



Kauno technologijos universitetas

Informatikos fakultetas

**Dirbtiniu intelektu grįstas kognityvinių funkcijų sutrikimo
prognozavimas širdies chirurgijos metu**

Baigiamasis magistro projektas

Justina Krevnevičiūtė

Projekto autorė

dr. Agnė Paulauskaite-Tarasevičienė

Vadovė

Kaunas, 2025



Kauno technologijos universitetas

Informatikos fakultetas

Dirbtiniu intelektu grįstas kognityvinių funkcijų sutrikimo prognozavimas širdies chirurgijos metu

Baigiamasis magistro projektas

Studijų programos pavadinimas (kodas)

Justina Krevnevičiūtė

Projekto autorė

dr. Agnė Paulauskaite-Tarasevičienė

Vadovė

doc. Andrius Kriščiūnas

Recenzentas

Kaunas, 2025



Kauno technologijos universitetas

Informatikos fakultetas

Justina Krevnevičiūtė

Dirbtiniu intelektu grįstas kognityvinių funkcijų sutrikimo prognozavimas širdies chirurgijos metu

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

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

Justina Krevnevičiūtė

Patvirtinta elektroniniu būdu

Krevnevičiūtė Justina. Dirbtiniu intelektu grįstas kognityvinių funkcijų sutrikimo prognozavimas širdies chirurgijos metu. Magistro studijų baigiamasis projektas / vadovė dr. Agnė Paulauskaite-Tarasevičienė; Kauno technologijos universitetas, informatikos fakultetas.

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

Reikšminiai žodžiai: biologiniai signalai, klasifikacija, signalų paruošimas, pooperacinis pažinimo sutrikimas.

Kaunas, 2025. 47 p.

Santrauka

Magistro darbe pateikiami fiziologinių laiko eilučių duomenų – arterinio kraujospūdžio (ABP) ir transkranijinio doplerio (TCD) signalų, klasifikavimo metodai. Apžvelgiami signalų apdorojimo būdai (triukšmo šalinimas, segmentavimą, požymių inžinerija), nustatomi ABP ir TCD požymiai, kurie yra reikšmingiausi prognozuojant pooperacinį pažinimo funkcijų sutrikimą.

Tyrimo metu įgyvendinami ir palyginami įvairūs dirbtinio intelekto modeliai – nuo statistinių iki hibridinių ir transformatorių architektūrų, naudojant spektrogramos ir rekurencijos matricas bei požymių vektorius. Lyginamas modelių tikslumas, atitikimas bei F1 balas.

Realizuoti modeliai ir duomenų paruošimo metodai parodė, jog mažam duomenų rinkiniui, kurį sudaro skirtingo ilgio biologiniai signalai, geriausi rezultatai pasiekti naudojant mašininio mokymo modelius su požymių vektorių įvestimi.

Krevnevičiūtė Justina. Prediction of Cognitive Impairment in Cardiac Surgery Using Artificial Intelligence. Master's Final Degree Project / supervisor dr. Agnė Paulauskaite-Tarasevičienė; Faculty of Informatics, Kaunas University of Technology.

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

Keywords: biological signals, classification, signal preprocessing, postoperative cognitive impairment.

Kaunas, 2025. 47 pages.

Summary

The master's thesis presents methods for classifying physiological time series data – arterial blood pressure (ABP) and transcranial Doppler (TCD) signals. Signal processing methods (noise removal, segmentation, feature engineering) are reviewed. The most significant ABP and TCD features are identified in predicting postoperative cognitive impairment.

During the study, various artificial intelligence models are implemented and compared - from statistical to hybrid and transformer architectures, using spectrogram and recurrence matrices and feature vectors. The accuracy, fit and F1 score of the models are compared.

The implemented models and data preparation methods showed that for a small dataset consisting of biological signals of different lengths, the best results were achieved using machine learning models with feature vector input.

Turinys

Lentelių sąrašas	8
Paveikslų sąrašas	9
Santrumpų ir terminų sąrašas	10
Įvadas.....	11
1. Metodų, skirtų medicininių laiko eilučių klasifikavimui, analizė	12
1.1. Pooperacinė kognityvinė disfunkcija	12
1.2. Biologinių signalų klasifikavimo metodai.....	12
1.2.1. Statistiniai metodai	13
1.2.2. Mašininio mokymosi metodai	14
1.2.3. Neuroniniai tinklai.....	15
1.2.4. Hibridiniai modeliai.....	17
1.2.5. Transformeriai	19
1.3. Skirtingų ilgių laiko eilučių paruošimo metodai	20
1.3.1. Signalų karpymas (angl. <i>Cropping</i>)	20
1.3.2. Signalų užpildymas (angl. <i>Padding</i>)	21
1.3.3. Slenkančio langelio karpymas (angl. <i>Sliding window cropping</i>)	21
1.3.4. Požymių inžinerija (angl. <i>Feature engineering</i>)	21
1.4. Biologinių signalų rinkinio didinimo metodai	21
1.4.1. Bendras laiko tempimas (angl. <i>Time Warping</i>).....	21
1.4.2. Bendras laiko poslinkis (angl. <i>Time Shifting</i>).....	22
1.4.3. Koreliacinio triukšmo pridėjimas (angl. <i>Correlated Noise Injection</i>).....	22
1.4.4. Langelių ištraukimas (angl. <i>Window Slicing</i>).....	22
1.4.5. Kanalo maskavimas (angl. <i>Channel Masking</i>).....	22
2. Biologinių signalų paruošimo metodai	23
2.1. Duomenys.....	23
2.2. Duomenų rinkinio paruošimas	26
2.2.1. Neapdorotų signalų paruošimas	26
2.2.2. Duomenų rinkinio didinimas	28
2.2.3. Parametrų inžinerija.....	31
2.2.4. Laiko eilučių konvertavimas į vaizdus	34
2.2.5. Laiko eilučių karpymas	35
3. Biologinių signalų klasifikavimo modelių kūrimo metodai.....	36
3.1. Modelių specifikacija	36
3.2. Metrikos.....	37
4. Modelių, skirtų biologinių signalų klasifikavimui, tyrimo rezultatai.....	38
4.1. Statistiniai metodai	38
4.1.1. Paslėptasis Markovo modelis	38
4.2. Mašininio mokymo metodai.....	39
4.2.1. XGBoost.....	39
4.2.2. SVM	41
4.3. Neuroniniai tinklai.....	42
4.3.1. LSTM modelis.....	42

4.3.2. InceptionTime modelis	44
4.4. Hibridiniai neuroniniai tinklai	46
4.4.1. MiniRocket	46
4.5. Transformeriai	47
4.6. Analizuotų modelių tikslumo metrikų palyginimas	49
Išvados	52
Literatūros sąrašas	54

Lentelių sąrašas

1 lentelė. HMM modelių tikslumas.....	39
2 lentelė. XGBoost modelio tikslumas.....	41
3 lentelė. SVM modelio tikslumas	41
4 lentelė. LSTM modelių tikslumas	44
5 lentelė. InceptionTime modelių tikslumas	46
6 lentelė. MiniRocket modelio tikslumas.....	47
7 lentelė. Vit modelių tikslumas	49
8 lentelė. Realizuotų modelių tikslumas	50
9 lentelė. Modelių klasių tikslumo palyginimas	51
10 lentelė. Duomenų paruošimo metodų palyginimas.....	51

Paveikslų sąrašas

1 pav. HMM architektūra.....	13
2 pav. SVM modelis.....	14
3 pav. MiniRocket modelio architektūra.....	15
4 pav. InceptionTime modelio architektūra	16
5 pav. LSTM architektūra	17
6 pav. CNN-RNN nuoseklaus modelio architektūra.....	18
7 pav. CNN-RNN lygiagretaus modelio architektūra	18
8 pav. GTN architektūra.....	19
9 pav. ViT modelio architektūra	20
10 pav. ABP, TCD signalų ir jų koreliacijos koeficiento grafikas.....	24
11 pav. Pacientų amžiaus pasiskirstymo diagrama	24
12 pav. Pacientų mokymosi trukmė metais	25
13 pav. Pacientų lyties pasiskirstymas	25
14 pav. POCD diagnozės pasiskirstymas.....	26
15 pav. Originalaus ir filtruoto ABP (LPF) signalų grafikai	27
16 pav. Originalaus ir filtruoto ABP (LPF) signalų grafikai	27
17 pav. Filtruotų ABP (LPF ir MA) signalų grafikai.....	28
18 pav. Filtruotų TCD (LPF ir MA) signalų grafikai	28
19 pav. Duomenų augmentacija laiko poslinkio metodu	29
20 pav. Duomenų augmentacija mastelio keitimo metodu	30
21 pav. Duomenų augmentacija laiko ištempimo metodu	31
22 pav. Koreliacijos verčių pasiskirstymas tarp klasių	33
23 pav. Koreliacijos rėžių tankio pasiskirstymas tarp klasių	33
24 pav. Koreliacijos signalo spektrograma	34
25 pav. Koreliacijos signalo rekurencijos matrica	35
26 pav. Modelių realizacijos procesų diagrama	36
27 pav. Tikslumo metrikų ataskaita	37
28 pav. HMM_0 (<i>tied</i>) rezultatai	38
29 pav. HMM_1 (<i>full</i>) rezultatai	39
30 pav. Reikšmingiausi XGBoost modelio parametrai.....	40
31 pav. XGBoost rezultatai	40
32 pav. SVM rezultatai	41
33 pav. LSTM_0 modelio architektūra	42
34 pav. LSTM_0 rezultatai	42
35 pav. LSTM_1 modelio architektūra	43
36 pav. LSTM_1 rezultatai	43
37 pav. InceptionTime modelio architektūra	44
38 pav. InceptionTime_0 rezultatai.....	45
39 pav. InceptionTime_1 rezultatai.....	45
40 pav. MiniRocket – XGBoost modelio architektūra.....	46
41 pav. MiniRocket rezultatai	47
42 pav. ViT_0 rezultatai.....	48
43 pav. ViT_1 rezultatai.....	48
44 pav. ViT_2 rezultatai.....	49

Santrumpų ir terminų sąrašas

Santrumpos:

DI – dirbtinis intelektas;

POCD – pooperacinis pažinimo sutrikimas;

ABP – arterinis kraujo spaudimas;

TCD – transkranijinis doplerio signalas;

CAR – smegenų kraujagyslių autoreguliacija;

EEG – elektroencefalograma;

EKG – elektrokardiograma;

NIRS – smegenų oksigenacija.

Įvadas

Senėjančioje visuomenėje vis didėja vyresnio amžiaus pacientų dalis, todėl širdies chirurgijos apimtis auga: daugėja sudėtingų invazinių intervencijų, kuriose palaikyti arterinį kraujo spaudimą (ABP) ir užtikrinti smegenų perfuziją tampa vis didesnis iššūkis [1]. Nepaisant techninės pažangos ir geriau valdomo kardiopulmoninio šuntavimo, pooperaciniai pažinimo sutrikimai (POCD) išlieka dažni – literatūroje nurodoma, kad 10–40 % pacientų kognityviniai gebėjimai pablogėja per pirmąsias savaites po kardiologinės chirurgijos [2].

Pooperacinė kognityvinė disfunkcija (POCD) sukelia kognityvinių funkcijų, tokių kaip dėmesys, kalba, vykdomoji funkcija, vizualinė interpretacija ir motoriniai įgūdžiai, sutrikimą. POCD ne tik blogina paciento gyvenimo kokybę ir pailgina reabilitaciją, bet ir ženkliai didina gydymo kaštus. Jungtinių Amerikos Valstijų duomenimis, pacientų, patiriančių šį sutrikimą, gydymo išlaidos vidutiniškai siekia apie 8 973 USD, o be POCD beveik 35% mažiau – apie 5 914 USD [3].

Tradiciškai POCD rizika vertinama pagal paciento anamnezę, demografinius duomenis (amžių, išsilavinimą) bei neurokognityvinių bandymų rezultatus, atliktus prieš ir po operacijos. Tačiau šie metodai neleidžia sekti dinamiškų smegenų autoreguliacijos pokyčių operacijos metu. Nauja medicininė įranga, tokia kaip „Vittamed 505“, suteikia galimybę fiksuoti intraoperacinius parametrus – arterinį kraujo spaudimui (ABP), transkranijinį doplerio signalą (TCD). Naudojant šiuos duomenis su dirbtinio intelekto algoritmais, galima identifikuoti pacientus, kuriems kyla POCD rizika ir operacijos metu taikyti prevencines priemones.

Tyrimo tikslas – parinkti, realizuoti ir ištirti dirbtinio intelekto modelius, kurie, remdamiesi intraoperaciniais smegenų kraujotakos autoreguliacijos rodikliais (ABP ir TCD signalais), gebėtų prognozuoti pooperacinių pažinimo sutrikimų tikimybę kardiologinės chirurgijos metu.

Uždaviniai:

1. Atlikti išsamią mokslinės literatūros apžvalgą ir įvertinti skirtingų dirbtinio intelekto modelių taikymo galimybes analizuojant medicininės laiko eilutes;
2. Išanalizuoti laiko eilučių paruošimo metodus ir nustatyti labiausiai tinkamas metodikas, kurios padėtų pasiekti atliekamo tyrimo tikslus;
3. Realizuoti dirbtinio intelekto modelius tinkamus pažinimo sutrikimų prognozei bei įvertinti ir palyginti jų tikslumą, nustatyti modelių taikymo apribojimus ir galimybes;
4. Palyginti duomenų paruošimo metodikas, identifikuojant jų taikymo ypatumus ir tinkamumą atitinkamoms dirbtinio intelekto modelių grupėms.

Darbo struktūra:

Darbą sudaro analitinė dalis, kurioje pateikiami literatūros analizės rezultatai; metodologinėje dalyje pristatomi duomenys, jų paruošimo metodikos bei modelių realizavimo aspektai. Eksperimentinėje dalyje pristatomi ir lyginami tyrime nagrinėtų modelių bei duomenų ruošimo metodų rezultatai.

1. Metodų, skirtų medicininių laiko eilučių klasifikavimui, analizė

1.1. Pooperacinė kognityvinė disfunkcija

Pooperacinė kognityvinė disfunkcija (POCD) yra dažna pooperacinė komplikacija po širdies operacijų, pažeidžiančių centrinę nervų sistemą. Ji gali pasireikšti sutrikusiu dėmesiu, kalba, vykdomąja funkcija, vaizdine interpretacija bei motorika [4]. Tokie simptomai kaip nerimas, asmenybės pokyčiai, atminties sutrikimas ir sutrikęs mąstymas turi įtakos atsigavimo laikui, padidina sergamumą ir mirtingumą po operacijos [5].

Nėra vienodų diagnostinių kriterijų POCD vertinti. Keletas neklinikinių tyrimų atskleidė, kad tam tikri rizikos veiksniai, tokie kaip amžius, išsilavinimo lygis, jau esančios ligos, fizinė būklė ir gyvenimo būdas, gali būti susiję su padidėjusia POCD rizika [6]. Kiti veiksniai, tokie kaip anestezijos gylis ir aplinkos triukšmo lygis, buvo kliniškai ištirti ir parodė, kad pernelyg gili anestezija padidina POCD riziką, o intensyvus perioperacinis triukšmas skatina nervinio audinio uždegimą bei kognityvinių funkcijų sutrikimą [7, 8]. Nors šiuo klausimu yra tam tikrų nesutarimų, dažnis yra didžiausias atliekant dideles operacijas, tokias kaip vainikinių arterijų šuntavimas (sutrikimų dažnis svyruoja nuo 10 % iki 80 %) [9]. Visgi, sutariama, kad tikrosios priežastys ir galimi veiksniai, sukiantys POCD, lieka neaiškūs.

Bandomasis klinikinis tyrimas, atliktas B. Kumpaitienės, M. Švagždienės ir kt. LSMU Klinikose ir LSMU Medicinos akademijos Kardiologijos institute rodo, kad neinvazinis smegenų kraujagyslių autoreguliacijos (CAR) stebėjimas galėtų būti naudojamas kaip neurologinių komplikacijų prevencija atliekant širdies operaciją taikant kardiopulmoninį šuntavimą (CPB) [10]. Rezultatai parodė koreliaciją tarp bendros CAR sutrikimo trukmės ir POCD. Tolesni tyrimai atskleidė, kad yra statistiškai reikšminga koreliacija tarp vieno ilgiausio CAR sutrikimo įvykio CPB operacijos metu trukmės ir POCD atsiradimo [11]. Kiti tyrimai patvirtina, kad POCD yra susijęs su padidėjusiu efektyviu smegenų perfuzijos slėgiu, gaunamu iš ABP atėmus kritinį uždarymo slėgį (CrCP) [12]. Nors šie klinikiniai tyrimai identifikavo galimus POCD simptomus sukeliančius veiksniai, prevencijos mechanizmai nebuvo įtraukti ir lieka neaiškūs.

CAR yra homeostatinis procesas, reguliuojantis ir palaikantis smegenų kraujotaką (CBF), atsižvelgiant į arterinį kraujospūdį (ABP) [13]. Laikoma, kad jis sumažėjęs, jei CBF stipriai koreliuoja su ABP. Tuo tarpu maža arba neigiama koreliacija rodo nepažeistą CAR. Sutrikusios CAR vaidmuo stebimas esant trauminiam smegenų sužalojimui, insultui ir pacientams po operacijų, kurios gali sukelti smegenų disfunkciją [14].

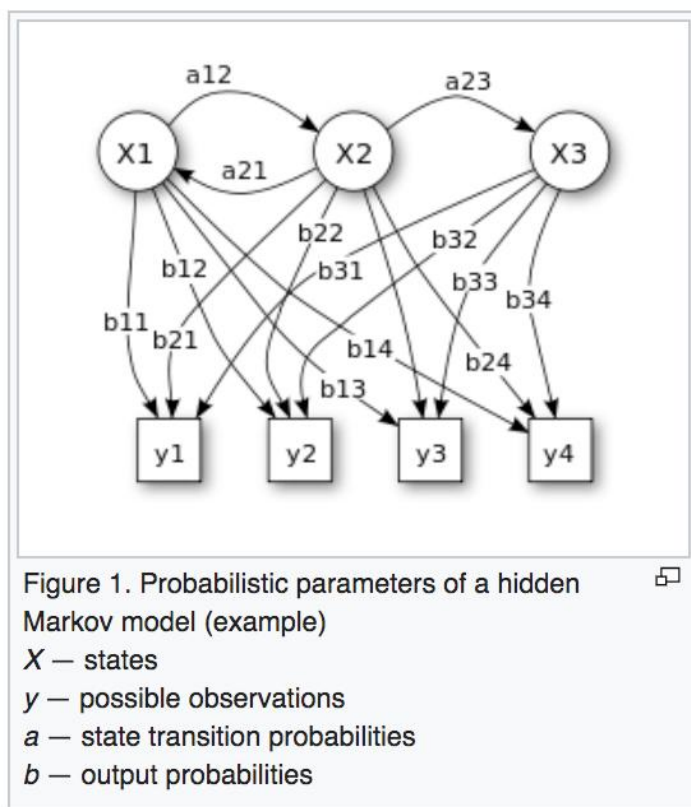
1.2. Biologinių signalų klasifikavimo metodai

Laiko eilučių ir biologinių signalų klasifikavimas – tai metodų visuma, leidžianti atpažinti ir suskirstyti fiziologinių signalų duomenis į kategorijas (pvz., nustatyti patologinius pokyčius ar būsenas). Medicinoje tokie signalai kaip intraoperacinis arterinis kraujospūdis, transkranijinis dopleris, elektroencefalograma (EEG), elektrokardiograma (EKG) ar net netiesioginė smegenų oksigenacija (NIRS) suteikia informacijos apie paciento būklę. Literatūroje pasiūlyta įvairių signalų klasifikavimo metodų, kuriuos galima suskirstyti į kelias kategorijas: statistiniai metodai, tradicinio mašininio mokymosi metodai, neuroniniai tinklai, hibridiniai ir vaizdais grįsti modeliai. Toliau aptariama, kiekviena šių metodų grupių bei jų suderinamumas su duomenimis, kuriuose yra skirtingo ilgio signalai, privalumai bei apribojimai.

