrocardiogram recordings. *Journal of Electrocardiology*, 44(2), 189–194. <https://doi.org/10.1016/j.jelectrocard.2010.12.004>
91. Martín-Clemente, R., & Zarzoso, V. (2018). L1-PCA signal subspace identification for non-sphered data under the ICA model. *2017 IEEE 7th International Workshop on Computational Advances in Multi-Sensor Adaptive Processing, CAMSAP 2017, 2017-December* (1), 1–5. <https://doi.org/10.1109/CAMSAP.2017.8313181>
92. Maskeliunas, R., & Damasevicius, R. (2016). Gender, Age, Colour, Position and Stress: How They Influence Attention at Workplace? *CEUR Workshop Proceedings, 1603*(July), 1–8. <https://doi.org/10.1007/978-3-319-62404-4>
93. Mastoi, Q. U. A., Wah, T. Y., Raj, R. G., & Iqbal, U. (2018). Automated Diagnosis of Coronary Artery Disease: A Review and Workflow. *Cardiology Research and Practice*. <https://doi.org/10.1155/2018/2016282>
94. McBride, J., Sullivan, A., Xia, H., Petrie, A., & Zhao, X. (2011). Reconstruction of physiological signals using iterative retraining and accumulated averaging of neural network models. *Physiological Measurement*, 32(6), 661–675. <https://doi.org/10.1088/0967-3334/32/6/004>
95. McCrary, J. M., Ackermann, B. J., & Halaki, M. (2018). EMG amplitude, fatigue threshold, and time to task failure: A meta-analysis. *Journal of Science and Medicine in Sport*, 21(7), 736–741. <https://doi.org/10.1016/j.jsams.2017.11.005>
96. McHugh, M. L. (2012). Lessons in biostatistics interrater reliability: the kappa statistic. *Biochemica Medica*, 22(3), 276–282. <https://hrcaj.srce.hr/89395>
97. Meškauskas, T. (Vilnius U. (2017). *Signalų analizė ir apdorojimas*. <https://klevas.mif.vu.lt/~meska/>
98. Messaoud, M. Ben, Khelil, B., & Kachouri, A. (2009). Analysis and parameter extraction of P wave using correlation method. *International Arab Journal of Information Technology*, 6(1), 40–46.
99. Miežinis, D., Telksnys, L. (2013). Elektrokardiogramų ir ritmogramų signalų perdavimas nedideliu atstumu į mobiliuosius Android tipo įrenginius, taupant energijos ir duomenų

- srauto perdavimo sąnaudas. *Computational Science and Techniques*, 1, 112–123.
100. Miller, R. (2007). Theory of the normal waking EEG: From single neurones to waveforms in the alpha, beta and gamma frequency ranges. *International Journal of Psychophysiology*, 64(1), 18–23. <https://doi.org/10.1016/j.ijpsycho.2006.07.009>
 101. Miranda, J., Cabral, J., Wagner, S. R., Pedersen, C. F., Ravelo, B., Memon, M., & Mathiesen, M. (2016). An open platform for seamless sensor support in healthcare for the internet of things. *Sensors (Switzerland)*, 16(12), 1–23. <https://doi.org/10.3390/s16122089>
 102. Momot, A. (2009). Methods of weighted averaging of ECG signals using Bayesian inference and criterion function minimization. *Biomedical Signal Processing and Control*, 4(2), 162–169. <https://doi.org/10.1016/j.bspc.2009.01.002>
 103. Monaco, A., Cattaneo, R., Ortu, E., Constantinescu, M. V., & Pietropaoli, D. (2017). Sensory trigeminal ULF-TENS stimulation reduces HRV response to experimentally induced arithmetic stress: A randomized clinical trial. *Physiology and Behavior*, 173, 209–215. <https://doi.org/10.1016/j.physbeh.2017.02.014>
 104. Morales, R., Segura, E., Somolinos, J. A., Núñez, L. R., & Sira-Ramírez, H. (2016). Online signal filtering based on the algebraic method and its experimental validation. *Mechanical Systems and Signal Processing*, 66–67, 374–387. <https://doi.org/10.1016/j.ymsp.2015.06.021>
 105. Muduli, P. R., Mukherjee, A. (2017). A Subspace Projection-Based Joint Sparse Recovery Method for Structured Biomedical Signals. *IEEE Transactions on Instrumentation and Measurement*, 66(2), 234–242. <https://doi.org/10.1109/TIM.2016.2615449>
 106. Muntianaitė-Dulkinienė, I., Poškaitis, V., Vainoras, A., Jurevičius, J., L. Bikulčiene, L., Navickas, Z. (2009). Cointegration of different ECG parameters for various physical tasks. *Elektronika Ir Elektrotechnika*, 6(6), 77–80. <https://doi.org/10.5755/j01.eee.94.6.10111>
 107. Nagaraja, S. W. P., Saul, J. P., Stone, P. H., & Van Der Molen, M. W. (1997). Heart rate variability: Origins, methods, and interpretive caveats. *Psychophysiol*, 34, 623–648.
 108. Nenadic, Z., & Burdick, J. W. (2005). Spike detection using the continuous wavelet transform. *IEEE Transactions on Biomedical Engineering*, 52(1), 74–87. <https://doi.org/10.1109/TBME.2004.839800>
 109. Nguyen, T., Qin, X., Dinh, A., & Bui, F. (2019). Low resource complexity R-peak detection based on triangle template matching and moving average filter. *Sensors (Switzerland)*, 19(18). <https://doi.org/10.3390/s19183997>
 110. Nikfarjam, A., Sarker, A., O'Connor, K., Ginn, R., & Gonzalez, G. (2015). Pharmacovigilance from social media: Mining adverse drug reaction mentions using sequence labeling with word embedding cluster features. *Journal of the American Medical Informatics Association*, 22(3), 671–681. <https://doi.org/10.1093/jamia/ocu041>
 111. Ning, X., Selesnick, I. W., & Duval, L. (2014). Chromatogram baseline estimation and denoising using sparsity (BEADS). *Chemometrics and Intelligent Laboratory Systems*, 139, 156–167. <https://doi.org/10.1016/j.chemolab.2014.09.014>
 112. Oeda, S., & Chieda, M. (2019). Visualization of programming skill structure by log-data analysis with decision tree. *Procedia Computer Science*, 159, 582–589.

- <https://doi.org/10.1016/j.procs.2019.09.213>
113. Orphanidou, C., & Drobnjak, I. (2017). Quality Assessment of Ambulatory ECG Using Wavelet Entropy of the HRV Signal. *IEEE Journal of Biomedical and Health Informatics*, 21(5), 1216–1223. <https://doi.org/10.1109/JBHI.2016.2615316>
 114. Pan, J., & Tompkins, W. J. (1985). A Real-Time QRS Detection Algorithm. *IEEE Transactions on Biomedical Engineering*, BME-32(3), 230–236. <https://doi.org/10.1109/TBME.1985.325532>
 115. Paudel, B. H., Panta, R., Limbu, N., & Shrestha, B. (2012). *Electroencephalography: Neurophysiology Application Notes* (B. Paudel, N. Limbu, D. Thakur, & R. Khadka ed.)
 116. Peng, C. K., Havlin, S., Stanley, H. E., & Goldberger, A. L. (1995). Quantification of scaling exponents and crossover phenomena in nonstationary heartbeat time series. *Chaos*, 5(1), 82–87. <https://doi.org/10.1063/1.166141>
 117. Peritz, D. C., Howard, A., Ciocca, M., & Chung, E. H. (2015). Smartphone ECG AIDS real time diagnosis of palpitations in the competitive college athlete. *Journal of Electrocardiology*, 48(5), 896–899. <https://doi.org/10.1016/j.jelectrocard.2015.07.010>
 118. Piskorski, J., & Guzik, P. (2005). Filtering Poincaré plots. *Computational Methods in Science and Technology*, 11(1), 39–48. <https://doi.org/10.12921/cmst.2005.11.01.39-48>
 119. Platiša, M. M., Bojić, T., Mazić, S., & Kalauzi, A. (2019). Generalized Poincaré plots analysis of heart period dynamics in different physiological conditions: Trained vs. untrained men. *PLoS ONE*, 14(7), 1–11. <https://doi.org/10.1371/journal.pone.0219281>
 120. Poderys, J., Grunovas, A., Poderiene, K., Buliuolis, A., Šilinskas, V., & Trinkunas, E. (2015). Cardiovascular changes during the performance by nonathletes of Bosco repeated jumps anaerobic test. *Medicina (Lithuania)*, 51(3), 187–192. <https://doi.org/10.1016/j.medici.2015.06.003>
 121. Poderys, J., Venskaitytė, E., Poderienė, K., Buliuolis, A., & Vainoras, A. (2010). Functional state assessment on the dynamics of interparametric concatenations during exercise tests. *Medicina*, 46(6), 429. <https://doi.org/10.3390/medicina46060060>
 122. Prasad, S. T., & Varadarajan, S. (2014). ECG Signal Analysis: Different Approaches. *International Journal of Engineering Trends and Technology*, 7(5), 212–216. <https://doi.org/10.14445/22315381/ijett-v7p275>
 123. Prichard, D., & Theiler, J. (1994). Generating Surrogate Data for Time Series With Several Simultaneously Measured Variables. *Physical Review Letters*, 73, 7, 951–954.
 124. Proakis, J. G., & Manolakis, D. G. (1996). *Digital Signal Processing: Principles, Algorithms, and Applications 3rd ed.*
 125. Pu, Y., Apel, D. B., & Lingga, B. (2018). Rockburst prediction in kimberlite using decision tree with incomplete data. *Journal of Sustainable Mining*, 17(3), 158–165. <https://doi.org/10.1016/j.jsm.2018.07.004>
 126. Ramalho, E. S. V., Souza-Junior, E. L., Magnani, M., & Braga, V. A. (2017). Gender differences in heart rate variability among individuals undergoing regular resistance training: Preliminary observations. *Sultan Qaboos University Medical Journal*, 17(2), e209–e212. <https://doi.org/10.18295/squmj.2016.17.02.012>
 127. Ray, P. P. (2015). Home Health Hub Internet of Things (H3IoT): An architectural framework for monitoring health of elderly people. *2014 International Conference on*

