



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Mašininiu mokymusi grįstų miego apnėjos stebėsenos metodų tyrimas

Baigiamasis magistro projektas

Žygimantas Marma

Projekto autorius

Prof. Vaidotas Marozas

Vadovas

Kaunas, 2025



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Mašininiu mokymusi grįstų miego apnėjos stebėsenos metodų tyrimas

Baigiamasis magistro projektas

Elektronikos inžinerija (6211EX012)

Žygimantas Marma

Projekto autorius

Prof. Vaidotas Marozas

Vadovas

Prof. Darius Andriukaitis

Recenzentas

Kaunas, 2025



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Žygimantas Marma

Mašininiu mokymusi grįstų miego apnėjos stebėsenos metodų tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

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

Žygimantas Marma

Patvirtinta elektroniniu būdu

Marma, Žygimantas. Mašininiu mokymusi grįstų miego apnėjos stebėsenos metodų tyrimas. Magistro baigiamasis projektas / vadovas Prof. dr. Vaidotas Marozas; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

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

Reikšminiai žodžiai: miego apnėja, laiko eilučių klasifikavimas, neuroniniai tinklai, fotopletizmografija.

Kaunas, 2025. 54 p.

Santrauka

Miegas yra labai svarbus sveikatos ir gerovės komponentas, tačiau jo sutrikimai, tokie kaip obstrukcinė miego apnėja, yra rimta problema, sukelianti reikšmingų sveikatos komplikacijų. Šiame magistro baigiamajame projekte buvo atliktas išsamus tyrimas apie mašininiu mokymusi grįstus metodus, skirtus miego apnėjos stebėsenai ir diagnostikai, naudojant fotopletizmografijos (FPG) signalus.

Pirmojoje darbo dalyje analizuojama miego apnėjos problema, jos klinikinis aktualumas ir tradiciniai diagnostikos metodai, tokie kaip polisomnografija, bei jų trūkumai – aukšta kaina, sudėtingumas ir pacientų diskomfortas. Aptariamos neinvazinės diagnostikos alternatyvos, ypatingai akcentuojant FPG technologijos potencialą dėl jos paprastumo ir patogumo naudoti namų aplinkoje.

Antrojoje darbo dalyje pateikiami išsamūs tyrimų metu taikyti algoritmai, jų taikymo metodika ir įvertinimo kriterijai. Buvo analizuoti du pagrindiniai algoritmų tipai: vienas naudojantis tiesiogiai iš FPG signalų išskirtais požymiais (pvz., PPI ir DAP), kitas – naudojantis giliojo mokymosi transformatorių modeliais, nereikalaujančiais rankiniu būdu išgautų požymių.

Trečiojoje dalyje pateikti eksperimentų rezultatai rodo, kad požymiais grįstas modelis, apdorojant 60 sekundžių intervalus (0,5–7 Hz filtras) ir naudojant atrinktus penkis svarbiausius požymius (*Aoff*, *Adn*, *deltaT*, *Tsw10*, *Tdia*), pasiekė aukščiausią AUC – 84,3 % ir F1 – 77,4 %. Transformatorių modelis su 10 s signalais (0,5–7 Hz) užfiksavo geriausią jaurumo rodiklį (71,2 %) ir AUC – 78,7 %. Išteklių sąnaudų požiūriu požymiais grįstas sprendimas reikalauja žymiai mažiau skaičiavimo operacijų ir atminties, todėl jis yra tinkamiausias įterptinėms sistemoms.

Gaunami rezultatai patvirtina, kad mašininio mokymosi metodai, naudojant FPG signalus, gali būti efektyvi alternatyva tradicinei polisomnografijai ir suteikti galimybę neinvazinei apnėjos stebėsenai namų sąlygomis.

Marma, Žygimantas. Investigation of Machine Learning-Based Methods for Sleep Apnea Monitoring. Master's Final Degree Project / supervisor Prof. Vaidotas Marozas; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

Study field and area (study field group): Electronics Engineering, Engineering Sciences.

Keywords: sleep apnea, time series classification, neural networks, photoplethysmography.

Kaunas, 2025. 54 p.

Summary

Sleep is a very important component of health and well-being, but its disorders, such as obstructive sleep apnea, are a serious problem that causes significant health complications. This master's thesis project conducted a comprehensive study on machine learning-based methods for monitoring and diagnosing sleep apnea using photoplethysmography (FPG) signals.

The first part of the paper analyses the problem of sleep apnea, its clinical relevance and traditional diagnostic methods, such as polysomnography, and their disadvantages - high cost, complexity and patient discomfort. Non-invasive diagnostic alternatives are discussed, with particular emphasis on the potential of FPG technology due to its simplicity and convenience for use in the home environment.

The second part of the paper presents detailed algorithms used in the research, their application methodology and evaluation criteria. Two main types of algorithms were analysed: one using features extracted directly from FPG signals (e.g. PPI and DAP), the other using deep learning transformer models that do not require manually extracted features.

The experimental results presented in the third part show that the feature-based model, when processing 60-second intervals (0.5–7 Hz filter) and using the selected five most important features (*Aoff*, *Adn*, *deltaT*, *Tsw10*, *Tdia*), achieved the highest AUC – 84.3% and F1 – 77.4%. The transformer model with 10-second signals (0.5–7 Hz) recorded the best sensitivity indicator (71.2%) and AUC – 78.7%. In terms of resource consumption, the feature-based solution requires significantly less computational operations and memory, making it most suitable for embedded systems.

The results obtained confirm that machine learning methods using FPG signals can be an effective alternative to traditional polysomnography and provide an opportunity for non-invasive apnea monitoring at home.

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Santrumpų ir terminų sąrašas	9
Įvadas	10
1. Literatūros šaltinių analizė	11
1.1. Kvėpavimo sutrikimų miego metu problemos analizė	11
1.2. Kvėpavimo sutrikimų miego metu tyrimų ir technologijų apžvalga	12
1.2.1. Fotopletizmogramos signalai	15
1.2.2. Klasterizavimo ir klasifikavimo metodų analizė	16
1.2.3. Išmanios apnėjos atpažinimo sistemos	19
1.2.4. Fotopletizmografijos pagrindu apnėjos detektavimo algoritmų analizė	21
1.3. Atviros prieigos signalų duomenų bazių apžvalga	22
2. Miego apnėjos atpažinimo algoritmų tyrimas	24
2.1. Miego tyrimo duomenų rinkinys OSASUD	24
2.2. Siūlomi apnėjos atpažinimo algoritmai	28
2.2.1. Algoritmas Nr. 1: FPG požymių išskyrimu grįstas algoritmas	29
2.2.2. Algoritmas Nr. 2: FPG požymių išskyrimo nenaudojantis algoritmas	32
2.3. Algoritmų įvertinimas pagal klasifikavimo patikimumą ir skaičiavimo resursų poreikį	34
3. Miego apnėjos atpažinimo algoritmų tyrimo rezultatai	37
3.1. Algoritmo Nr. 1 tyrimo rezultatai	38
3.1.1. Požymių svarbos analizės rezultatai	41
3.2. Algoritmo Nr. 2 tyrimo rezultatai	43
3.3. Rezultatų palyginimas su kitų autorių metodais	47
3.4. Algoritmų palyginimas kompiuterinių skaičiavimo resursų požiūriu	48
Išvados	50
Literatūros sąrašas	51

Lentelių sąrašas

1 lentelė. Apnėjos ir hipopnėjos indeksas	12
2 lentelė. Pagrindiniai OSASUD duomenų rinkinio duomenų kanalai ir jų parametrai	24
3 lentelė. Duomenų rinkinio demografija.....	25
4 lentelė. Apnėjos epizodų pasiskirstymas esant skirtingiems FPG analizės langams	28
5 lentelė. MM modelio klasifikavimo rezultatai naudojant 05-12 Hz filtrą FPG signalui.....	38
6 lentelė. MM modelio klasifikavimo rezultatai naudojant 05-7 Hz filtrą FPG signalui.....	39
7 lentelė. MM modelio klasifikavimo rezultatai naudojant tik aukštų dažnių (0,5 Hz) filtrą FPG signalui	39
8 lentelė. LSTM tipo modelio klasifikavimo rezultatai, naudojant skirtingus požymių rinkinius....	43
9 lentelė. LSTM modelio klasifikavimo rezultatų pokyčiai (%) naudojant atrinktus požymius.....	43
10 lentelė. Algoritmo Nr. 2 su transformatoriaus tipo modelių rezultatai.....	45
11 lentelė. Klasifikavimo rezultatų palyginimas su kitais autoriais naudojančiais FPG signalą kaip įvestį	48
12 lentelė. Resursų įvertinimas.....	49

Paveikslų sąrašas

1 pav. Normalaus kvėpavimo ir miego apnėjos atvejų iliustracija.....	11
2 pav. CPAP prietaiso veikimas	13
3 pav. Įvairių elektrodų ir jutiklių, naudojamų miegui stebėti polisomnografijos metu iliustracija [13]	14
4 pav. Elektroniniai blokai, naudojami tipinėje FPG matavimo sistemoje [14].....	16
5 pav. Standartinė konvoliucinio neuroninio tinklo struktūra [21]	17
6 pav. Pasiūlyto neuroninio tinklo architektūra kombinuojant CNN ir LSTM [31]	20
7 pav. Autorių pasiūlytos sistemos schema [34]	22
8 pav. Duomenų rinkinio anotuotos apnėjos įvykiai [38]	25
9 pav. Nefiltruoto FPG signalo iškarpa laiko srityje	26
10 pav. Trūkstamų duomenų dalis aktualiuose duomenų rinkinio kanaluose.....	26
11 pav. Viršuje be apnėjos, apačioje su apnėja (hipopnėjos įvykis)	27
12 pav. FPG signalė surasti orientaciniai taškai naudojami požymių skaičiavimui.....	30
14 pav. Išgautų požymių iš FPG signalo naudojant <i>pyPPG</i> iškarpa	30
15 pav. Požymių kiekio pasiskirstymas.....	31
16 pav. Algoritmo Nr. 1 struktūrinė schema	31
17 pav. FPG signalai su skirtingais filtrais	32
18 pav. Algoritmo Nr. 2 struktūrinė schema	33
19 pav. Autoenkoderio architektūra laiko eilutės FPG signalui.....	34
20 pav. Klasifikavimo matricos pavyzdys esant keturioms klasėms [44]	35
21 pav. Modelių rezultatų gavimo procedūra.....	37
22 pav. Požymiais pagrįsto MM modelio architektūra.....	38
23 pav. Sumaišties matrica su geriausius rezultatus pasiekusiu modeliu.....	39
24 pav. ROC kreivė kai naudojamas 60s įvesties langas ir 90 požymių skaičius	40
25 pav. Geriausio modelio AUC (kairėje) ir nuostolių funkcijos verčių kitimas treniravimo metu .	40
26 pav. AUC reikšmės palyginimas pagal filtrą ir intervalą	41
27 pav. Požymių svarbos analizė naudojant <i>Integrated Gradients</i> metodą	42
28 pav. Požymių įtakos analinė naudojant 1000 testavimo imčių.....	42
29 pav. Neapdorotu FPG pagrįsto transformatoriaus modelio architektūra.....	44
30 pav. Modelio AUC (kairėje) ir nuostolių funkcijos verčių kitimas treniravimo metu (10s, 0,5-7 Hz)	45
31 pav. Klasifikavimo matrica geriausiai parametrų kombinacijai (10s, 0,5-7 Hz).....	46
32 pav. Modelio AUC (kairėje) ir F1 verčių kitimas treniravimo metu (30s, 0,5-7 Hz).....	46
33 pav. Modelio nuostolių funkcijos verčių kitimas treniravimo metu (30s, 0,5-7 Hz)	47

Santrumpų ir terminų sąrašas

Santrumpos:

AASM – Amerikos miego medicinos akademija (angl. *American Academy of Sleep Medicine*);

AHI – apnėjos ir hipopnėjos indeksas;

EEG – elektroencefalografija (angl. *Electroencephalography*);

EKG – Elektrokardiografija (angl. *Electrocardiography*);

EMG – elektromiografija (angl. *Electromyography*);

FPG – fotopletizmograma (angl. *Photoplethysmogram* – PPG);

OMA – obstrukcinė miego apnėja;

MM – mašininis mokymasis (angl. *Machine learning*);

PSG – polisomnografija (angl. *Polysomnography*);

SpO₂ – arterinio kraujo įsotinimas deguonimi (angl. *Oxygen saturation*).

Ivadas

Miegas yra esminis geros savijautos elementas, tačiau gerai išsimiegoti pavyksta nevisiems žmonėms. Miego sutrikimai, tokie kaip miego trūkumas ir nemiga, veikia mūsų imunitetą, širdies ir kraujagyslių sistemą, gali sukelti vėžį ir yra galima depresijos atsiradimo priežastis [1]. Viena iš dažniausiai pasitaikančių miego sutrikimo formų yra obstrukcinė miego apnėja (OMA), kurią patiria maždaug 5-15% populiacijos [2]. Ši sutrikimo forma pasižymi pasikartojančiu kvėpavimo takų užsivėrimu miego metu, dėl per daug atsipalaidavusių minkštųjų audinių [3]. Užsidarius šiems takams sergantieji dažnai knarkia ir jiems tampa sunku kvėpuoti. Ši sutrikimo forma turi neigiamų pasekmių žmonių sveikatai, todėl svarbu ieškoti gydymo ir ankstyvo aptikimo priemonių norint sustabdyti sutrikimo progresavimą. Literatūroje galima rasti, kad negydoma OMA gali sukelti: hipertenziją (padidėjusį kraujo spaudimą), insultą, arterijų ligas ar prieširdžių virpėjimą [4].

Miego apnėjos diagnostikos problema susijusi ne tik su brangia ir nepatogia polisomnografijos procedūra, bet ir su dideliu nediagnozuotų atvejų skaičiumi. Remiantis moksliniais tyrimais, apie 80% obstrukcinės miego apnėjos atvejų lieka nediagnozuota, o tai reiškia, kad pacientai negauna būtino gydymo ir rizikuoja kitomis sveikatos problemomis [5]. Polisomnografija (angl. *polysomnography* – *PSG*) yra labiausiai paplitęs metodas apnėjos diagnostikai. Atliekant šį tyrimą, pacientas guldomas per naktį miego laboratorijoje kur yra stebimi jo fiziologiniai kintamieji [6]. PSG tyrimo metu registruojama kūno padėtis, galūnių judesiai, prisotinimas deguonimi, širdies ritmas ir dažnis, kvėpavimo pastangos, smegenų veikla, akių judesiai ir miego fazės [6]. Nors PSG tyrimas gali pateikti tikslią diagnozę, jis yra brangus medicinos tyrimas ir sukelia nepatogumų pacientams.

Siekiant išspręsti šias ligos aptikimo problemas, mokslininkai ir medikai kuria naujus metodus ir algoritmus, kuriuos galima būtų taikyti neinvaziniu būdu. Atsisakant PSG tyrimo ir miego laboratorijų galima būtų padėti daugiau žmonių atliekant ankstyvą diagnozę ir efektyvų gydymą.

Šiame darbe analizuojami miego sutrikimų atpažinimo ir charakterizavimo metodai pagrįsti mašininio mokymosi algoritmais. Analizuojami algoritmai, kuriems pakanka neinvaziniu būdu gautų fiziologinių duomenų. Aptariami naujausi tyrėjų pasiūlyti sprendimai, leidžiantys kurti automatizuotas apnėjos atpažinimo sistemas. Taip pat remiamasi panašių problemų sprendimais kituose duomenų mokslo taikymo kontekstuose, siekiant identifikuoti gerąsias praktikas bei galimus klasifikavimo rezultatų tobulinimo kelius. Ypatingas dėmesys skiriamas paaiškinamojo dirbtinio intelekto metodų taikymui, siekiant padidinti sistemų patikimumą ir interpretuojamumą. Galiausiai šiame darbe pristatoma ir išsamiai analizuojama fotopletizmografijos signalais pagrįsta miego apnėjos stebėsenos ir aptikimo sistema.

Darbo tikslas: ištirti mašininio mokymosi pagrįstus miego apnėjos stebėsenos algoritmus naudojant fotopletizmogramos signalus.

Uždaviniai:


1. išanalizuoti kvėpavimo sutrikimų miego metu atpažinimo klinikinę aktualumą, problematiką, stebėsenos technologijas ir apžvelgti atviros prieigos signalų duomenų bazes;
2. sukurti mašininio mokymosi pagrįstus miego apnėjos atpažinimo algoritmus;
3. ištirti pasiūlytą mašininio mokymosi pagrįstą miego apnėjos stebėsenos algoritmą naudojant atviros prieigos duomenų bazę;
4. suformuluoti išvadas ir rekomendacijas.

1. Literatūros šaltinių analizė

Šiame skyriuje yra aprašomi svarbiausi literatūros šaltiniai, susiję su miego apnėja ir jos padariniais, PSG tyrimu ir jo privalumais bei trūkumais. Taip pat yra išanalizuoti egzistuojantys alternatyvūs metodai miego apnėjos diagnozei, dėmesį skiriant neinvaziniu būdu surinktų duomenų pagrįstoms sistemoms, apžvelgiami standartiniai dirbtinio intelekto algoritmai bei pažangūs metodai tokie kaip: žinių perdavimo (angl. *transfer learning*), konvoliuciniai bei transformatorių (angl. *transformer*) tipo modeliai.