1.2.1. Statistiniai metodai

Statistiniai laiko eilučių modeliai, tokie kaip autoregresiniai (AR), ARMA ar ARIMA, yra vieni seniausių signalų analizės metodų. Autoregresinis modelis (AR) signalą aprašo kaip linijinę ankstesnių reikšmių kombinaciją, todėl jį pritaikius biologiniam signalui galima gauti keletą modelio koeficientų, apibūdinančių signalo dinamiką. Siekiant, kad statistinis modelis gerai aprašytų signalo dinamiką, svarbu parinkti tinkamą modelio eilę: per žemos eilės AR modelis neaprašys visų dinaminių komponentų, o per aukštos eilės – imituos ir triukšmą [15]. ARIMA modeliai, papildomai įvertinantys integruotą (kaupiamą) pokytį, plačiau taikomi prognozavimui, tačiau gali būti naudojami ir klasifikavimui netiesiogiai – pavyzdžiui, nustatant, ar signalas nukrypsta nuo prognozuotos normos (anomalijų aptikimas).

Kitas statistinis metodas naudojamas medicininių signalų klasifikavimui – Paslėptasis Markovo Modelis (HMM). Šis modelis pagrįstas tikimybių teorija, todėl jis gali modeliuoti ne tik konkrečius stebėjimus, bet ir tikimybinis jų kitimus ateityje. Tai svarbu klasifikavimo uždaviniuose, kur reikia atsižvelgti į neapibrėžtumą ir tikimybinis procesus. HMM turi būsenų perėjimo tikimybes, kurios leidžia modeliuoti santykį tarp įvairių signalo būsenų įtraukiant kontekstą į klasifikavimą ir atsižvelgti į signalų eigos struktūrą. Šis modelis taip pat gali modeliuoti kelių signalų šaltinių (arba būsenų) kartu egzistavimą. Tai yra svarbu, kai yra keletas biologinių signalų, kurie gali būti susiję su skirtingomis kūno funkcijomis [16]. Paslėptasis Markovo modelis pateiktas 1 pav.



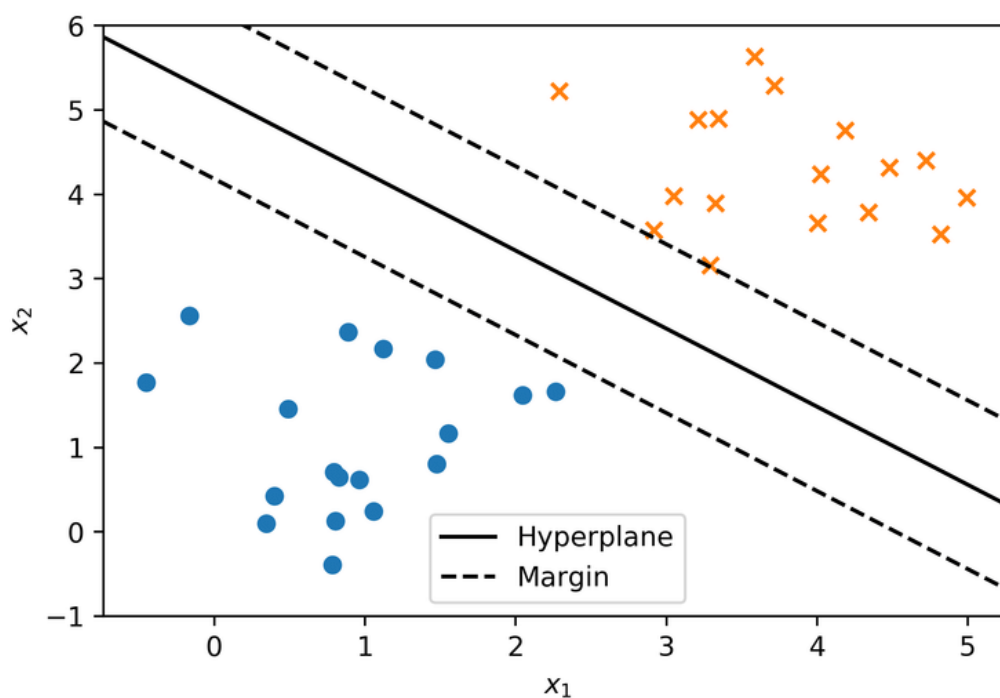
1 pav. HMM architektūra

Statistiniai metodai paprastai reikalauja, kad signalai naudojami modelio mokymui ir testavimui būtų vienodo ilgio. Fiziologiniai signalai dažnai nestacionarūs ir netiesiniai, todėl grynai linijiniai modeliai turi ribotas galimybes: jie neatvaizduoja sudėtingų netiesinių ryšių, būdingų biologiniams signalams.

Statistinių metodų privalumas yra jų paaiškinamumas ir paprastumas. AR/ARIMA modelių parametrai turi aiškia fizikinę interpretaciją, todėl juos lengviau sieti su fiziologiniais procesais [17]. Statistiniams modeliams reikia palyginti nedaug duomenų mokymui, tačiau ribotos galimybės aptinkant netiesinius ryšius sudėtingiems biologiniams signalams lemia žemą klasifikavimo tikslumą.

1.2.2. Mašininio mokymosi metodai

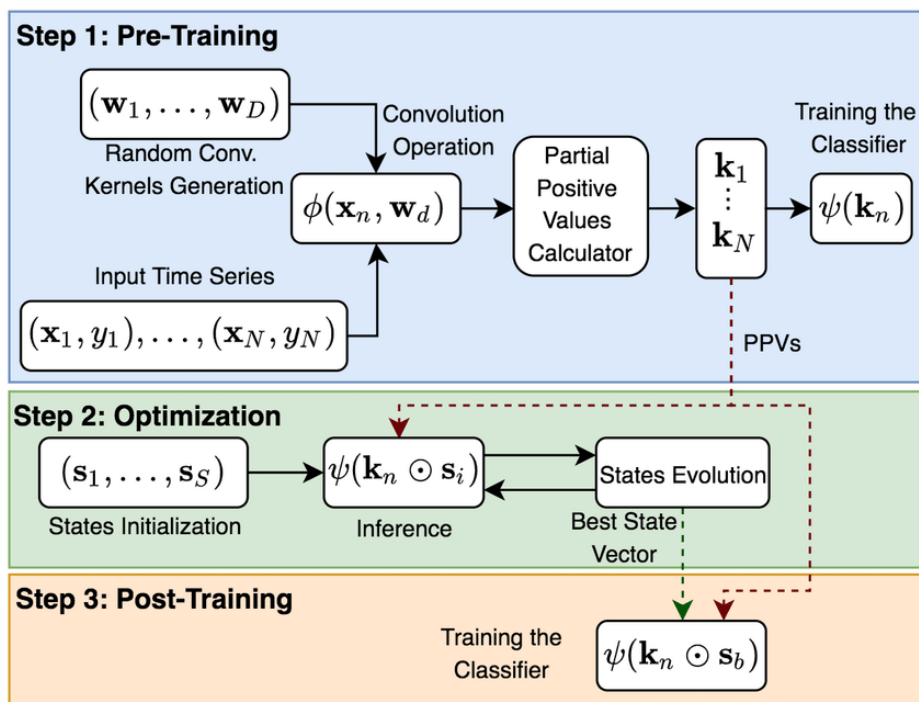
Tradiciniai mašininio mokymosi metodai – tokie kaip atraminių vektorių mašina (SVM), atsitiktiniai miškai (angl. *Random Forest*), gradientiniai algoritmai ir kt. yra plačiai taikomi biologinių signalų klasifikavimo uždaviniams. Šiems metodams būtina parinkti tinkamus požymius iš neapdorotų signalų. Dažnai naudojami standartiniai požymiai: statistiniai (vidurkis, dispersija), spektriniai (galios dažnių juostose), bangelių transformacijų koeficientai, autoregresinio modelio koeficientai. EEG epilepsijos klasifikavimo tyrimuose plačiai taikyti SVM algoritmai su tokiais požymiais kaip bangelių transformacijos energijos arba AR modelio koeficientai [18]. Palaikymo vektorių mašina (SVM) yra mašininio mokymo metodas, naudojamas klasifikacijai ir regresijai, pagrįstas ribos paieška. Jis siekia surasti optimalų sprendimo hiperplokštumą, kuris atskirtų dvi klases ir maksimaliai padidintų atstumą tarp atskiriančių hiperplokštumų ir duomenų taškų. SVM optimizuoja šį atstumą, kad užtikrintų kuo geresnę klasifikaciją. SVM taip pat gali naudoti branduolio funkcijas (angl. *kernel*) netiesiniams duomenims apdoroti (2 pav.)



2 pav. SVM modelis

EKG klasifikavimui klasikiniai algoritmai taip pat demonstruoja puikius rezultatus, literatūroje aprašoma, kaip naudojant ~15 atrinktų požymių ir k-NN klasifikatorių galima pasiekti ~99% tikslumą širdies ligų diagnostikoje pagal EKG [17]. Kitas mašininio mokymo algoritmas naudojamas biologinių signalų klasifikavimui – atsitiktiniai miškai, sujungiantys daugelį sprendimų medžių. Tyrime, kuriame pagal pulso bangos harmoninius rodiklius klasifikuota signalo kokybė, atsitiktinių miškų modelis pasiekė $AUC \approx 0,96$ atskiriant aukštos ir žemos kokybės signalus [19]. Kitas pažangus pavyzdys – XGBoost modelis, pritaikytas ADP bangos analizei operacinėje. Modeliui naudoti

daugiau nei 3000 požymių, išskaičiuotų iš kiekvieno širdies ciklo. Apmokytas XGBoost modelis 15 min. anksčiau įspėjo apie artėjančią hipotenzijos epizodą, pasiekdamas apie 88% tikslumą [20]. Šis rezultatas prilygsta modernių giliųjų modelių tikslumui, parodant, kad teisingai parinkti požymiai su galingais ML klasifikatoriais gali labai daug. MiniRocket. - naujas modelis, kuris remiasi atsitiktiniais konvoliuciniais branduoliais požymių generavimui ir paprastu linijiniu klasifikatoriumi. Šis modelis nereikalauja sudėtingos požymių inžinerijos ir stabiliai veikia net su ribotais duomenų kiekiais [21].



3 pav. MiniRocket modelio architektūra [22]


Tradiciniai mašininio mokymo algoritmai reikalauja fiksuoto dydžio įvesties vektorių, todėl kintančio ilgio signalus būtina transformuoti – skaidyti į vienodo ilgio intervalus arba apskaičiuoti signalų požymių rinkinį. Tai gali būti trūkumas, kai signalų trukmė labai nevienoda arba nėra aišku, kokio ilgio fragmentą naudoti. Taip pat reikalingos ekspertinės žinios požymių parinkimui, o netinkamai parinkti parametrai gali lemti prastą modelio tikslumą. Tradicinių ML modelių pranašumai – galimybė apmokyti modelį su ribotu duomenų kiekiu ir sprendimai lengvai interpretuojami atsižvelgiant į signalo požymių reikšmes.

1.2.3. Neuroniniai tinklai

Gilieji neuroniniai tinklai yra metodų klasė, gebanti tiesiogiai išmokyti požymius iš duomenų. Medicininių laiko eilučių klasifikavime plačiai naudojami tiek konvoliuciniai neuroniniai tinklai (CNN), tiek rekurentiniai tinklai (RNN), įskaitant ilgalaikės trumpalaikės atminties tinklus (LSTM). Skirtingai nei anksčiau minėti metodai, gilieji tinklai gali priimti neparuoštą signalą ir išmokyti hierarchinius požymius bei klasifikavimo taisykles.

Konvoliuciniai neuroniniai tinklai yra giliosios mokymosi architektūros dalis, specializuota erdvinė duomenų analizei. Jų struktūroje yra trys pagrindiniai sluoksniai: konvoliucijos sluoksnis, atraminis sluoksnis ir visiškai sujungtas sluoksnis. Konvoliucijos sluoksnis yra esminis CNN komponentas.

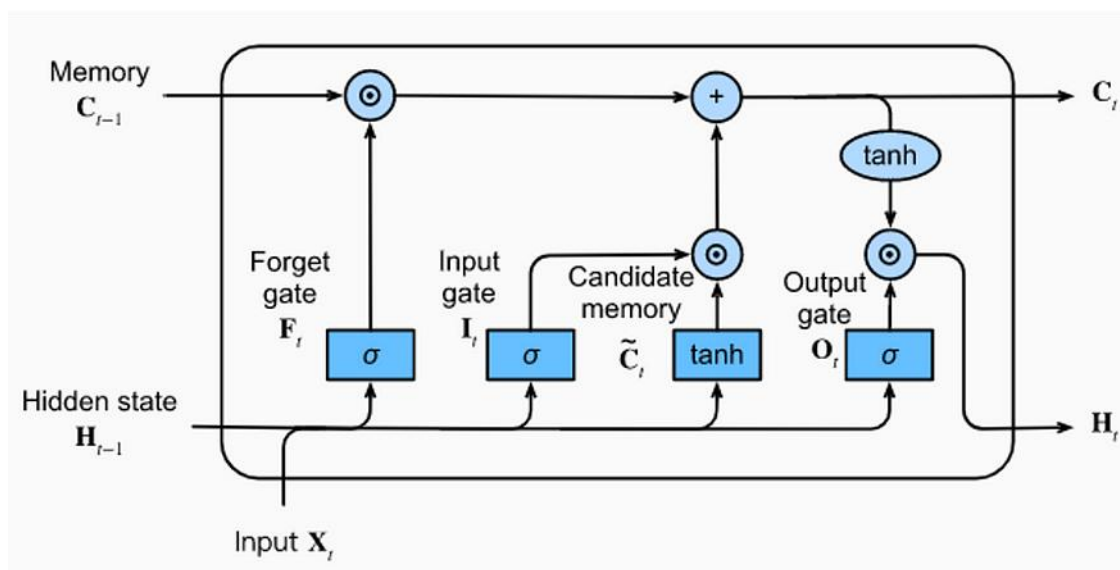
Jame naudojami filtrai, kuriuos vadiname branduoliais, norint atpažinti vietines savybes, pavyzdžiui, kraštus arba tekstūras. Šis sluoksnis leidžia tinklui efektyviai išgryninti savybes iš duomenų. Atraminis sluoksnis naudojamas išlaikyti tinklo hierarchiją ir atlikti neriboto perėjimo (angl. *pooling*), kuris sumažina erdviųjų matmenų dydį, tačiau išlaiko svarbias informacijos savybes. Visiškai sujungtas sluoksnis atlieka galutinį sprendimą arba klasifikavimą. Jame kiekvienas neuronas yra sujungtas su visais ankstesnio sluoksnio neuronais. Nors CNN išpopuliarėjo vaizdų atpažinime, juos galima pritaikyti ir vienmačiams signalams analizuoti. CNN tinklo sluoksniai atlieka slenkančio lango tipo filtravimą per laiko ašį, tokiu būdu identifikuojami morfologiniai signalų bruožai (pavyzdžiui., bangos formos ypatybės) [23]. Toks metodas itin pravartus analizuojant pulsinius signalus (ABP, EKG), kur svarbu atpažinti tipines bangų. Optimalios architektūros modelis gali pasiekti ypač aukštą tikslumą, pavyzdžiui, 34 sluoksnių CNN, klasifikuojantis 12 skirtingų širdies aritmijų iš vieno kanalo EKG – tinklo diagnozių kokybė praktiškai prilygo kardiologų konsiliumo įvertinimams ($AUC \approx 0,97$; vidutinis $F1=0,837$, lyginant su $0,780$ gydytojų) [24]. Tai rodo, kad tinkamai parengtas gilus mokymosi modelis gali išanalizuoti sudėtingas laiko eilutes ir pasiekti aukštą diagnostikos tikslumą. Taip pat ResNet modelis 96% tikslumu atskiria sveikų asmenų smegenų kraujotakos bangas nuo kritiškai sergančių pacientų bangų [25]. InceptionTime – kitas konvoliucinis neuroninis tinklas, sudarytas iš kelių „Inception“ modulių, pritaikytų vienmatėms laiko eilutėms. Kiekvienas modulis taiko skirtingų dydžių filtrus, leidžiančius vienu metu užfiksuoti trumpalaikes ir ilgalaikes sekos savybes (4 pav.). Modelis puikiai tinka biologiniams signalams dėl gebėjimo apdoroti įvairaus mastelio charakteristikas bei didelius duomenų kiekius [26]. EfficientNet V2_S sukurtas pagerinti mokymosi greitį ir našumą. Šis modelis naudoja sujungtus smulkesnius sluoksnius, „įtraukimo ir išmetimo“ mechanizmą bei tinklelio mastelio vienijimą. Didelis modelio našumas leidžia apdoroti didelius medicininių duomenų kiekius [27].



4 pav. InceptionTime modelio architektūra

Rekurentiniai neuroniniai tinklai yra dirbtinių neuroninių tinklų kategorija, specialiai pritaikyta nuosekliems duomenims apdoroti. Skirtingai nuo tradicinių grįžtamųjų neuroninių tinklų, RNN savo architektūroje įtraukia ciklinius ryšius, leidžiančius išiminti praeities įvesčių informaciją. Ši ciklinė struktūra leidžia RNN užfiksuoti laikinąsias priklausomybes, todėl jie puikiai tinka tokioms užduotims kaip laiko eilučių numatymas, natūralios kalbos apdorojimas ir biologinių signalų klasifikavimas. Pagrindinis RNN elementas yra paslėptų būsenų, atspindinčių vidinę atmintį, įtraukimas, kuri atnaujinama, kai tinklas apdoroja nuoseklias įvestis. Ši galimybė išsaugoti informaciją iš ankstesnių veiksmų leidžia RNN modeliuoti dinaminis modelius ir ryšius laiko

eilutėse. Tačiau RNN susiduria su sunkumais mokantis ilgalaikių priklausomybių dėl nykstančios arba sprogstančios gradiento problemos [28]. LSTM ir GRU – tai patobulinti RNN, galintys „prisiminti“ ilgesnius sekų kontekstus dėka vidinių atminties ląstelių ir vartų mechanizmų. Laiko eilučių klasifikacijoje LSTM tinklai leidžia modeliuoti ilgalaikes priklausomybes, pavyzdžiui, jie gali integruoti kelių minučių signalų dinamiką sprendžiant, ar įvykis tam tikras įvykis (pvz., hipotenzija ar priepuolis), ko neįstengtų trumpą segmentą analizuojantys modeliai. GRU yra supaprastinta LSTM versija su mažiau parametru, dažnai treniruojama greičiau. Praktikoje LSTM tinklai taikyti, pavyzdžiui, EEG sekų klasifikavimui į miego stadijas ar priepuolių detekcijai, kur svarbu laike atsekti būsenų perėjimus – šie modeliai parodė pranašumą prieš statinius klasifikatorius dėl gebėjimo išlaikyti kontekstą. Visgi LSTM veikimui reikia pakankamai daug duomenų tinkamam modelio apmokymui [29, 30].