- Science Engineering and Management Research, ICSEMR 2014*, 1–3. <https://doi.org/10.1109/ICSEMR.2014.7043542>
128. Sahambi, J. S., Tandon, S. N., & Bhatt, R. K. P. (1997). Using wavelet transforms for ECG characterization. *IEEE Engineering in Medicine and Biology Magazine*, 16(1), 77–83. <https://doi.org/10.1109/51.566158>
 129. Schmitt, L., Regnard, J., & Millet, G. P. (2015). Monitoring fatigue status with HRV measures in elite athletes: An avenue beyond RMSSD? *Frontiers in Physiology*, 6(NOV), 2013–2015. <https://doi.org/10.3389/fphys.2015.00343>
 130. Schreiber, T., & Schmitz, A. (2000). Surrogate time series. *Physica D: Nonlinear Phenomena*, 142(3–4), 346–382. [https://doi.org/10.1016/S0167-2789\(00\)00043-9](https://doi.org/10.1016/S0167-2789(00)00043-9)
 131. Sedghamiz, H., Santonocito, D. (2016) Unsupervised detection and classification of motor unit action potentials in intramuscular electromyography signals. *2015 E-Health and Bioengineering Conference, EHB 2015*, 1–6. <https://doi.org/10.1109/EHB.2015.7391510>
 132. Sedighi Maman, Z., Alamdar Yazdi, M. A., Cavuoto, L. A., & Megahed, F. M. (2017). A data-driven approach to modeling physical fatigue in the workplace using wearable sensors. *Applied Ergonomics*, 65, 515–529. <https://doi.org/10.1016/j.apergo.2017.02.001>
 133. Selesnick, I. W., Graber, H. L., Pfeil, D. S., & Barbour, R. L. (2014). Simultaneous low-pass filtering and total variation denoising. *IEEE Transactions on Signal Processing*, 62(5), 1109–1124. <https://doi.org/10.1109/TSP.2014.2298836>
 134. Serenity, C. (2020). *Best apps for tracking your HRV (heart rate variability) on iPhone*. <https://www.imore.com/best-apps-tracking-your-hrv-heart-rate-variability> Žiūrėta: 2020-04-13.
 135. Shahbakhti, M. (2015). A novel DWT method for ECG noise elimination. *IEEE Transactions on Electrical and Electronic Engineering*, 10(3), 353–355. <https://doi.org/10.1002/tee.22093>
 136. Shao, M., Bin, G., Wu, S., Bin, G., Huang, J., & Zhou, Z. (2018). Detection of atrial fibrillation from ECG recordings using decision tree ensemble with multi-level features. *Physiological Measurement*, 39(9). <https://doi.org/10.1088/1361-6579/aadf48>
 137. Shatte, A. B. R., Hutchinson, D. M., & Teague, S. J. (2019). Machine learning in mental health: A scoping review of methods and applications. *Psychological Medicine*, 49(9), 1426–1448. <https://doi.org/10.1017/S0033291719000151>
 138. Silva, B. M. C., Rodrigues, J. J. P. C., de la Torre Díez, I., López-Coronado, M., & Saleem, K. (2015). Mobile-health: A review of current state in 2015. *Journal of Biomedical Informatics*, 56, 265–272. <https://doi.org/10.1016/j.jbi.2015.06.003>
 139. Šmidaitė, R. (Kauno T. U. (2017). *Antros eilės matricių struktūriniai dėstiniai netiesinių sistemų tyrimuose*.
 140. Spanakis, G., Weiss, G., & Roefs, A. (2016). Bagged boosted trees for classification of ecological momentary assessment data. *Frontiers in Artificial Intelligence and Applications*, 285(2016), 1612–1613. <https://doi.org/10.3233/978-1-61499-672-9-1612>
 141. Stasiunas, A., Verikas, A., Bacauskiene, M., & Miliauskas, R. (2012). An adaptive panoramic filter bank as a qualitative model of the filtering system of the cochlea: The peculiarities in linear and nonlinear mode. *Medical Engineering and Physics*, 34(2), 187–194. <https://doi.org/10.1016/j.medengphy.2011.07.009>

142. Taouli, S. A., & Bereksi-Reguig, F. (2012). Nonlinear analysis of the heart rate variability. *2012 6th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications, SETIT 2012*, 721–725. <https://doi.org/10.1109/SETIT.2012.6482003>
143. Teague, S. J., & Shatte, A. B. (2018). Exploring the Transition to Fatherhood: Feasibility Study Using Social Media and Machine Learning. *JMIR Pediatrics and Parenting*, 1(2), e12371. <https://doi.org/10.2196/12371>
144. Torabi Haghighi, A., & Kløve, B. (2015). A sensitivity analysis of lake water level response to changes in climate and river regimes. *Limnologica*, 51, 118–130. <https://doi.org/10.1016/j.limno.2015.02.001>
145. Tsuzuki, Y., & Ogihara, N. (2018). A recurrent neural network model for generation of humanlike reaching movements. *Advanced Robotics*, 32(15), 837–849. <https://doi.org/10.1080/01691864.2018.1496031>
146. Vainoras, A. (1996). *Širdies repoliarizacijos procesų tyrimas ramybės ir fizinio krūvio metu = Investigation of the heart during rest and bicycle ergometry: (100-taškės ir įprastinės EKG duomenys): habilitacinis darb medicina (5A)* (Vol. 26, Issues 1–63) [Lietuvos sveikatos mokslų universitetas]. <https://hdl.handle.net/20.500.12512/57868>
147. Vandecasteele, K., De Cooman, T., Gu, Y., Cleeren, E., Claes, K., Van Paesschen, W., Van Huffel, S., & Hunyadi, B. (2017). Automated epileptic seizure detection based on wearable ECG and PPG in a hospital environment. *Sensors (Switzerland)*, 17(10), 1–12. <https://doi.org/10.3390/s17102338>
148. Vehkaoja, A., Verho, J., Cömert, A., Aydogan, B., Perhonen, M., Lekkala, J., & Halttunen, J. (2008). System for ECG and heart rate monitoring during group training. *Proceedings of the 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS'08 – “Personalized Healthcare through Technology,”* 4832–4835. <https://doi.org/10.1109/iembs.2008.4650295>
149. Venskaitytė, E. (2011). *Širdies ir kraujagyslių sistemos funkcinių rodiklių sąsajų kaita vertinant sportuojančiųjų organizmo būsenas.*
150. Venskaityte, E., Poderys, J., Balagué, N., & Bikulciene, L. (2009). Assessment of dynamics of inter-parameter concatenation during exercise tests. *Elektronika Ir Elektrotechnika*, 6(6), 89–92. <https://doi.org/10.5755/j01.eee.94.6.10114>
151. Verlinde, D., Beckers, F., Ramaekers, D., & Aubert, A. E. (2001). Wavelet decomposition analysis of heart rate variability in aerobic athletes. *Autonomic Neuroscience: Basic and Clinical*, 90(1–2), 138–141. [https://doi.org/10.1016/S1566-0702\(01\)00284-3](https://doi.org/10.1016/S1566-0702(01)00284-3)
152. Vollmer, M. (2015). A robust, simple and reliable measure of heart rate variability using relative RR intervals. *Computing in Cardiology*, 42(September 2015), 609–612. <https://doi.org/10.1109/CIC.2015.7410984>
153. Walker, E. A. (2017). New Members and Foreign Members of the National Academy of Engineering. *Angewandte Chemie (International Ed. in English)*, 56(27), 7711–7712. <https://doi.org/10.1002/anie.201705180>
154. Wang, F., Wang, H., & Fu, R. (2018). Real-time ECG-based detection of fatigue driving using sample entropy. *Entropy*, 20(3). <https://doi.org/10.3390/e20030196>
155. Wang, Z., Shah, A. D., Tate, A. R., Denaxas, S., Shawe-Taylor, J., & Hemingway, H.