1.1. Kvėpavimo sutrikimų miego metu problemos analizė

Obstrukcinė miego apnėja yra kvėpavimo sistemos sutrikimas, kuris turi įtakos kvėpavimui miegant. Šį sutrikimą sukelia pasikartojantys viršutinių kvėpavimo takų obstrukcijos (užsivėrimai) kurios trunka mažiausiai 10 sekundžių, bet gali trukti iki minutės [7]. Tai gali atsirasti dėl kelių priežasčių, įskaitant raumenų, palaikančių gerklės ir liežuvis minkštuosius audinius, atsipalaidavimą, dėl kurio šie audiniai gali žlugti ir užkimšti kvėpavimo takus. Taip pat, riebalinių audinių perteklius gerklėje ir liežuvyje, padidėjusios tonzilės, didelis liežuvis ar mažas žandikaulis gali prisidėti prie kvėpavimo takų obstrukcijos miego metu. Kiti veiksniai, galintys padidinti kvėpavimo takų kolapso riziką, yra nutukimas, alkoholio vartojimas, rūkymas ir miegas ant nugaros. Šio sutrikimo iliustracija vizualiai pateikiama paveikslėlyje (1 pav.).



1 pav. Normalaus kvėpavimo ir miego apnėjos atvejų iliustracija¹

Mieguistumas dienos metu ir nuovargis yra pagrindiniai simptomai, kuriuos sukelia obstrukcinė miego apnėja (OMA). Tai atsitinka, dėl periodiškai pasikartojančių atsibudimų kurie yra sukelti kvėpavimo trukdžių [2]. Kiti dažnai pasireiškiantys sutrikimo simptomai yra garsus knarkimas, kvėpavimo pauzės, kurios pastebimos lovos partnerio, užspringimas ar dusulys, rytinis galvos skausmas, rytinis gerklės skausmas ir per didelis nuovargis ar negalavimas.

Tačiau labiau standartizuotas sutrikimo matavimo vienetas, naudojamas obstrukcinės miego apnėjos sunkumui diagnozuoti, yra apnėjos ir hipopnėjos indeksas (AHI). Jis apskaičiuojamas bendrą apnėjų (visiškų kvėpavimo pauzių) ir hipopnėjų (dalinių kvėpavimo takų obstrukcijų) skaičių padalijus iš miego valandų skaičiaus. OMA laipsnį galima išmatuoti apnėjos ir hipopnėjos indeksu (AHI), kuris yra padalintas į keturis sunkumo laipsnius pagal apnėjų ir hipopnėjų skaičių per miego valandą (1 lentelė). Jeigu AHI mažesnis nei 5 per valandą tai reiškia normalų miegą ir neegzistuojančia apnėja.

¹ Apnėjos vizualizacija, prieiga per: <https://www.uvmhealth.org/healthwise/topic/tp12620>

AHI nuo 5 iki 15 yra lengva liga, nuo 15 iki 30 yra vidutinio sunkumo liga, o jeigu AHI viršija 30 yra diagnozuojama sunki ligos forma [7].

1 lentelė. Apnėjos ir hipopnėjos indeksas

OMA sunkumas	AHI vertė per valanda miego
Nėra / įprastas miegas	<5
Lengva forma	5-15
Vidutinis	15-30
Sunkus	>30

Nors šiuo metu obstrukcinę miego apnėją patiria maždaug 5–15 % populiacijos [2] didesnė problema yra tai, jog vis didėja populiacijos dalis, kuri serga šia liga arba turi didelę tikimybę sirgti ja ateityje. Remiantis ilgalaikiais tyrimais, obstrukcinės miego apnėjos (OMA) paplitimas pasaulyje per pastaruosius dešimtmečius reikšmingai išaugo. 1993 m. atliktame tyrime nustatyta, kad OMA (apnėjos-hipopnėjos indeksas (AHI) ≥ 5) pasireiškė 24 % vyrų ir 9 % moterų [8]. Vėlesni duomenys rodo, kad pasauliniu mastu OMA paplitimas taip pat išaugo. 2020 m. JAV atlikta metaanalizė parodė, kad OMA pasireiškia 9–38 % suaugusiųjų, o vidutinio sunkumo ar sunkios formos OMA (AHI ≥ 15) – 6–17 % [9]. Šie skaičiai rodo didėjančią OMA paplitimą visame pasaulyje. Pagrindinės šio didėjimo priežastys – augantis nutukimo paplitimas, didėjantis visuomenės informuotumas apie ligą bei gerėjanti diagnostikos prieinamumas.

Tuo tarpu Lietuvoje situacija dėl obstrukcinės miego apnėjos diagnostikos ir gydymo yra sudėtinga. Pacientai, norintys išsitiirti dėl šios ligos, dažnai susiduria su ilgomis eilėmis – tyrimų gali tekti laukti net trejus metus. Santaros klinikose kasnakt atliekami tyrimai vos dviem pacientams, o diagnostikos prieinamumas išlieka ribotas. Be to, nors vidutinio sunkumo ir sunki OMA forma sergantiems asmenims yra rekomenduojamas gydymas nuolatinio teigiamo slėgio aparatais (CPAP), šie aparatai Lietuvoje nėra kompensuojami, todėl pacientams tenka patiems mokėti apie 700 eurų už aparatą ir papildomai įsigyti specialias kaukes. Diagnostikos kainos taip pat yra nemažos – polisomnografijos tyrimas kainuoja nuo 150 iki 220 eurų², priklausomai nuo klinikos, kas gali būti papildoma finansinė našta pacientams.

1.2. Kvėpavimo sutrikimų miego metu tyrimų ir technologijų apžvalga

Viena iš obstrukcinės hipopnėjos gydymo būdų yra nuolatinis teigiamas kvėpavimo takų slėgio ventiliacijos forma (CPAP), kai žmogaus viršutiniuose kvėpavimo takuose nuolat veikiamas pastovus slėgis, didesnis nei atmosferos slėgis. Miego metu pacientas dėvi kaukę ant nosies ir (arba) burnos ir oro slėgis reguliuojamas taip, kad jo pakaktų palaikyti atvertus kvėpavimo takus.

² Miego tyrimas Lietuvoje, prieiga per: <https://www.nordclinic.lt/miego-tyrimas>




2 pav. CPAP prietaiso veikimas

Tuo tarpu lengva obstrukcinė hipopnėja dažnai gali būti gydoma metant svorį arba vengiant miegoti ant nugaros. Taip pat gana efektyvu yra mesti rūkyti ir vengti alkoholio, raminamųjų ar migdomųjų vaistų prieš miegą. Chirurgija paprastai yra paskutinė hipopnėjos gydymo priemonė, stengiantis pašalinti specifinę problemą trukdančią laisvai kvėpuoti. Chirurginis OMA gydymas siekia praplėsti ir stabilizuoti susiaurėjusius viršutinius kvėpavimo takus. Priklausomai nuo paciento būklės, gali būti atliekamos minkštųjų audinių ar kaulinio skeleto operacijos.

Dabartinis auksinis obstrukcinės miego apnėjos diagnostavimo standartas yra naktinė daugiakanalė polisomnografija (PSG), brangi, daug darbo reikalaujanti ir nepatogi procedūra. Polisomnografija yra procedūra, kurios metu naudojama elektroencefalograma, elektrookulograma, elektromiograma, elektrokardiograma, pulso oksimetrija, matuojamas oro srautas ir kvėpavimo pastangos, siekiant įvertinti pagrindines miego sutrikimų priežastis [10]. Įprastam PSG reikalinga visapusiška stebėjimo sistema, leidžianti registruoti miego stadijas, galūnių judesius, oro srautą, kvėpavimo pastangas, širdies susitraukimų dažnį ir ritmą, deguonies prisotinimą ir kūno padėtį. Šio tipo tyrimai atliekami miego laboratorijoje, kurioje visą tyrimo laiką dalyvauja apmokytas miego technikas. PSG pirmiausia naudojami diagnozuoti su miegu susijusius kvėpavimo sutrikimus, įskaitant OMA, centrinę miego apnėją ir su miegu susijusią hipoventiliaciją / hipoksiją. Vis dėlto miego apnėja yra labiausiai paplitęs miego sutrikimas, dėl kurio diagnostiniai tyrimai atliekami miego centruose.

PSG metu naudojami kokybiški oro srauto jutikliai aptinka įkvėpto ir iškvėpto kvėpavimo temperatūros pokyčius, kad būtų galima stebėti oro srautą tiksliai apnėjos diagnostavimui. Nosies slėgio daviklis aptinka slėgio pokyčius įkvėpimo ir iškvėpimo metu, kad būtų galima stebėti oro srautą, ir yra naudojamas hipoanėjai nustatyti [11]. Tyrime taip pat naudojami du kvėpavimo induktyvumo pletizmografijos (angl. *respiratory inductance plethysmography* – RIP) jutikliai arba diržai naudojami kokybinei krūtinės ląstos ir pilvo kvėpavimo pastangoms nustatyti. RIP diržuose naudojami įterpti pjezokristalai, kurie skleidžia įtampos pokyčius, atitinkančius krūtinės ląstos ir pilvo judėjimą kvėpavimo metu. Būtent kartu naudojami šie jutiklių duomenys ir yra svarbiausiai miego ligoms aptikti. Ši polisomnografijos procedūra yra naudojama įvairių tipų kvėpavimo sutrikimams nustatyti, įskaitant obstrukcinę apnėją (visiškas kvėpavimo takų užsiklojimas, išliekant kvėpavimo pastangoms), obstrukcinę hipopnėją (dalinis kvėpavimo takų užsiklojimas, sukeliantis sumažėjusį oro srautą bei deguonies kiekį kraujyje) ir centrinę apnėją (nutrūksta tiek kvėpavimas, tiek kvėpavimo pastangos dėl centrinės nervų sistemos neveiklumo). Tačiau, dėl šiame tyrime reikalingų didelio kiekio sensorių (3 pav.), pacientams yra sukeliamas stresas, kas ne visada

tiksliai leidžia aptikti sutrikimus. Šis stresas ir nemiga yra dažniausiai sukeliamas dėl sunkumo užmigti naujoje aplinkoje, kitaip dar vadinamo pirmosios nakties efekto [12].



3 pav. Įvairių elektrodų ir jutiklių, naudojamų miegui stebėti polisomnografijos metu iliustracija [13]

Taip pat verta paminėti, jog norit išanalizuoti išmatuotus fiziologinius duomenis yra reikalingas apmokytas miego specialistas/ medikas. Apnėjos ir hipopnėjos įvykių anotavimas atliekamas remiantis Amerikos Miego Medicinos Akademijos (AASM) nustatytais kriterijais. Apnėja apibrėžiama kaip oro srauto sumažėjimas bent 90% netrumpiau kaip 10 sekundžių. Tuo tarpu hipopnėja – oro srauto sumažėjimas bent 30% netrumpiau 10 sekundžių, kuris yra lydimas bent 3% deguonies desaturacijos arba EEG užfiksuoto prabudimo. Šie kriterijai užtikrina vienodą ir patikimą įvykių identifikavimą. Anotavimas reikalauja aukštos kvalifikacijos specialistų, kurie peržiūri daugiakanalius duomenis (EEG, EOG, EMG, EKG, kvėpavimo srautus, deguonies saturaciją), identifikuoja ir klasifikuoja kvėpavimo įvykius pagal nustatytus kriterijus bei atskiria skirtingus apnėjos tipus (obstrukcinė, centrinė, mišri). Tai yra laiko ir darbo jėgos intensyvus procesas, kuris prisideda prie tyrimų brangumo.

Kita šio tyrimo problema yra tai, kad jis yra labai brangus ir sudėtingas diagnostikos metodas, reikalaujantis specializuotos įrangos ir medicinos personalo. Lietuvoje yra mažai PSG tyrimų centų, o klinikų, turinčių PSG įrangą, yra tik kelios. Dėl to, žmonės dažnai turi laukti ilgą laiką, kol jie gali gauti polisomnografijos tyrimą. Dažniausiai tyrimo laukimo laikas yra kelios savaitės ar net iki keleto mėnesių. Toks ilgas laukimo laikas gali būti ypač problemiškas pacientams, kuriems yra įtariama miego apnėja, kadangi jie jų būklė gali dar pablogėti. To būtų galima išvengti atliekant tyrimus namuose arba kitais pažangesniais metodais. Vienas iš tokių metodų yra fotopletizmografija (FPG). Tai optinė technologija, leidžianti ne tik patogiau stebėti pacientą namų aplinkoje, bet ir suteikianti vertingą informaciją apie kraujotaką ir širdies veiklą. Dėl savo paprastumo ir nedidelių išlaidų FPG signalai gali būti tinkama alternatyva arba papildomas įrankis tradicinei polisomnografijai.

1.2.1. Fotopletizmogramos signalai


Fotopletizmografija yra optinė, neinvazinė technologija, naudojama kraujo tūrio pokyčiams mikrovaskuliname audinyje registruoti. Šis metodas pagrįstas šviesos absorbcijos ir atspindžio principu: FPG jutiklis naudoja šviesos diodą (LED), kuris spinduliuoja šviesą į odą, ir fotodetektorius, kuris fiksuoja atgal atsispindėjusią ar praeinančią šviesą. Kadangi kraujas sugeria šviesą priklausomai nuo jo tūrio ir deguonies prisotinimo lygio, šie matavimai leidžia analizuoti kraujotakos dinamiką.

FPG signalas susideda iš dviejų pagrindinių komponentų: pulsinės (AC) dalies, kuri atspindi širdies plakimo sukeltus kraujo tūrio svyravimus, ir lėtosios (DC) komponentės, kuri yra susijusi su kvėpavimo, simpatinės nervų sistemos aktyvumo bei termoreguliacijos poveikiu kraujagyslėms [14]. Šie komponentai suteikia vertingos informacijos apie širdies ir kraujagyslių sistemos veiklą. Nors visi FPG signalo komponentai dar nėra iki galo suprasti, ši technologija plačiai naudojama medicinoje dėl jos paprastumo, mažų kaštų ir galimybės atlikti matavimus įvairiose klinikinėse aplinkose.

FPG jutikliai gali veikti perdavimo režimu (angl. *transmission mode*), kai šviesa praeina per audinį (dažniausiai pirštą ar ausies spenelį), arba atspindžio režimu (angl. *reflection mode*), kai šviesa atsispindi nuo odos paviršiaus (pvz., riešo, kaktos ar krūtinės srityje). Pastarasis metodas dažnai naudojamas nešiojamuosiuose įrenginiuose, tokiuose kaip išmanieji laikrodžiai ir apyrankės.

Dėl savo lankstumo FPG taikomas įvairiose srityse: jis naudojamas deguonies saturacijos (SpO_2) matavimui, širdies ritmo stebėjimui, kraujospūdžio vertinimui ir net miego sutrikimų, tokių kaip miego apnėja, diagnostikai. Be to, FPG signalų analizė leidžia įvertinti kraujagyslių standumą, autonominės nervų sistemos veiklą ir endotelio funkciją, todėl ši technologija turi didelį potencialą ankstyvajai širdies ir kraujagyslių ligų diagnostikai. Pastaraisiais metais susidomėjimas FPG ženkliai išaugo dėl didėjančio poreikio nebrangiems, neinvaziniams ir dėvimais sveikatos stebėsenos sprendimams.

Šiuolaikiniai FPG jutikliai naudoja nebrangią puslaidininkių technologiją su šviesos diodais ir suderintais fotodetektoriais, veikiančiais raudonais arba artimais infraraudonųjų spindulių bangų ilgiais. Šviesos diodai efektyviai paverčia elektros energiją į šviesą siauru dažnių juostos plokščiu (~ 50 nm), užtikrindami ilgaamžiškumą, stabilumą įvairiose temperatūrose ir minimalų mechaninį susidėvėjimą. Jų intensyvumas turėtų išlikti pastovus ir mažas, kad būtų išvengta audinių įkaitimo ir radiacijos rizikos. Fotodetektoriai, parinkti taip, kad atitiktų šviesos diodo spektrą, paverčia šviesą elektriniais signalais. Mažo triukšmo grandinė, įskaitant transimpedanso stiprintuvą ir filtrus, apdoroja signalą, sumažindama nuolatinės srovės komponentus ir filtruodama aukšto dažnio triukšmą, pvz., 50 Hz tinklo trikdžius. Paveikslėlyje (4 pav.(a)) pavaizduotas transimpedanso (angl. *transimpedance*) stiprintuvas, o paveikslėlyje (4 pav.(b)) pavaizduoti signalo apdorojimo etapai, įskaitant filtravimą, stiprinimą, inversiją ir signalo sąsają. Aukšto dažnio filtro ribinis dažnis yra svarbus sistemos parametras – pasirinkus per didelį AD filtro pjūvio dažnį filtravimas iškraipo impulso formą, o per mažas pjūvio dažnis leidžia dominuoti beveik nuolatinės srovės komponentui [14]. Ši sistema apima nuolatinės srovės tvarkyklę (angl. *driver*) FPG zondo šviesos diodui.



4 pav. Elektroniniai blokai, naudojami tipinėje FPG matavimo sistemoje [14]

FPG veikia dviem režimais: perdavimo režimu, kai audinys (pvz., piršto galiukas) yra tarp šviesos diodo ir detektoriaus, ir atspindžio režimu, kai abu yra vienas šalia kito. Perdavimo režimas riboja matavimo vietas labiau nei atspindžio režimas. Jutiklis turi būti uždėtas ant kūno taip, kad būtų kuo mažiau judesio artefaktų. Kiti artefaktai, tokie kaip aplinkos šviesos trukdžiai, gali būti sumažinti naudojant filtravimą. Verta paminėti, jog SpO_2 matavimui būtina naudoti du skirtingus šviesos šaltinius – raudoną (apie 660 nm) ir infraraudoną (apie 940 nm) šviesos diodus (LED). Tai padidina įrenginio sudėtingumą, energijos suvartojimą ir kainą. Be to, reikalingi papildomi komponentai, tokie kaip fotodiodai ir sudėtingesnės signalo apdorojimo grandinės, kad būtų galima atskirti ir analizuoti skirtingų bangų ilgių signalus [15]. Tuo tarpu FPG signalas, net ir naudojant vieną šviesos šaltinį, gali suteikti vertingos informacijos apie širdies ritmą, kraujagyslių tonusą ir kvėpavimo ritmą.