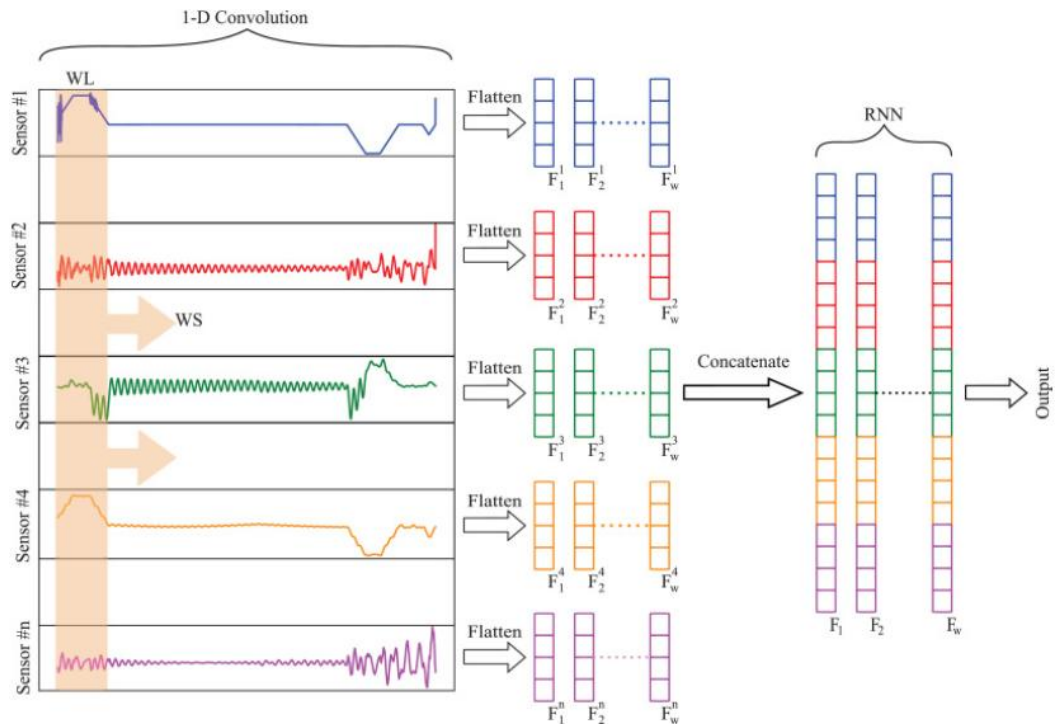
5 pav. LSTM architektūra [31]

Neuroninių tinklai geba išmokti labai sudėtingus, netiesinius ryšius, automatiškai atrasti diagnostinius požymius ir dažnai pasiekia aukščiausią tikslumą, ypač turint didelius duomenų kiekius. Jie gerai prisitaiko prie įvairialypių duomenų – pavyzdžiui, tas pats tinklas gali būti apmokytas su įvairių pacientų duomenimis, tačiau yra didelis skaičiavimų ir duomenų poreikis. Be to, šių modelių sprendimai sunkiau interpretuojami, priešingai nei statistiniai modeliai, jie veikia kaip „juodoji dėžė“.

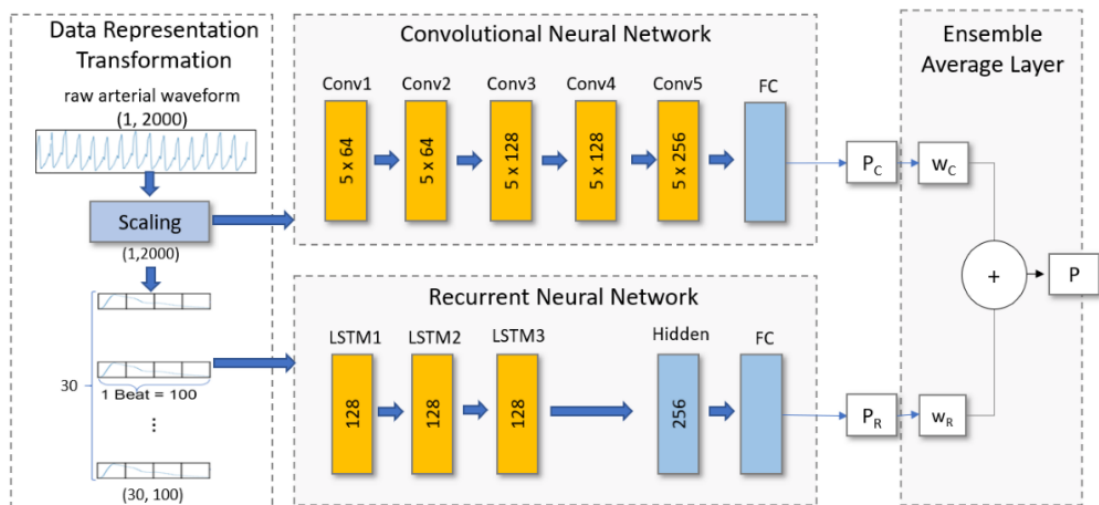
1.2.4. Hibridiniai modeliai

Konvoliuciniai neuroniniai tinklai ir rekurentiniai neuroniniai tinklai gali būti naudojami kartu klasifikuojant biologinius signalus. Toks duomenų apdorojimo modelis sujungia CNN galimybę efektyviai išgryninti erdvesnes charakteristikas su RNN gebėjimu apdoroti ir išgryninti laiko eilučių tendencijas.

Bendras CNN – RNN modelis gali panaudojant abiejų architektūrų stipriąsias puses. CNN gali būti panaudotas išgryninti erdvinės savybes, o gautas požymių vektorius perduodamas RNN, kuris modeliuoja laiko priklausomybę ir ilgalaikį ryšį signaluose (žr. 4 pav.). Arba šie du modeliai klasifikuojantys lygiagrečiai ir rezultatai sujungiami (žr. 5 pav.). Ši integracija gali būti itin naudinga, kai analizuojami sudėtingi biologiniai signalai, kurie reikalauja tiek erdvinės, tiek laiko informacijos [32 – 33].



6 pav. CNN-RNN nuoseklus modelio architektūra [32]



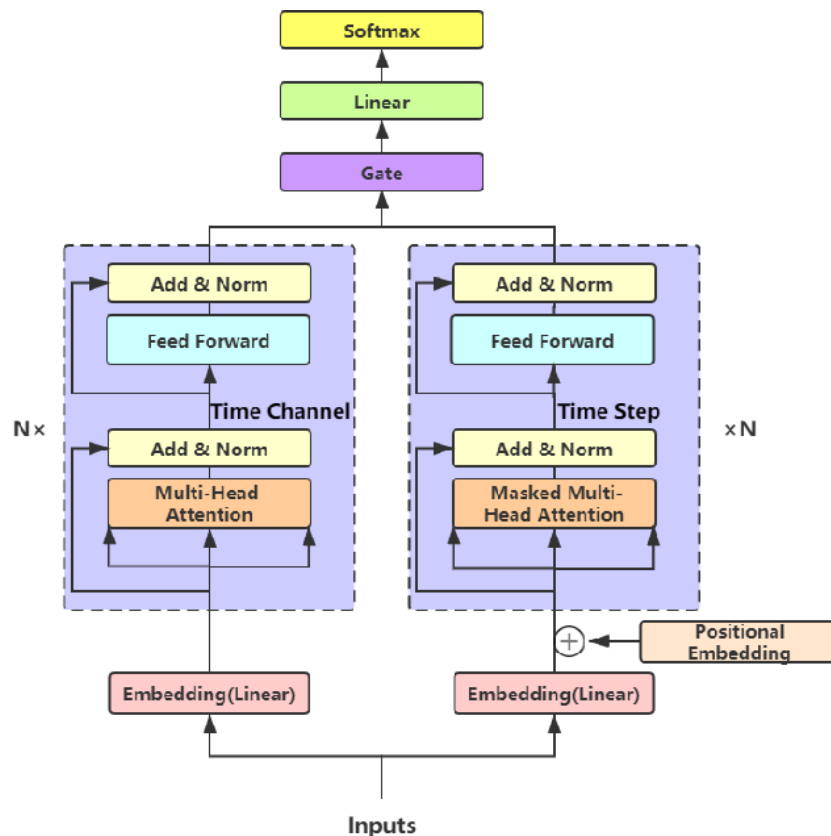
7 pav. CNN-RNN lygiagretaus modelio architektūra [33]

CNN – LSTM architektūroje konvoliuciniai sluoksniai identifikuoja lokalizuotus požymius iš signalo, o LSTM sluoksniai įsimena požymių seką laike, suteikdami modeliui laikinę atmintį [34]. Toks modelis gali “atsiminti” ankstesnes signalo būsenas ir atpažinti klasę pagal dabartinės būsenos pokyčių tendenciją – tai ypač naudinga, pavyzdžiui, nuovargio ar EEG signalų klasifikacijoje, kur svarbu ne vien momentinė būsena, bet ir jos kitimo dinamika.

Hibridiniai modeliai kiekvienam signalų tipui ar duomenų aspektui gali parinkti tinkamiausią architektūrą (pavyzdžiui, CNN erdviniam požymiams, LSTM – laiko sekai) ir taip maksimaliai išnaudoti informaciją. Toks multimodalumas didina ir modelio, tačiau šie modeliai pasižymi sudėtingu apmokymu bei dideliais skaičiavimų sąnaudais. Taip pat, reikalingas dar didesnis duomenų kiekis, kad kiekviena modelio dalis būtų patikimai.

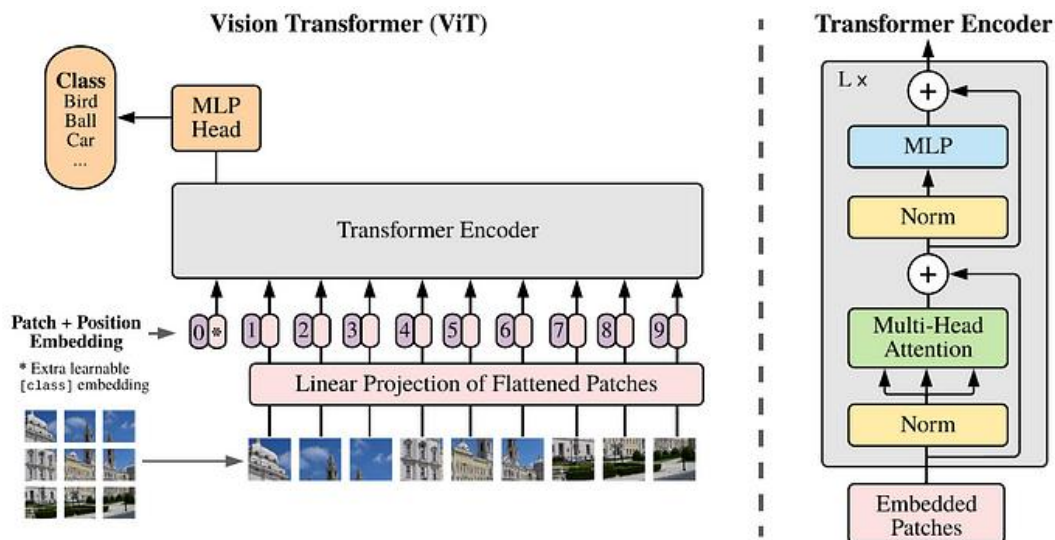
1.2.5. Transformeriai

Gated Transformer Networks (GTN) – tai pažangus dėmesio mechanizmą naudojantis neuroninis tinklas, skirtas laiko eilių duomenų apdorojimui. Modelis puikiai tinka biologinių signalų klasifikacijai: jos aptinka svarbiausias laiko priklausomybes, filtruoja triukšmą ir geba mokytis bei atpažinti tiek trumpalaikius impulsus, tiek ilgalaikes priklausomybes [35].



8 pav. GTN architektūra [35]

ViT-B_16 (Vision Transformer) – tai Transformerių grįsta architektūra, pritaikyta vaizdams, tačiau tinkama ir laiko eilučių klasifikavimui. Biologiniai signalai turi būti konvertuoti į dviejų dimensijų spektrogramas, kurias modelis interpretuoja kaip vaidą [36].



9 pav. ViT modelio architektūra [36]

Transformeriai gerai fiksuoja ilgalaikes priklausomybes ir signalo dinamiką, tačiau jiems reikalingi itin dideli duomenų rinkiniai. Taip pat, dėl savo struktūros gali prasčiau identifikuoti trumpalaikes signalų variacijas bei jų įtaką biologinių signalų klasifikavimo uždaviniui.

Apibendrinant, per pastarąjį dešimtmetį medicininių biologinių signalų klasifikavimo srityje įvyko akivaizdi metodų evoliucija – nuo klasikinių statistinių modelių ir mašininio mokymo algoritmų pereita prie sudėtingesnių giliųjų ir hibridinių architektūrų, gebančių išgauti daugiau informacijos iš duomenų. Statistiniai metodai išlieka naudingi dėl paaiškinamumo, tačiau jų taikymo sritis apsiriboja paprastesniais, labiau stacionariais signalais. Mašininio mokymosi algoritmai su tinkamais atrinktais laiko eilučių požymiais demonstruoja aukštą tikslumą ir gali konkuruoti su giliaisiais neuroniniais tinklais daugelyje uždavinių. Neuroniniai tinklai suteikia galimybę aptikti sunkiai pastebimus signalų dėsningumus. Hibridiniai modeliai sujungia stipriąsias modelių savybes. Kiekviena iš šių kategorijų turi savo nišą ir paskirtį: optimalaus sprendimo parinkimas priklauso nuo turimų duomenų kiekio, problemos sudėtingumo ir paaiškinamumo poreikio. Atsižvelgiant į tyrimo duomenis, daugiausiai potencialo rodo mašininio mokymo metodai, nes neuroniniai tinklai bei vaizdais grįsti modeliai gali būti netinkami dėl mažo duomenų rinkinio, statistiniai metodai – neidentifikuoti sudėtingos biologinių signalų dinamikos.

1.3. Skirtingų ilgių laiko eilučių paruošimo metodai

Dalis dirbtinio intelekto modelių (pavyzdžiui, konvoliuciniai neuroniniai tinklai ir suportu vektoriu mašinos) gali apdoroti tik fiksuoto ilgio duomenis. Biologiniai signalai pasižymi dinamišku signalų ilgiu, kuris priklauso nuo medicininės procedūros trukmės, todėl reikalingi metodai, leidžiantys arba suvienodinti laiko eilučių ilgius, arba išskirti reikšmingus signalų bruožus, kurie būtų naudojami kaip modelių parametrai. Tolesniuose skyriuose apžvelgti dažniausiai taikomi skirtingų ilgio laiko eilučių paruošimo metodai.

1.3.1. Signalų karpymas (angl. *Cropping*)

Jeigu signalas ilgesnis nei modelio leistinas ilgis L , nukerpama pradinė arba galinė jo dalis, siekiant užtikrinti, kad visi signalai duomenų rinkinyje yra vienodo ilgio. Šis metodas gali lemti svarbios

informacijos praradimą, jei lemiantys požymiai yra iškerpamoje signalo dalyje, ypač, jei signalų ilgiai žymiai skiriasi.

1.3.2. Signalų užpildymas (angl. *Padding*)

Kai signalas trumpesnis nei reikiamas ilgis, jo pabaiga arba pradžia pildoma nulinėmis reikšmėmis arba paskutinėmis stebėjimų reikšmėmis, taip išlaikant pradinį fazinį profilį ir užtikrinant vienodą duomenų formatą. Tačiau signalai, kurių ilgis žymiai trumpesnis, gali turėti daug nulinių verčių, tai iškreiptų originalaus signalo dinamiką.

1.3.3. Slenkančio langelio karpymas (angl. *Sliding window cropping*)

Signalas karpomas slenkančiais L ilgio langeliais, taip iš vienos laiko eilutės sukuriant daug atkarpų. Kiekvienai iš jų modelis pateikia atskiras prognozes. Dominuojanti prognozė nulemia bendro signalo klasifikavimo rezultata. Šis metodas leidžia įvertinti visą signalo dinamiką, tačiau jei reikšmingi požymiai yra tik mažoje dalyje langelių, galutinis rezultatas bus parinktas pagal daugumą.

1.3.4. Požymių inžinerija (angl. *Feature engineering*)

Iš kintamo ilgio signalų generuojami fiksuoto ilgio požymių vektoriai: statistinės charakteristikos (vidurkis, dispersija, asimetrijos koeficientas, ekscesas), spektrinės savybės, energija ir pan. Šis metodas leidžia išskirti svarbias signalo charakteristikas, tačiau reikalauja ekspertinių žinių apie taikymo sritį bei kokie parametrai gali būti reikšmingi.

Apibendrinant, karpymas suteikia greitą būdą fiksuoti signalų ilgį, tačiau kelia riziką pašalinti svarbią informaciją. Užpildymas išlaiko visą pradinę signalų struktūrą ir fazinį profilį, tačiau ypač trumpas sekas papildo nereikšmingais nuliais. Slenkamasis langelis leidžia įvertinti visą signalą, bet galutinį sprendimą nulemia dominuojanti fragmentų prognozė. Požymių inžinerija išgauna kompaktišką, informatyvų bruožų rinkinį. Tyrimo duomenų rinkinį sudarančių signalų ilgis gali skirtis net du kartus, todėl karpymas bei užpildymas nėra tinkamos metodikos, o slenkančio langelio karpymas ir požymių inžineriją gali lemti geriausius rezultatus.

1.4. Biologinių signalų rinkinio didinimo metodai

Tyrimo naudojamame duomenų rinkinyje yra 57 pacientai, turimų signalų kiekis nėra didelis, tai gali apriboti klasifikavimui skirtų modelių pasirinkimą, todėl neretai naudojamos duomenų kiekio didinimo (augmentacijos) metodikos. Jei modelio uždavinys yra klasifikuoti biologinius signalus remiantis jų tarpusavio sąveika, augmentacija turi būti atliekama ypač atsargiai, kad nebūtų iškraipyti signalų tarpusavio ryšiai. Tolesniuose skyriuose aptarti dažniausiai taikomi augmentacijos metodai.

1.4.1. Bendras laiko tempimas (angl. *Time Warping*)

Laiko tempimo metu kiekvienas signalas pailginamas arba sutrumpinamas pagal tą patį tempimo koeficientą, taip išsaugant fazinę abiejų kanalų tarpusavio padėtį. Praktikoje dažnai taikoma atsitiktinio koeficiento transformacija, vykdančią ją sinchroniškai abiem signalams. Šis metodas leidžia modelyje imituoti įvairius ritminius pokyčius be tarpusavio koreliacijos praradimo.

1.4.2. Bendras laiko poslinkis (angl. *Time Shifting*)

Vienodas abiejų signalų poslinkis laiko ašyje (pavyzdžiui, ± 10 sekundžių), išlaikantis jų tarpusavio sinchronizaciją. Naudojamas imituoti vėlavimus arba ankstyvus įvykius, tačiau turi būti ribojamas taip, kad svarbios patloginės fazės nebūtų nustumto už stebėjimo lango ribų.

1.4.3. Koreliacinio triukšmo pridėjimas (angl. *Correlated Noise Injection*)

Pridedamas gausinis triukšmas, generuojamas iš bendro latentinio proceso, todėl abiejuose signalų kanaluose triukšmo komponentai yra dalinai koreliuoti. Tai padeda išlaikyti tiek autokoreliaciją, tiek jų tarpusavio koreliaciją.