- (2012). Extracting diagnoses and investigation results from unstructured text in electronic health records by semi-supervised machine learning. *PLoS ONE*, 7(1). <https://doi.org/10.1371/journal.pone.0030412>
156. Wei, J. X., Wang, J., Zhu, Y. X., Sun, J., Xu, H. M., & Li, M. (2018). Traditional Chinese medicine pharmacovigilance in signal detection: Decision tree-based data classification. *BMC Medical Informatics and Decision Making*, 18(1), 1–9. <https://doi.org/10.1186/s12911-018-0599-5>
157. Weinstein, A. A., Diao, G., Baghi, H., Escheik, C., Gerber, L. H., & Younossi, Z. M. (2017). Demonstration of two types of fatigue in subjects with chronic liver disease using factor analysis. *Quality of Life Research*, 26(7), 1777–1784. <https://doi.org/10.1007/s11136-017-1516-6>
158. Wen, C., Yeh, M. F., Chang, K. C., & Lee, R. G. (2008). Real-time ECG telemonitoring system design with mobile phone platform. *Measurement: Journal of the International Measurement Confederation*, 41(4), 463–470. <https://doi.org/10.1016/j.measurement.2006.12.006>
159. Wen, X., Kang, M., Yao, L., & Zhao, X. (2016). Real-time ballistocardiographic artifact reduction using the k-teager energy operator detector and multi-channel referenced adaptive noise cancelling. *International Journal of Imaging Systems and Technology*, 26(3), 209–215. <https://doi.org/10.1002/ima.22178>
160. Wheeler, B. C., & Heetderks, W. J. (1982). A Comparison of Techniques for Classification of Multiple Neural Signals. *IEEE Transactions on Biomedical Engineering*, BME-29(12), 752–759. <https://doi.org/10.1109/TBME.1982.324870>
161. Wiens, J., & Shenoy, E. S. (2018). Machine Learning for Healthcare: On the Verge of a Major Shift in Healthcare Epidemiology. *Clinical Infectious Diseases*, 66(1), 149–153. <https://doi.org/10.1093/cid/cix731>
162. Wu, J., Lu, X., Xu, H., & Nakagoshi, N. (2013). *Resources and Sustainable Development*
163. Wu, Q., Xi, C., Ding, L., Wei, C., Ren, H., Law, R., Dong, H., & Li, X. L. (2017). Classification of EMG Signals by BFA-Optimized GSVCMM for Diagnosis of Fatigue Status. *IEEE Transactions on Automation Science and Engineering*, 14(2), 915–930. <https://doi.org/10.1109/TASE.2016.2564419>
164. Wu, S. C., Swindlehurst, A. L., & Nenadic, Z. (2015). A novel framework for feature extraction in multi-sensor action potential sorting. *Journal of Neuroscience Methods*, 253, 262–271. <https://doi.org/10.1016/j.jneumeth.2015.07.003>
165. Xia, H., Asif, I., & Zhao, X. (2013). Cloud-ECG for real time ECG monitoring and analysis. *Computer Methods and Programs in Biomedicine*, 110(3), 253–259. <https://doi.org/10.1016/j.cmpb.2012.11.008>
166. Xia, H., Garcia, G. A., & Zhao, X. (2012). Automatic detection of ECG electrode misplacement: A tale of two algorithms. *Physiological Measurement*, 33(9), 1549–1561. <https://doi.org/10.1088/0967-3334/33/9/1549>
167. Xue, Q., Hen Hu, Y., & Tompkins, W. J. (1992). Neural-Network-Based Adaptive Matched Filtering. *Transaction on Biomedical Engineering*, 39(4), 317–329.
168. Yaghoobi Karimui, R., & Azadi, S. (2017). Cardiac arrhythmia classification using the phase space sorted by Poincare sections. *Biocybernetics and Biomedical Engineering*,

- 37(4), 690–700. <https://doi.org/10.1016/j.bbe.2017.08.005>
169. Yi, F., Li, C., Feng, Y. (2018) Two precautions of entropy-weighting model in drought-risk assessment. *Natural Hazards*, 93(1), 339–347. <https://doi.org/10.1007/s11069-018-3303-2>
170. Yousaf, K., Mehmood, Z., Saba, T., Rehman, A., Munshi, A. M., Alharbey, R., & Rashid, M. (2019). Mobile-health applications for the efficient delivery of health care facility to people with dementia (PwD) and support to their carers: A survey. *BioMed Research International*, 2019. <https://doi.org/10.1155/2019/7151475>
171. Yücelbaş, Ş., Yücelbaş, C., Tezel, G., Özşen, S., & Yosunkaya, Ş. (2018). Automatic sleep staging based on SVD, VMD, HHT and morphological features of single-lead ECG signal. *Expert Systems with Applications*, 102, 193–206. <https://doi.org/10.1016/j.eswa.2018.02.034>
172. Zangróniz, R., Martínez-Rodrigo, A., López, M. T., Pastor, J. M., & Fernández-Caballero, A. (2018). Estimation of mental distress from photoplethysmography. *Applied Sciences (Switzerland)*, 8(1). <https://doi.org/10.3390/app8010069>
173. Zareba, W., McNitt, S., Polonsky, S., & Couderc, J. P. (2017). JT interval: What does this interval mean? *Journal of Electrocardiology*, 50(6), 748–751. <https://doi.org/10.1016/j.jelectrocard.2017.07.019>
174. Žemaitytė, D., Varoneckas, G., & Sokolov, E. (1984). Heart rhythm control during sleep. *Psychophysiology*, 21(3), 279–289. <https://doi.org/10.1111/j.1469-8986.1984.tb02935.x>
175. Zeytinoğlu, M., Tuncay, Ü., Akay, M. C., & Soydan, I. (2013). Holder ECG assessment of the effects of three different local anesthetic solutions on cardiovascular system in the sedated dental patients with coronary artery disease. *Anadolu Kardiyoloji Dergisi*, 13(5), 480–485. <https://doi.org/10.5152/akd.2013.146>
176. Zhang, Z. (2018). Optimization performance analysis of 1090ES ADS-B signal separation algorithm based on PCA and ICA. *International Journal of Performability Engineering*, 14(4), 741–750. <https://doi.org/10.23940/ijpe.18.04.p17.741750>
177. Zhao, L., Liu, C., Wei, S., Shen, Q., Zhou, F., & Li, J. (2018). A new entropy-based atrial fibrillation detection method for Scanning Wearable ECG recordings. *Entropy*, 20(12), 1–17. <https://doi.org/10.3390/e20120904>
178. Zhong, H., Eungpinichpong, W., Wang, X., Chatchawan, U., Wanpen, S., & Buranruk, O. (2018). Effects of mechanical-bed massage on exercise-induced back fatigue in athletes. *Journal of Physical Therapy Science*, 30(3), 365–372. <https://doi.org/10.1589/jpts.30.365>
179. Zhou, G., Tang, X., & Qin, S. (2019). Adaptive grid decomposition algorithm based on standard deviation circle radius. *International Journal of Performability Engineering*, 15(8), 2145–2152. <https://doi.org/10.23940/ijpe.19.08.p14.21452152>
180. Zhou, Y., & Qiu, G. (2018). Random forest for label ranking. *Expert Systems with Applications*, 112, 99–109. <https://doi.org/10.1016/j.eswa.2018.06.036>
181. Ziani, S., Jbari, A., Bellarbi, L., & Farhaoui, Y. (2018). Blind Maternal-Fetal ECG Separation Based on the Time-Scale Image TSI and SVD - ICA Methods. *Procedia Computer Science*, 134, 322–327. <https://doi.org/10.1016/j.procs.2018.07.179>