Tačiau vien tik FPG signalo tiesioginio stebėjimo ir standartinių signalų apdorojimo metodų gali nepakakti tiksliai nustatyti miego apnėjos epizodus. Kadangi FPG signalas turi daug subtilių, sunkiai pastebimų savybių ir yra veikiamas įvairių artefaktų, tokių kaip judesiai, aplinkos trikdžiai ar individualūs fiziologiniai skirtumai, reikalinga išsamesnė signalo analizė. Todėl norint išnaudoti visą turimą informaciją ir patikimai atskirti apnėjos įvykius nuo normalių kvėpavimo sąlygų, būtina taikyti inovatyvius metodus – tokius kaip duomenų klasterizavimas ir mašininio mokymosi klasifikavimo algoritmai. Šie metodai leidžia automatiškai nustatyti reikšmingus FPG signalo požymius bei efektyviai juos panaudoti tiksliai ir patikimai miego apnėjos diagnostikai.

1.2.2. Klasterizavimo ir klasifikavimo metodų analizė


Mašininis mokymasis yra dirbtinio intelekto metodų klasė, apimanti algoritmų, galinčių mokytis iš duomenų ir daryti prognozes ar sprendimus kūrimą [16]. Ši metodika yra susijusi su automatinio duomenų dėsningumų atradimu, kurie vėliau yra naudojami prognozėms ar klasifikavimui atlikti, nesant anksčiau griežtai tam suprogramuotiems. Tačiau mašininio mokslo sritis yra labai plati todėl reikia apžvelgti keletą technikų reikalingų tiksliai miego apnėjos sistemos sukūrimui.

Dirbtinis neuroninis tinklas. Dirbtiniai neuroniniai tinklai (angl. *Artificial neural network* – ANN) yra mašininio mokymosi algoritmų klasė, įkvėpta žmogaus smegenų biologinių neuroninių tinklų struktūros ir funkcijų [17]. ANN susideda iš tarpusavyje sujungtų mazgų, vadinamų neuronais, suskirstytų į sluoksnius. Kiekvienas neuronas gauna įvestį, atlieka tam tikrus skaičiavimus ir

perduoda išvestį kitam sluoksniui, kol bus gaunama galutinė išvestis. Modelio treniravimo metu jungčių tarp neuronų svoris yra reguliuojamas taip, kad būtų sumažintas skirtumas tarp numatomos išvesties ir tikrosios išvesties. Tai yra vadinamasis prižiūrimas (angl. *supervised*) mokymasis. Šiam procesui reikalingi anotuoti mokymosi ir treniravimo duomenys pagal kurio modelis siekia minimizuoti tikslo funkciją. ANN tapo nauju ir naudingu problemų sprendimo ir mašininio mokymosi modeliu. Jie geba spręsti sudėtingas įvairių sričių problemas. ANN yra naudojami įvairiose srityse, įskaitant žemės ūkį, mokslą, mediciną, finansus, saugumą, bankininkystę, draudimą, nekilnojamojo turto vertinimą ir energetiką [18].

Tačiau didžiausias šių modelių trūkumas yra erdvinio nekintamumo (angl. *spatial invariance*) nebuvimas [19]. ANN įvestis traktuoja kaip plokščius savybių vektorius ir neišsaugo vaizdų erdvinės struktūros. Tai reiškia, kad ANN, išmokytas atpažinti konkretų objektą vienoje vaizdo dalyje, gali neatpažinti to paties objekto kitoje vaizdo dalyje. Šis erdvinio nekintamumo trūkumas yra reikšmingas vaizdų klasifikavimo užduočių trūkumas. Todėl objektų atpažinimui ar klasifikavimui yra naudojami specialaus tipo konvoliuciniai neuroniniai tinklai

Konvoliucinis neuroninis tinklas. Mašininio mokymosi architektūros, žinomos kaip konvoliuciniai neuroniniai tinklai (CNN), dažnai naudojamos kompiuterinės regos užduotims, tokioms kaip objektų aptikimas ar vaizdų klasifikavimas. CNN naudoja telkimo sluoksnius, kad sumažintų įvesties vaizdų matmenis, ir konvoliucinius sluoksnius, kad išskirtų savybes iš analizuojamo vaizdo [20]. Vienas ar daugiau pilnai sujungtų sluoksnių, dažnai yra dedami po šių konvoliucijos sluoksnių, kad galima būtų klasifikuojanti vaizdą naudojant išskirtas savybes.



5 pav. Standartinė konvoliucinio neuroninio tinklo struktūra [21]

Konvoliucinės operacijos atliekamos savybių ištraukimui, o gautas rezultatas yra perduodamas aktyvinimo funkcijai [21]. Siekiant įvesti netiesiškumą į savybių erdvę ir palengvinti abstrakcijų mokymąsi, naudojamos aktyvinimo funkcijos. Būtent šis aktyvacijos funkcijų netiesiškumas ir leidžia išmokti semantinius vaizdų skirtumus. CNN modeliai gali pasiekti erdvinę arba laikinę duomenų koreliaciją dėl naudojamų konvoliucinių sluoksnių. Verta paminėti, kad viena iš pagrindinių CNN privalumų yra galimybė automatiškai išgauti savybes, todėl nereikia atskiros funkcijų ištraukėjo. Mokymuisi naudojamas atgalinio sklaidos algoritmas, kuris keičia svorius pagal tikslo funkciją. Taip CNN tipo modeliai geba išgauti įvairaus lygio savybes iš įvesties vaizdo dėl savo daugiapakopės struktūros [21].

Giliuoju mokymusi pagrįsti metodai. Gilusis mokymasis yra mašininio mokymosi metodų klasė, kurioje yra naudojami neuroniniai tinklai turintys daug didesnę sluoksnių skaičių, siekiant iš

neapdorotų duomenų išgauti aukšto lygio požymius. Tai yra svarbu, nes mokslininkams ranka atrenkant požymius pagal kuriuos turėtų mokytis neuroninis modelis atsiranda vietos klaidoms ir yra reikalingos ganėtinai tikslios analizuojamos srities žinios. Dėl šių trukumų sunku išgauti tikslingus požymius ir labiau sunkina tyrimą bei prailgina kūrimo ir testavimo laiką. Tuo tarpu giliojo mokymosi modeliai neturi šios problemos, todėl šio tipo modeliai pasiekė aukštų rezultatų įvairiose programose, įskaitant kompiuterinį regėjimą, natūralios kalbos apdorojimą, kalbos atpažinimą ir daugelį kitų. Šiuos rezultatus leidžia pasiekti didesnis paslėptų neuronų sluoksnių skaičius modelyje, kurie yra sujungti netiesinėmis aktyvinimo funkcijomis ir taip tinklas geba išmoksti sudėtingus ryšius tarp įvesties ir išvesties, kas nėra įmanoma vieno sluoksnio tinkle [22]. Tačiau norint tai įgyvendinti yra reikalingi didžiuliai duomenų rinkiniai, kuriuose dažnai yra milijonai pavyzdžių, ir didžiulė skaičiavimo galia, dažniausiai išreiškiama kaip grafinių vaizdo plokščių (GPU) poreikis [23]. Populiarios gilaus mokymosi architektūros apima konvoliucinius neuroninius tinklus (CNN), rekurentinius neuroninius tinklus (RNN) ir transformatorių modelius. Šie modeliai pasiekė aukšto lygio našumą atliekant įvairias užduotis, kadangi yra apmokomi aukštos kokybės didelio masto duomenų rinkiniais [24].

Transformatorių modeliai. Transformatorių architektūra yra viena iš naujausių ir pažangiausių neuroninių tinklų struktūrų. Pristatyta 2017 m. [25] ši architektūra tyrėjams leido pasiekti didžiulius proveržius kalbos atpažinimo, kompiuterinio matymo ir ypač natūralios kalbos apdorojimo srityse. Šie modeliai buvo pristatyti kaip alternatyva tradiciniams rekursiniams neuroniniams tinklams (RNN) ir ilgosios trumposios atminties tinklams (LSTM), kurių veikimą riboja sunkumai mokantis ilgalaikes priklausomybes duomenyse. Transformatorių modeliai pagrįsti *savidėmesio* (angl. *self-attention*) mechanizmu, kuris leidžia efektyviai modeliuoti ilgalaikes ir trumpalaikes priklausomybes tarp įvesties duomenų elementų be rekursinių skaičiavimų poreikio.

Kadangi transformatorių modeliai sėkmingai pritaikyti įvairioms natūralios kalbos apdorojimo ir kompiuterinio matymo užduotims, jie vis dažniau taikomi ir laiko eilučių (angl. *time series*) analizės srityje [26]. Tarp daugybės transformatorių pranašumų, galimybė užfiksuoti ilgalaikes priklausomybes ir sąveikas yra ypač patraukli laiko eilučių modeliavimui, o tai lemia pažangą įvairiose laiko eilučių uždaviniuose. Tarp daugelio transformatorių architektūros pranašumų, ypač svarbus yra gebėjimas įvertinti ilgalaikes priklausomybes ir sąveikas. Dėl šios priežasties transformatorių modeliai tampa itin veiksmingi laiko eilučių analizėje ir skatina reikšmingą pažangą įvairiose laiko srities duomenų taikymo srityse.

Žinių perdavimas. Žinių perdavimas (angl. *transfer learning*) yra mašininio mokymosi technika, kai žinios įgytos sprendžiant vieną problemą yra pritaikomos kitai, bet susijusiai problemai. Giliojo mokymosi kontekste žinių perkėlimas apima pakartotinį iš anksto paruošto neuroninio tinklo naudojimą, kad būtų išspręsta nauja užduotis su ribotais testavimo imties duomenimis. Tokios technikos naudojimas žymiai pagerina modelio našumą ir taip duomenų mokslininkas nėra reikalingi dideli sužymėti duomenų rinkiniai. Mokymosi perkėlimas tapo esmine technika, leidžiančia pasiekti aukščiausio lygio tikslumo rodiklius kompiuterinės regos uždaviniuose, ypač kai užduoties duomenų rinkinys yra mažas [27]. Mokymosi perkėlimas veikia pasinaudojant iš anksto apmokytais modeliais su didelio šaltinio duomenų rinkiniu. Taip yra išskiriami esminiai požymiai, kurie dažnu atveju yra panašūs kompiuterinės regos uždaviniuose. Tai leidžia modeliui efektyviau mokytis iš tikslinio duomenų rinkinio nei kuriant naujus modelius ir apmokant juos su atsitiktiniais pradiniais neuronų svoriais.


Mokslininkai yra nustatę, kad dėl panašios fizinės prigimties galima atlikti žinių perdavimą tarp elektromiografinių (EMG) signalų ir elektroencefalografinių (EEG) smegenų bangų [28] iš gestų atpažinimo srities į psichinės būsenos atpažinimo srities. Pastebėta, kad šis ryšys veikė abiem kryptimis, parodydamas, kad elektroencefalografija taip pat gali būti naudojama klasifikuojant EMG. Eksperimentuose buvo pastebėta, kad neuronų tinklų ir konvoliucinių neuroninių tinklų tikslumas buvo pagerintas, perkeliant mokymąsi prieš bet kokį mokymąsi (pirmoji epocha), kitaip sakant lyginant su standartiniu atsitiktiniu svorio pasiskirstymu, ir mokymosi proceso pabaiga. Tai reiškia, kad kontaktas su kita sritimi per mokymosi perkėlimą gali pagerinti mokymosi proceso rezultatus.

Mokymosi perkėlimas tampa vis populiariesnis dirbtinio intelekto srityje, ypač gilaus mokymosi srityje, nes atsirado prieiga prie atvirų didelio masto duomenų rinkinių, kaip pavyzdžiui „ImageNet“. Pastaruoju metu buvo įrodyta, kad tiek žemo, tiek aukšto lygio atpažinimo savybės gali būti perkeltos į bendrą atpažinimo užduotį, o daugelis gilaus mokymosi bibliotekų, tokių kaip *Keras*, *Tensorflow* ar *PyTorch*, suteikia prieigą prie iš anksto paruoštų modelių [29].

1.2.3. Išmanios apnėjos atpažinimo sistemos

Apžvelgus kitų mokslininkų darbus siekiant automatiškai ir su aukštu tikslumu diagnozuoti miego apnėjos epizodus, paprastai yra naudojama viena technika iš keturių metodų grupės. Šie metodai remiasi: pulso oksimetrija (kartais kartu su FPG), EKG, kvėpavimu, garsu arba kombinuojant šiuos metodus kartu [30]. Dėl jau anksčiau aptarto streso, sukeliama polisomnografijos būdu registruojant signalus, šiame darbe keliamas klausimas ar galima atpažinti apnėjos epizodus naudojant tik vieną FPG jutiklį.

Nors atraminių vektorių klasifikatorių pagrindu kuriami algoritmai geba klasifikuoti garso signalus, naujausiuose darbuose dirbtinio intelekto srityje pastebima tendencija link labiau pažengusių metodų, tokių kaip konvoliuciniai, neuroniniai tinklai ar ilgos-trumpos atminties neuroniniai tinklai. Būtent naudojantis šių dviejų metodų kombinacija Xu Lin pasiūlė apnėjos atpažinimo sistemą [31]. Šiame darbe mokslininkai naudojo garsus surinktus iš 32 pacientų ir sugebėjo pasiekti 73,92 procentų tikslumą naudojant keturių klasių klasifikavimą. Knarkimo garsai buvo įrašomi su *Sony PCM A100* įrenginiu naudojant du mikrofonus. Įrašymo prietaisai buvo padėti vieno metro atstumu nuo pacientų. Garso duomenų fiksavimo dažnis (angl. *sampling rate*) buvo 44,1 kHz, o įrašytas garsas buvo išsaugotas kaip dviejų kanalų wav failas. Tyrime buvo naudojamos Melo filtrų banku išskirti požymiai iš knarkimo garsų. Būtent Melo filtrai buvo pasirinkti remiantis žmogaus klausos sistemos netiesinio garso dažnio suvokimo ypatybėmis. Naudojant šiuos filtrus tyrėjai gavo 16x16 pikselių dydžio nuotraukas, kurias naudojo kaip neuroninių tinklų įvestis.



6 pav. Pasiūlyto neuroninio tinklo architektūra kombinuojant CNN ir LSTM [31]

Mašiniam mokymuisi buvo naudojamas konvoliucinis neuroninis tinklas kartu su rekurentiniu LSTM tipo neuroniniu tinklu sujungiant šių dviejų tinklų paskutinius išėjimo vektorius į vieną sluoksnį. Verta paminėti, kad mokslininkai sukurtą modelį testavo su *STM32* ARM procesoriaus tipo realaus laiko įterptine sistema. Dėl įterptinių sistemų resursų ribotumo tinklo parametrų skaičius buvo sumažintas 40,27 % tuo tarpu tikslumas sumažėjo tik 0,35 %. Nors autoriai teigia, kad tai yra džiuginantis rezultatas iš tiesų galėtume kelti klausimą ar pradinis neuroninis tinklas nebuvo per didelis, jei sumažinus parametrų skaičių tikslumas sumažėtų taip neženkiai. Vis dėlto, tai parodo potencialą sukurti išmaniuosius įrenginius, naudojamus namuose, šios ligos prevencijos tikslams.

Kaip kitą konvoliuciniu neuroniniu tinklu paremtą mašininio mokymosi darbą galima pateikti 2022 metų Li Ding tyrimą knarkimo garsų klasifikavimui [32]. Tyrime yra nagrinėjamas mažas ir nesubalansuotas duomenų rinkinys su 828 knarkimo epizodais, kurie jau buvo suskirstyti į mokymo, testavimo ir validavimo grupes. Duomenų rinkinyje knarkimo įvykiai buvo išgauti ir išsaugoti kaip atskiri 16 bitų rezoliucijos wav failai, kurių įrašymo dažnis buvo 16 kHz. Iš visų 828 įrašų treniravimui skirtose dalyje buvo tik 282 įrašai, kas lemia problemas naudojant mašininio mokymosi metodus ir gilųjį mokymąsi, norint išmokyti kiekvienos klasės bruožus. Todėl autoriai modelio mokymuisi naudojo naują mašininio mokymosi paradigmą, vadinama „kelių šūvių mokymasis“ (angl. *Few-Shot Learning*), su keliais pažymėtais pavyzdžiais kiekvienai klasei. Kaip modelio įvestis buvo naudojamos Melų spektrogramos analizuojamiems knarkimo garsams išreikšti. Darbe buvo palyginamos skirtingos neuroninių tinklų architektūros: skirtingi konvoliucijos sluoksnių skaičiai (4 ir 6) ir įvairios vidurinių sluoksnių kombinacijos. Galiausiai, tyrėjai nustatė, kad geriausius rezultatus pasiekė CNN tinklas su šešių sluoksnių konvoliucija ir papildoma kryžminės entropijos (angl. *complement-cross-entropy*) tikslo funkcija, kuri atsižvelgia į duomenų rinkinio netolygumo problemą. Galiausiai geriausiu atveju testavimo imtyje buvo pasiektas 77,13 procentų nesvertinio vidutinio atšaukimo rodiklis (angl. *Unweighted Average Recall*). Taip naudojantis Melų spektrogramomis ir konvoliuciniais neuroniniais tinklais autoriai teigia pagerinę kitų mokslininkų rezultatus kurių geriausi siekė 72,6% pagal analogišką įvertį.