1.4.4. Langelį ištraukimas (angl. *Window Slicing*)

Atsitiktinių signalų fragmentų pašalinimas iš abiejų kanalų. Tokiu būdu modelis mokomas atpažinti ir trumpesnius pacientų būklės epizodus, tuo pat metu neprarandant sinchronizacijos.

1.4.5. Kanalo maskavimas (angl. *Channel Masking*)

Atsitiktinai pašalinamas nedidelis vieno signalo fragmentas, o kitas paliekamas nepakitęs, Taip modelis apmokomas atlikti prognozę net ir praradus dalį informacijos. Kad tarpusavio sąveika neišsikraipytų, masyvai pasirenkami taip, kad maskavimas nesutaptų su lemiančiomis abiejų signalų fazėmis.

Apibendrinant, laiko tempimas ir laiko poslinkis – geriausiai išlaiko signalų tarpusavio sąveiką. Langelį ištraukimas leidžia mokyti modelį trumpesniems epizodams be dinamikos iškreipimo, tačiau kaip ir kanalo maskavimas gali pašalinti iš signalų reikšmingiausią informaciją.

2. Biologinių signalų paruošimo metodai


2.1. Duomenys

Tyrimo duomenys gauti stebint pacientų galvos smegenų kraujotakos autoreguliacijos signalus kardiologinių operacijų metu Lietuvos sveikatos mokslų universiteto ligoninėje Kauno klinikose naudojant neinvazinį smegenų kraujotakos autoreguliacijos stebėjimo prietaisą „Vittamed 505“. Tyrimas apima aštuoniasdešimt pacientų, nė vienam iš jų nebuvo diagnozuotas joks neurologinis sutrikimas. Visi pacientai buvo įvertinti naudojant neuropsichologinius testus dieną prieš operaciją ir 10 dienų po operacijos, siekiant nustatyti POCD simptomus (Mini Mental State Evaluation, Rey klausos verbalinio mokymosi testas, skaitmenų intervalo testas, skaitmenų simbolių pakeitimo testas ir Schulte lentelė). Be kraujotakos autoreguliacijos signalų taip pat fiksuotas pacientų amžius, lytis, išsilavinimas (mokymosi trukmė metais). Galutinį duomenų rinkinį sudaro duomenys apie 57 pacientus, kuriems nepasireiškė pažinimo funkcijų pablogėjimas ir 11 pacientų patyrusių POCD. Operacijos trukmė varijavo nuo 2,8 iki 5,8 valandos.

Kognityvinės funkcijos sutrikimo prognozė remiasi dviem signalais:

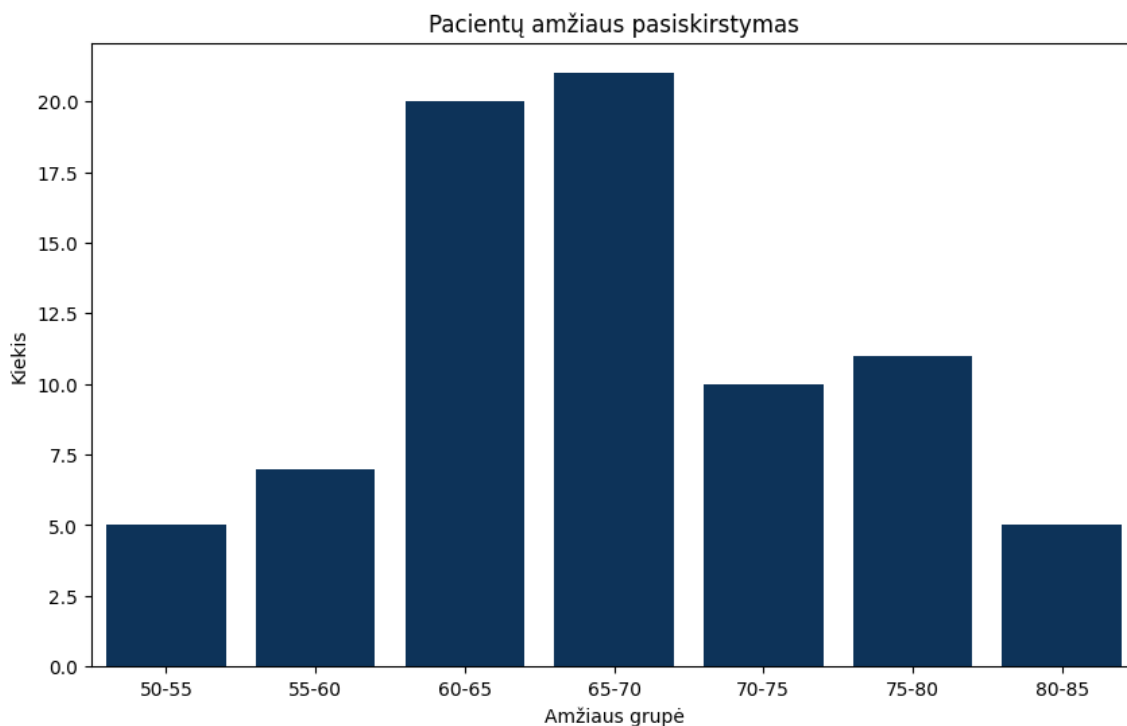
5. Arterinis kraujospūdis (ABP) yra slėgis į arterijų sienelės. Jis išreiškiamas dviem reikšmėmis: sistolinis slėgis (didesnis skaičius), kuris rodo spaudimą širdies susitraukimo metu, ir diastolinis slėgis (mažesnis skaičius), kuris rodo spaudimą, kai širdis yra ramybės metu tarp dūžių [37].
6. Transkranijinis dopleris (TCD) leidžia išmatuoti kraujo tėkmės greitį pagrindinėse arterijose, suteikiant vertingos informacijos apie smegenų hemodinamiką. TCD signalas yra naudojamas klinikinėje aplinkoje įvairiems tikslams, įskaitant smegenų kraujotakos įvertinimą, stebėjimą operacijos metu ir būklių, tokių kaip insultas ir kraujagyslių spazmas, tyrimą [38].
TCD signalo ištakos gali būti siejamos su doplerio ultragarso technologijos kūrimu ir jos taikymu tiriant kraujotaką smegenų arterijose. Doplerio efektas, apimantis bangos dažnio arba bangos ilgio pasikeitimą stebėtojo, judančio jos šaltinio atžvilgiu, naudojamas kraujo tėkmės greičiams matuoti. Esant TCD, ultragarso bangos perduodamos per kaukolę, o atsispindėjusių bangų dažnio poslinkis nuo judančių raudonųjų kraujo kūnelių naudojamas kraujo tėkmės greičiui apskaičiuoti.

Paciento arterinio kraujospūdžio, transkranijinis doplerio signalų ir jų koreliacijos koeficiento kitimas pateiktas 10 pav.

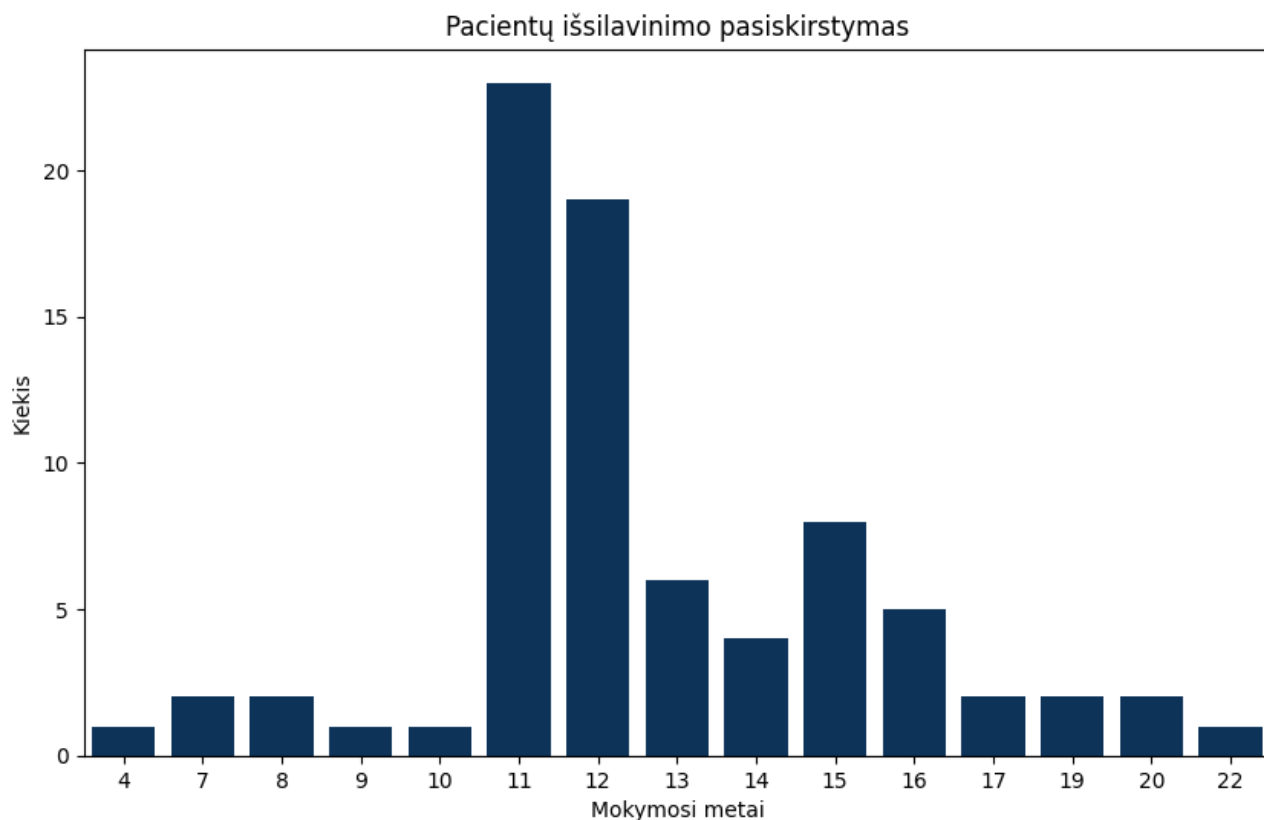


10 pav. ABP, TCD signalų ir jų koreliacijos koeficiento kitimo grafikas

Duomenų rinkinį taip pat sudaro pacientų demografiniai duomenys, tokie kaip amžius, lytis bei išsilavinimas (mokslams skirti metai). Duomenų pasiskirstymas pagal minėtus parametrus pateiktas 11 – 14 pav. Didžioji dalis pacientų yra amžiaus grupėje nuo 60 iki 70 metų.




11 pav. Pacientų amžiaus pasiskirstymo diagrama




12 pav. Pacientų mokymosi trukmė metais

Mokymosi trukmės vidurkis ir mediana yra tarp 11 ir 12 metų. Šie rodikliai gali lemti ir pradinį paciento kognityvinių funkcijų kokybės lygį, todėl šis parametras svarbus vertinant galimą POCD riziką.



13 pav. Pacientų lyties pasiskirstymas

Apie 25% pacientų sudaro moterys, 12,5% savo lyties nenurodė, o daugiau nei 60% pacientų yra vyrai. Jei bus nustatytas statistinis skirtumas tarp lyčių ir rizikų pasireikšti POCD, šios klasės turės būti subalansuotos arba atskirtos į atskirus modelius.



14 pav. POCD diagnozės pasiskirstymas

Pradiniame duomenų rinkinyje 33 pacientai, kuriems pasireiškė pooperacinis pažinimo funkcijos sutrikimas (klasė 1), 24 pacientams diagnozė nenustatyta (klasė 0), o 23 pacientų būklė nebuvo įvertinta tinkamai. Tyrimo duomenų rinkinį sudaro tik 0 ir 1 klasių pacientai.

2.2. Duomenų rinkinio paruošimas

2.2.1. Neapdorotų signalų paruošimas

Nepriklausomai nuo duomenų paruošimo metodo, biologiniuose signaluose yra triukšmo, kuris šalinamas nuosekliai pritaikant duomenų valymo filtrus:

1. Žemų dažnių filtras (angl. *Low-Pass Filter, LPF*) praleidžia žemo dažnio signalus, tuo pačiu slopinant aukšto dažnio komponentes. Filtras naudojamas biomedicinos inžinerijoje, kai reikia pašalinti nepageidaujamus aukšto dažnio triukšmus ar interferencijas [39, 40];
2. Slenkančio vidurkio filtras (angl. *Moving Average Filter*) naudojamas signalo triukšmui sumažinti arba signalui išlyginti [41 – 42].

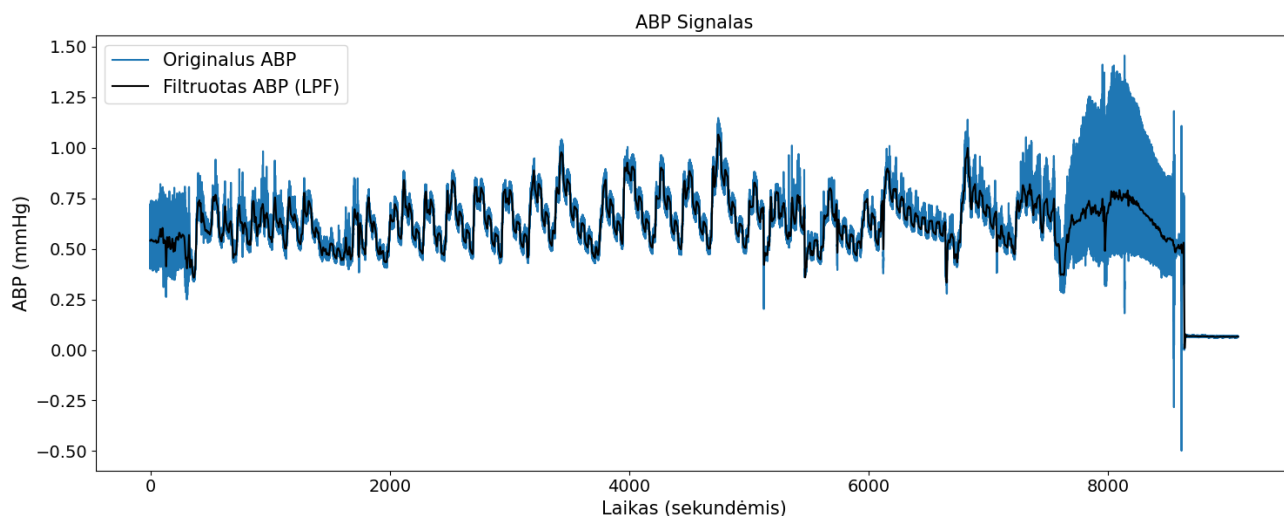
2.2.1.1. Žemų dažnių filtras

Signalų apdorojimui naudojamas 5 eilės Batervorto (angl. *Butterworth*) filtras su 0,1 Hz ribiniu dažniu (angl. *cutoff*) dėl lygaus dažnių atsako ir minimalaus signalo iškraipymo. Filtro atsakas apskaičiuojamas pagal (1) išraišką:

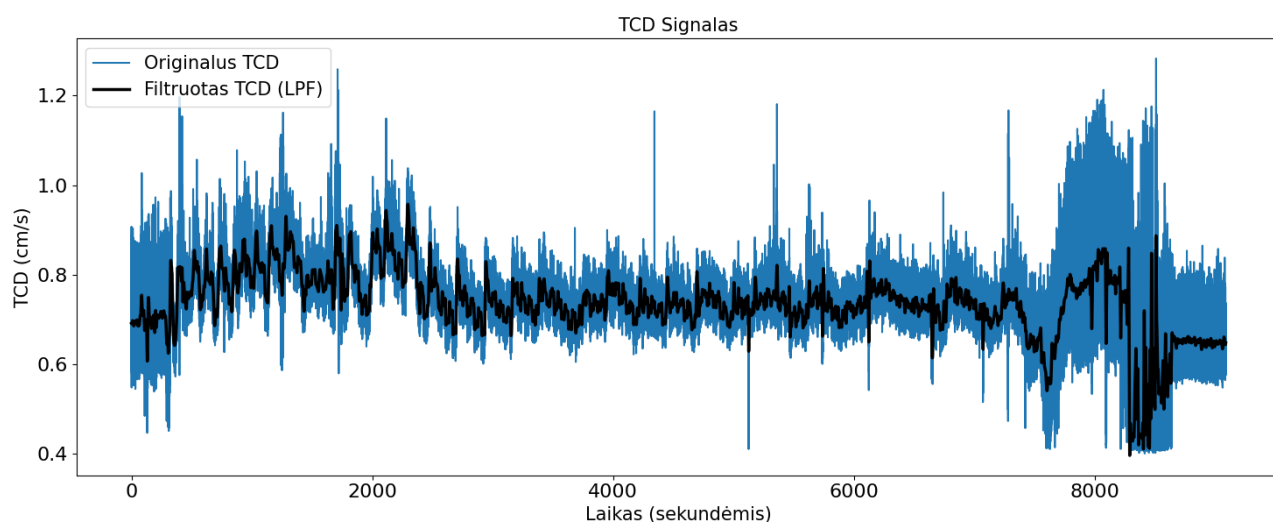
$$H(s) = \frac{1}{\sqrt{1 + \left(\frac{f}{f_c}\right)^{2n}}} \quad (1)$$

f – filtruojamas dažnis, f_c – ribinė dažnio reikšmė, n – filtro eilė.

Pradinių ir apdorotų signalų grafikai pateikti 15 – 16 pav. Naujai gauti signalai yra kur kas glotnesni ir turiu mažiau triukšmo.