MOKSLINIŲ PUBLIKACIJŲ DISERTACIJOS TEMA SĄRAŠAS

Web of Science duomenų bazėje indeksuotuose leidiniuose su cituojamumo rodikliu

1. [S1; US] Butkevičiūtė, Eglė; Bikulčienė, Liepa; Sidekerskienė, Tatjana; Blažauskas, Tomas; Maskeliūnas, Rytis; Damaševičius, Robertas; Wei, Wei. Removal of movement artefact for mobile EEG analysis in sports exercises // IEEE Access. Piscataway, NJ : IEEE. eISSN 2169-3536. 2019, vol. 7, p. 7206–7217. DOI: 10.1109/ACCESS.2018.2890335. [Science Citation Index Expanded (Web of Science); Scopus; DOAJ] [IF: 4,098; AIF: 3,177; IF/AIF: 1,289; Q1 (2018, InCites JCR SCIE)] [M.kr.: N 009, T 007] [Indėlis: 0,142]
2. [S1; LT] Blažauskas, Tomas; Muliulis, Alvydas; Bikulčienė, Liepa; Butkevičiūtė, Eglė. Service-oriented architecture solution for ECG signal processing // Information technology and control = Informacinė technologija ir valdymas. Kaunas : KTU. ISSN 1392-124X. eISSN 2335-884X. 2017, vol. 46, iss. 4, p. 445–458. DOI: 10.5755/j01.itc.46.4.18470. [Science Citation Index Expanded (Web of Science); INSPEC] [IF: 0,800; AIF: 2,925; IF/AIF: 0,273; Q4 (2017, InCites JCR SCIE)] [M.kr.: N 009, T 007] [Indėlis: 0,250]

Kituose recenzuojamuose mokslo leidiniuose (Periodiniuose leidiniuose, tęstiniuose ir vienkartinuose straipsniu rinkiniuose)

1. [S5; LT] Bikulčis, Aurimas; Poderienė, Kristina; Butkevičiūtė, Eglė; Bikulčienė, Liepa; Poderys, Jonas. EKG rodiklių analizės būdai vertinant žmogaus nuovargio būsenas // Sportinį darbingumą lemiantys veiksniai (XII) : mokslinių straipsnių rinkinys. Kaunas : Lietuvos sporto universitetas. Treniravimo mokslo katedra. eISSN 2538-7944. 2019, T. 12, p. 10–16. [M.kr.: N 009, N 010] [Indėlis: 0,200]

Konferencijų pranešimų medžiagoje


1. [P1c; CH] Butkevičiūtė, Eglė; Eriņš, Matīss; Bikulčienė, Liepa. Mobile platform for fatigue evaluation: HRV analysis // Information and software technologies: 25th international conference, ICIST 2019, Vilnius, Lithuania, October 10–12, 2019: proceedings / Robertas Damaševičius, Giedrė Vasiljeviėnė (Eds.). Cham : Springer, 2019. ISBN 9783030302740. eISBN 9783030302757. p. 541–552. (Communications in computer and information science, ISSN 1865-0929, eISSN 1865-0937 ; vol. 1078). DOI: 10.1007/978-3-030-30275-7_42. [Scopus] [M.kr.: N 009] [Indėlis: 0,334]
2. [P1c; SG] Butkevičiūtė, E.; Bikulciene, L.; Poderiene, K. Training system methodology using ECG signal // Precision medicine powered by pHealth and connected health: proceedings of the 3rd ICBHI, Thessaloniki, Greece, 18–21 November 2017 / Maglaveras N., Chouvarda I., de Carvalho P. (eds). Singapore : Springer, 2018. ISBN 9789811074189. eISBN 9789811074196. p. 261–265. (IFMBE Proceedings, ISSN 1680-0737 ; vol. 66). DOI: 10.1007/978-981-10-7419-6_43. [Scopus] [M.kr.: N 009, N 010] [Indėlis: 0,334]

Konferencijų tezės ir straipsniai nerecenzuojamoje konferencijų pranešimų medžiagoje

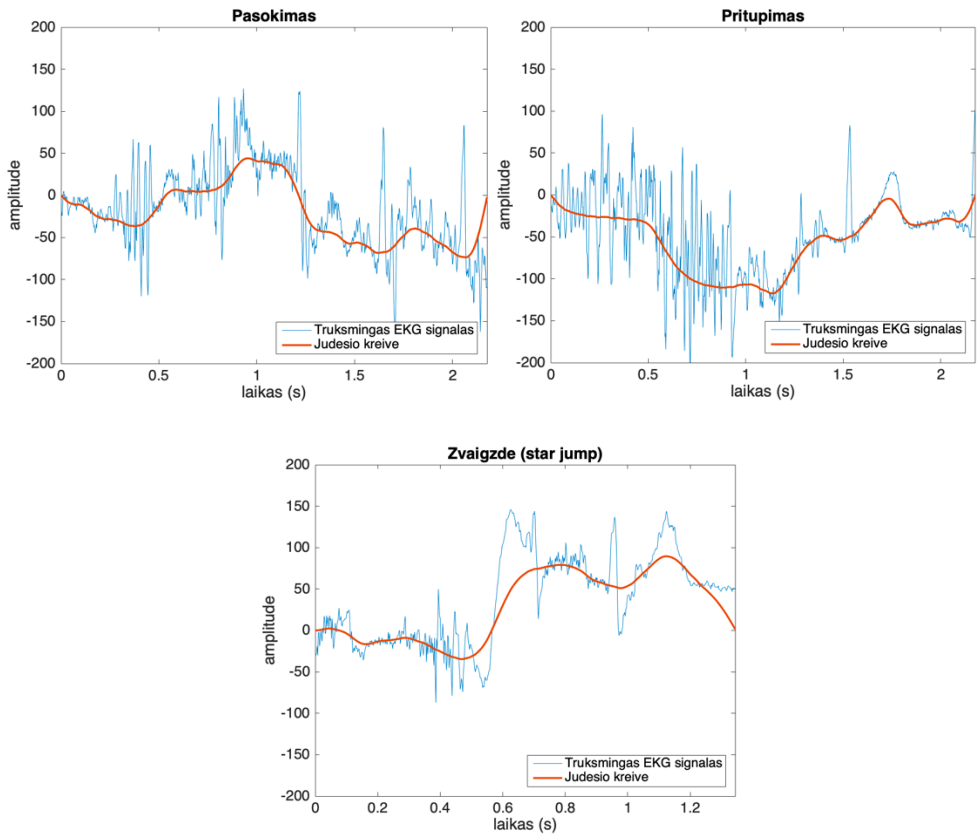
1. [T1e; LT] Bikulčis, Aurimas; Poderienė, Kristina; Butkevičiūtė, Eglė; Bikulčienė, Liepa; Poderys, Jonas. Funkcinė būklės vertinimas „Fatigue“ projekte: EKG rodiklių analizė, vertinant organizmo būsenas // Sportininkų rengimo valdymas ir sportininkų darbingumą lemiantys veiksniai: sporto forumas – tarptautinė mokslinė konferencija, skirta Lietuvos sporto universiteto 85-mečiui paminėti : programa ir pranešimų tezės, 2019 lapkr. 21–22 d., Kaunas, Lietuva. Kaunas : Lietuvos sporto universitetas. eISSN 2538-7952. 2019, p.