1.2.4. Fotopletizmografijos pagrindu apnėjos detektavimo algoritmų analizė

Vienas iš inovatyvių darbų pasitelkiant mašininį mokymąsi bei naudojant FPG signalus yra Remo Lazazzera ir kolegų darbas [33]. Šiame tyrime buvo pasiūlytas metodas, pagrįstas fotopletizmografijos ir periferinio deguonies prisotinimo (SpO_2) signalų analize, siekiant tiksliai identifikuoti kvėpavimo sutrikimus miego metu ir klasifikuoti juos į skirtingas kategorijas. Tyrime pasiūlytas algoritmas susideda iš dviejų pagrindinių detektorių: 1) DAP detektorius – aptinka FPG signalo amplitudės svyravimų sumažėjimus, kurie gali būti susiję su simpatinės nervų sistemos suaktyvėjimu dėl kvėpavimo sutrikimų. 2) Deguonies desaturacijos detektorius – nustato SpO_2 signalo kritimus, kurie dažnai lydi miego apnėjos epizodus. Be to, buvo išgautos pulso dažnio variacijos charakteristikos, kurios leidžia įvertinti autonominės nervų sistemos atsaką į miego sutrikimus. Vėliau šios savybės buvo naudojamos klasifikacijai tarp centrinės ir obstrukcinės apnėjos bei hipopnėjos. Klasifikacija buvo atliekama trijuose etapuose: centrinė ar obstrukcinė apnėja, centrinė apnėja ar centrinė hipopnėja, obstrukcinė apnėja ar obstrukcinė hipopnėja. Tyrime buvo išbandyti keli klasifikatoriai, o geriausius rezultatus parodė *Fine Gaussian SVM* metodas su Gausso branduoliu. Straipsnyje atsižvelgiama į klasių disbalansą. Kadangi skirtingų miego sutrikimų įvykių pasiskirstymas duomenų rinkinyje buvo netolygus, autoriai taikė adaptyvųjį sintetinių duomenų generavimo (angl. *Adaptive Synthetic Sampling*) metodą. Ši technika generuoja papildomus sintetinius duomenis mažiau atstovaujamoms klasėms, ypač akcentuojant tas sritis, kuriose klasės ribos yra neaiškios.

Mokslininkų gauti rezultatai – bendras apnėjos ir hipopnėjos aptikimo tikslumas - 75.1% (vienos minutės segmentuose), centrinės ar obstrukcinės apnėjos klasifikacija- 92.6% tikslumas, centrinės apnėjos ar hipopnėjos atskyrimas- 83.7% tikslumas, obstrukcinės apnėjos ar hipopnėjos atskyrimas: 82.7% tikslumas. Taip šis tyrimas parodė, kad FPG ir SpO_2 signalų analizė gali būti efektyvi miego apnėjos pirminiam aptikimui ir klasifikavimui, ypač neinvazinėse namų sąlygomis.

Kitas iš tyrimų, nagrinėjančių miego apnėjos ir hipopnėjos aptikimą bei klasifikaciją naudojant FPG signalus, yra 2023 metų Keming Wei ir kitų autorių darbas “MS-Net” [34]. Šiame straipsnyje pasiūlytas MS-Net modelis apjungia *multi-scale* vienmatės konvoliucinės tinklo bloką ir šešėlinį (*shadow*) modulį. *Multi-scale* blokas leidžia išgauti laiko eigos savybes skirtinguose laiko masteliuose, o *shadow* modulis padeda efektyviau išnaudoti perteklinę informaciją po *multi-scale* konvoliucijų, išlaikant paprastą modelio struktūrą bei sumažinant reikalingų kompiuterinių resursų kiekį. Taip pat autoriai naudojo duomenų subalansavimo metodus (angl. *balanced bootstrapping*) ir klasių svorius, siekiant sumažinti klasės disbalanso įtaką klasifikavimo rezultatams. Kaip modelių įvestis buvo naudojami du iš FPG signalų išskirti požymiai: 1) laiko intervalai tarp FPG viršūnių - PPI (angl. *Peak-to-Peak Interval*), 2) FPG signalo amplitudės pokyčiai - DAP (angl. *Decreases in Amplitude Fluctuation*).

Iš kiekvieno 1 minutės segmento buvo išgauti PPI ir DAP požymiai. Kad duomenys būtų vienodo formato, PPI ir DAP sekos buvo interpoliuotos iki 200 taškų naudojant kubinio splaino interpoliacijos algoritmą (angl. *cubic spline interpolation*).



7 pav. Autorių pasiūlytos sistemos schema [34]

Straipsnyje naudojama apnėjos-FPG duomenų bazė buvo surinkta Sun Yat-sen universiteto ligoninėje. Duomenų rinkinys sudarytas iš 110 vieno kanalo FPG įrašų, užfiksuotų nakties metu. Diskretizavimo dažnis – 100 Hz. Vieno įrašo trukmė svyruoja nuo 200 iki 586 minučių, bendrai surinkta 53089 minutės FPG duomenų. FPG signalai buvo suskaidyti į 1 minutės segmentus. Apnėjos epizodai buvo identifikuojami pagal $AHI \geq 30$ (apnėjos-hipopnėjos indeksą), kuris naudojamas kaip apnėjos klasifikavimo kriterijus. Galiausiai mokslininkai po 5-kartotinės kryžminės validacijos segmentui (60s FPG signalo) klasifikacijoje pasiekė šiuos rezultatus: tikslumas (angl. *accuracy*)-82.0%, jautrumas (angl. *sensitivity*)-74.4% specifiškumas (angl. *specificity*)-85.1%, F1-įvertis: 69.8%. Tuo tarpu per įrašą (*per-recording*) klasifikacijoje: tikslumas-93.6%, jautrumas-80.0%, specifiškumas-97.6%.

Tarp naujausių darbų, analizuojančių miego apnėjos detekciją remiantis vien tik fotopletizmografijos signalais, svarbus yra T. Choksatchawathi ir kt. 2024 pristatytas algoritmas ApSense [35]. Šiame tyrime buvo pasiūlyta specializuota giliojo mokymosi architektūra, kurioje derinami septyni iš FPG signalo išskiriami požymiai, susiję su kraujotakos sistemos veikla, pavyzdžiui: pulso bangos amplitudė (PWA), piko intervalai (PPI), jų dariniai bei sistolinės ir diastolinės fazės trukmės. FPG signalas segmentuojamas slankiuoju langu į 60 s trukmės langus su 50 % persidengimu, o kiekvienas langas filtruojamas naudojant Chebyshev II tipo juostinį filtrą (0.1–20 Hz). ApSense sudarytas iš kelių erdvės-laiko blokų, šakoto konvoliucinio tinklo (BCNN) ir pilnai sujungtų sluoksnių. Analizė atskleidė, kad tinkamai parinktos architektūros dalys – ypač variacinis *dropout* LSTM sluoksniuose ir kelių mastelių konvoliucijos – reikšmingai pagerina modelio našumą skirtinguose duomenų rinkiniuose. Modelis buvo testuotas su dviem viešais duomenų rinkiniais – *MESA* ir *HeartBEAT*, pasižyminčiais skirtinga signalų kokybe. Testuojant su *MESA* rinkiniu ApSense pasiekė 75.1 % tikslumą, o *HeartBEAT* – 62.3 %, tuo tarpu AUROC atitinkamai siekė 77.6 % ir 74.4 %.

1.3. Atviros prieigos signalų duomenų bazių apžvalga

Analizuojant kitų mokslininkų apnėjos aptikimo sistemas naudojant mašininį mokymą yra pastebima vis pasikartojanti problema – aukštos kokybės viešai prieinamų duomenų rinkinių trūkumas. Tai lemia, kad mokslininkams tenka bendradarbiauti su klinikomis ar kitomis medicinos įstaigomis norint surinkti reikiamų duomenų modelių treniravimui. Būtent ši kliūtis yra itin aktuali kuriant sistemas aptikti apnėjos sutrikimą, naudojantis fotopletizmogramos signalu. Stengiantis apeiti šią problemą šiame darbe pradiniais modeliams sukurti yra naudojami viešai pasiekiami PSG miego tyrimo duomenų rinkiniai.

MESA (Multi-Ethnic Study of Atherosclerosis) yra ilgalaikis tyrimas, kuriame analizuojama širdies ir kraujagyslių ligų raida skirtingų etninių grupių žmonių [36]. Tyrime buvo surinkti įvairūs fiziologiniai duomenys, įskaitant ir miego tyrimus, todėl *MESA* naudojama moksliniuose darbuose, susijusiuose su miego sutrikimais, įskaitant apnėją. Vis dėlto šis duomenų rinkinys nėra lengvai prieinamas – norint jį gauti, reikia pateikti oficialų prašymą, kuris turi būti patvirtintas tyrimo komiteto. Tai apsunkina galimybę greitai ir lengvai naudoti šiuos duomenis kuriant naujus modelius ar algoritmus. Be to, nors duomenų kiekis yra nemažas, jis nėra orientuotas būtent į fotopletizmogramos (FPG) signalą, kuris šiame darbe yra pagrindinis analizės objektas. Dėl šių priežasčių *MESA* duomenų rinkinys šiame darbe nebus naudojamas.

Kitas duomenų rinkinys susijęs su obstrukcinės miego apnėjos gydymo poveikiu širdies ir kraujagyslių sistemos veiklai yra *HeartBEAT (Heart Biomarker Evaluation in Apnea Treatment)*. [37]. Šiame tyrime dalyvavo 318 pacientų, sergančių vidutinio sunkumo arba sunkia OMA, kurie buvo atsitiktinai paskirstyti į tris grupes: gydymą nuolatinio teigiamo slėgio kvėpavimo takuose (CPAP) aparatu, papildomu deguonimi arba sveikos gyvensenos ir miego edukacija. Pagrindinis tyrimo tikslas buvo įvertinti šių intervencijų poveikį 24 valandų vidutiniam arteriniam kraujospūdžiui po 12 savaičių gydymo. Nors *HeartBEAT* tyrimas suteikia vertingų įžvalgų apie OMA gydymo poveikį širdies ir kraujagyslių sistemai, jo duomenys nėra viešai prieinami. Norint gauti prieigą prie šių duomenų, reikia kreiptis į tyrimo organizatorius ir gauti jų leidimą. Be to, tyrime daugiausia dėmesio skiriama gydymo intervencijų poveikiui, o ne specifiniams signalams, tokiems kaip fotopletizmogramos (FPG), analizuoti. Dėl šių priežasčių *HeartBEAT* duomenų rinkinys nėra tinkamas šio darbo tikslams.

Tinkamiausias šio darbo tikslams yra *OSASUD (Obstructive Sleep Apnea Stroke Unit Dataset)* duomenų rinkinys [38], sudarytas iš 30 pacientų, hospitalizuotų Udine universiteto ligoninės insulto skyriuje (Italija), dėl įtariamo cerebrovaskulinio įvykio (insulto). Šis rinkinys išsiskiria tuo, kad pacientai turi įvairių gretutinių ligų, duomenys pasižymi triukšmu ir trūkstamomis reikšmėmis, todėl jis geriau atspindi realią klinikinę aplinką nei kiti anksčiau publikuoti miego apnėjos duomenų rinkiniai, kurie dažnai renkami kontroliuojamomis sąlygomis. Kiekvienam pacientui pirmosiomis dienomis po insulto buvo atlikti vienalaikiai visos nakties polisomnografijos ir gyvybinių funkcijų matavimai. Duomenys apima įrašus, gautus naudojant daugiakanalę EKG, fotopletizmografiją (FPG) ir polisomnografiją. Be to, pateikiamos su tuo susijusios OSAS epizodų anotacijos, parengtos ekspertų. Rinkinys skirtas automatizuotų OSAS epizodų aptikimo metodų kūrimui, pasitelkiant įprastai stebimus medicininius rodiklius, siekiant pritaikyti juos realiose klinikinėse situacijose. Kadangi šis duomenų rinkinys yra atviros prieigos ir tinkamas automatizuotų OSAS epizodų aptikimo metodų kūrimui realiose klinikinėse situacijose, nuspręsta jį pasirinkti tolimesniems šio darbo tyrimams. Duomenų kiekis yra pakankamas modeliui treniruoti, bet ne per didelis – viso rinkinio dydis siekia apie 3,5 GB. *OSASUD* duomenų bazės kūrėjai jau pristatė algoritminį sprendimą OSAS epizodams atpažinti [39], tačiau jų sukurtas metodas remiasi vieninteliu įėjimo signalu - EKG. Studijų, naudojančių *OSASUD* duomenų bazę ir FPG signalą, nėra.

2. Miego apnėjos atpažinimo algoritmų tyrimas

Šiame darbe nagrinėjami mašininio mokymusi grįsti metodai, skirti miego apnėjai atpažinti ir klasifikuoti naudojant tik FPG signalą. Tyrime analizuojama, kaip skirtingos duomenų apdorojimo ir klasifikavimo technikos gali padėti tiksliau nustatyti kvėpavimo sutrikimus. Šiame skyriuje pristatomas duomenų rinkinys modeliams apmokyti ir testuoti, taip pat aptariami pagrindiniai metodologiniai aspektai, susiję su FPG signalų analize, apdorojimu ir modelių taikymu apnėjai atpažinti bei metodu įvertinimui.


2.1. Miego tyrimo duomenų rinkinys OSASUD

Tyrime naudojamą OSASUD duomenų rinkinį sudaro ne tik pirminiai signalai (EKG, FPG), bet ir išvestiniai parametrai: širdies susitraukimų dažnis, deguonies saturacija, pulso indeksas, kvėpavimo dažnis ir priešlaikinės skilvelinės kontrakcijos (angl. *premature ventricular contractions*). Jie buvo išgauti atlikus trečio lygio polisomnografiją (PSG) naudojant *Embletta MPR* polisomnografą be vaizdo stebėsenos.

2 lentelė. Pagrindiniai OSASUD duomenų rinkinio duomenų kanalai ir jų parametrai

Signalas	Specifika	Dažnis	Apdorojimas
EKG	Ag-AgCl elektrodai, 12 laidų (<i>Mindray</i> prietaisas)	80 Hz	Žemųjų dažnių 0,5 Hz ir aukštųjų 40 Hz dažnių filtrai; 60 Hz įpjovos filtras
Širdies pulsas	Gauta iš EKG duomenų	1 Hz	Nėra
FPG	Raudonųjų infraraudonųjų spindulių šviesos diodas ir jutiklis yra priešingose piršto pusėse (<i>Mindray</i> prietaisas)	80 Hz	Nėra
Deguonies prisotinimas (SpO ₂)	Gauta iš FPG duomenų	1 Hz	Nėra

Matuojant deguonies saturaciją buvo naudojama peršvietimo principu veikianti FPG technologija su raudona ir infraraudona šviesa. Signalų diskretizavimo dažniai: 80 Hz EKG, FPG ir krūtinės impedanso signalams, 1 Hz širdies ir kvėpavimo dažniui, saturacijai bei kraujospūdžiui (pastarasis registruotas kas valandą). Toliau PSG duomenys buvo analizuoti programine įranga, o anotacijas atliko miego medicinos specialistai pagal Amerikos miego medicinos akademijos (AASM) taisykles. Kiekvienas užfiksuotas miego sutrikimo epizodas buvo pažymėtas pagal jo tipą (centrinė, obstrukcinė ar mišri apnėja bei hipopnėja) ir laiką (8 pav.).




8 pav. Duomenų rinkinio anotuotos apnėjos įvykiai [38]

Miego tyrimo duomenų rinkinys OSASUD, kuris yra naudojamas šiame tyrime, yra pateikiamas *Pickle* formatu, (failu *dataset_OSAS.pickle*). Jį sudaro 18 stulpelių (signalų kanalų) ir 961357 eilučių (įvairių signalų verčių), kurios yra išsaugotos 1 sekundės intervalais.

3 lentelė. Duomenų rinkinio demografija

Parametras	Vidutinė reikšmė	Mažiausia reikšmė	Didžiausia reikšmė	Mediana	Standartinis nuokrypis
Amžius (metais)	68,97	33	87	70	11,21
Kūno masės indeksas (kg/m ²)	29,17	16,8	45	28	5,64
PSG įrašymo trukmė (val.)	8,9	4,1	11,9	9,05	1,45
Apnėjos/hipopnėjos indeksas – AHI	25,43	0	73	23,50	20,95


Siekiant geriau suprasti, kaip atrodo surinkti duomenys, pateikiama FPG signalo iškarpa laiko srityje (9 pav.). Vienas iš pagrindinių šiame tyrime analizuojamų signalų yra FPG, kuris atspindi kraujotakos pokyčius ir gali būti naudojamas kvėpavimo sutrikimams nustatyti. Norint tinkamai interpretuoti duomenis ir įvertinti jų kokybę, svarbu vizualizuoti signalus ir suprasti ar jie yra logiški. Toliau pateikiama FPG signalo iškarpa leidžia įvertinti jo struktūrą bei dinamiką laiko atžvilgiu.



9 pav. Nefiltruoto FPG signalo iškarpa laiko srityje

Toliau analizuojant duomenų rinkinį, buvo įvertintas trūkstamų reikšmių (*null values*) pasiskirstymas. Kadangi FPG signalas naudojamas miego apnėjos detekcijai, svarbu užtikrinti, kad duomenų kokybė būtų kuo aukštesnė. Literatūroje pateikiama, jog trūkstamos reikšmės OSASUD duomenų rinkinyje buvo žymimos kaip *numpy.NaN*, siekiant išlaikyti laiko žymų tęstinumą [38]. Šios trūkstamos reikšmės dažniausiai atsiranda dėl žmogaus judėjimo miego metu – pacientas gali nesąmoningai judėti, pasisukti arba net nusiimti neinvazinius FPG jutiklius nuo rankos, dėl ko gaunamos nelogiškos arba nepatikimos reikšmės. Taip pat, pagal duomenų rinkinio aprašymą, reikšmės, neatitinkančios fiziologiškai pagrįstų intervalų (pvz., deguonies išotininimas mažesnis nei 50% arba didesnis nei 100%, širdies susitraukimų dažnis mažesnis nei 20 arba didesnis nei 200, kvėpavimo dažnis mažesnis nei 5 arba didesnis nei 40), buvo pažymėtos kaip *null* reikšmės.