15 pav. Originalaus ir filtruoto ABP (LPF) signalų grafikai



16 pav. Originalaus ir filtruoto ABP (LPF) signalų grafikai

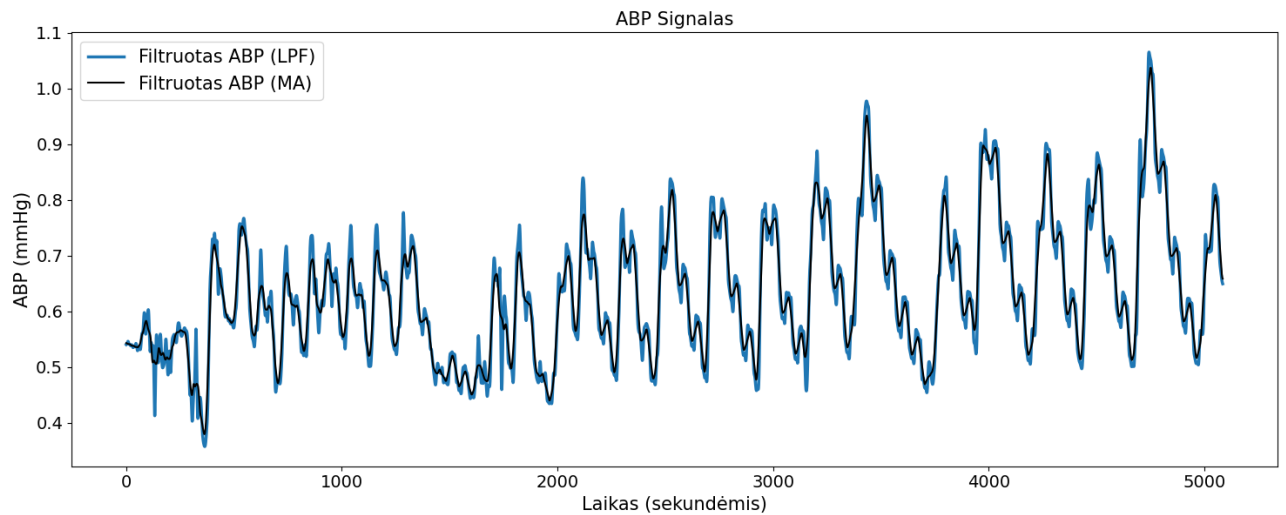
2.2.1.2. Slenkančio vidurkio filtras

Signalų apdorojimo procese slenkančio vidurkio filtras naudojamas 30 sekundžių lango dydis. Filtras veikia apskaičiuodamas vidutinę tam tikro dydžio lango signalų reikšmę ir ją priskirdamas centriniam lango elementui [41 – 42] (žr. (2) išraišką):

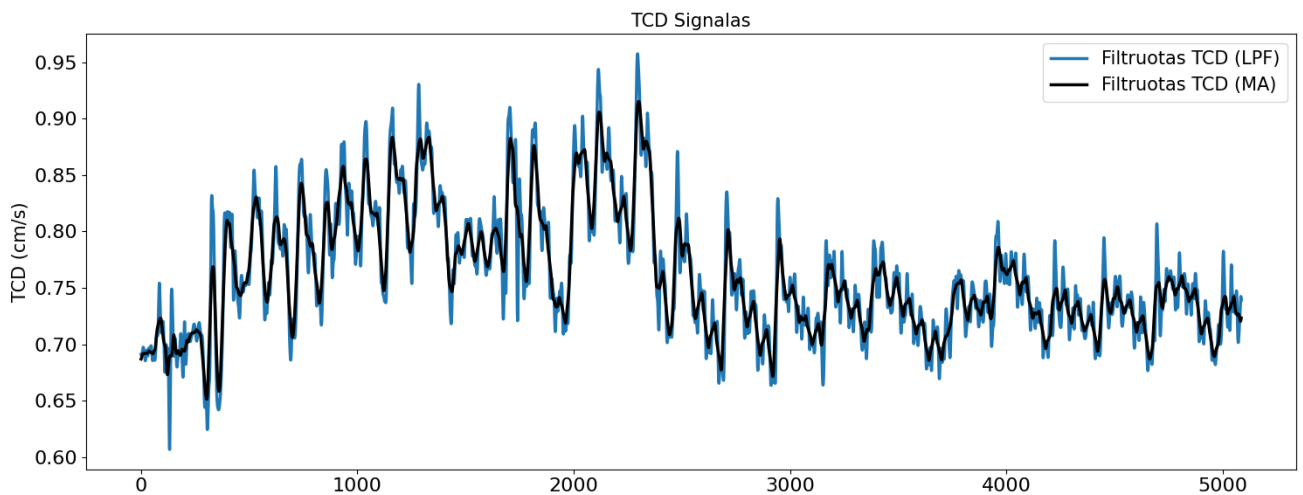
$$y[n] = \frac{1}{M} \sum_{k=0}^{M-1} x[n - k] \quad (2)$$

M – filtro lango dydis, $x[n]$ – filtruojamas signalo taškas, $y[n]$ – gauta vidutinė filtruojamo režio reikšmė.

Signalų apdorojimo procese slenkančio vidurkio filtras naudojamas 30 sekundžių lango dydis. Gauti signalai pavaizduoti 17 – 18 pav. Grafiko mastelis pakeistas dėl aiškesnio vaizdavimo.



17 pav. Filtruotų ABP (LPF ir MA) signalų grafikai



18 pav. Filtruotų TCD (LPF ir MA) signalų grafikai

Naujai gautuose signaluose žemų dažnių filtras pašalina aukšto dažnio triukšmą, išlaikant reikšmingas signalų tendencijas. Slenkantis vidurkis dar labiau sumažina atsitiktinius svyravimus bei triukšmą, kurį sukėlė naudota medicininė įranga.

2.2.2. Duomenų rinkinio didinimas

Signalų karpymas slenkančiu langu gali iškraipyti rezultatus, nes kritinis momentas, kuris lemia POCD nėra žinomas. Realizuotas duomenų kiekio didinimas struktūra grįstais metodais (angl. *Pattern-Based methods*):

3. Laiko poslinkio;
4. Mastelio;
5. Laiko ištempimo.

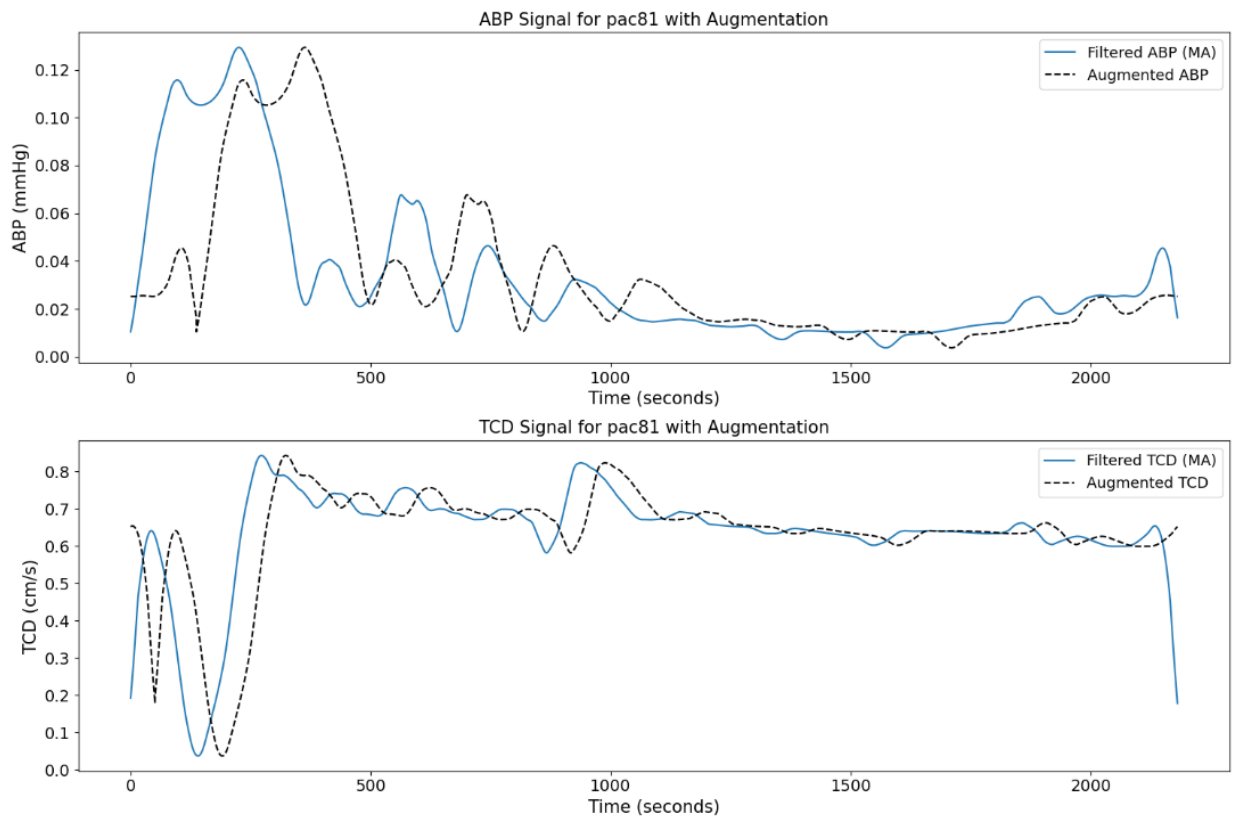
Šie metodai pasirinkti tam, kad būtų kuo mažiau iškraipomi originalūs signalai ir nebūtų prarasta signalų tarpusavio sąveika, kuri ir lemia POCD riziką.

2.2.2.1. Laiko poslinkio metodas

Laiko poslinkio metodas (angl. *Time Shifting*) – laiko eilutės duomenys paslenkami tam tikru laiko intervalu. Šis metodas išlaiko signalo amplitudės ir dažnio informaciją, tačiau keičia laiko ašį, perkeldamas duomenis pirmyn arba atgal (15 pav.).

$$x_p(t) = x(t - \Delta t) \quad (3)$$

$x_p(t)$ – nauja signalo reikšmė t laiko momentu, Δt – laiko poslinkis



19 pav. Duomenų augmentacija laiko poslinkio metodu


Naudojant laiko poslinkio augmentaciją, tiek ABP, tiek TCD signalai išlaiko savo pagrindinę dinamiką, tačiau yra aiškiai poslinkis laiko ašyje. Augmentuotose kreivėse (juodos punktyrinės linijos) matosi, kad pikų formas ir aukščiai beveik nesikeičia.

2.2.2.2. Mastelio keitimo metodas

Mastelio keitimas (angl. *Scaling*) yra metodas, kai signalo amplitudė padauginama iš tam tikros konstantos. Tai keičia signalo amplitudės lygį, bet išlaiko jo laiko struktūrą. Metodo signalo amplitudės skaičiavimuose naudojama (4) išraiška:

$$x_{sc}(t) = \alpha \cdot x(t) \quad (4)$$

$x_{sc}(t)$ – nauja signalo reikšmė t laiko momentu, α – mastelio koeficientas



20 pav. Duomenų augmentacija mastelio keitimo metodu

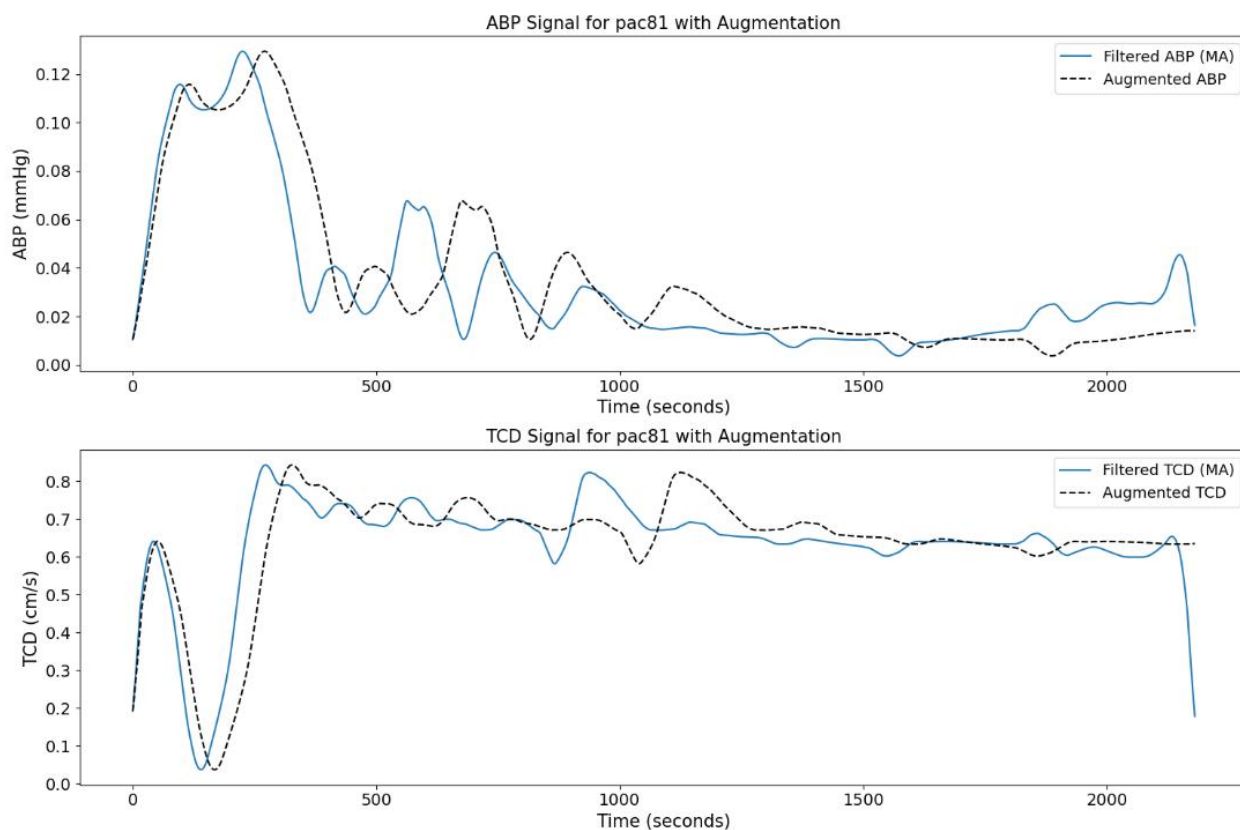
2.2.2.3. Laiko ištempimo metodas

Laiko ištempimas (angl. *Time Stretching*) yra metodas, kai signalo laiko ašis yra ištempama arba suspaudžiama, keičiant signalo greitį. Tai keičia signalo laiko struktūrą, bet išlaiko jo formą ir dažnio turinį. Naujai signalo reikšmei skaičiuoti metode naudojama (5) išraiška:

$$x_{st}(t) = x(t \cdot \alpha) \quad (5)$$

x_{st} – nauja signalo reikšmė t laiko momentu, α – laiko ištempimo koeficientas.

Kai $\alpha > 1$, signalas ištempiamas, kai $\alpha < 1$ – suspaudžiamas.



21 pav. Duomenų augmentacija laiko ištempimo metodu

2.2.3. Parametrų inžinerija

Parametrų inžinerija yra labai svarbus mašininio mokymosi ir signalų apdorojimo žingsnis, ypač dirbant su laiko eilučių duomenimis, tokiais kaip ABP ir TCD signalais. Šiame tyrime iš neapdorotų signalų buvo išskirtas išsamus funkcijų rinkinys, siekiant pagerinti modelio gebėjimą užfiksuoti svarbius modelius ir ryšius. Iš šių signalų apskaičiuotos funkcijos skirtos apibūdinti jų statistines savybes, dinaminę elgesį ir laiko ryšius, kartu įtraukiant paciento metaduomenis. Šiame skyriuje pateikiama apskaičiuotų funkcijų apžvalga, jų potenciali svarba ir patvirtinančios nuorodos iš darbo rengimo metu prieinamos literatūros.

2.2.3.1. Statistinės funkcijos

Statistinės funkcijos yra esminės norint užfiksuoti signalų tendenciją, dinamiką ir pasiskirstymą. Šios funkcijos apskaičiuojamos tiek ABP, tiek TCD signalams, taip pat jų išvestinėms koreliacijoms. Pagrindinės statistinės funkcijos apima:

- Vidurkis: vidutinė signalo vertė, kuri suteikia bendrą signalo centrinės vertės supratimą. Tai dažnai naudojama klasifikavimo užduotyse kaip bazinis signalo amplitudės.
- Standartinis nuokrypis (std): Signalų sklaidos arba kintamumo matas. Signalai su didesniu standartiniu nuokrypiu paprastai turi daugiau svyravimų, kurie gali būti svarbūs atskiriant tam tikras širdies ligas ar įvykius.
- Mažiausia ir didžiausia reikšmės: Minimali ir maksimali signalo vertės, nurodančios jo amplitudės diapazono ribas. Šios savybės padeda apibūdinti signalo elgsenos kraštutinumus, kurie gali būti susiję su tam tikromis fiziologinėmis sąlygomis.

- Asimetrija ir ekscesas: Šios dvi savybės apibūdina signalo pasiskirstymo formą. Asimetrija matuoja asimetriją, o ekscesas fiksuoja signalo ištempimą arba išskirtinių verčių buvimą duomenyse.

2.2.3.2. Energija ir entropija

- Energija: Signalų energija apskaičiuojama kaip jo kvadratinių verčių suma, atspindinti bendrą signalo stiprumą. Tai plačiai naudojama funkcija laiko eilučių klasifikavime, nes stipresni signalai paprastai rodo reikšmingesnius fiziologinius įvykius.
- Entropija: entropija kiekybiškai įvertina signalo nenuspėjamumą ar netvarkos kiekį. Didelės entropijos vertės rodo, kad signalas yra labiau chaotiškas arba nenuspėjamas, o tai gali būti naudinga nustatant nenormalius įvykius ar sutrikimus.

Šios dvi savybės, energija ir entropija, yra svarbios norint nustatyti ir atskirti reguliarius ir netaisyklingus signalo modelius fiziologinio stebėjimo metu.

2.2.3.3. Išvestinės savybės

Signalų išvestinė fiksuoja kitimo greitį laikui bėgant, o tai yra labai svarbu norint suprasti fiziologinių procesų dinamiką.

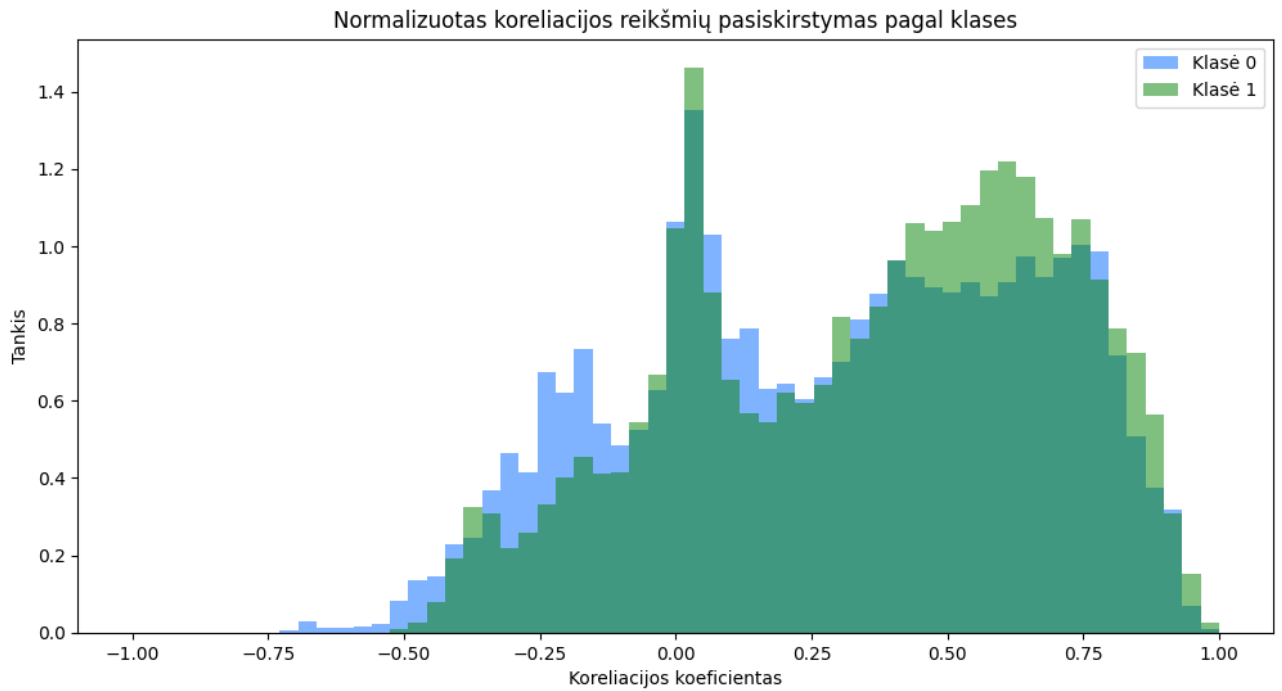
- Išvestinės vidurkis ir standartinė vertė: šios savybės rodo signalo kitimo greičio vidutinį pokytį (vidurkį) ir kintamumą (standartinį nuokrypį). Didesnė vidutinė išvestinė gali rodyti greitesnius arba staigesnius signalo pokyčius, o didesnis standartinis nuokrypis rodo didesnį signalo kitimo greičio kintamumą.