- 25–26. [M.kr.: N 009, N 010]
2. [T2; LT] Bikulčienė, L.; Blažauskas, T.; Butkevičiūtė, E.; Muliolis, A. System architecture of the fatigue and workability evaluation platform // 10th international workshop on data analysis methods for software systems, Druskininkai, Lithuania, November 29 –December 1, 2018. Vilnius : Vilnius University press, 2018. ISBN 9786090700433. p. 13. [M.kr.: N 009, T 007]
 3. [T2; EE] Butkevičiūtė, Eglė; Bikulčienė, Liepa. Optimization of automated health evaluation and training methodology system using decision making algorithms // Sampling theory and applications 2017: 12th international conference, Tallinn, Estonia, July 3–7. Tallinn : Tallinn University. 2017, p. 1. [M.kr.: N 009]
 4. [T1e; LT] Butkeviciute, Egle; Bikulciene, Liepa. ECG processing algorithms in mobile training system // Mathematical modelling and analysis: 22nd international conference, May 30–June 2, 2017, Druskininkai, Lithuania: abstracts. Vilnius : VGTU. 2017, p. 11. [M.kr.: N 009]

Priedas 1. BEADS algoritmo paklaidos, priklausomai nuo r parametro reikšmių



Priedas 2. BEADS metodu rastų judesio trendų pavyzdžiai



Priedas 3. Atliekamų pratimų vizualizacijos

Jas rasite šiose Youtube nuorodose:

1. Plank'as (<https://www.youtube.com/watch?v=pSHjTRCQxIw>)
2. Šoninis plank'as (<https://www.youtube.com/watch?v=NXr4Fw8q60o>)
3. Dead-bug'as (<https://www.youtube.com/watch?v=I5xbsA71v1A>)
4. Star-jumps (https://www.youtube.com/watch?v=h6wu4_LOhyU)
5. Aukštai keliant kelius (<https://www.youtube.com/watch?v=oDdkytliOqE>)
6. Burpee (<https://www.youtube.com/watch?v=TU8QYVW0gDU>)
7. Air-squat (https://www.youtube.com/watch?v=C_VtOYc6j5c)
8. Įtūpstas (<https://www.youtube.com/watch?v=QF0BQS2W80k>)
9. Skaterjumps (<https://www.youtube.com/watch?v=GASFfpVpEu0>)
10. Atsispaudimas (<https://www.youtube.com/watch?v=M7fWdJIDxPQ>)

Priedas 4. Skirtingų asmenų EKG signalų registravimo skirtingose aktyvumo būsenose protokolais

1 dalis. Tiriamųjų fizinis parengtumas

Asmuo	Amžius	Fizinis parengtumas	Komentaras
Asm1	26	Geras	Sportuoja nuolat, darbas susijęs su profesionalia sportine veikla
Asm2	26	Geras	Sportuoja nuolat, darbas susijęs su profesionalia sportine veikla
Asm3	30	Vidutiniškas	Reguliariai sportuoja
Asm4	30	Vidutiniškas	Reguliariai sportuoja
Asm5	25	Prastas	Ilgą laiką (daugiau nei pusę metų) neturėjo jokios intensyvios fizinės veiklos

2 dalis. Aktyvumo būsenų aprašymas

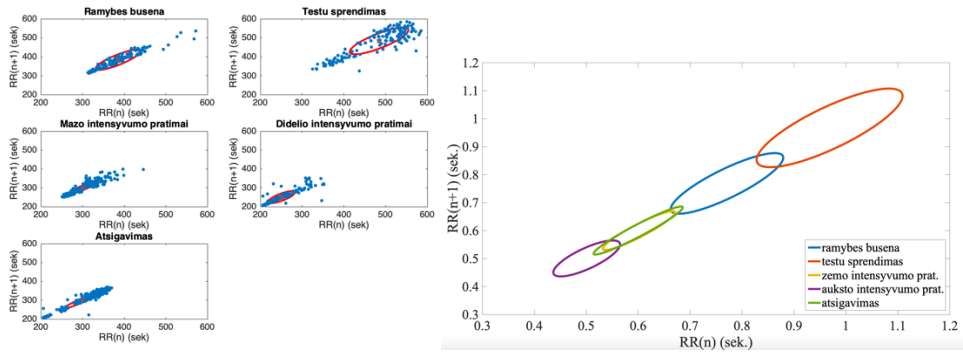
Būsenos pav.	Būsenos aprašymas	Apytikslė trukmė
S1	Ramybės būseną atsistojus (išskyrus tiriamajam Asm5, kur ramybės būseną buvo atsisėdus)	2 min
S2	Protinė veikla sprendžiant IQ testą prie kompiuterio atsisėdus	5 min
S3	Ramybės būseną atsisėdus (tyrime ši būseną yra nevertinama)	1 min
S4	Fiziniai pratimai (4 aukšto intensyvumo ir 4 žemo intensyvumo)	Laikas neregistruojamas
S5	Atsigavimas atsistojus (Asm3 ir Asm5 po truputį judėjo – lėtai vaikščiojo)	3 min
S6	Atsigavimas atsisėdus	1 min

3 dalis. Atliekami fiziniai pratimai ir jų aprašymas

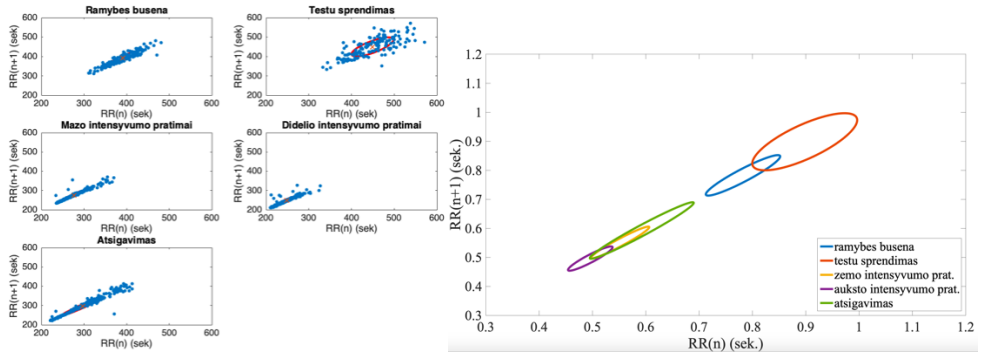
Nr.	Pavadinimas	Intensyvumas	Kiekis	Aprašymas
1	Pritūpimai	Mažas	15 vnt	Pradedama iš stovimos padėties, tada įtūpiama ir atsistojama.
2	Atsistojimai	Mažas	15 vnt	Pradedama iš sėdimos padėties, pilnai atsistojama abiem kojomis. Pratimas baigiamas vėl atsisėdus.
3	Įtūpstai atgal	Mažas	Po 8 vnt kojai	Pradedama kaire koja. Pratimas pilnai atliekamas įtūpus ir grįžus į pradžią
4	Įtūpstai į šoną	Mažas	Po 8 vnt kojai	Pradedama dešine koja. Pratimas pilnai atliekamas įtūpus ir grįžus į pradinę poziciją.
5	Bėgimas aukštai keliant kelius	Didelis	Po 8 vnt kojai	Pradedama kaire koja. Greitai atliekamas pratimas, kai po abiejų kojų pakėlimų yra užfiksuojama pradinė pozicija.
6	Pašokimai iš pritūpimo	Didelis	15 vnt	Pradedama iš įtūpimo. Pašokus iš karto grįžtama į pradinę poziciją.
7	„Žvaigždės šuolis“	Didelis	15 vnt	Pradedama atsistojus ir suglaudus rankas bei kojas. Pratimas baigiamas po šuolio sugrįžus į tą pačią poziciją.
8	„Čiuožiko šuolis“	Didelis	Po 8 vnt kojai	Pradedama kaire koja. Fiksuojamas pašokimas į šoną, tada iš karto peršokama į kitą šoną, t. y. į pradinę poziciją grįžtama tik atlikus visus šuoliukus.