Šiame tyrime visos trūkstamos reikšmės buvo pašalintos, nes jos neturi informacinės vertės modelio mokymui. Žemiau pateikiamas paveikslėlis (10 pav.) su trūkstamų reikšmių pasiskirstymu tarp duomenų rinkinio signalų.



10 pav. Trūkstamų duomenų dalis aktualiuose duomenų rinkinio kanaluose

Anotacijos apie apnėją analizuojamame duomenų rinkinyje pateikiamos kaip žymos, kurios nurodo kvėpavimo būseną kiekvienu laiko momentu. Konkretūs žymų pavadinimai duomenų rinkinyje yra *NONE* (normalus kvėpavimas), *HYPOPNEA* (hipopnėja) ir trys skirtingi apnėjos tipai: *APNEA-CENTRAL* (centrinė apnėja), *APNEA-OBSTRUCTIVE* (obstrukcinė apnėja) ir *APNEA-MIXED* (mišri apnėja). Be to, pateikiamas papildomas loginis kintamasis, kuris leidžia paprasčiau atskirti normalius ir sutrikusius kvėpavimo epizodus – jei reikšmė yra *True*, tai reiškia, kad buvo užfiksuota hipopnėja ar apnėja.

Norint aiškiau suprasti, kaip šios anotacijos susijusios su FPG signalu, žemiau pateikiama 30 sekundžių FPG signalo iškarpa. Taip pat vizualizuojamas tokio pačio ilgio, 30 sekundžių intervalas, kuriame užfiksuotas apnėjos epizodas. Tokia analizė padeda įvertinti signalo pokyčius ir jų ryšį su kvėpavimo sutrikimais.



11 pav. Viršuje be apnėjos, apačioje su apnėja (hipopnėjos įvykis)

Šios anotacijos yra svarbios modelių mokymui, nes jos leidžia algoritmui susieti FPG signalo pokyčius su kvėpavimo anomalijomis. Kadangi duomenų rinkinys pateikiamas su iš anksto paruoštomis žymomis, jis gali būti tiesiogiai naudojamas giluminio mokymosi modelių treniravimui, siekiant efektyviai aptikti ir klasifikuoti kvėpavimo sutrikimus.

Vienas bendras iššūkis, su kuriuo susiduria apnėjos atpažinimo metodai, yra klasių disbalansas. Turimas OSASUD duomenų rinkinys pasižymi reikšmingu skirtumu tarp apnėjos ir sveikų (be apnėjos epizodų) klasių pasiskirstymo. Kadangi duomenys yra anotuoti vienos sekundės tikslumu, jame apnėjos epizodai sudaro tik 15,76 %, o likę 84,24 % – tai sveiko miego atvejai. Šiame darbe siekiama įvertinti klasifikavimo rezultatų pokytį, taikant skirtingo ilgio analizės langus, todėl duomenys buvo agreguoti į FPG langus po 10, 20, 30 ir 60 sekundžių. Langas laikomas apnėjos, jei jame fiksuojama bent 10 sekundžių trukmės apnėja. Apnėjos epizodų pasiskirstymas skirtingų ilgių languose pateikiamas lentelėje (4 lentelė). Pasirinktas 10 sekundžių slenkstis (angl. *threshold*) remiasi AASM apibrėžta apnėjos trukme. Langai nėra persidengiantys (angl. *non-overlapping*), siekiant išvengti duomenų nutekėjimo (angl. *data leakage*), kuris galėtų lemti pervertintą modelio tikslumą.

4 lentelė. Apnėjos epizodų pasiskirstymas esant skirtingiems FPG analizės langams

Klasė	Procentinė dalis, 1s intervalais, %	Procentinė dalis, 10s intervalais (kai iš jų bent 10s apnėjos), %	Procentinė dalis, 20s intervalais (kai iš jų bent 10s apnėjos), %	Procentinė dalis, 30s intervalais (kai iš jų bent 10s apnėjos), %	Procentinė dalis, 60s intervalais (kai iš jų bent 10s apnėjos), %
Apnėjos epizodai	15,76	9,10	16,93	24,59	33,69
Sveiki (neapnėjos) epizodai	84,24	90,90	83,07	75,41	66,31

Taigi, toks ryškus disbalansas lemia, kad mokomi modeliai natūraliai yra linkę teikti prioritetą dažniausiai pasitaikančiai klasei (neapnėjos epizodams), todėl kyla rizika prarasti gebėjimą patikimai identifikuoti retesnius, tačiau kritškai svarbius apnėjos atvejus. Norint išspręsti šią problemą, naudojami klasių svoriai. Klasių svoriai padeda sumažinti modelio polinkį dominuojančiai klasei, suteikiant didesnę svorį rečiau sutinkamai klasei (šiuo atveju – apnėjai). Tokiu būdu užtikrinama, kad modelis daugiau dėmesio skiria anomalijų atpažinimui, geriau geba identifikuoti apnėjos epizodus, ir išvengiama perteklinių klaidingų neigiamų prognozių.

Šiame darbe modeliams treniruoti naudojami paprasti, proporcingai duomenų pasiskirstymui pritaikyti klasių svoriai, kai retesnei klasei (apnėjos epizodams) priskiriamas didesnis svoris, o dominuojančiai klasei (neapnėjos epizodams) – mažesnis:

$$w_k = \frac{N}{2 * n_k} ; \quad (1)$$

čia: w_k klasės k svoris, N – bendras epizodų skaičius (visų klasių suma), n_k - epizodų skaičius klasei k , skaičius 2 žymi, kad turime 2 klases. Taip siekiama užtikrinti, kad gautas modelis būtų jautresnis ir patikimesnis rečiau pasitaikančių apnėjos epizodų aptikimui.

2.2. Siūlomi apnėjos atpažinimo algoritmai

Šiame darbe ištirti dviejų tipų apnėjos epizodų atpažinimo metodai ir atitinkami algoritmai:

- Naudojantys iš signalo išgautus požymius. Šiuo atveju iš FPG signalo yra išskiriami tik svarbiausi (esminiai) požymiai, taip ženkliai sumažinant mokymui reikalingų duomenų kiekį. Paprastai dėl to naudojamos architektūros būna paprastesnės, reikalauja mažiau skaičiavimo

resursų ir gali būti efektyviai pritaikomos įterptinėse sistemose. Vis dėlto toks metodas turi ir trūkumų – papildomas signalo apdorojimas gali lemti dalinį informacijos praradimą.


- Naudojantys neapdorotą signalą (šiuo atveju fotopletizmogramos (FPG) signalą). Pasirinkus šį būdą išvengiama galimo informacijos praradimo, kuris dažnai atsiranda dėl filtravimo arba požymių išskyrimo procedūrų. Kita vertus, toks metodas reikalauja gerokai didesnių skaičiavimo resursų, naudojami sudėtingesni modeliai, o jų mokymo procesas tampa ženkliai ilgesnis.

Šiame darbe bus palygintos abi šios apnėjos detektavimo tyrimų kryptys, įvertinant jų efektyvumą ir pritaikomumą.

2.2.1. Algoritmas Nr. 1: FPG požymių išskyrimu grįstas algoritmas

Algoritmas Nr1 yra pagrįstas FPG požymių išskyrimu ir jų naudojimu kaip įvestini į MM modelį. Skirtingai nei *apSense* modelyje [35], šiame darbe nenaudojamas rankinis FPG signalo viršūnių aptikimas su *find_peaks* funkcija ir savarankiškas požymių skaičiavimas. FPG požymiai yra išgaunami naudojant *pyPPG* biblioteką [40], kuri automatizuoja signalų analizę norint pasiekti geresnį klasifikavimo tikslumą. *pyPPG* yra atvirojo kodo *Python* biblioteka, skirta ilgalaikių piršto fotopletizmogramos signalų analizei. Ji leidžia automatizuotai aptikti orientacinius taškus (angl. *fiducial points*) ir išgauti standartizuotus signalo požymius, kurie yra svarbūs vertinant širdies ir kraujagyslių sistemos būklę.

Bibliotekos veikimas prasideda nuo neapdorotų FPG signalų įkėlimo, palaikant įvairius duomenų formatus (pvz., .mat, .csv, .edf). Tada signalas gali būti nufiltruojamas pasirinktu filtru, siekiant pašalinti triukšmą ir artefaktus. FPG signalų filtravimui buvo naudoti standartiniai 4 eilės juostiniai filtrai kurių dažnių juostos buvo: 0,5 – 12Hz (*pyPPG* autorių rekomenduotas), 0,5 – 7hz ir tik aukštųjų dažnių (0,5 Hz) filtras. Filtruotam signalui apskaičiuojamos pirmosios, antrosios ir trečiosios išvestinės (atitinkamai žymimos kaip PPG', PPG'' ir PPG'''), kurios vėliau naudojamos orientacinių taškų identifikavimui. Segmentuojant pulso bangas, aptinkami sistoliniai pykai, o remiantis jų padėtimi nustatomi pulso pradžios ir pabaigos taškai. Tuomet kiekvienoje pulso bangoje identifikuojamas standartizuotas rinkinys orientacinių taškų (bendras jų skaičius – 15), kurie apima tokius taškus kaip pulso pradžia (*on*), sistolinis pikas (*sp*), dikrocinis įdubimas (*dn*), diastolinis pikas (*dp*), pulso pabaiga (*off*) bei atitinkami darinių taškai iš PPG', PPG'' ir PPG''' signalų (12 pav.).



12 pav. FPG signalė surasti orientaciniai taškai naudojami požymių skaičiavimui

Remiantis šiais orientaciniais taškais, *pyPPG* biblioteka automatiškai apskaičiuoja 74 morfologinius FPG biologinius žymenis. Jie apima laiko intervalus, amplitudes, sričių plotus bei jų santykius, leidžiančius išsamiai įvertinti kraujagyslių būklę, kraujospūdį, širdies veiklą bei autonominės nervų sistemos įtaką. Gauti požymiai išsaugomi .csv formatu (13 pav.) taip pat išsaugojant ir laiką (vektoriaus indeksą) kada buvo aptiktas širdies dūžis (FPG pikas).


	A	B	C	D	E	F	G	H	I	J	K
1	Index of pulse	TimeStamp	Tpi	Tpp	Tsys	Tdia	Tsp	Tdp	deltaT	Tsw10	Tsw25
2	1	0	1.475	1.3	0.6125	0.8375	0.4875	0.6375	0.15	0.1625	0.15
3	2	118	1.2875	1.3	0.45	0.8	0.3125	0.4875	0.175	0.25	0.225
4	3	221	1.3	1.2875	0.475	0.7875	0.325	0.5125	0.1875	0.2625	0.225
5	4	325	1.2875	1.3	0.4375	0.8125	0.3125	0.475	0.1625	0.25	0.2125
6	5	428	1.3125	1.2875	0.475	0.7875	0.325	0.525	0.2	0.25	0.225
7	6	533	1.3	1.3375	0.45	0.6	0.3	0.7	0.4	0.2375	0.2
8	7	637	1.325	1.3	0.4875	0.7875	0.3375	0.5375	0.2	0.2625	0.2375
9	8	743	1.325	1.325	0.4375	0.8375	0.3125	0.4875	0.175	0.25	0.2125
10	9	849	1.3	1.325	0.45	0.7875	0.3125	0.5125	0.2	0.2375	0.2
11	10	953	1.3375	1.3125	0.4875	0.8	0.3375	0.5375	0.2	0.2625	0.225
12	11	1060	1.3	1.3125	0.4375	0.8125	0.3125	0.4875	0.175	0.2375	0.2125

13 pav. Išgautų požymių iš FPG signalo naudojant *pyPPG* iškarpa

Kitas iššūkis taikant giluminio mokymosi metodus miego apnėjos atpažinimui iš skaitmeninių fiziologinių signalų (pvz., FPG) yra tai, kad analizuojamų požymių kiekis per fiksuotą laiko intervalą nėra pastovus. Pavyzdžiui, iš 10 sekundžių trukmės lango išskiriamų požymių jų skaičius gali svyruoti nuo 7 iki 17, priklausomai nuo širdies ritmo (14 pav.). Kadangi dauguma neuroninių tinklų architektūrų reikalauja fiksuoto ilgio įvesties vektorių, būtina taikyti papildomus duomenų paruošimo metodus. Nors kai kurie autoriai šią problemą sprendžia taikydami interpoliaciją, šiame darbe pasirinkta alternatyvi strategija – požymių sekos normalizavimas iki fiksuoto ilgio (pvz., 10 elementų), pašalinant perteklines reikšmes ir papildant trūkstamas nulinėmis reikšmėmis. Tokiu būdu išvengiama interpoliacijos įvestų papildomų triukšmų ir išsaugomas modelio jautrumas esminiems signalų pokyčiams. Palyginimui, *ApSense* darbe [35] naudotas 60 sekundžių langas su 60 požymių, darant prielaidą, kad širdies ritmas yra 60 dūžių per minutę. Šiame tyrime vertinami tiek normalaus (~60 dūžių per minutę), tiek padidėjusio (~90 dūžių per minutę) širdies ritmo atvejai. Todėl


analizuojami du aiškiai apibrėžti scenarijai – kai požymių kiekis atitinka normalią ($1\times$) ir padidintą ($1,5\times$) širdies ritmo situaciją.

Požymių kiekio pasiskirstymas 10 s intervaluose (pacientas nr. 7)



14 pav. Požymių kiekio pasiskirstymas

Galiausiai, apjungus visus etapus, galutinė algoritmo Nr. 1 struktūrinė schema pateikta paveikslėlyje (15 pav.). Naudojantis šiuo algoritmu yra išgaunami įvesties duomenys. Tuo tarpu išvestis – tai binarinis kintamasis, kuris įgyja reikšmę 1 (apnėjos epizodas) arba 0 (normalaus miego epizodas). Ši reikšmė nustatoma, kaip buvo minėta anksčiau, pasirinkus 10 sekundžių trukmės apnėjos epizodų slenkstį, remiantis AASM apibrėžimu.




15 pav. Algoritmo Nr. 1 struktūrinė schema

2.2.2. Algoritmas Nr. 2: FPG požymių išskyrimo nenaudojantis algoritmas


Algoritmas Nr. 2 nuo Algoritmo Nr. 1 skiriasi įėjimo duomenimis ir MM modeliu. Šiuo atveju į MM modelio įėjimą yra paduodama tik juostiniu filtru nufiltruoti FPG signalo intervalai. Šiuo atveju skirtingai nei algoritmu Nr. 1 neriekia rūpintis dėl skirtingų įvesties kiekio, nes FPG signalą galima dalinti laiko intervalais ir vektoriaus ilgis išliks vienodi. Tačiau svarbu įvertinti signalo ir pašalinio triukšmo kiekį. Todėl ypač aktualu suprasti filtravimo įtaką. Mokslinėje literatūroje dažniausiai naudojami juostiniai filtrai, skirti FPG signalų analizei, yra tarp 0,3–10 Hz dažnių diapazone [41] priklausomai nuo pasirinkto algoritmo ir jo paskirties. Vis dėlto, nėra vienareikšmiško sutarimo ar empiriškai pagrįsto aiškiai geriausio dažnio diapazono, nes optimalus filtro pasirinkimas priklauso nuo taikymo srities, judesio artefaktų tipo ir norimų išgauti fiziologinių parametrų. Todėl pasirenkami ir palyginami keli filtrų diapazonai – siekiant empiriškai įvertinti, kuris filtras pasiekia geresnius rezultatus. Filtrų kūrimui buvo naudota *scipy* biblioteka, juostinis filtras analogiškos eilės (ketvirtos) kaip ir algoritmo Nr. 1. juostos pločio analizuojamos juostos: 0,5 – 7 Hz; 0,5–12 Hz ir tik aukštų dažnių 0,5 Hz filtras.

Vizualiai analizuojant signalus laiko ašyje (16 pav.) matyti, kad naudojant tik aukštų dažnių filtrą nėra pašalinami aukšto dažnio komponentai, kurie dažnai yra susiję su triukšmu ir kitais nepageidaujamais artefaktais. Taip pat šie artefaktai gali –atsirasti dėl piršto ar kūno judėjimo ar elektrinio triukšmo – pavyzdžiui, 50–60 Hz elektros tinklo dažnio. Tuo tarpu juostiniu 0,5–7Hz filtru nufiltruotas signalas neturi smulkių virpesių, aštresnių pikų ar šlaitų ir yra tolygesnis.




16 pav. FPG signalai su skirtingais filtrais

Be to, šiame tyrime analizuojami trys skirtingi laiko langai: 10 sekundžių, 20 sekundžių ir 30 sekundžių. Tai leidžia įvertinti, kaip įėjimo intervalo trukmė veikia modelio rezultatus bei galimą signalo dinaminį pokyčių įtaką. Struktūrinė algoritmo schema, atitinkanti šį aprašymą, pateikta paveikslėlyje (17 pav.).