2.2.3.4. Slenkanti koreliacija

Slenkanti koreliacija yra technika, naudojama dviejų signalų ryšiui laikui bėgant užfiksuoti. Šiame tyrime slenkančios koreliacijos tarp ABP ir TCD signalų buvo apskaičiuotos naudojant slenkančio lango metodą (skaičiuota 3 minučių intervale). Kiekvienam koreliacijos langui skaičiuota:

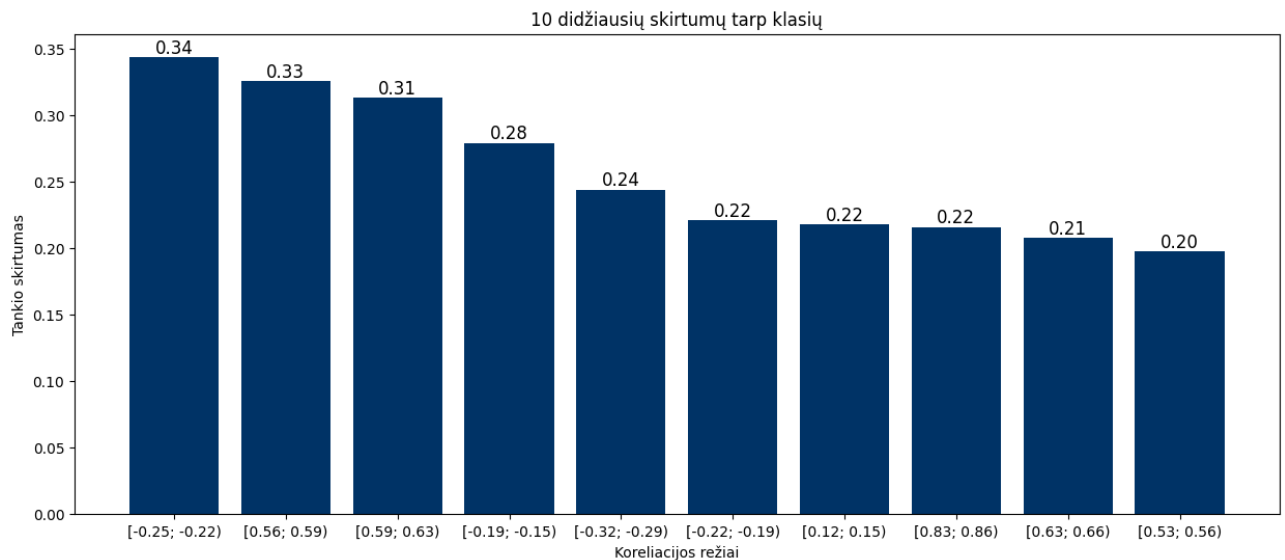
- Laikotarpių skaičius, ilgiausias laikotarpis, bendra trukmė: šios savybės leidžia suprasti signalų laiko charakteristikas, tokias kaip konkrečių įvykių ar signalų modelių trukmė ir nuoseklumas;
- Koreliacijos koeficientas: koreliacijos koeficientas matuoja tiesinio ryšio tarp ABP ir TCD signalų stiprumą ir kryptį. Aukštos koreliacijos vertės rodo, kad abu signalai turi panašius laiko modelius, o tai gali rodyti sinchronizuotus fiziologinius įvykius, o žemos koreliacijos vertės gali rodyti disociuotus įvykius;

Nustatant POCD riziką atsižvelgiama į biologinių signalų sąveiką. Aukšta koreliacija didina sutrikimo tikimybę. Siekiant išanalizuoti koreliacijos skirtumus tarp klasių (1 – pasireiškė sutrikimas, 0 – pacientui POCD nenustatyta) ieškota, kokios koreliacijos verčių reikšmės geriausiai atskiria signalus. Analizės rezultatai pateikti 22 – 23 pav. X ašyje pateiktos koreliacijos koeficiento reikšmės, Y – normalizuotas dažnių tankis (tikimybės tankis).



22 pav. Koreliacijos verčių pasiskirstymas tarp klasių

22 pav. pateikta koreliacijos verčių pasiskirstymo diagrama, pirminė hipotezė, jog aukšta koreliacija (aukštesnė nei 0.6) lemia sutrikimą – nepasitvirtina. Abiejų klasių elementai pasižymi dažnomis aukštos koreliacijos reikšmėmis, negalima išskirti slenkstinio koeficiento reikšmės. Tačiau diagramoje matomi režiai, kuriuose yra didžiausias skirtumas tarp klasių. Šių skirtumų įverčiai pavaizduoti 23 pav.



23 pav. Koreliacijos režių tankio pasiskirstymas tarp klasių

23 pav. pažymėti koreliacijos koeficiento režiiai, kuriuose skirtumas tarp klasių didžiausias:


1. [-0,25; -0,22];
2. [0,56; 0,59];
3. [0,59; 0,63].

Parametrų inžinerijos etape skaičiuojama bendra trukmė, kiek laiko koreliacijos koeficiento reikšmė buvo tarp šių režių. Ilgiausias periodas šiame intervale ir kiek kartų signalų tarpusavio sąveika buvo šiuose intervaluose. Taip pat įtrauktos bendros statistinės, išvestinės bei energijos charakteristikos. Šios vertės įtraukiamos į galutinį parametrų rinkinį.

2.2.4. Laiko eilučių konvertavimas į vaizdus

Nors vaizdais grįsti modeliai reikalauja didelių duomenų kiekių, tyrimo metu išbandytos ir šios architektūros. Ruošiant duomenis, laiko eilutes (ABP, TCD koreliacijos signalai) keistos į spektrogramas bei rekurencijos matricas (angl. *Recurrence plot*).

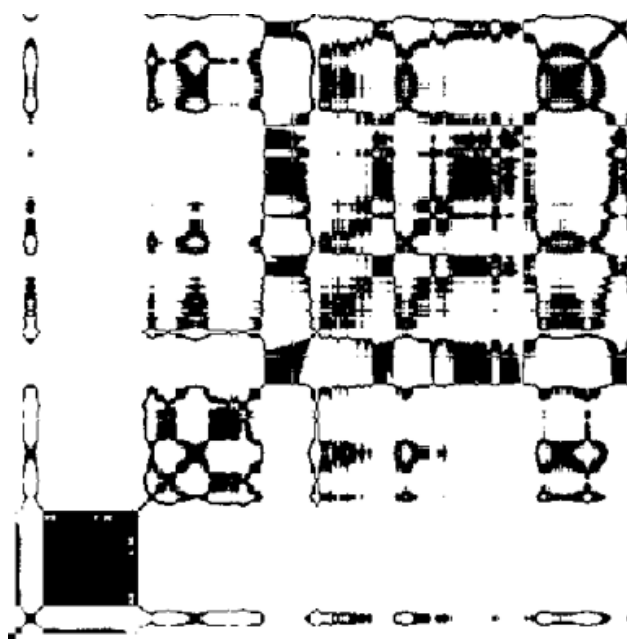
Spektrograma rodo, kaip signalų dažniai kinta laiko atžvilgiu. Ji parodo, kaip kinta dažnių komponentų intensyvumas (amplitudė) laikui bėgant (24 pav.).



24 pav. Koreliacijos signalo spektrograma

Rekurencijos matrica (25 pav.) naudojama laiko eilučių analizėje, siekiant vizualizuoti pasikartojančius elgesio modelius ir struktūras. Tai padeda nustatyti, ar tam tikros sistemos būsenos ar elgsena pasikartoja per tam tikrą laiką, ir atskleisti periodinius ar chaotiškus procesus. Norint sukurti rekurencijos matricą, kiekvienas taškas laiko eilutėje yra lyginamas su visais kitais taškais. Tam naudojamas atstumo matavimas, kuris nurodo skirtumą tarp dviejų taškų. Jei atstumas tarp dviejų taškų yra mažesnis už numatytą slenkstį, tuomet laikoma, kad šie taškai yra „panašūs“, tai yra, sistemos elgsena pasikartoja. Kiekvienas laiko eilučių taškas lyginamas su kitais, ir galiausiai mes gauname kvadratinę matricą, kurioje pavaizduojami visi palyginimai. Juodos dėmės ir netaisyklingos

linijos rodo, kad kai kurie sistemos taškai yra labai panašūs arba visiškai nesiskiria, tačiau yra ir nereguliarumų, kurie gali rodyti chaotišką ar nestabilių elgesį [43].



25 pav. Koreliacijos signalo rekurencijos matrica

2.2.5. Laiko eilučių karpymas

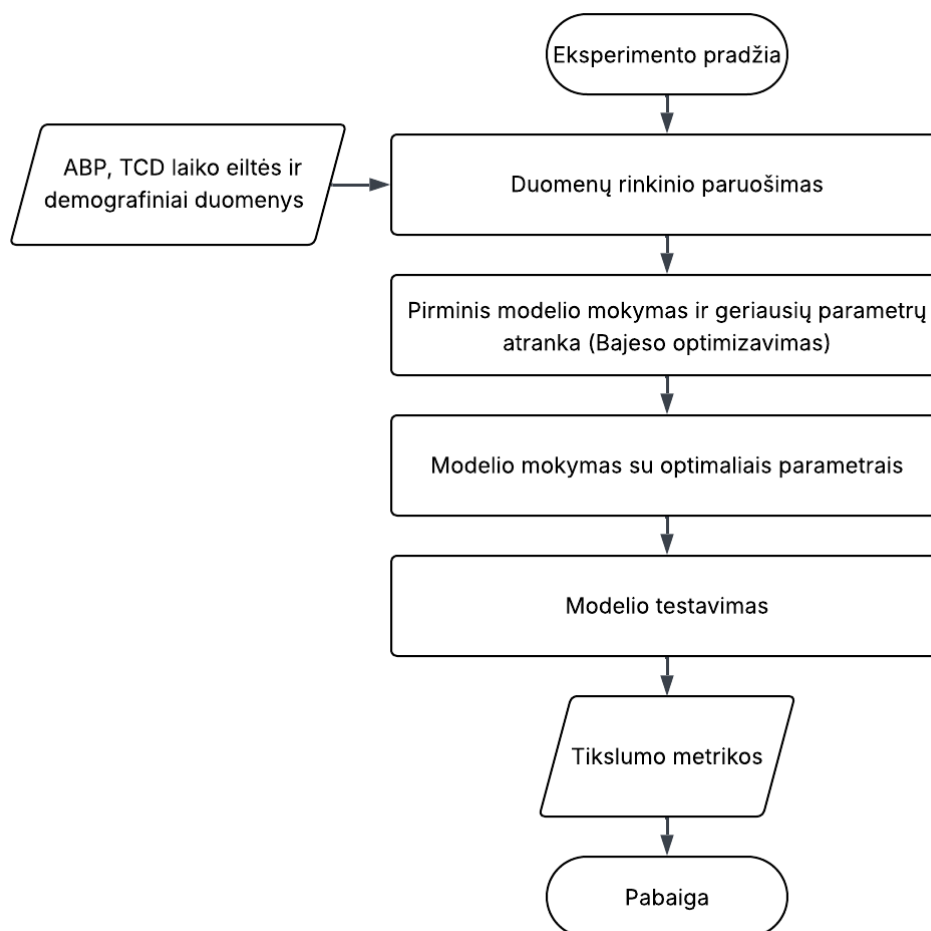
Modeliams, kurie gali priimti fiksuoto ilgio biologinius signalus buvo atliktas laiko eilučių karpymas. Šio duomenų paruošimo metodo metu buvo apskaičiuota visų signalų ilgių mediana, kiekviena laiko eilutė, kuri yra ilgesnė už medianą buvo nukirpta, o trumpesnės – užpildytos atitinkamai ABP, TCD ar koreliacijos koeficiento signalų medianos reikšmėmis.

Apibendrinant, visi duomenų rinkinių sudarantys signalai buvo išvalyti nuo triukšmo naudojant žemų dažnių bei slenkančio vidurkio filtrus. Kiekvienai apdorotų ABP ir TCD signalų porai pritaikyta viena iš augmentacijos metodikų (laiko poslinkio, mastelio keitimo arba tempimo). Išvalyti ir augmentuoti signalai buvo naudojami ruošiant duomenų rinkinius. Sukurti trijų tipų duomenys: karpytos laiko eilutės, parametrų vektoriai bei vaizdai (spektrogramos ir rekurencijos matricos).

3. Biologinių signalų klasifikavimo modelių kūrimo metodai

3.1. Modelių specifikacija

Atliekant tyrimą, realizuojami skirtingų klasių modeliai, kuriems reikalingas atitinkamas duomenų paruošimo būdas. Kiekvienam modeliui ar jų grupei pritaikytas vienas ar keli iš 2.2.3. – 2.2.5. skyriuose aprašytų metodų. Konkretus duomenų rinkinys pateiktas prie modelio rezultatų aprašymo eksperimentinėje dalyje. Bendra duomenų paruošimo bei modelių apmokymo eigą iliustruoja 26 pav.



26 pav. Modelių realizacijos procesų diagrama

Modeliui parenkamas tinkamas duomenų apdorojimo procesas. Parengtam duomenų rinkiniui taikoma SMOTE (angl. *Synthetic Minority Over-sampling Technique*) metodika, kuri padidina mažesnės klasės elementų kiekį. Nauji elementai SMOTE metodu generuojami pasirinkus du artimiausius pavyzdžius iš mažesnės klasės, apskaičiuojant jų skirtumus ir sukuriant naujus pavyzdžius, kurie yra atsitiktinai išsidėstę tarp jų, remiantis jų atstumu.

Su paruoštu duomenų rinkiniu aplikamas pirminis modelio apmokymas. Šio apmokymo metu naudojamas Bajeso optimizavimo metodas, kuris padeda atrinkti geriausius modelio parametrus.

3.2. Metrikos

Modelio veikimo klasifikavimo uždaviniuose vertinti dažnai pasirenkami ne tik bendrojo tikslumo rodikliai, bet ir jautrumas, tikslumas bei F1 balas, nes jie padeda subalansuotai įvertinti klaidingų teigiamų ir klaidingų neigiamų prognozių poveikį – ypač svarbų medicinos srityse. Vertinant klasifikavimo modelių rezultatus skaičiuotos pagrindinės metrikos:

1. Bendras tikslumas (angl. *Accuracy*) parodo, kokia dalis visų prognozių buvo teisingos;
2. Jautrumas (angl. *Recall*) rodo, kokią dalį visų tikrųjų teigiamų atvejų (POCD pacientų) sėkmingai aptinka modelis;
3. Tikslumas (angl. *Precision*) matuoja, kokią dalį modelio priskirtų teigiamų prognozių sudaro tikrieji teigiami atvejai.;
4. F1 balas (angl. *F1 – score*) yra harmoninis jautrumo ir tikslumo vidurkis, subalansuojantis abu rodiklius į vieną metriką.

Šiame tyrime bus vertinamas bendras modelių tikslumas bei F1 metrikos reikšmė, nes nepastebėti ligoniai ir klaidingai diagnozuoti sveikieji gali lemti rimtas pasekmes, F1 balas—derindamas jautrumą ir tikslumą—yra reikšmingas šios klasės vertinimo rodiklis.

Tikslumo metrikų ataskaita pavaizduota 27 pav. Joje palyginami realūs ir modelio prognozuoti duomenys. Y ašyje yra tikrosios klasės, o X – prognozuotos, atitinkamuose langeliuose įrašytas pacientų skaičius tose kategorijose. TP (angl. *True Positives*) – tikrai teigiami atvejai, TN (angl. *True Negatives*) – tikrai neigiami, FP (angl. *False Positives*) – klaidingai teigiami, FN (angl. *False Negatives*) – klaidingai neigiamų atvejų kiekis.

		Spėta klasė	
		1	0
Reali klasė	1	TP	FN
	0	FP	TN

27 pav. Tikslumo metrikų ataskaita

Jautrumas, tikslumas bei F1 skaičiuojami atitinkamai pagal (6), (7) ir (8) išraiškas:

$$\text{Jautrumas (1 klasei)} = TP : (TP + FN) \quad (6)$$

$$\text{Tikslumas (1 klasei)} = TP : (TP + FP) \quad (7)$$

$$F1 = 2 * (\text{tikslumas} \times \text{jautrumas}) \div (\text{tikslumas} + \text{jautrumas}) \quad (8)$$


4. Modelių, skirtų biologinių signalų klasifikavimui, tyrimo rezultatai

4.1. Statistiniai metodai

4.1.1. Paslėptasis Markovo modelis


Paslėptojo Markovo modelio (HMM) mokymui buvo naudoti du duomenų rinkiniai: laiko eilutės bei signalų parametrų rinkinys. Išbandant HMM modelį eksperimentuota su skirtingomis kovariacijos matricomis (*diag*, *spherical*, *tied*, *full*).

Geriausias modelio tikslumas, kai duomenys yra laiko eilutės, pasiektas naudojant „*tied*“ kovariacijos matricą ir nustačius maksimalų 5000 iteracijų kiekį. Gauti rezultatai pateikti 27 pav. Bendras tikslumas – 0.6.



28 pav. HMM_0 (*tied*) rezultatai

Kai HMM modelyje naudojamos ne laiko eilutės, o parametrų rinkiniai, aukščiausias tikslumas pasiektas naudojant „*full*“ kovariacijos matricą ir nustačius maksimalų 5000 iteracijų kiekį gauti rezultatai pateikti 28 pav. Tikslumas – 0.6, kitos modelių tikslumo metrikos pateiktos 1 lentelėje.



29 pav. HMM_1 (*full*) rezultatai

1 lentelė. HMM modelių tikslumas

Modelis	Duomenys	Bendras tikslumas	Jautrumas	Tikslumas	F1
HMM_0 (<i>tied</i>)	Laiko eilutės	0,60	0,28	0,53	0,37
HMM_1 (<i>full</i>)	Parametrų vektorius	0,60	0,65	0,51	0,57

Nors modelių bendras tikslumas yra toks pat, tačiau HMM, kurio duomenų rinkinį sudarė parametrų vektorius, pasiekė geresnę F1 balą bei jautrumą. Tai rodo, kad šis modelis aptinka daugiau tikrųjų POCD pacientų lyginant su laiko eilutėmis apmokytu modeliu.