Priedas 5. Poincare diagramos skirtingose būsenose

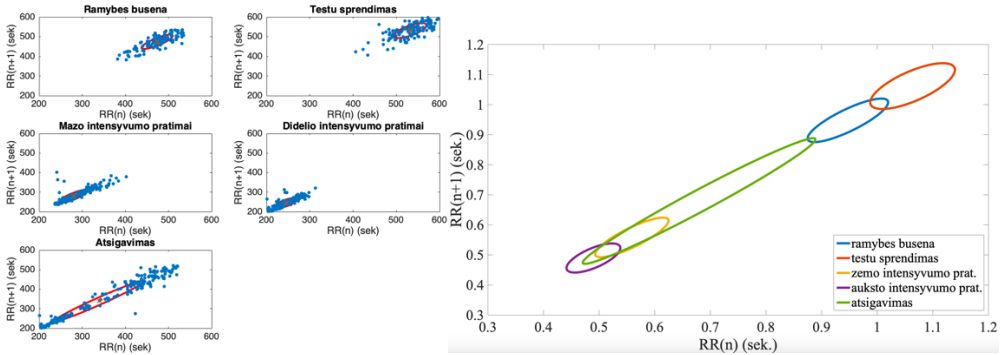
Asm1



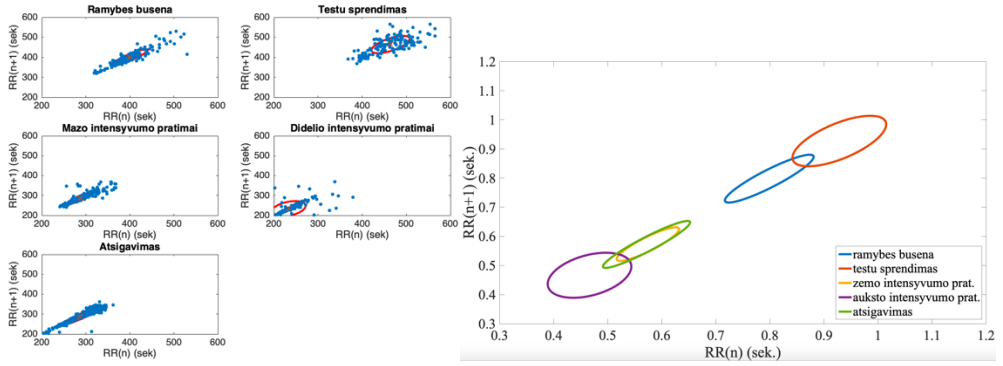
Asm2




Asm3



Asm4




Asm5




Priedas 6. Atletų R-R intervalų sekos ir EKG signalų spektrogramos


Atletas1




Atletas2



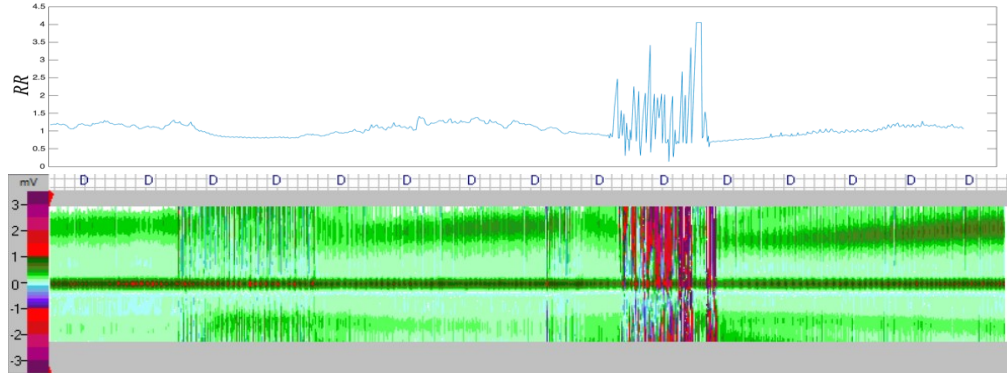
Atletas3




Atletas4



Atletas5



Atletas6



Priedas 7. Skirtingu paros metu registruotų EKG signalų protokolas

Nr.D ata	Būseną	Tiriamasis 1		Tiriamasis 2	
		Savijauta	Dienos užimtumas	Savijauta	Dienos užimtumas
1. 2020 03 23	A1	Labai gera, nuovargio nėra	24000 žingsnių, nedaug darbo prie kompiuterio	Vidutiniška, nuovargio nėra	24000 žingsnių, nedaug darbo prie kompiuterio
	A2	Labai gera, nuovargio nėra		Fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Bendras nuovargis	
2. 2020 03 24	A1	Vidutiniška, nuovargio nėra	18000 žingsnių, daug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Gera, nuovargio nėra	18000 žingsnių, daug ir intensyvaus darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Bendras nuovargis		Nedidelis bendras nuovargis	
3. 2020 03 25	A1	Gera, nuovargio nėra	8000 žingsnių, daug ir intensyvaus darbo prie kompiuterio	Vidutiniška, nuovargio nėra	8000 žingsnių, daug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Vidutiniška, nuovargio nėra	
	A3	Bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Bendras nuovargis		Nedidelis bendras nuovargis	
4. 2020 03 26	A1	Vidutiniška, nuovargio nėra	20000 žingsnių, nedaug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Gera, nuovargio nėra	20000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Gera, nuovargio nėra	
	A3	Fizinis nuovargis		Nedidelis bendras nuovargis	
	A4	Didelis fizinis nuovargis		Nedidelis bendras nuovargis	
5. 2020 03 29	A1	Gera, nuovargio nėra	8500 žingsnių, vidutiniškai darbo prie kompiuterio	Gera, nuovargio nėra	8500 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Fizinis nuovargis		Nedidelis bendras nuovargis	
	A4	Fizinis nuovargis		Nedidelis bendras nuovargis	
6. 2020 03 30	A1	Gera, nuovargio nėra	18000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	18000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
7. 2020 03 31	A1	Gera, nuovargio nėra	14000 žingsnių, valandos trukmės treniruotė, vidutiniškai darbo prie kompiuterio	Gera, nuovargio nėra	14000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Nedidelis fizinis nuovargis		Nuovargio nėra	
	A4	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
8. 2020 04 01	A1	Vidutiniška, nuovargio nėra	800 žingsnių, labai daug darbo prie kompiuterio	Vidutiniška, nuovargio nėra	800 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	

		nuovargis		nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
9. 2020 04 02	A1	Gera, nuovargio nėra	20000 žingsnių, daug darbo prie kompiuterio	Vidutiniška, nuovargio nėra	20000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
10. 2020 04 03	A1	Gera, nuovargio nėra	2000 žingsnių, labai daug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Gera, nuovargio nėra	2000 žingsnių, daug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Didelis nuovargis		Nedidelis bendras nuovargis	
	A4	Fizinis nuovargis		Nedidelis nuovargis	
11. 2020 04 04	A1	Gera, nuovargio nėra	23000 žingsnių, daug darbo prie kompiuterio	Lengvas nuovargis, mieguistumas	23000 žingsnių, daug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Fizinis nuovargis	
	A3	Bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
12. 2020 04 05	A1	Vidutiniška, nuovargio nėra	18000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	18000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Vidutiniška, nuovargio nėra		Gera, nuovargio nėra	
	A3	Bendras nuovargis		Bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
13. 2020 04 07	A1	Gera, nuovargio nėra	21000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	21000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Bendras nuovargis		Bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
14. 2020 04 08	A1	Vidutiniška, nuovargio nėra	15000 žingsnių, daug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Vidutiniška, nuovargio nėra	15000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nuovargio nėra	
	A4	Bendras nuovargis		Nedidelis fizinis nuovargis	
15. 2020 04 09	A1	Gera, nuovargio nėra	23000 žingsnių, nedaug darbo prie kompiuterio	Vidutiniška, nuovargio nėra	23000 žingsnių, nedaug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Fizinis nuovargis	
	A3	Nedidelis fizinis nuovargis		Bendras nuovargis	
	A4	Nedidelis fizinis nuovargis		Bendras nuovargis	
*****Pakeisti vienkartiniai elektrodai*****					
16. 2020 04 10	A1	Vidutiniška, mieguistumas	14000 žingsnių, vidutiniškai darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Gera, nuovargio nėra	14000 žingsnių, daug darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Gera, nuovargio nėra	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
17. 2020 04 11	A1	Labai gera, nuovargio nėra	17000 žingsnių, vidutiniškai darbo prie kompiuterio	Vidutiniška, nuovargio nėra	17000 žingsnių, daug ir intensyvaus darbo prie
	A2	Labai gera, nuovargio nėra		Fizinis nuovargis	