17 pav. Algoritmo Nr. 2 struktūrinė schema

MM modelis buvo pasirinktas transformatoriaus (angl. *transformer*) tipo remiantis esamais darbais [42] [43] kurie naudojo šią architektūrą su atviros prieigos duomenų rinkiniais apnėjos atpažinimui iš EKG ir SpO₂ signalų. Šie darbai parodė, kad transformatoriaus tipo modeliai yra tinkami apnėjos detektavimui. Tačiau šiame tyrime, siekiant efektyviai apdoroti FPG signalą, reikėjo atlikti modifikacijas – ženkliai sumažinti modelio neuroninių sluoksnių skaičių ir juose esančių filtrų kiekį, nes dėl didelio įėjimo duomenų kiekio (10 s – 800 verčių, 20 s – 1600 verčių ir t. t.) išauga kompiuterinių resursų poreikis.



18 pav. Autoenkoderio architektūra laiko eilutės FPG signalui

2.3. Algoritmų įvertinimas pagal klasifikavimo patikimumą ir skaičiavimo resursų poreikį

Klasifikavimo problemos yra viena iš plačiausiai tyrinėtų sričių pasaulyje. Naudojimo atvejų yra beveik visose gamybos ir pramonės aplinkose: kalbos atpažinimas, veido atpažinimas, teksto klasifikavimas ir begalė kitų. Klasifikavimo modeliai turi atskirą išvestį, todėl reikalingos metrikos, kurios tam tikra forma palygintų atskiras klases. Klasifikavimo metrika įvertina modelio veikimą ir nurodo, kokia gera ar bloga klasifikacija, tačiau kiekviena iš jų vertina ją skirtingai. Pagrindinės klasifikavimo modelių įvertinimo metrikos:

Tikslumas (angl. *Accuracy*) – nurodo teisingai klasifikuotų pavyzdžių dalį visame duomenų rinkinyje. Jis apskaičiuojamas pagal (6) formulę:

$$\text{Tikslumas} = \frac{TP + TN}{TP + TN + FP + FN}; \quad (2)$$

Šioje formulėje teisingas teigiamas (angl. *true positive*, *TP*) – tai atvejis, kai algoritmas teisingai priskiria stebėjimą tam tikrai klasei. Teisingas neigiamas (angl. *true negative*, *TN*) – kai algoritmas teisingai nustato, kad stebėjimas nepriklauso tam tikrai klasei. Klaidingas teigiamas (angl. *false positive*, *FP*) – kai algoritmas klaidingai priskiria stebėjimą teigiamai klasei, nors jis iš tikrųjų priklauso neigiamai klasei. Klaidingas neigiamas (angl. *false negative*, *FN*) – kai algoritmas klaidingai priskiria stebėjimą neigiamai klasei, nors jis turėtų būti priskirtas teigiamai klasei.

Tačiau tikslumo metrika gali būti klaidinanti, jei duomenų rinkinys yra nesubalansuotas. Preciziškumas ir jautrumas (angl. *Precision and Recall*) – tai dvi pagrindinės metrikos, naudojamos vertinant modelių našumą.

Preciziškumas (angl. *Precision*) – parodo, kokia dalis modelio nuspėtų teigiamų atvejų iš tikrųjų yra teisingi:

$$\text{Preciziškumas} = \frac{TP}{TP + FP}; \quad (3)$$

Jautrumas (angl. *Sensitivity* arba *Recall*) – parodo, kokia dalis visų teigiamų atvejų buvo teisingai nustatyta:

$$Jautrumas = \frac{TP}{TP + FN}; \quad (4)$$

F1-įvertis – harmoninis vidurkis tarp tikslumo ir atšaukimo:

$$F1 = 2 * \frac{Preciziškumas \cdot Jautrumas}{Preciziškumas + Jautrumas}; \quad (5)$$

Ši metrika yra ypač naudinga, kai duomenų rinkinys yra nesubalansuotas.

Specifiškumas (angl. *Specificity*) – tai rodiklis, parodantis, kiek teisingai nustatytų neigiamų atvejų yra tarp visų neigiamų pavyzdžių.

$$Specifiškumas = \frac{TN}{TN + FP}; \quad (6)$$

ROC-AUC (angl. *Receiver Operating Characteristic – Area Under Curve*) – parodo modelio gebėjimą atskirti klases. Kuo didesnė ROC-AUC reikšmė, tuo geresnis modelis.

Klasifikavimo matrica (angl. *Confusion Matrix*) – tai lentelė, rodanti modelio klasifikavimo rezultatus skirtingoms klasėms.

Class designation		Actual class	
		True (1)	False (0)
Predicted class	Positive (1)	TP	FP
	Negative (0)	FN	TN

19 pav. Klasifikavimo matricos pavyzdys esant keturioms klasėms [44]

Šios metrikos leidžia išsamiai įvertinti klasifikavimo modelio patikimumą ir pritaikymą konkrečioms problemoms. Modelio vertinimo metu svarbu ne tik vienas rodiklis, bet jų visuma, atsižvelgiant į problemos pobūdį ir duomenų pasiskirstymą

Modelių įvertis pagal skaičiavimo resursus

Siekiant įvertinti sukurtų modelių pritaikomumą įterptinėse sistemose, bus atlikta jų palyginamoji analizė pagal skaičiavimo resursų poreikį. Vertinami šie aspektai:

Modelio dydis (*Flash* atminties poreikis) – modelio dydis nustatytas išsaugojus kiekvieną modelį į standartinį failo formatą. Failo dydis tiesiogiai atspindi, kiek vietos modelis užimtų įrenginio nuolatinėje (*Flash*) atmintyje.

Darbinės atminties (RAM) poreikis – RAM poreikis įvertintas pagal modelio parametrų kiekį bei tarpinių skaičiavimų poreikį inferencijos metu. Skaičiavimams naudota informacija apie kiekvieno sluoksnio išvesties duomenų dydį.

Modelio parametrų skaičius – kiekvieno modelio svorių (angl. *weights*) ir poslinkių (angl. *biases*) skaičius bus išanalizuotas. Didesnis parametrų skaičius paprastai reikalauja daugiau atminties ir gali lemti ilgesnį skaičiavimo laiką.

Skaiciavimo sudėtingumas (FLOPs) – modelių sudėtingumas vertintas pagal reikalingų skaičiavimo operacijų (angl. *FLOPs – Floating Point Operations*) skaičių vienai įvesties prognozei. FLOPs parodo, kiek realiųjų skaičių daugybų ir sudėčių reikia norint atlikti vieną inferenciją.


Inferencijos laikas (greitaveika) – kiekvienam modeliui bus matuojamas vienos prognozės atlikimo laikas ant bendro naudojimo centrinio procesoriaus (CPU). Inferencijos laikas parodo modelio greitaveiką ir padeda įvertinti realaus laiko sistemos galimybes.

Šie rodikliai leidžia objektyviai palyginti skirtingus modelius ir įvertinti jų tinkamumą įterptinių sistemų aplinkoje, kur skaičiavimo resursai dažnai yra riboti.

3. Miego apnėjos atpažinimo algoritmų tyrimo rezultatai

Galiausiai darbe buvo atliktas dirbtinio intelekto modelių apmokymas bei gauti apnėjos detektavimo rezultatai. Atliekant šį procesą visi turimi duomenys buvo standartiškai padalinti į treniravimo ir testavimo poaibius santykiu 80:20, siekiant užtikrinti pakankamą duomenų kiekį dirbtinio intelekto modelių apmokymui ir objektyviam jų įvertinimui. Siekiant išvengti pernelyg didelio prisitaikymo prie treniravimo duomenų (angl. *overfitting*), treniravimo poaibis papildomai buvo padalintas į mokymo ir validavimo duomenų rinkinius, tokiu būdu suteikiant galimybę tinkamai parinkti modelių parametrus ir kontroliuoti apmokymo eigą. Tuo tarpu testavimo poaibis naudotas galutiniam modelių veikimo efektyvumo įvertinimui su anksčiau nematytais duomenimis.

Siekiant objektyviai įvertinti apmokytų algoritmų kokybę, buvo taikyti anksčiau šiame darbe (žr. 2.3 skyrių) aptarti vertinimo metodai, ypač aktualūs analizuojant duomenų rinkinius, pasižyminčius reikšmingu klasių disbalansu. Abiejų algoritmų galutinių rezultatų gavimo struktūra yra analogiška ir schematiškai pavaizduotos paveikslėlyje (20 pav.).




20 pav. Modelių rezultatų gavimo procedūra

Abiejų metodų modelių implementacijai ir rezultatų gavimui buvo naudojama *TensorFlow* biblioteka. Siekiant užtikrinti modelių treniravimo stabilumą ir optimizuoti mokymosi procesą, buvo taikytos standartinės mašininio mokymosi metodikos, tokios kaip ankstyvas stabdymas (*EarlyStopping*) ir mokymosi spartos mažinimas pasiekus mokymosi rezultatų sąstingį (*ReduceLROnPlateau*). Modelių nuostolių funkcijai buvo pasirinkta dvejetainė kryžminė entropija (*BinaryCrossentropy*) su anksčiau aprašytais klasių svoriais, siekiant atsižvelgti į duomenų klasių disbalansą.

3.1. Algoritmo Nr. 1 tyrimo rezultatai

Išgavus požymius ir atliekant filtrų įtakos, analizės lango bei požymių kiekio analizę klasifikavimo rezultatams, kaip įvestis į MM buvo naudojami šie požymiai: **Asp** (sistolės piko amplitudė – amplitudės skirtumas tarp impulso pradžios ir sistolinio piko), **Tpp** (pikų periodas – laiko tarpas tarp dviejų iš eilės einančių sistolinių pikų), **Tsys** (sistolės laikas – laiko tarpas tarp impulso pradžios ir dikrocinio lūžio taško), **Tdia** (diastolės laikas – laiko tarpas tarp dikrocinio lūžio taško ir impulso pabaigos), bei **AUCpi** (plotas po impulso intervalo kreivė – plotas po impulso banga tarp impulso pradžios ir pabaigos).

Sukurtą mašininio mokymosi modelį sudarė du konvoliuciniai sluoksniai, trys LSTM sluoksniai, du telkimo (*Dense*) sluoksniai ir galutinis telkimo sluoksnis su vienu neuronu bei *sigmoid* aktyvacijos funkcija, skirta galutinei klasei prognozuoti. Modelio vidiniuose sluoksniuose buvo naudojama partijų normalizacija (*Batch Normalization*), siekiant stabilizuoti ir paspartinti mokymosi procesą. Maksimalus mėginių sumažinimas (*MaxPooling*), siekiant sumažinti duomenų dimensiją po konvoliucinių sluoksnių, bei išmetimo (*Dropout*) metodas, taikytas reguliariam modelio mokymuisi ir persimokymo prevencijai. Aktyvacijos funkcijai konvoliuciniuose ir tankiuosiuose sluoksniuose naudota *ReLU* funkcija. Sukurto tinklo architektūra pavaizduota paveikslėlyje (21 pav.).



21 pav. Požymiais pagrįsto MM modelio architektūra

Apnėjos atpažinimo gauti tikslumo rezultatai nuo analizės lango trukmės: (10s, 30s, 60s), požymių skaičiaus ir naudoto filtro pateikiami lentelėse (5 lentelė, 6 lentelė ir 7 lentelė).

5 lentelė. MM modelio klasifikavimo rezultatai naudojant 05-12 Hz filtrą FPG signalui

Intervalo trukmė ir požymių skaičius	AUC, %	Jautrumas (pasvertas), %	Preciziškumas (pasvertas), %	F1 (pasvertas), %	Nuostolių vertė	Tikslumas, %
10s, 10 požymių	72,95	66,76	88,20	73,79	0,5583	66,76
10s, 15 požymių	69,02	77,5	86,65	81,20	0,4737	77,53
20s, 20 požymių	76,27	71,67	81,32	74,72	0,5206	71,67
20s, 30 požymių	74,14	76,58	80,04	77,99	0,5058	76,58
60s, 60 požymių	79,40	74,26	74,11	74,18	0,5228	74,26
60s, 90 požymių	83,44	72,89	77,12	76,34	0,5011	75,99


6 lentelė. MM modelio klasifikavimo rezultatai naudojant 05-7 Hz filtrą FPG signalui

Intervalo trukmė ir požymių skaičius	AUC, %	Jautrumas (pasvertas), %	Preciziškumas (pasvertas), %	F1 (pasvertas), %	Nuostolių vertė	Tikslumas, %
10s, 10 požymių	75,21	67,01	88,59	73,99	0,5510	67,01
10s, 15 požymių	71,06	73,39	87,33	78,56	0,4990	73,39
20s, 20 požymių	77,73	73,29	82,08	76,08	0,5098	73,29
20s, 30 požymių	76,02	78,33	80,74	79,35	0,4491	78,33
60s, 60 požymių	81,43	75,26	76,35	75,61	0,5230	75,26
60s, 90 požymių	82,94	77,03	77,48	77,20	0,4885	77,03


7 lentelė. MM modelio klasifikavimo rezultatai naudojant tik aukštų dažnių (0,5 Hz) filtrą FPG signalui

Intervalo trukmė ir požymių skaičius	AUC, %	Jautrumas (pasvertas), %	Preciziškumas (pasvertas), %	F1 (pasvertas), %	Nuostolių vertė	Tikslumas, %
10s, 10 požymių	70,18	66,22	87,05	73,22	0,5580	66,22
10s, 15 požymių	68,09	72,10	86,58	77,48	0,5070	72,10
20s, 20 požymių	77,15	74,73	81,76	77,11	0,4955	74,73
20s, 30 požymių	67,45	80,86	77,71	78,81	0,4471	80,86
60s, 60 požymių	80,02	75,59	75,67	75,63	0,5159	75,59
60s, 90 požymių	80,93	75,66	75,23	75,37	0,5051	75,66


Analizuojant rezultatus, nustatyta, kad geriausius klasifikavimo rodiklius (vertinant pagal F1 rodiklį, AUC ir nuostolių funkcijos vertę) pavyko pasiekti modeliui naudojant 0,5–7 Hz juostiniu filtru apdorotus duomenis. Šio modelio įvestis buvo 60 sekundžių FPG signalo intervalo 90 požymių vektorių masyvas (sudarytas iš 5 požymių po 90 verčių kiekvienam). Žemiau pateikta geriausius rezultatus pasiekusio modelio sumaišties matrica (22 pav.) bei ROC kreivė (23 pav.). Taip pat pavaizduotos nuostolių funkcijos ir AUC kitimo treniravimo metu nuo epochos grafikai (24 pav.).




22 pav. Sumaišties matrica su geriausius rezultatus pasiekusiu modeliui



23 pav. ROC kreivė kai naudojamas 60s įvesties langas ir 90 požymių skaičius



24 pav. Geriausio modelio AUC (kairėje) ir nuostolių funkcijos verčių kitimas treniravimo metu



25 pav. AUC reikšmės palyginimas pagal filtrą ir intervalą

Remiantis 5–7, 5–12 Hz ir tik 0,5 Hz dažnių filtrų rezultatais, galima daryti kelias išvadas apie filtro įtaką modelio klasifikavimo kokybei. Bendrai, 0,5–7 Hz dažnių filtras pasižymėjo geresniais klasifikavimo rezultatais nei 0,5–12 Hz filtras. Nors kai kuriais atvejais (pvz., ilgesniuose intervaluose) 0,5–12 Hz filtras užtikrino kiek aukštesnius AUC ar preciziškumo rodiklius, 0,5–7 Hz filtras dažniau pasiekė aukštesnį jautrumą ir F1 rodiklį, ypač naudojant didesnę požymių kiekį. Pavyzdžiui, 20 sekundžių intervale su 30 požymių ilgiu 0,5–7 Hz filtras pasiekė 79,35 % F1, kai tuo tarpu 0,5–12 Hz – 77,99 %. Taip pat 0,5–7 Hz filtrui pritaikius 60s/90 požymių ilgio konfigūraciją buvo gautas vienas aukščiausių jautrumo (77,03 %) ir F1 (77,20 %) rodiklių.


Tuo tarpu naudojant tik aukštų dažnių filtrą (su 0,5 Hz žemutine riba), klasifikavimo rezultatai buvo prasčiausi. Nepaisant pavienių aukštų jautrumo verčių, šis filtras dažniausiai nesugebėjo užtikrinti pakankamai aukštos AUC ar F1 reikšmės, o preciziškumo ir tikslumo rodikliai taip pat buvo mažesni lyginant su kitais filtrais. Tai leidžia daryti prielaidą, kad vien aukštų dažnių komponentai nėra pakankami efektyviai apnėjos klasifikacijai – reikalingi bent jau vidutinio dažnio komponentai, kurie geriau atspindi informatyviuos fiziologinius pokyčius FPG signale.

3.1.1. Požymių svarbos analizės rezultatai

Nustačius, jog filtravimo parametrų ir lango trukmės pasirinkimas daro reikšmingą įtaką klasifikavimo rezultatams, buvo atlikta detalesnė analizė, siekiant išsiaiškinti, kurie konkretūs požymiai labiausiai prisideda prie modelio tikslumo. Šiai analizei naudotas modelis su 20 sekundžių ilgio langais ir 30 požymių ilgio įvesties vektoriais. Šis modelis pasirinktas, kadangi paaiškinamojo dirbtinio intelekto metodai yra skaičiavimams imlūs ir reikalauja daug resursų bei laiko, todėl nebuvo pasirinktas geriausių rezultatų pasiekęs modelis su 60 sekundžių langais ir 90 požymių. Požymių reikšmingumui įvertinti buvo pasitelktas *Integrated Gradients* metodas, įgyvendintas naudojant *alibi* biblioteką


Paveikslėlyje (26 pav.) pateikiama modelio požymių įtakos analizė laiko skalėje. Kuo didesnė požymio reikšmė pagal absoliutų dydį, tuo didesnė jo įtaka modelio sprendimui. Kaip matyti, šiuo

atveju požymis AUC_{pi} turi mažiausią įtaką priimamam sprendimui, todėl gali būti laikomas mažiau reikšmingu klasifikacijos procese.