4.2. Mašininio mokymo metodai

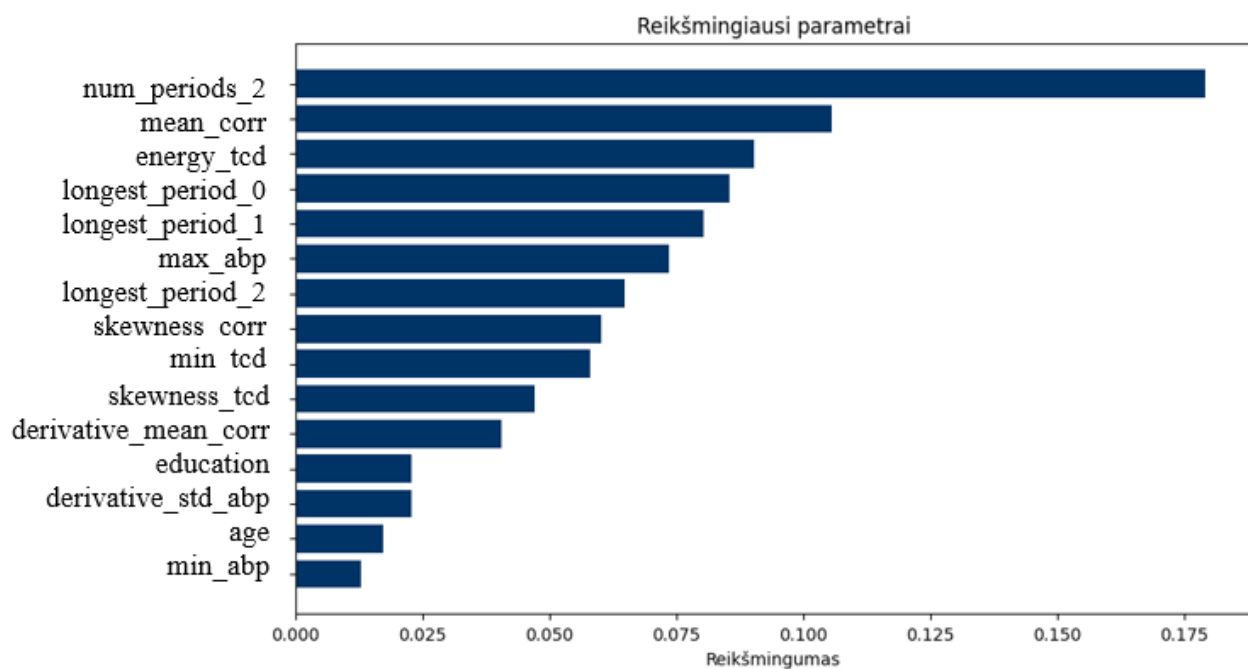
4.2.1. XGBoost

XGBoost modeliui naudotas parametrų rinkinys, kuris buvo apskaičiuotas ABP, TCD ir koreliacijos signalams. Papildomai buvo įtraukti koreliacijos signalo fragmentai, kuriuose koreliacijos koeficiento reikšmės yra numatytuose režiuose (plačiau aprašyta skyriuje: 2.2.3.4. Slenkanti koreliacija) ir apskaičiuoti jų parametrai.

Modelis realizuotas kaip nurodyta 2.3. skyriuje, taip pat pirminio modelio apmokymo metu atlikta parametrų atranka. Iš bendro parametrų sąrašo modelis atranka svarbiausius kintamuosius remiantis Gini koeficientu (angl. *Gini Impurity*) Jie pateikti 30 pav. Tai padeda sumažinti modelio sudėtingumą išsaugant reikšmingą informaciją.


Bajeso optimizavimo metodo atrinkti geriausi hyper parametrai modeliui:

1. Parametrų skirtų medžio apmokymui procentas (*colsample_bytree*): 0.7899;
2. Mokymosi žingsnis (*learning_rate*): 0.2888;
3. Didžiausias medžio gylis (*max_depth*): 3;
4. Medžių kiekis modelyje (*n_estimators*): 290;
5. Imties dalis (*subsample*): 0.7252



30 pav. Reikšmingiausi XGBoost modelio parametrai

Svarbiausias XGBoost modelio parametras – „num_periods_2“, tai yra, kiek kartų koreliacijos koeficiento reikšmė buvo antruosiuose režiuose (plačiau aprašyta 2.2.3.4. skyriuje), vidutinė koreliacijos koeficiento reikšmė, TCD signalo energija ir t.t. Taip pat be signalų charakteristikų išskirtas išsilavinimas bei paciento amžius.



31 pav. XGBoost rezultatai


2 lentelė. XGBoost modelio tikslumas

Modelis	Duomenys	Bendras tikslumas	Jautrumas	Tikslumas	F1
XGBoost	Parametrų vektorius	0,81	0,67	0,86	0,75

Modelis su optimizuotais meta – parametrais, bei atrinktu požymių vektoriumi pasiekė gerų rezultatų (31 pav.). Bendras modelio tikslumas siekia 0.81, o F1 – 0.75. Lyginant jautrumą bei tikslumą pastebėta, jog modelis užtikrintai prognozuoja POCD klasę (0.86), tačiau mažesnis procentas (0.67) tikrųjų teigiamų atvejų yra klasifikuojama teisingai.

4.2.2. SVM

Atraminių vektorių modelis apmokytas su ABP, TCD ir koreliacijos signalų parametrų vektoriumi, geriausi rezultatai pasiekti su tiesine branduolio funkcija. Rezultatų matrica pateikta 32 pav., kitos metrikos – 3 lentelėje.



32 pav. SVM rezultatai

3 lentelė. SVM modelio tikslumas

Modelis	Duomenys	Bendras tikslumas	Jautrumas	Tikslumas	F1
SVM	Parametrų vektorius	0,59	0,53	0,67	0,59

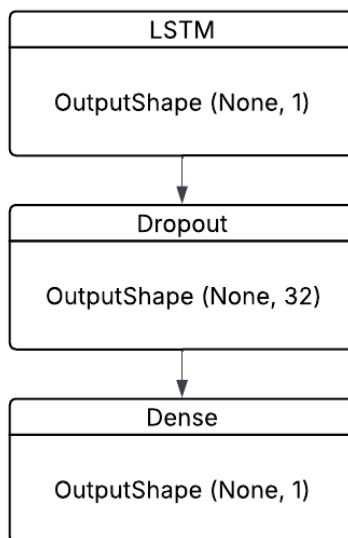
Atraminių vektorių metodas pasiekė vidutiniškus rezultatus, bendras tikslumas siekia 0.59, F1 – 0.59. Modelis labiau užtikrintai spėja (0.67) POCD pacientus, tačiau tik kiek daugiau nei pusė (0.53) tikrųjų POCD atvejų yra aptinkami.

4.3. Neuroniniai tinklai

4.3.1. LSTM modelis


Eksperimentams su modeliu naudoti du duomenų rinkiniai: ABP, TCD signalai; ABP, TCD signalai ir duomenys apie paciento amžių, išsilavinimą bei lytį.

Pirmojo eksperimento metu realizuota paprasčiausia modelio architektūra (33 pav.) ABP ir TCD signalams klasifikuoti.



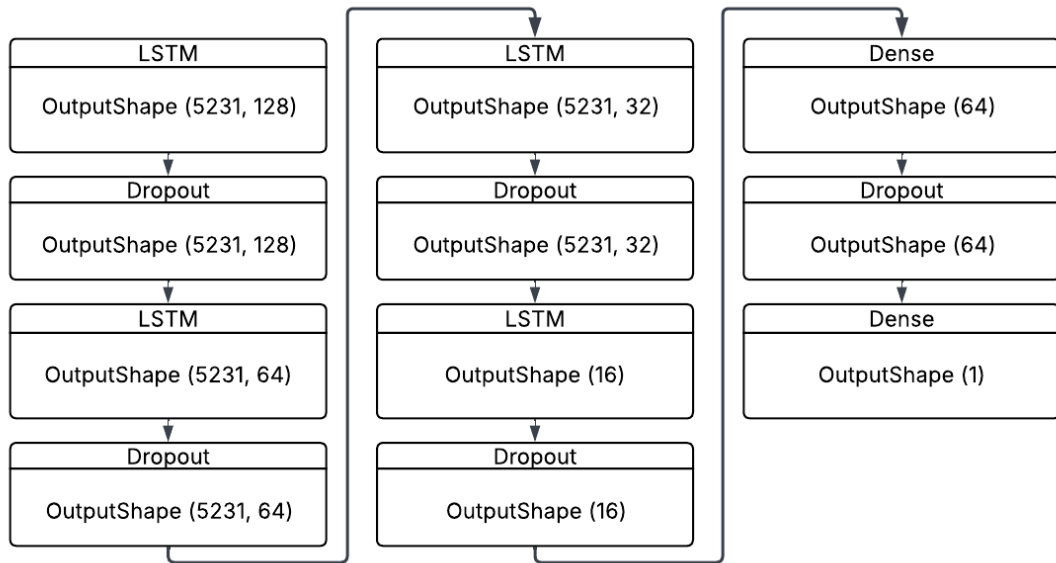
33 pav. LSTM_0 modelio architektūra

Šio eksperimento rezultatai pateikti 34 pav. Modelis spėja vieną reikšmę „0“, kuri reiškia, kad POCD nepasireišk pacientui. Tai gali būti dėl per mažo duomenų kiekio, LSTM modelis su turimomis laiko eilutėmis neaptinka reikšmingų požymių signalų klasifikavimui.




34 pav. LSTM_0 rezultatai

Modelis nėra tinkamas duomenims ir yra per paprastas, todėl išbandyta sudėtingesnė LSTM modelio architektūra (35 pav.). Modelio rezultatai pateikti 36 pav., o detalesnės abiejų LSTM modelių tikslumo metrikos pateiktos 4 lentelėje.



35 pav. LSTM_1 modelio architektūra



36 pav. LSTM_1 rezultatai

Gauti rezultatai nepakito, viena iš galimų priežasčių yra nepakankamas duomenų kiekis rinkinys, dėl kurio modelis negali išmokti reikšmingų savybių.


4 lentelė. LSTM modelių tikslumas

Modelis	Duomenys	Bendras tikslumas	Jautrumas	Tikslumas	F1
LSTM_0	Laiko eilutės	0,53	0,0	0,0	0,0
LSTM_0	Laiko eilutės	0,53	0,0	0,0	0,0

Abu LSTM modelių bendras tikslumas yra 0.53, o kitos tikslumo metrikos – 0, tai rodo, kad modelis prisitaiko prie dažnesnės klasės ir negali išskirti reikšmingų skirtumu klasifikuojant POCD klasę.


4.3.2. InceptionTime modelis

InceptionTime modelio apmokymui naudojami du duomenų rinkiniai: ABP, TCD; ABP, TCD ir koreliacijos signalai. Modelio architektūra pateikta 37 pav.




37 pav. InceptionTime modelio architektūra

Pirmojo modelio, kurio apmokymui naudoti tik ABP ir TCD signalai, rezultatai pateikti 38 pav., kito modelio duomenys papildyti koreliacijos signalu, rezultatai 39 pav. Modelių bendras tikslumas yra gana panašūs, esminiais skirtumai vertinant atitikimą bei tikslumą. Modelio, kurio mokymui naudojamas ir koreliacijos koeficiento signalas turi aukštesnę atitikimo įvertį, tačiau mažesnę tikslumą. Detali informacija apie gautus InceptionTime modelių tikslumus pateikta 5 lentelėje.



38 pav. InceptionTime_0 rezultatai



39 pav. InceptionTime_1 rezultatai

5 lentelė. InceptionTime modelių tikslumas


Modelis	Duomenys	Bendras tikslumas	Jautrumas	Tikslumas	F1
InceptionTime_0	Laiko eilutės	0,72	0,66	0,80	0,72
InceptionTime_1	Laiko eilutės ir koreliacijos signalas	0,74	0,73	0,70	0,71

Vertinant InceptionTime modelius, geresnį bendrą tikslumą (0.74) ir jautrumas (0.73) pasiekė modelis apmokytas su laiko eilutėmis ir koreliacijos signalais, tačiau modelis, apmokytas tik su laiko eilutėmis pasiekė geresnį tikslumą (0.80) bei F1 (0.72). Tai reiškia, kad InceptionTime_1 modelis geriau aptinka tikruosius POCD atvejus, o InceptionTime_0, užtikrinčiau prognozuoja aukštą pažinimo funkcijų sutrikimo riziką.

4.4. Hibridiniai neuroniniai tinklai


4.4.1. MiniRocket

MiniRocket modelis naudojamas laiko eilučių analizei ir reikšmingų parametrų atrankai, todėl kartu su šiuo modeliu naudojamas ir XGBoost. MiniRocket sukuria požymių vektorių iš laiko eilučių, o klasifikatorius naudoja požymius prognozuojant klasę. Bendro modelio architektūra pateikta 40 pav.



40 pav. MiniRocket – XGBoost modelio architektūra

Modelio rezultatai pateikti 41 pav., o tikslumo metrikos 6 lentelėje.



41 pav. MiniRocket rezultatai

6 lentelė. MiniRocket modelio tikslumas


Modelis	Duomenys	Bendras tikslumas	Jautrumas	Tikslumas	F1
MiniRocket	Laiko eilutės	0,73	0,72	0,72	0,72

MiniRocket modelio bendras tikslumas siekia 0.73, jautrumas, tikslumas bei F1 – 0.72, Tai rodo, kad modelis yra vienodai tikslus tiek klaidingai neigiamų, tiek klaidingai teigiamų POCD atvejų atžvilgiu.


4.5. Transformeriai

Apmokant ViTSignalClassifier modelį naudoti kelių tipo vaizdiniai duomenys: spektrogramos bei rekurencijos matricos arba jų kombinacija.


Pirmojo bandymo metu naudotos ABP, TCD ir koreliacijos koeficiento signalų spektrogramos. Šio modelio rezultatai pateikti 42 pav. Antrojo eksperimento metu naudotos šių signalų rekurencijos matricos, rezultatai 43 pav., o trečiojo bandymo metu buvo naudotos tik koreliacijos signalo spektrograma bei rekurencijos matrica (44 pav.).



42 pav. ViT_0 rezultatai



43 pav. ViT_1 rezultatai



44 pav. ViT_2 rezultatai

7 lentelė. Vit modelių tikslumas

Modelis	Duomenys	Bendras tikslumas	Jautrumas	Tikslumas	F1
ViT_0	Spektrogramos	0,67	0,80	0,57	0,72
ViT_1	Rekurencijos matricos	0,52	0,57	0,44	0,49
ViT_2	Rekurencijos matricos ir Spektrogramos	0,64	0,71	0,55	0,62

Lyginant transformeriais grįstų modelių tikslumą, geriausius visų metrikų įverčius pasiekė modelis, kurio apmokymui naudotos spektrogramos (ViT_0), bendras tikslumas yra 0.67, jautrumas 0.80, tikslumas 0.57, o F1 – 0.72. Tai reiškia, jog šis modelis patikimai aptinka tikruosius POCD pacientus, tačiau yra linkęs dažniau blogai klasifikuoti sveikus pacientus. Prasčiausi rezultatai modelio, kurio įvestis buvo rekurencijos matricos (ViT_1), o modelis, kurio apmokymui naudotos spektrogramos ir rekurencijos matricos (ViT_2), pasiekė geresnių rezultatų lyginant su ViT_1, bet prastesnių nei ViT_0. Tai reiškia, kad rekurencijos matricos yra prastesnis duomenų paruošimo metodas lyginant su spektrogramomis.

4.6. Analizuotų modelių tikslumo metrikų palyginimas

Vertinant visus realizuotus modelius (8 lentelė) bei jų tikslumą, išsiskiria XGBoost modelis, kuris apmokytas naudojant parametrų vektorius. Modelis pasiekia didžiausią bendrą tikslumą (0,81), tikslumą (0,86) ir F1 balą (0,75).

Lyginant laiko eilutėmis pagrįstus metodus geriausias metrikų reikšmes demonstruoja InceptionTime_1. Modelis pirmąją vertinant jautrumą (0,73), išlaikant aukštą bendrą 0,74 tikslumą

ir 0,71 F1 balą – nežymiai atsilieka nuo XGBoost modelio bendro tikslumo, tikslumo bei F1 įverčiais, o vertinant jautrumą - lenkia. MiniRocket modelis pasižymi stabiliais įverčiais visose metrikose (bendras tikslumas 0,73, jautrumas 0,72, tikslumas 0,72, F1 0,72), todėl jis yra patikimas subalansuotam klasifikavimui. Spektrogramomis apmokytas ViT_0 modelis pasiekia didžiausią bendrą jautrumo rodiklį (0,80), tačiau daugiau klaidingai teigiamų rezultatų (tikslumas 0,57).

Visos kitos architektūros (HMM variantai, SVM ir paprastas LSTM) pasižymi žymiai mažesniais F1 balais (žemiau 0,60), o tai rodo ribotą praktinį pritaikymą, palyginti su pirmaujančiais modeliais.

8 lentelė. Realizuotų modelių tikslumas

Modelis	Duomenys	Bendras tikslumas	Jautrumas	Tikslumas	F1
HMM_0 (<i>tied</i>)	Laiko eilutės	0,60	0,28	0,53	0,37
HMM_1 (<i>full</i>)	Parametrų vektorius	0,60	0,65	0,51	0,57
XGBoost	Parametrų vektorius	0,81	0,67	0,86	0,75
SVM	Parametrų vektorius	0,59	0,53	0,67	0,59
LSTM_0	Laiko eilutės	0,53	0,0	0,0	0,0
LSTM_0	Laiko eilutės	0,53	0,0	0,0	0,0
InspectionTime_0	Laiko eilutės	0,72	0,66	0,80	0,72
InspectionTime_1	Laiko eilutės ir koreliacijos signalas	0,74	0,73	0,70	0,71
MiniRocket	Laiko eilutės	0,73	0,72	0,72	0,72
ViT_0	Spektrogramos	0,67	0,80	0,57	0,72
ViT_1	Rekurencijos matricos	0,52	0,57	0,44	0,49
ViT_2	Rekurencijos matricos ir Spektrogramos	0,64	0,71	0,55	0,62

Vertinant modelių grupių tikslumo metrikas (9 lentelė), išsiskiria hibridiniai ir mašininio mokymo modeliai, šie modeliai pasiekė geriausią tikslumą. Hibridiniai modeliai dominuoja daugumoje metrikų: bendras tikslumas, jautrumas ir F1. Mašininio mokymosi metodai pasižymi aukščiausiu tikslumu, todėl ypač tinka, kai svarbiausia mažinti klaidingų POCD atvejų.

9 lentelė. Modeliu klasių tikslumo palyginimas

Modeliu grupė	Duomenys	Bendras tikslumas	Jautrumas	Tikslumas	F1
Statistiniai	Parametrų vektorius / laiko eilutės	0,60	0,47	0,52	0,47
Mašininio mokymo	Parametrų vektorius	0,70	0,60	0,77	0,67
Neuroniniai tinklai	Laiko eilutės	0,63	0,35	0,38	0,36
Hibridiniai	Laiko eilutės	0,73	0,72	0,72	0,72
Transformeriai	Vaizdai	0,61	0,69	0,52	0,61

Lyginant duomenų paruošimo metodus (10 lentelė), dominuoja modeliai, kurių apmokymui naudojami parametrų vektoriai. Šie modeliai pasižymi geriausiu bendru tikslumu (0,67), tikslumu (0,68) ir F1 balu (0,64), tai rodo, kad šie modeliai sugeba patikimai atskirti tiek teigiamus, tiek neigiamus POCD atvejus. Laiko eilutėmis grįsti modeliai pasiekė žemiausius visų keturių metrikų rodiklius (bendras tikslumas 0,64; jautrumas 0,40; tikslumas 0,46; F1 0,42), tai leidžia daryti išvadą, jog kraujotakos autoreguliacijos signalai, be papildomų požymių inžinerijos ar transformacijų, yra nepakankamai informatyvūs POCD aptikimui. Vaizdais grįsti modeliai pasiekia aukščiausią jautrumą (0,69), tačiau kitos metrikos nusileidžia parametrų vektoriais apmokytiems modeliams. Vaizdais grįstiems modeliams gali nepakakti esamo duomenų rinkinio apmokymui, o signalų augmentacija yra ribota, signalų kiekio didinimas gali iškreipti signalų tarpusavio sąveiką, kuri lemia POCD prognoze operacijos metu.