	A3	Nedidelis bendras nuovargis		Bendras nuovargis	kompiuterio
	A4	Nedidelis bendras nuovargis		Labai prasta, pykina	
18. 2020 04 12	A1	Vidutiniška, nuovargio nėra	14000 žingsnių, daug ir intensyvaus darbo prie kompiuterio	Gera, nuovargio nėra	14000 žingsnių, daug ir intensyvaus darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
19. 2020 04 13	A1	Labai gera, nuovargio nėra	18000 žingsnių, daug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Vidutiniška, nuovargio nėra	18000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Labai gera, nuovargio nėra		Vidutiniška, nuovargio nėra	
	A3	Bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Bendras nuovargis		Nedidelis bendras nuovargis	
20. 2020 04 14	A1	Vidutiniška, nuovargio nėra	16000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	16000 žingsnių, daug darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Gera, nuovargio nėra	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
21. 2020 04 15	A1	Gera, nuovargio nėra	26000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	26000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Fizinis nuovargis		Fizinis nuovargis	
	A4	Fizinis nuovargis		Fizinis nuovargis	
22. 2020 04 16	A1	Gera, nuovargio nėra	17000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	17000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
23. 2020 04 17	A1	Gera, nuovargio nėra	14000 žingsnių, valandos trukmės treniruotė, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	14000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Fizinis nuovargis		Nedidelis bendras nuovargis	
	A4	Fizinis nuovargis		Fizinis nuovargis	
24. 2020 04 18	A1	Vidutiniška, nuovargio nėra	10000 žingsnių, daug ir intensyvaus darbo prie kompiuterio	Vidutiniška, nuovargio nėra	10000 žingsnių, daug darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Vidutiniška, nuovargio nėra	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
25. 2020 04 19	A1	Gera, nuovargio nėra	21000 žingsnių, daug darbo prie kompiuterio	Vidutiniška, nuovargio nėra	21000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Bendras nuovargis	
26. 2020	A1	Vidutiniška, nuovargio nėra	13000 žingsnių, labai daug darbo	Gera, nuovargio nėra	13000 žingsnių, daug darbo prie

04 20	A2	Nedidelis fizinis nuovargis	prie kompiuterio	Gera, nuovargio nėra	kompiuterio
	A3	Didelis nuovargis		Nedidelis bendras nuovargis	
	A4	Didelis nuovargis		Nedidelis nuovargis	
27. 2020 04 22	A1	Gera, nuovargio nėra	12000 žingsnių, daug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Lengvas nuovargis, mieguistumas	12000 žingsnių, daug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Fizinis nuovargis	
	A3	Didelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
28. 2020 04 23	A1	Gera, nuovargio nėra	27000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	27000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Bendras nuovargis		Bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
29. 2020 04 24	A1	Gera, nuovargio nėra	22000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	22000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
30. 2020 04 25	A1	Vidutiniška, nuovargio nėra	17000 žingsnių, vidutiniškai darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Vidutiniška, mieguistumas	17000 žingsnių, daug darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Bendras nuovargis		Nedidelis bendras nuovargis	
31. 2020 04 26	A1	Gera, nuovargio nėra	27000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	27000 žingsnių, nedaug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Fizinis nuovargis		Nedidelis fizinis nuovargis	
	A4	Fizinis nuovargis		Nedidelis fizinis nuovargis	
32. 2020 04 27	A1	Gera, nuovargio nėra	20000 žingsnių, vidutiniškai darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Gera, nuovargio nėra	20000 žingsnių, daug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Fizinis nuovargis		Nedidelis bendras nuovargis	
33. 2020 04 28	A1	Vidutiniška, nuovargio nėra	12000 žingsnių, labai daug darbo prie kompiuterio	Gera, nuovargio nėra	12000 žingsnių, labai daug darbo prie kompiuterio
	A2	Vidutiniška, nuovargio nėra		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
34. 2020 05 01	A1	Gera, nuovargio nėra	23000 žingsnių, vidutiniškai darbo prie kompiuterio	Gera, nuovargio nėra	23000 žingsnių, daug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
35. 2020 05 02	A1	Gera, nuovargio nėra	32000 žingsnių	Gera, nuovargio nėra	32000 žingsnių, nedaug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Fizinis nuovargis		Fizinis nuovargis	
	A4	Fizinis nuovargis		Fizinis nuovargis	
36.	A1	Vidutiniška, nedidelis	20000 žingsnių,	Vidutiniška,	20000 žingsnių,

2020 05 03		fizinis nuovargis	vidutiniškai darbo prie kompiuterio	nuovargio nėra	vidutiniškai darbo prie kompiuterio
	A2	Fizinis nuovargis		Vidutiniška, nuovargio nėra	
	A3	Bendras nuovargis		Bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
37. 2020 05 04	A1	Vidutiniška, nuovargio nėra	22000 žingsnių, vidutiniškai darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Vidutiniška, nuovargio nėra	22000 žingsnių, daug darbo prie kompiuterio
	A2	Vidutiniška, nuovargio nėra		Nedidelis fizinis nuovargis	
	A3	Bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Bendras nuovargis			
38. 2020 05 06	A1	Vidutiniška, nuovargio nėra	11000 žingsnių, labai daug darbo prie kompiuterio	Vidutiniška, nuovargio nėra	11000 žingsnių, labai daug darbo prie kompiuterio
	A2	Vidutiniška, nuovargio nėra		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nuovargio nėra	
	A4	Nedidelis bendras nuovargis		Nedidelis fizinis nuovargis	
39. 2020 05 07	A1	Gera, nuovargio nėra	16000 žingsnių, vidutiniškai darbo prie kompiuterio	Gera, nuovargio nėra	16000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Gera, nuovargio nėra	
	A3	Nuovargio nėra		Nuovargio nėra	
	A4	Nedidelis fizinis nuovargis		Nuovargio nėra	
40. 2020 05 08	A1	Labai gera, nuovargio nėra	17000 žingsnių, vidutiniškai darbo prie kompiuterio	Vidutiniška, nuovargio nėra	1700 žingsnių, daug ir intensyvaus darbo prie kompiuterio
	A2	Labai gera, nuovargio nėra		Fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Labai prasta, pykina	
41. 2020 05 09	A1	Vidutiniška, nuovargio nėra	18000 žingsnių, daug ir intensyvaus darbo prie kompiuterio	Gera, nuovargio nėra	18000 žingsnių, daug ir intensyvaus darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
42. 2020 05 10	A1	Labai gera, nuovargio nėra	16000 žingsnių, daug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Vidutiniška, nuovargio nėra	16000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Labai gera, nuovargio nėra		Vidutiniška, nuovargio nėra	
	A3	Bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Bendras nuovargis		Nedidelis bendras nuovargis	
43. 2020 05 13	A1	Vidutiniška, nuovargio nėra	14000 žingsnių, nedaug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Gera, nuovargio nėra	14000 žingsnių, daug darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Gera, nuovargio nėra	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
44. 2020	A1	Gera, nuovargio nėra	27000 žingsnių, vidutiniškai darbo	Gera, nuovargio nėra	27000 žingsnių, vidutiniškai
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	