26 pav. Požymių svarbos analizė naudojant *Integrated Gradients* metodą

Toliau analizė atlikta naudojant 1000 testavimo imčių, apskaičiuojant kiekvieno požymio absoliutinių reikšmių vidurkį. Rezultatai pateikti paveikslėlyje (27 pav.), kuris leidžia vizualiai įvertinti, kurių požymių įtaka klasifikavimo sprendimams yra didžiausia. Remiantis šia analize, požymis AUC_{pi} pasirodo esąs mažiausiai reikšmingas. Rezultatai rodo, jog *Integrated Gradients* metodas pagrįstai identifikavo AUC_{pi} kaip mažiausiai svarbų požymį modelio sprendimams.



27 pav. Požymių įtakos analizė naudojant 1000 testavimo imčių

Pašalinus požymį *AUCpi* iš įvesties vektoriaus ir pakartotinai įvertinus modelio veikimą, nustatyta, kad klasifikavimo rezultatai beveik nesuprastėjo. Tai leidžia daryti pagrįstą prielaidą, jog *AUCpi* indėlis į klasifikavimą yra mažiausias. Toliau pateiktoje lentelėje (8 lentelė) pateikiami LSTM modelio klasifikavimo rezultatai, kai naudojamas pilnas požymių rinkinys bei jo variantai, iš kurių paeiliui pašalinami atskiri požymiai. Akivaizdu, kad *AUCpi* pašalinimas turi mažiausią įtaką modelio tikslumui, tuo tarpu požymiai *ASp* ir *Tsys* turi reikšmingą poveikį klasifikavimo kokybei.

8 lentelė. LSTM tipo modelio klasifikavimo rezultatai, naudojant skirtingus požymių rinkinius

Naudoti požymiai	AUC, %	Jautrumas (pasvertas), %	Preciziškumas (pasvertas), %	F1 (pasvertas), %	Nuostolių vertė	Tikslumas, %
Pradinis modelis	76,02	78,33	80,74	79,35	0,4491	78,33
Nenaudojant <i>AUCpi</i>	76,98	73,92	81,40	76,44	0,5134	73,92
Nenaudojant <i>ASp</i>	69,85	75,61	75,65	76,31	0,4982	75,61
Nenaudojant <i>Tsys</i>	69,46	73,85	78,44	75,70	0,4999	73,85

Galiausiai, remiantis ankstesne analizės eiga, buvo sukurtas patobulintas MM modelis, kurio įvestyje naudoti 32 atrinkti požymiai, pašalinus mažiau reikšmingus, tokius kaip *AUCpi*, *AUCsys* ir *AUCdia*. Šio modelio tikslas – nustatyti, kurie požymiai turi didžiausią įtaką klasifikavimo tikslumui.

Analizė parodė, kad svarbiausi požymiai modelio veikimui yra šie: *Aoff*, *Adn*, *deltaT*, *Tsw10*, *Tdia*. Siekiant įvertinti pagerėjimą, buvo palyginti modelių rezultatai, gauti naudojant standartinį požymių rinkinį ir atrinktus svarbiausius požymius. lentelėje (9 lentelė) pateikti LSTM modelio rezultatų pokyčiai procentine išraiška.

Rezultatai rodo, kad požymių atranka gali pagerinti klasifikavimo tikslumą, ypač trumpesnių langų atveju (20 s / 30 požymių). Ilgesnių langų atveju (60 s / 90 požymių) pastebimas mišrus efektas – kai kurios metrikos pagerėja (pvz., AUC, F1), tačiau kitos (pvz., preciziškumas) šiek tiek suprastėja.


9 lentelė. LSTM modelio klasifikavimo rezultatų pokyčiai (%) naudojant atrinktus požymius

Modelio tipas	AUC, pokytis %	Jautrumo pokytis (pasvertas), %	Preciziškumas pokytis (pasvertas), %	F1 pokytis (pasvertas), %	Nuostolių pokytis vertė	Tikslumo pokytis, %
20s, 30 požymių ilgis	+ 2,15	+ 0,33	+ 1,33	+ 0,18	+ 0,0305	+ 0,33
60s, 90 požymių ilgis	+ 1,39	0	- 2,27	+0,17	- 0,0199	0

3.2. Algoritmo Nr2 tyrimo rezultatai

Šiame etape buvo analizuojamas apnėjos atpažinimo tikslumo priklausomumas nuo analizės lango trukmės (10 s, 20 s, 30 s) bei nuo įėjimo signalo dažnių juostos pločio – palyginant filtravimą šiose juostose: 0,5–5 Hz, 0,5–12 Hz ir tik aukštų dažnių komponentų išlaikymą (nuo 0,5 Hz). Šio eksperimento metu naudotas neapdoroto FPG signalo pagrindu veikiantis MM modelis t. y. be iš anksto išskirtų požymių. Modeliui buvo taikyta transformatoriaus tipo autoenkoderio architektūra,

kuri pavaizduota paveikslėlyje (28 pav.). Pradiniame etape įėjimo signalas yra apdorojamas dviem konvoliucijos (kodavimas) ir dviem atvirkštinės konvoliucijos (dekodavimo) sluoksniais, siekiant išryškinti svarbiausius požymius bei sumažinti triukšmą. Po šio apdorojimo duomenys patenka į transformatoriaus bloką, kuris apima daugiagalvio dėmesio (angl. *multi-head attention*) ir normalizacijos sluoksnius, bei sudėties sluoksnius. Galutiniame etape naudojamas visuotinio vidurkinimo (angl. *global average pooling*) sluoksnis, kuris leidžia sumažinti sekos duomenis į fiksuoto dydžio vektorių, tinkamą klasifikacijai. Tokia architektūra leidžia modeliui efektyviai apdoroti laiko sekos duomenis bei atpažinti sudėtingus kvėpavimo sutrikimų dėsningumus



28 pav. Neapdorotu FPG pagrįsto transformatoriaus modelio architektūra


Eksperimentų metu buvo taikytos šios techninės sąlygos: naudojant 10 s ir 20 s trukmės analizės langus, modelio architektūra išliko identiška, tačiau buvo sumažintas treniravimo paketo dydis (angl. *batch size*) – nuo 64 iki 32, atsižvelgiant į kompiuterinių resursų apribojimus. Naudojant 30 s trukmės signalus, įvesties vektoriaus ilgis siekė 2400 taškų, todėl treniravimo paketo dydis buvo dar labiau sumažintas – iki 8. Toks reikšmingas sumažinimas galėjo turėti įtakos ir galutiniams modelio rezultatams

Skaičiavimams atlikti buvo naudota *TensorFlow* aplinka, o modeliui apmokyti naudoti KTU dirbtinio intelekto centro kompiuteriniai ištekliai: 10 s ir 20 s ilgio langams naudota *Nvidia A100* grafinė plokštė, 30 s ilgio langams – *Nvidia H100* grafinė plokštė.


10 lentelė. Algoritmo Nr. 2 su transformatoriaus tipo modelių rezultatai

FPG signalo ilgis ir naudotas filtras	AUC, %	Jautrumas (pasvertas), %	Preciziškumas (pasvertas), %	F1 (pasvertas), %	Nuostolių vertė	Tikslumas, %
10s; 0,5 –12Hz	79,78	70,06	82,48	74,75	0,5751	70,34
10s; 0,5 –7Hz	78,68	71,19	81,91	75,02	0,5526	70,87
10s; 0,5 Hz	78,11	69,47	79,13	73,63	0,5869	69,54
20s, 0,5 – 12 Hz	70,27	62,39	78,31	66,91	0,6320	62,08
20s, 0,5 –7Hz	76,46	67,39	77,48	71,13	0,6068	67,55
20s, 0,5 Hz	69,00	63,35	78,40	67,73	0,6297	63,07
30s, 0,5 – 12 Hz	73,44	66,87	75,04	69,11	0,5965	66,85
30s, 0,5 –7Hz	79,92	72,46	73,86	73,19	0,5437	72,46
30s, 0,5 Hz	78,88	71,64	73,38	72,77	0,5607	71,82

Analizuojant transformatoriaus tipo modelių rezultatus (10 lentelė), nustatyta, kad geriausią klasifikavimo tikslumą (pagal AUC, F1 rodiklį, nuostolių funkcijos vertę ir kitus rodiklius) pasiekė modelis, naudojęs 10 sekundžių trukmės FPG signalus, apdorotus 0,5–7 Hz juostiniu filtru. Geriausio modelio pasvertasis F1 rodiklis siekė 75,02 %, AUC – 78,68 %, o nuostolių funkcijos vertė – 0,5526. Žemiau pateikta šio modelio pateikti nuostolių funkcijos ir AUC reikšmių kitimo nuo epochos grafikai (29 pav.) ir sumaišties matrica (30 pav.).




29 pav. Modelio AUC (kairėje) ir nuostolių funkcijos verčių kitimas treniravimo metu (10s, 0,5-7 Hz)




30 pav. Klasifikavimo matrica geriausiai parametų kombinacijai (10s, 0,5-7 Hz)

Lyginant rezultatų skirtumus tarp skirtingų algoritimų architektūrų, pastebėta, kad algoritmas, pagrįstas rankiniu požymių išskyrimu, geriausius rezultatus pasiekė su 30 sekundžių trukmės FPG signalais, apdorotais 0,5–7 Hz juostiniu filtru. Tačiau transformatoriaus tipo modelis geriausiai veikė naudodamas tik 10 sekundžių ilgio signalus. Analizuojant mokymosi kreives (31 pav. ir 32 pav.), matyti aiškūs permokymo (angl. *overfitting*) požymiai, ypač naudojant ilgesnius įvesties langus (pvz., 30s). Tai galima paaiškinti tuo, jog transformatoriaus architektūra, pasižyminti didele modelio galia ir jautrumu detalioms struktūroms, reikalauja itin didelio duomenų kiekio norint tinkamai apmokyti parametrus. Naudojant ilgesnius langus, stipriai išauga įvesties vektoriaus dimensija, o jei modelis neturi pakankamo skaičiaus sutelkimo (*pooling*) sluoksnių ar kito tipo sumažinimo mechanizmų, tinklas tampa linkęs į per didelį prisitaikymą prie mokymo duomenų. Dėl šios priežasties trumpesni – 10 sekundžių – intervalai leidžia išlaikyti geresnį balansą tarp modelio kompleksiskumo ir turimo duomenų kiekio, taip užtikrinant geresnį klasifikavimą.



31 pav. Modelio AUC (kairėje) ir F1 verčių kitimas treniravimo metu (30s, 0,5-7 Hz)



32 pav. Modelio nuostolių funkcijos verčių kitimas treniravimo metu (30s, 0,5-7 Hz)

3.3. Rezultatų palyginimas su kitų autorių metodais

Nors rezultatų tiesioginis palyginimas su kitų autorių darbais nėra visiškai objektyvus dėl skirtingų naudojamų duomenų rinkinių ir apdorojimo metodų, vis dėlto galima pastebėti tam tikras tendencijas ir įvertinti sukurtų modelių konkurencingumą. Svarbu paminėti, kad kai kurie literatūroje pateikiami jautrumo ar F1 rodikliai nėra pasverti pagal klasių pasiskirstymą, o tai turi reikšmingą įtaką rezultatų interpretacijai, ypač esant ženkliai išbalansuotoms klasėms – kaip tai būdinga apnėjos aptikimo uždaviniui. Lentelėje (11 lentelė) pateikiami kitų autorių apnėjos klasifikavimo metodų rezultatai, kai kaip įvestis buvo naudojamas FPG signalas. Kaip matyti, kai kurių sistemų, tokių kaip *MS-Net*, tikslumas siekia 82 %, tačiau F1 rodiklis išlieka santykinai žemas – 69,8 %, kas rodo, kad jautrumas ir specifiškumas nėra tolygiai subalansuoti. Savo ruožtu, šiame darbe sukurti modeliai pasiekė itin konkurencingus rezultatus, ypač vertinant pasvertus F1 ir jautrumo rodiklius. Pavyzdžiui, geriausias modelis, naudojęs 60 sekundžių segmentus bei išvestus požymius (*Aoff*, *Adn*, *deltaT*, *Tsw10*, *Tdia*), pasiekė 77,03 % tikslumą ir net 74,81 % nepasvertą F1 rodiklį. Tai rodo, kad modelis ne tik tiksliai identifikuoja įvykius, bet ir išlaiko pusiausvyrą tarp klasių, o tai itin svarbu praktinėje klinikinėje diagnostikoje.

Net ir trumpesniais, 10 sekundžių langais paremti transformatorių tipo modeliai, nors pagal nepasvertą F1 rodiklį pasiekė kuklesnius rezultatus (57,99 %), išlaikė pakankamai aukštą jautrumo lygį (71,19 % pasvertas). Svarbu pažymėti, kad šie modeliai nereikalauja sudėtingo rankinio požymių išskyrimo proceso – jie tiesiogiai apdoroja apdorotą signalą, taip sumažindami bendrą sistemos sudėtingumą. Dėl šios priežasties jie gali būti ypač naudingi realaus laiko sistemose, kur svarbus ne tik klasifikavimo tikslumas, bet ir greitas, automatizuotas duomenų apdorojimas.

Apibendrinant, nors naudoti duomenų rinkiniai ir eksperimentiniai sąlygos skiriasi, gauti rezultatai leidžia teigti, kad darbe pasiūlyti modeliai pagal klasifikavimo kokybę nėra prastesni nei literatūroje aprašyti metodai, o kai kuriais aspektais netgi juos lenkia.

11 lentelė. Klasifikavimo rezultatų palyginimas su kitais autoriais naudojančiais FPG signalą kaip įvestį

Modelio tipas	Tikslumas, %	F1 makro (nepasvertas) rodiklis, %	Jautrumas, %	AUC, %
<i>ApSense</i> su <i>MESA</i> duomenų rinkiniu	75,10	65,73	78,46	77,64
<i>ApSense</i> su <i>HeartBeat</i> duomenų rinkiniu	62,31	54,12	74,84	74,35
<i>MS-Net</i> su <i>apnea-PPG</i> duomenų rinkiniu	82,00	69,80	74,40	87,00
Geriausias algoritmo Nr.1 modelis (60s, 90 požymių vektoriaus ilgis, naudoti: <i>Aoff</i> , <i>Adn</i> , <i>deltaT</i> , <i>Tsw10</i> , <i>Tdia</i>)	77,03	69,20 (77,37 pasvertas)	74,81 (77,03 pasvertas)	84,33
Geriausias algoritmo Nr.2 modelis (10s signalas, 0,5–7 Hz filtras)	70,877	57,99 (75,02 pasvertas)	64,27 (71,19 pasvertas)	78,68

3.4. Algoritmų palyginimas kompiuterinių skaičiavimo resursų požiūriu

Atliekant palyginimą, lyginami keturi pagrindiniai kompiuterinių resursų rodikliai: programinės atminties (FLASH) poreikis, parametrų skaičius, skaičiavimo operacijų skaičius (FLOPs) bei reali greitaveika (ms). 12 lentelėje pateikti keturių skirtingų modelių rezultatai, įvertinti 20 s, 30 s ir 60 s signalo trukmėms.

Tarp modeliavimo konfigūracijų Parametrų skaičius išlieka pastovus tiems patiems modeliams—pirmųjų dviejų atvejuose jis visada siekia 165 665 parametrus (~647 KB), tuo tarpu antro algoritmo modeliams kinta proporcingai signalui: nuo 119 531 (466,9 KB) iki 324 331 (1,24 MB). Parametrų skaičius tiesiogiai koreliuoja su reikalinga RAM apimtimi, todėl atminties reikalavimai auga kartu su modelio sudėtingumu.

FLOPs rodikliai akivaizdžiai atskleidžia, jog transformatoriaus tipo modelio skaičiavimo našumas auga eksponentiškai. 20 s trukmės transformatoriaus modelio profilyje matome, kad pagrindinę dalį visų operacijų atlieka „BatchMatMulV2“ (10,50 mlrd., t. y. 97,9 % visų float_ops) bei „Softmax“ (204,8 mln., t. y. 1,9 %) operacijos. Tuo tarpu tradicinis požymių modelis su 20 s signalu reikalauja keleriopai mažiau FLOPs: „Conv2D“ – 426,2 tūkst. (90,8 %), „MatMul“ – 24,7 tūkst. (5,3 %). Taigi transformatoriaus sprendimai, nors pasižymi aukštesne tikslumo riba, žymiai padidina skaičiavimų apimtį.

Interferencijos trukmė buvo matuota Python aplinkoje, kuri iš esmės nėra optimali produkciniam paleidimui – tai reikštų, kad realioje (pvz., C/C++) implementacijoje laiko sąnaudos turėtų būti ženkliai mažesnės. Be to, įrašant ir pozicionuojant signalus naudojant specializuotą įterptą įrenginį, sumažėja duomenų perdavimo kaštai ir pagerėja realaus laiko apdorojimo galimybės. Papildomo AI sistemos sluoksnio taikymas leidžia kompensuoti dalį triukšmo ir pagerina modelio stabilumą esant dinamiškoms sąlygoms, tačiau tai kartu didina bendrą skaičiavimo krūvį.