10 lentelė. Duomenų paruošimo metodų palyginimas

Duomenys	Bendras tikslumas	Jautrumas	Tikslumas	F1
Parametrų vektorius	0,67	0,62	0,68	0,64
Laiko eilutės	0,64	0,40	0,46	0,42
Vaizdai	0,61	0,69	0,52	0,61

Gauti rezultatai rodo, kad geriausias tikslumas pasiekiamas taikant parametrų vektoriais grįstus modelius ir hibridines architektūras, nes šios metodikos geba išnaudoti tiek struktūrinius, tiek statistinius duomenų aspektus optimaliam klasifikavimui. Tuo tarpu laiko eilutes arba vaizdų analizę naudojantys modeliai pritaikymui reikalauja didesnio duomenų rinkinio arba augmentacijos, be šių priemonių jų gebėjimas atskirti POCD atvejus išlieka ribotas.

Lyginant tyrimo metu naudotas dirbtinio intelekto modelių grupes galima teikti, kad mašininio mokymo metodai (pavyzdžiui XGBoost) pasiekė panašų – aukštesnį nei 80% – tikslumą, kaip ir kitų biologinių signalų klasifikavimo modeliai [19, 20]. Neuroninių tinklų ir vaizdais grįstų metodų rezultatai kur kas prastesni – tačiau šiems literatūroje aprašytiems tyrimams buvo naudojami daugiau nei dešimt kartų didesni duomenų rinkiniai [24, 25], todėl gautus rezultatus gali lemti ne tik modelio architektūra, o duomenų kiekio skirtumas.

Išvados

1. Tyrimų, susijusių su medicininių laiko eilučių analize, studija parodė, kad šio tipo eilučių klasifikavimui naudojamas platus dirbtinio intelekto modelių spektras, apimantis statistinius, mašininio mokymo metodus, neuroninius tinklus bei jų kombinacijas (hibridinius modelius). Nustatyta, kad skirtingų modelių taikymą ribojantis faktorius yra biologinių signalų ilgis, turimų duomenų kiekis ir biologinių tarpusavio ryšys. Dalis modelių (CNN, LSTM ir kt.) gali priimti tik fiksuoto ilgio signalus, todėl taikant šias architektūras reikalingas papildomas duomenų paruošimas. Vaizdais grįsti metodų apmokymui reikalingas didelis duomenų kiekis, tuomet šie modeliai gali pasiekti itin aukštą tikslumą. Statistiniai metodai gerai identifikuoja tiesinius ryšius, todėl geriausi rezultatai pasiekiami tais atvejais, kai biologiniai signalai nepasizymi sudėtingais tarpusavio ryšiais;
2. Laiko eilučių apdorojimui skirtų metodų analizės rezultatai parodė, kad signalai gali būti apdorojami skirtingais metodais, o jų pasirinkimas priklauso nuo realizuojamo dirbtinio intelekto modelio tipo. Medicininėms laiko eilutėms labiausiai tinkami yra laiko eilučių karpymo, parametrų vektoriaus sudarymo ir laiko eilučių konvertavimo į vaizdus metodai. Nustatyta, kad skirtingos laiko eilučių apdorojimo metodikos turi įtakos duomenų kokybei. Fiksuojant signalo ilgį, kai ilgesni signalai nukerpami, o trumpesni – papildomi nulinėmis arba medianos vertėmis, gali būti prarandama svarbi informacija arba iškreipiama signalo dinamika. Laiko eilučių konvertavimo į vaizdus atveju kuriamos spektrogramos, rekurencijos matricos arba signalo grafiko konvertavimas į vaizdą, tai leidžia pritaikyti konvoliucinių tinklų architektūras bei aptikti sudėtingus laiko – dažnio šablonus. Laiko eilučių apdorojimui taikant parametrų vektoriaus sudarymo metodiką, skaičiuojamos statistinės, koreliacinės ir kitos signalų savybės, kurios naudojamos modelio apmokymui. Tai leidžia sukurti kokybiškus fiksuoto ilgio duomenis, tačiau reikalauja ekspertinių žinių taikymo srityje;
3. Tyrimo metu realizuota 12 skirtingų modelių architektūrų apimant statistinių, mašininio mokymo, neuroninių tinklų, hibridinių bei transformerio architektūros modelių grupes. Eksperimentiniai rezultatai parodė, kad tiksliausiai kognityvinį sutrikimą prognozuoja mašininio mokymo bei hibridinių modelių grupės: geriausią rezultatą pasiekė XGBoost modelis (bendras tikslumas siekia 0.81, POCD klasės klasifikavimo tikslumas – 0.86, o F1 įvertis yra 0.75), o antras tiksliausias modelis buvo hibridinė MiniRocket ir XGBoost architektūra. Hibridinio modelio bendras tikslumas yra 0.73, o F1 – 0.72. Tai rodo, kad modeliai gali išskirti reikšmingus skirtumus tarp klasifikuojamų signalų;
4. Realizuotiems modeliams paruošti atitinkamų duomenų rinkiniai – karpytos laiko eilutės, parametrų vektoriai bei signalai konvertuoti į vaizdus. Geriausias tikslumas pasiektas taikant parametrų vektoriais grįstus modelius, tai rodo, jog ši metodika geba išnaudoti tiek struktūrinius, tiek statistinius duomenų aspektus atliekant klasifikavimą net ir su ribotu duomenų kiekiu (57 pacientų duomenimis). Tuo tarpu laiko eilutes arba vaizdų analizę naudojantys modeliai reikalauja didesnio duomenų rinkinio arba augmentacijos, be šių priemonių jų gebėjimas atskirti POCD atvejus išlieka ribotas;
5. Eksperimentinio tyrimo metu buvo pastebėta, kad pradinė hipotezė dėl aukšto koreliacijos koeficiento reikšmės pažinimo sutrikimo identifikavimui nepasitvirtino, todėl duomenų rinkiniui atlikta išsami signalų parametrų analizė ir inžinerija. Atlikus signalų požymių inžineriją ir pritaikius medžiais grįstą parametrų reikšmingumo analizę nustatyta, jog reikšmingiausi veiksniai prognozuojant kognityvinio sutrikimo riziką yra koreliacijos koeficiento vidurkis, TCD signalo

energija, periodų kiekis ir laikas, kai koreliacijos koeficiento reikšmė buvo tarp nustatytų reikšmingų rėžių ([-0,25; -0,22], [0,56; 0,59]).

Literatūros sąrašas

1. WONG, C.W.Y. et al. Estimated prevalence of frailty and prefrailty in patients undergoing coronary artery or valvular surgeries/procedures: A systematic review and proportional meta-analysis. In *Ageing Research Reviews* [interaktyvus]. 2024. Vol. 96, p. 102266. Prieiga per internetą: <<https://doi.org/10.1016/j.arr.2024.102266>>. Vu, Tony, and Julian A. Smith. "An Update on Postoperative Cognitive Dysfunction Following Cardiac Surgery." *Frontiers in Psychiatry*, vol. 13, June 2022, p. 884907. *PubMed Central*, <https://doi.org/10.3389/fpsy.2022.884907>
2. SURAARUNSUMRIT, P. et al. Postoperative cognitive dysfunction in older surgical patients associated with increased healthcare utilization: a prospective study from an upper-middle-income country. In *BMC Geriatrics* [interaktyvus]. 2022. Vol. 22, no. 1. Prieiga per internetą: <https://doi.org/10.1186/s12877-022-02873-3>
3. BOONE, M.D. et al. Economic burden of postoperative neurocognitive disorders among US Medicare patients. In *JAMA Network Open* [interaktyvus]. 2020. Vol. 3, no. 7, p. e208931. Prieiga per internetą: <https://doi.org/10.1001/jamanetworkopen.2020.8931>
4. VU, T. - SMITH, J.A. An update on postoperative cognitive dysfunction following cardiac surgery. In *Frontiers in Psychiatry* [interaktyvus]. 2022. Vol. 13. Prieiga per internetą: <https://doi.org/10.3389/fpsy.2022.884907>
5. WANG, M. et al. Abnormal expression of circRNA_089763 in the plasma exosomes of patients with post-operative cognitive dysfunction after coronary artery bypass grafting. In *Molecular Medicine Reports* [interaktyvus]. 2019. Prieiga per internetą: <https://doi.org/10.3892/mmr.2019.10521>
6. YAN, W. et al. Effects of different analgesia regimens on early post-operative cognitive dysfunction in elderly patients undergoing radical resection of cervical carcinoma. In *Experimental and Therapeutic Medicine* [interaktyvus]. 2019. Prieiga per internetą: <https://doi.org/10.3892/etm.2019.7702>
7. LIN, F. et al. Attenuation of noisy environment-induced neuroinflammation and dysfunction of learning and memory by minocycline during perioperative period in mice. In *Brain Research Bulletin* [interaktyvus]. 2020. Vol. 159, p. 16–24. Prieiga per internetą: <https://doi.org/10.1016/j.brainresbull.2020.03.004>
8. BERGER, M. et al. Best practices for Postoperative brain Health. In *Anesthesia & Analgesia* [interaktyvus]. 2018. Vol. 127, no. 6, p. 1406–1413. Prieiga per internetą: <https://doi.org/10.1213/ane.0000000000003841>
9. BRIEN, H.O. et al. Mind over Matter? The hidden epidemic of cognitive dysfunction in the older surgical patient. In *Annals of Surgery* [interaktyvus]. 2016. Vol. 265, no. 4, p. 677–691. Prieiga per internetą: <https://doi.org/10.1097/sla.0000000000001900>
10. KUMPAITIENE, B. et al. Disorder of cerebrovascular autoregulation during cardiac surgery with CPB and its relation with the rate of post – operative cognitive dysfunction. In *Journal of Cardiothoracic and Vascular Anesthesia* [interaktyvus]. 2016. Vol. 30, p. S5–S6. Prieiga per internetą: <https://doi.org/10.1053/j.jvca.2016.03.102>
11. PETKUS, V. et al. Continuous non-invasive monitoring of cerebrovascular autoregulation impairments during cardiac surgery with cardiopulmonary bypass in order to protect the brain from postoperative cognitive deterioration. In *Journal of the Neurological*

- Sciences* [interaktyvus]. 2017. Vol. 381, p. 851. Prieiga per internetą: <https://doi.org/10.1016/j.jns.2017.08.2397>
12. RHEE, C.J. et al. The ontogeny of cerebrovascular pressure autoregulation in premature infants. In *Journal of Perinatology* [interaktyvus]. 2014. Vol. 34, no. 12, p. 926–931. Prieiga per internetą: <https://doi.org/10.1038/jp.2014.122>
 13. ARMSTEAD, W.M. Cerebral blood flow autoregulation and dysautoregulation. In *Anesthesiology Clinics* [interaktyvus]. 2016. Vol. 34, no. 3, p. 465–477. Prieiga per internetą: <https://doi.org/10.1016/j.anclin.2016.04.002>
 14. KLEIN, S.P. et al. How I monitor cerebral autoregulation. In *Critical Care* [interaktyvus]. 2019. Vol. 23, no. 1. Prieiga per internetą: <https://doi.org/10.1186/s13054-019-2454-1>
 15. SINGH, A.K. - KRISHNAN, S. Trends in EEG signal feature extraction applications. In *Frontiers in Artificial Intelligence* [interaktyvus]. 2023. Vol. 5. Prieiga per internetą: <https://doi.org/10.3389/frai.2022.1072801>
 16. RABINER, L.R. A tutorial on hidden Markov models and selected applications in speech recognition. In *Proceedings of the IEEE* [interaktyvus]. 1989. Vol. 77, no. 2, p. 257–286. Prieiga per internetą: <https://doi.org/10.1109/5.18626>
 17. WANG, W.K. et al. A Systematic review of time series classification techniques used in biomedical applications. In *Sensors* [interaktyvus]. 2022. Vol. 22, no. 20, p. 8016. Prieiga per internetą: <https://doi.org/10.3390/s22208016>
 18. RASHED-AL-MAHFUZ, Md. et al. A deep convolutional neural network method to detect seizures and characteristic frequencies using epileptic electroencephalogram (EEG) data. In *IEEE Journal of Translational Engineering in Health and Medicine* [interaktyvus]. 2021. Vol. 9, p. 1–12. Prieiga per internetą: <https://doi.org/10.1109/jtehm.2021.3050925>
 19. OUYOUNG, T. et al. Machine-Learning Classification of pulse waveform Quality. In *Sensors* [interaktyvus]. 2022. Vol. 22, no. 22, p. 8607. Prieiga per internetą: <https://doi.org/10.3390/s22228607>
 20. HATIB, F. et al. Machine-learning algorithm to predict hypotension based on high-fidelity arterial pressure waveform analysis. In *Anesthesiology* [interaktyvus]. 2018. Vol. 129, no. 4, p. 663–674. Prieiga per internetą: <https://doi.org/10.1097/aln.0000000000002300>
 21. HATIB, F. et al. Machine-learning algorithm to predict hypotension based on high-fidelity arterial pressure waveform analysis. In *Anesthesiology* [interaktyvus]. 2018. Vol. 129, no. 4, p. 663–674. Prieiga per internetą: <https://doi.org/10.1097/aln.0000000000002300>
 22. SALEHINEJAD, H. et al. S-Rocket: Selective Random Convolution Kernels for Time Series classification. In *arXiv (Cornell University)* [interaktyvus]. 2022. Prieiga per internetą: <https://arxiv.org/abs/2203.03445>
 23. JO, Y.-Y. et al. Predicting intraoperative hypotension using deep learning with waveforms of arterial blood pressure, electroencephalogram, and electrocardiogram: Retrospective study. In *PLoS ONE* [interaktyvus]. 2022. Vol. 17, no. 8, p. e0272055. Prieiga per internetą: <https://doi.org/10.1371/journal.pone.0272055>
 24. HANNUN, A.Y. et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. In *Nature Medicine* [interaktyvus]. 2018. Vol. 25, no. 1, p. 65–69.

25. NISHA, N.N. et al. A deep learning framework for the detection of abnormality in cerebral blood flow velocity using transcranial doppler ultrasound. In *Diagnostics* [interaktyvus]. 2023. Vol. 13, no. 12, p. 2000. Prieiga per internetą: <https://doi.org/10.3390/diagnostics13122000>
26. FAWAZ, H.I. et al. InceptionTime: Finding AlexNet for time series classification. In *Data Mining and Knowledge Discovery* [interaktyvus]. 2020. Vol. 34, no. 6, p. 1936–1962. Prieiga per internetą: <https://doi.org/10.1007/s10618-020-00710-y>
27. M, U.K.N. - AHAMED, S.R. Wavelet-based Autoencoder and EfficientNet for Schizophrenia Detection from EEG Signals. In *arXiv (Cornell University)* [interaktyvus]. 2024. Prieiga per internetą: <http://arxiv.org/abs/2407.17540>
28. TU, W. et al. RNN-based signal classification for hybrid audio data compression. In *Computing* [interaktyvus]. 2019. Vol. 102, no. 3, p. 813–827. Prieiga per internetą: <https://doi.org/10.1007/s00607-019-00713-8>
29. HOCHREITER, S. - SCHMIDHUBER, J. Long Short-Term memory. In *Neural Computation* [interaktyvus]. 1997. Vol. 9, no. 8, p. 1735–1780. Prieiga per internetą: <https://doi.org/10.1162/neco.1997.9.8.1735>
30. CALZONE, O. An Intuitive explanation of LSTM - Ottavio Calzone - medium. In *Medium* [interaktyvus]. 2022. Prieiga per internetą: <https://medium.com/@ottaviocalzone/an-intuitive-explanation-of-lstm-a035eb6ab42c>
31. MANDHOIJ, B. et al. An automated classification of EEG signals based on spectrogram and CNN for epilepsy diagnosis. In *Analog Integrated Circuits and Signal Processing* [interaktyvus]. 2021. Vol. 108, no. 1, p. 101–110. Prieiga per internetą: <https://doi.org/10.1007/s10470-021-01805-2>
32. CANIZO, M. et al. Multi-head CNN–RNN for multi-time series anomaly detection: An industrial case study. In *Neurocomputing* [interaktyvus]. 2019. Vol. 363, p. 246–260. Prieiga per internetą: <https://doi.org/10.1016/j.neucom.2019.07.034>
33. CHOE, S. et al. Short-Term Event Prediction in the operating room (STEP-OP) of Five-Minute Intraoperative Hypotension using hybrid Deep Learning: retrospective observational study and model development. In *JMIR Medical Informatics* [interaktyvus]. 2021. Vol. 9, no. 9, p. e31311. Prieiga per internetą: <https://doi.org/10.2196/31311>
34. WANG, X. et al. Automated recognition of epilepsy from EEG signals using a combining space–time algorithm of CNN-LSTM. In *Scientific Reports* [interaktyvus]. 2023. Vol. 13, no. 1. Prieiga per internetą: <https://doi.org/10.1038/s41598-023-41537-z>
35. LIU, M. et al. Gated Transformer Networks for multivariate Time Series classification. In *arXiv (Cornell University)* [interaktyvus]. 2021. Prieiga per internetą: <https://doi.org/10.48550/arXiv.2103.14438>
36. TSANG, S.-H. Review: Vision Transformer (ViT) - Sik-Ho Tsang - Medium. In *Medium* [interaktyvus]. 2022. Prieiga per internetą: <https://sh-tsang.medium.com/review-vision-transformer-vit-406568603de0>
37. MCGHEE, B.H. - BRIDGES, E.J. Monitoring arterial blood pressure: what you may not know. In *Critical Care Nurse* [interaktyvus]. 2002. Vol. 22, no. 2, p. 60–79. Prieiga per internetą: <https://doi.org/10.4037/ccn2002.22.2.60>
38. PURKAYASTHA, S. - SOROND, F. Transcranial doppler ultrasound: technique and application. In *Seminars in Neurology* [interaktyvus]. 2013. Vol. 32, no. 04, p. 411–420. Prieiga per internetą: <https://doi.org/10.1055/s-0032-1331812>

39. GAN, S.E.S. et al. Fetal ECG Extraction from Abdominal ECG Using Chebyshev and Butterworth Filters. In *IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE)*. [interaktyvus]. 2021. p. 25–30. Prieiga per internetą: <https://doi.org/10.1109/isci51925.2021.9633595>
40. PISKOROWSKI, J. A new concept of filters for biomedical data processing needs. In *Journal of Applied Biomedicine* [interaktyvus]. 2011. Vol. 31, no. 1, p. 27–37. Prieiga per internetą: [https://doi.org/10.1016/s0208-5216\(11\)70003-1](https://doi.org/10.1016/s0208-5216(11)70003-1)
41. MUSTAFFA, I.B. et al. Significance of averaging method signal denoising. In *International Conference on Biomedical Engineering and Technology* [interaktyvus]. 2017. p. 1–6. Prieiga per internetą: <https://doi.org/10.1109/icoras.2017.8308040>
42. SONALI, N. et al. ECG signal denoising based on Empirical Mode Decomposition and moving average filter. In *International Conference on Electronics, Computing and Communication Technologies* [interaktyvus]. 2013. Prieiga per internetą: <https://doi.org/10.1109/ispcc.2013.6663412>
43. SPIRIDONOV, A. et al. Quantifying the community turnover of the uppermost Wenlock and Ludlow (Silurian) conodonts in the Baltic Basin. In *Palaeogeography Palaeoclimatology Palaeoecology* [interaktyvus]. 2019. Vol. 549, p. 109128. Prieiga per internetą: <https://doi.org/10.1016/j.palaeo.2019.03.029>