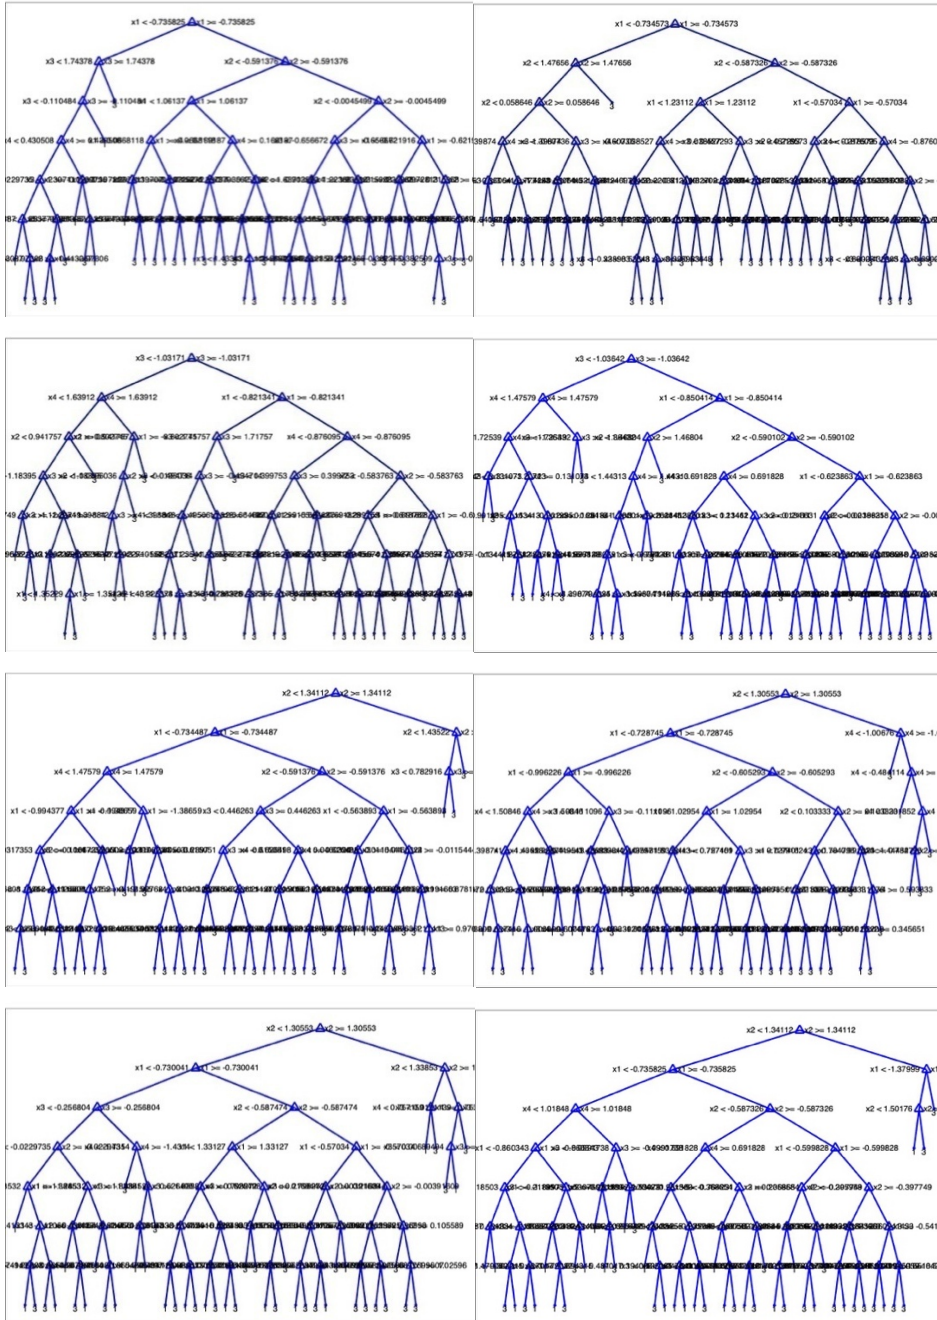
05 14	A3	Fizinis nuovargis	prie kompiuterio	Fizinis nuovargis	darbo prie kompiuterio
	A4	Fizinis nuovargis		Fizinis nuovargis	
45. 2020 05 15	A1	Gera, nuovargio nėra	12000 žingsnių, valandos trukmės treniruotė, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	12000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
46. 2020 05 16	A1	Gera, nuovargio nėra	27000 žingsnių, valandos trukmės treniruotė, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	27000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Didelis fizinis nuovargis		Didelis fizinis nuovargis	
	A4	Didelis fizinis nuovargis		Didelis fizinis nuovargis	
47. 2020 05 17	A1	Vidutiniška, nuovargio nėra	22000 žingsnių, vidutiniškai darbo prie kompiuterio	Vidutiniška, nuovargio nėra	22000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
48. 2020 05 18	A1	Gera, nuovargio nėra	24000 žingsnių, daug darbo prie kompiuterio	Vidutiniška, nuovargio nėra	24000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
49. 2020 05 21	A1	Gera, nuovargio nėra	11000 žingsnių, labai daug darbo prie kompiuterio	Gera, nuovargio nėra	11000 žingsnių, daug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Didelis nuovargis		Nedidelis bendras nuovargis	
	A4	Fizinis nuovargis		Nedidelis nuovargis	
50. 2020 05 22	A1	Gera, nuovargio nėra	11000 žingsnių, daug darbo prie kompiuterio	Lengvas nuovargis, mieguistumas	11000 žingsnių, daug darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Fizinis nuovargis	
	A3	Didelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Fizinis nuovargis		Fizinis nuovargis	
51. 2020 05 23	A1	Gera, nuovargio nėra	18000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	18000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Bendras nuovargis		Bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
52. 2020 05 25	A1	Gera, nuovargio nėra	14000 žingsnių, nedaug darbo prie kompiuterio	Gera, nuovargio nėra	14000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Gera, nuovargio nėra		Gera, nuovargio nėra	
	A3	Bendras nuovargis		Bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
53. 2020 05 26	A1	Gera, nuovargio nėra	7000 žingsnių, daug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Gera, nuovargio nėra	7000 žingsnių, daug darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Fizinis nuovargis		Nedidelis bendras nuovargis	
54. 2020 05 27	A1	Gera, nuovargio nėra	11000 žingsnių, labai daug darbo prie kompiuterio	Gera, nuovargio nėra	11000 žingsnių, labai daug darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	

		nuovargis		nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
55. 2020 05 28	A1	Gera, nuovargio nėra	15000 žingsnių labai daug darbo prie kompiuterio	Gera, nuovargio nėra	15000 žingsnių labai daug darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
56. 2020 05 29	A1	Vidutiniška, nuovargio nėra	14000 žingsnių labai daug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Gera, nuovargio nėra	14000 žingsnių vidutiniškai darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Gera, nuovargio nėra	
	A3	Bendras nuovargis		Bendras nuovargis	
	A4	Fizinis nuovargis		Bendras nuovargis	
57. 2020 05 30	A1	Vidutiniška, nuovargio nėra	2000 žingsnių, labai daug intensyvaus darbo prie kompiuterio	Gera, nuovargio nėra	2000 žingsnių, daug darbo prie kompiuterio
	A2	Vidutiniška, nuovargio nėra		Nedidelis fizinis nuovargis	
	A3	Bendras nuovargis		Bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
58. 2020 06 01	A1	Gera, nuovargio nėra	11000 žingsnių, daug darbo prie kompiuterio	Vidutiniška, nuovargio nėra	11000 žingsnių, daug darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Nedidelis bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Bendras nuovargis		Bendras nuovargis	
59. 2020 06 02	A1	Vidutiniška, nuovargio nėra	3000 žingsnių, labai daug darbo prie kompiuterio, valandos trukmės fizinė treniruotė	Vidutiniška, nuovargio nėra	3000 žingsnių, labai daug darbo prie kompiuterio
	A2	Vidutiniška, nuovargio nėra		Nedidelis fizinis nuovargis	
	A3	Bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Fizinis nuovargis		Nedidelis bendras nuovargis	
60. 2020 06 03	A1	Vidutiniška, nuovargio nėra	7000 žingsnių, daug darbo prie kompiuterio	Vidutiniška, nuovargio nėra	7000 žingsnių, vidutiniškai darbo prie kompiuterio
	A2	Nedidelis fizinis nuovargis		Nedidelis fizinis nuovargis	
	A3	Bendras nuovargis		Nedidelis bendras nuovargis	
	A4	Bendras nuovargis		Nedidelis bendras nuovargis	

Priedas 8. ML metodai, jų parametrai ir aprašymai

Pavadinimas	Parametrai	Aprašymas
KNN	Kaimynų skaičius 10	Skaičiuoja Euklido atstumą tarp taškų ir randa 10 arčiausiai esančių kaimynų
LDA		Duomenų klasifikavimui naudojama tiesinė regresija
Kvadratinis SVM		Naudojama kvadratinė Kernel funkcija
DT	Didžiausias išskaidymų skaičius 100, didžiausias skaičius charakteristikų, aprašančių duomenų išskaidymą kiekviename marge yra 9	Sudarytame modelyje yra 181 mazgas
Atsitiktinis miškas (nuoseklus)	20 maksimalių išskaidymų kiekvienam medžiui. Analizuojama 30 DT	Kiekvienas DT modelis apmokomas nuosekliai vienas po kito. Naujas modelis išmoksta iš prieš tai buvusio modelio klaidų. Kiekvienas medis turi savo mazgų skaičių

Priedas 9. Tyrimo metu sudaryto RF atskirų DT medžių schemų pavyzdžiai



SL344. 2021-*,*,*leidyb. apsk. I. Tiražas 14 egz. Užsakyamas *.
 Išleido Kauno technologijos universitetas, K. Donelaičio g. 73, 44249 Kaunas
 Spausdino leidykla „Technologija“ spaustuvė, Studentų g. 54, 51424 Kaunas