12 lentelė. Resursų įvertinimas

Modelis	FLASH, kB	Greitaveika, ms	FLOPs	Parametrų skaičius
Geriausias algoritmo Nr.1 modelis (60s, 90 požymių vektoriaus ilgis)	566,05	622,20	4,8 mln	165665 (647,13 kb)
Algoritmo Nr.1 modelis (20s, 30 požymių ilgis)	327,12	521,22	4,8 mln	165665 (647,13 kb)
Geriausias algoritmo Nr.2 modelis (10s signalas)	290,25	3304,10	2688 mln	119531 (466,92 kb)
Algoritmo Nr.2 modelis (20s signalas)	346,32	3431,61	10722 mln	221931 (866,92 kb)
Algoritmo Nr.2 modelis (30s signalas)	390,34	3657,12	24101 mln	324331 (1,24 Mb)

Aptariant rezultatus, akivaizdu, jog pasirinkus transformatoriaus architektūrą, būtinai reikia įvertinti padidėjusį skaičiavimo krūvį bei atminties poreikį, ypač įterptose sistemose. Tuo tarpu tradiciniai požymių išgavimą pagrindžiantys modeliai išlieka efektyvesni ribotuose įrenginiuose, nors gali šiek tiek nusileisti tikslumu.

Išvados

1. Išanalizavus literatūrą nustatyta, kad kvėpavimo sutrikimai miego metu, ypač obstrukcinė miego apnėja, yra reikšminga visuomenės sveikatos problema, turinti įtakos širdies ir kraujagyslių, nervų sistemoms bei gyvenimo kokybei. Tradicinė diagnostika (polisomnografija) yra brangi ir ribotai prieinama, todėl vystomos alternatyvios stebėsenos technologijos, pagrįstos fotopletizmografijos signalų analize. Šiam darbui tinkamiausiu pasirinktas OSASUD atviros prieigos duomenų rinkinys.
2. Darbe sukurti ir įgyvendinti du skirtingo tipo mašininio mokymosi algoritmai, skirti miego apnėjos epizodų atpažinimui iš fotopletizmografijos signalų: požymiais grįstas modelis ir transformatorių architektūros modelis nereikalaujantis požymių ištraukimo. Pirmasis algoritmas grindžiamas morfologinių požymių (*Aoff*, *Adn*, ΔT , *Tsw10*, *Tdia*) išgavimu ir jų apdorojimu naudojant neuroninių tinklų modelį. Jis pasižymi mažu skaičiavimo sudėtingumu ir tinkamumu įterptinėms sistemoms. Antrasis – giliojo mokymosi pagrindu veikiantis transformatorių modelis – tiesiogiai naudoja FPG signalą ir leidžia išvengti rankinio požymių parinkimo, taip užtikrindamas didesnę automatizavimo lygį. Abu algoritmai sukurti atsižvelgiant į neinvazinių, praktiškai pritaikomų diagnostikos sprendimų poreikį.
3. Atlikus pasiūlytų algoritmų apmokymą ir testavimą su OSASUD duomenų baze nustatyta, kad abiejų metodų klasifikavimo tikslumas yra tinkamas praktiniam taikymui. Požymiais grįstas modelis, analizuojant 60 s intervalus (0,5–7 Hz filtras), pasiekė didžiausius AUC – 84,3 % ir F1 balą – 77,4 %. Transformatorių modelis, naudojantis 10 s trukmės signalo segmentus (0,5–7 Hz), parodė didžiausią jautrumą – 71,19 % – ir AUC – 78,68 %.
4. Remiantis tyrimo rezultatais, rekomenduojama kuriant neinvazines miego apnėjos stebėsenos sistemas naudoti 0,5–7 Hz juostos filtrą, kadangi jis optimaliai slopina triukšmą ir išlaiko svarbiausius FPG signalų komponentus. Taip pat taikyti giluminį transformatorių architektūros modelį, kuris, esant dideliame duomenų kiekiui, gali konkuruoti su požymiais grįstu.

Literatūros sąrašas

1. IRWIN, Michael R. Why sleep is important for health: a psychoneuroimmunology perspective. *Annu Rev Psychol.* 2015, vol. 66, p. 143–172. doi:10.1146/annurev-psych-010213-115205.
2. PARISH, James M. ir Virend K. SOMERS. Obstructive sleep apnea and cardiovascular disease. *Mayo Clinic Proceedings.* 2004, t. 79, Nr. 8, p. 1036–1046. doi:10.4065/79.8.1036.
3. WHITE, David P. Sleep apnea. *Proceedings of the American Thoracic Society*, 2006, t. 3, nr. 1, p. 124–128. doi: 10.1513/pats.200510-116JH.
4. TIETJENS, Jeremy R., David CLAMAN, Eric J. KEZIRIAN, Teresa DE MARCO, Armen MIRZAYAN, Bijan SADROONRI, Andrew N. GOLDBERG, Carlin LONG, Edward P. GERSTENFELD ir Yerem YEGHIAZARIANS. Obstructive sleep apnea in cardiovascular disease: a review of the literature and proposed multidisciplinary clinical management strategy. *Journal of the American Heart Association*, 2019, 8(1), e010440. DOI: 10.1161/JAHA.118.010440.
5. KAPUR, Vishesh, Kingman P. STROHL, Susan REDLINE, Conrad IBER, George O'CONNOR ir Javier NIETO. Underdiagnosis of sleep apnea syndrome in U.S. communities. *Sleep and Breathing*, 2002, t. 6, nr. 2, p. 49–54. DOI: 10.1055/s-2002-32318.
6. MOTAMEDI, Kevin K., Andrew C. McCLARY ir Ronald G. AMEDEE. Obstructive sleep apnea: a growing problem. *Ochsner Journal* [interaktyvus]. 2009, 9(3), 149–153 [žiūrėta 2025-05-15]. Prieiga per: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3096276>.
7. BARAN, R., GRIMM, D., INFANGER, M. ir WEHLAND, M. The effect of continuous positive airway pressure therapy on obstructive sleep apnea-related hypertension. *International Journal of Molecular Sciences.* 2021, 22(5), 2300. doi:10.3390/ijms22052300.
8. YOUNG, T., M. PALTA, J. DEMPSEY, J. SKATRUD, S. WEBER ir S. BADR. The occurrence of sleep-disordered breathing among middle-aged adults. *New England Journal of Medicine.* 1993, 328(17), 1230–1235. ISSN 0028-4793 doi:10.1056/NEJM199304293281704
9. STRENGTH, Chance, Anna WANI, Rupini ALLA, Safia KHAN, Frank David SCHNEIDER ir Bhaskar THAKUR. Obstructive sleep apnea and its cardiac implications in the United States: an age-stratified analysis between young and older adults. *Journal of the American Heart Association.* 2024, 13(12), e033810. ISSN 2047-9980. doi:10.1161/JAHA.123.033810
10. VENSEL RUNDO, J. ir R. DOWNEY. Polysomnography. Iš: LEVIN, K. H. ir P. CHAUVEL (red.). *Handbook of Clinical Neurology.* 160 t., Elsevier, 2019, p. 381–392. ISSN 0072-9752. ISBN 9780444640321. doi:10.1016/B978-0-444-64032-1.00025-4.
11. ROFAIL, L. M., K. K. WONG, G. UNGER, G. B. MARKS ir R. R. GRUNSTEIN. The utility of single-channel nasal airflow pressure transducer in the diagnosis of OSA at home. *Sleep.* 2010, 33(8), p. 1097–1105. doi: 10.1093/sleep/33.8.1097.
12. LICHSTEIN, K. L. Insomnia identity. *Behaviour Research and Therapy.* 2017, vol. 97, p. 230–241. doi:10.1016/j.brat.2017.08.005.
13. BAHAMMAM, A. S., GACUAN, D. E., GEORGE, S., ACOSTA, K. L., PANDI-PERUMAL, S. R. ir GUPTA, R. Polysomnography I: procedure and technology. Iš: *Synopsis of Sleep Medicine.* 2016, p. 443–456. doi:10.1201/9781315366340-26.

14. ALLEN, John. Photoplethysmography and its application in clinical physiological measurement. *Physiological Measurement*. 2007, 28(3), R1–R39. ISSN 0967-3334. doi:10.1088/0967-3334/28/3/R01.
15. LEPPÄNEN, Timo, Samu KAINULAINEN, Henri KORKALAINEN, Saara SILLANMÄKI, Antti KULKAS, Juha TÖYRÄS ir Sami NIKKONEN. Pulse oximetry: the working principle, signal formation, and applications. In: PENZEL, Thomas ir Roberto HORNERO (red.). *Advances in the Diagnosis and Treatment of Sleep Apnea: Filling the Gap Between Physicians and Engineers*. Cham: Springer International Publishing, 2022, p. 205–218. ISBN 978-3-031-06412-8. doi:10.1007/978-3-031-06413-5_12.
16. EL NAQA, Issam ir M.J. MURPHY. What is machine learning? In: Springer International Publishing, 2015, p. 3–11. doi: 10.1007/978-3-319-18305-3_1.
17. TAVANAEE, A., M. GHODRATI, S. R. KHERADPISHEH, T. MASQUELIER ir A. MAIDA. Deep learning in spiking neural networks. *Neural Networks*. 2019, vol. 111, p. 47–63. doi: 10.1016/j.neunet.2018.12.002.
18. ABIODUN, Oludare Isaac, Aman JANTAN, Abiodun Esther OMOLARA, Kemi Victoria DADA, Nachaat Abdelatif MOHAMED ir Humaira ARSHAD. State-of-the-art in artificial neural network applications: A survey. *Heliyon*. 2018, vol. 4, nr. 11, e00938. doi: 10.1016/j.heliyon.2018.e00938.
19. MA, X., DAI, Z., HE, Z., MA, J., WANG, Y. ir WANG, Y. Learning traffic as images: A deep convolutional neural network for large-scale transportation network speed prediction. *Sensors*. 2017, 17(4), p. 818. doi: 10.3390/s17040818.
20. Patel, Rachana Rachana Patel, Sanskruti Patel (2020) “A Comprehensive Study of Applying Convolutional Neural Network for Computer Vision”, *International Journal of Advanced Science and Technology*, 29(6s), pp. 2161-2174.
21. ALAM, M., SAMAD, M. D., VIDYARATNE, L., GLANDON, A. ir IFTEKHARUDDIN, K. M. Survey on deep neural networks in speech and vision systems. *Neurocomputing*, 2020, vol. 417, p. 302–321. doi:10.1016/j.neucom.2020.07.053.
22. CHOI, Keunwoo, Gábor FAZEKAS, Kyunghyun CHO ir Mark SANDLER. A tutorial on deep learning for music information retrieval [interaktyvus]. 2017. doi: 10.48550/arXiv.1709.04396.
23. FAN, J., MA, C. ir ZHONG, Y. A selective overview of deep learning. *Statistical Science: a Review Journal of the Institute of Mathematical Statistics*. 2021, 36(2), p. 264. doi:10.1214/20-sts783.
24. GOODFELLOW, Ian, Yoshua BENGIO ir Aaron COURVILLE. *Deep learning*. Cambridge, MA: MIT Press, 2016. ISBN 9780262035613.
25. VASWANI, Ashish, Noam SHAZEER, Niki PARMAR, Jakob USZKOREIT, Llion JONES, Aidan N. GOMEZ, Łukasz KAISER ir Illia POLOSUKHIN. Attention is all you need. *Advances in Neural Information Processing Systems*. 2017, 30. doi:10.48550/arXiv.1706.03762
26. DONG, Chenghao, Xuejing KANG ir Anlong MING. ICDA: illumination-coupled domain adaptation framework for unsupervised nighttime semantic segmentation. In: *Proceedings of the Thirty-Second International Joint Conference on Artificial Intelligence (IJCAI-23)*. Macao, P.R. China, 2023, p. 672–680. ISBN 978-1-956792-03-4. doi:10.24963/ijcai.2023/75.

27. YOSINSKI, Jason, Jeff CLUNE, Yoshua BENGIO ir Hod LIPSON. How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems*. 2014, t. 27, p. 3320–3328. doi:10.5555/2969033.2969197.
28. BIRD, Jordan J., Jhonatan KOBYLARZ, Diego R. FARIA, Aniko EKART ir Eduardo P. RIBEIRO. Cross-domain MLP and CNN transfer learning for biological signal processing: EEG and EMG. *IEEE Access*, 2021, t. 8, p. 54789–54801. doi:10.1109/ACCESS.2020.2979074.
29. QURESHI, A. S., KHAN, A., ZAMEER, A. ir USMAN, A. Wind power prediction using deep neural network based meta regression and transfer learning. *Applied Soft Computing*. 2017, t. 58, p. 742–755. doi: 10.1016/j.asoc.2017.05.031.
30. MENDONCA, F., S. S. MOSTAFA, A. G. RAVELO-GARCIA, F. MORGADO-DIAS ir T. PENZEL. A review of obstructive sleep apnea detection approaches. *IEEE Journal of Biomedical and Health Informatics*. 2019, 23(2), 825–837. doi:10.1109/JBHI.2018.2823265.
31. LIN, Xu, Hanrong CHENG, Yun LU, Hong LUO, Hong LI, Yaqiong QIAN, Lin ZHOU, Lin ZHANG, ir Mingjiang WANG. Contactless sleep apnea detection in snoring signals using hybrid deep neural networks targeted for embedded hardware platform with real-time applications. *Biomedical Signal Processing and Control*. 2022, 77, p. 103765. doi:10.1016/j.bspc.2022.103765.
32. DING, L. ir J. PENG. Automatic classification of snoring sounds from excitation locations based on prototypical network. *Applied Acoustics*. 2022, t. 195, p. 108799. doi:10.1016/j.apacoust.2022.108799.
33. LAZAZZERA, Remo, Margot DEVIAENE, Carolina VARON, Bertien BUYSE, Dries TESTELMANS, Pablo LAGUNA, Eduardo GIL ir Guy CARRAULT. Detection and classification of sleep apnea and hypopnea using PPG and SpO₂ signals. *IEEE Transactions on Biomedical Engineering*. 2021, 68(5), 1496–1506. ISSN 0018-9294. doi:10.1109/TBME.2020.3028041.
34. WEI, Keming, ZOU, Lang, ir kt. MS-Net: Sleep apnea detection in PPG using multi-scale block and shadow module one-dimensional convolutional neural network. *Computers in Biology and Medicine*. 2023, vol. 155, 106469. doi:10.1016/j.compbimed.2022.106469.
35. CHOKSATCHAWATHI, Tanut ir kt. ApSense: Data-Driven Algorithm in PPG-Based Sleep Apnea Sensing. *IEEE Internet of Things Journal*. 2024, 11(20), 33915–33926. DOI: 10.1109/JIOT.2024.3433500.
36. BILD, Diane E., David A. BLUEMKE, Gregory L. BURKE, Robert DETRANO, Ana V. DIEZ ROUX, Aaron R. FOLSOM, Philip GREENLAND, David R. JACOBS Jr., Richard KRONMAL, Kiang LIU, Jennifer C. NELSON, Daniel O’LEARY, Mohammed F. SAAD, Steven SHEA, Moyses SZKLO ir Russell P. TRACY. Multi-Ethnic Study of Atherosclerosis: objectives and design. *American Journal of Epidemiology*. 2002, 156(9), 871–881. ISSN 0002-9262. doi:10.1093/aje/kwf113. PMID: 12397006.
37. LEWIS, E. F. ir kt. Impact of continuous positive airway pressure and oxygen on health status in patients with coronary heart disease, cardiovascular risk factors, and obstructive sleep apnea: A Heart Biomarker Evaluation in Apnea Treatment (HEARTBEAT) analysis. *American Heart Journal*. 2017, 189, 59–67. ISSN 0002-8703. doi:10.1016/j.ahj.2017.03.001.
38. BERNARDINI, Andrea, Andrea BRUNELLO, Gian Luigi GIGLI, Angelo MONTANARI ir Nicola SACCOMANNO. OSASUD: A dataset of stroke unit recordings for the detection of Obstructive Sleep Apnea Syndrome. *Scientific Data*, 2022, t. 9, nr. 1, p. 177. ISSN 2052-4463. doi:10.1038/s41597-022-01272-y.

39. BERNARDINI, Andrea, Andrea BRUNELLO, Gian Luigi GIGLI, Angelo MONTANARI ir Nicola SACCOMANNO. AIOSA: An approach to the automatic identification of obstructive sleep apnea events based on deep learning. *Artificial Intelligence in Medicine*. 2021, t. 118, p. 102133. ISSN 0933-3657. doi: 10.1016/j.artmed.2021.102133.
40. GODA, Márton Á., Peter H. CHARLTON ir Joachim A. BEHAR. pyPPG: a Python toolbox for comprehensive photoplethysmography signal analysis. *Physiological Measurement*. 2024, 45(4), 045001. doi:10.1088/1361-6579/ad33a2
41. POLLREISZ, David ir Nima TAHERINEJAD. Detection and removal of motion artifacts in PPG signals. *Mobile Networks and Applications*. 2022, t. 27, nr. 2, p. 728–738. ISSN 1383-469X. doi:10.1007/s11036-019-01323-6
42. ALMARSHAD, Malak Abdullah, Saad AL-AHMADI, Md Saiful ISLAM, Ahmed S. BaHAMMAM ir Adel SOUDANI. Adoption of transformer neural network to improve the diagnostic performance of oximetry for obstructive sleep apnea. *Sensors*. 2023, 23(18), 7924. doi:10.3390/s23187924.
43. LIU, Hang, Shaowei CUI, Xiaohui ZHAO ir Fengyu CONG. Detection of obstructive sleep apnea from single-channel ECG signals using a CNN-transformer architecture. *Biomedical Signal Processing and Control*. 2023, t. 82, 104581. ISSN 1746-8094. doi:10.1016/j.bspc.2023.104581
44. VUJOVIĆ, Željko Đ. Classification model evaluation metrics. *International Journal of Advanced Computer Science and Applications*, 2021, t. 12, nr. 6, p. 599–606. doi:10.14569/IJACSA.2021.0120670.