



Kauno technologijos universitetas

Panevėžio technologijų ir verslo fakultetas

Elektroencefalografijos signalų panaudojimo įrangai valdyti galimybių tyrimas

Baigiamasis magistro studijų projektas

Renaldas Ramanauskas

Projekto autorius

Asist. dr. Marius Mikolajūnas

Vadovas

Panevėžys, 2025



Kauno technologijos universitetas

Panevėžio technologijų ir verslo fakultetas

Elektroencefalografijos signalų panaudojimo įrangai valdyti galimybių tyrimas

Baigiamasis magistro studijų projektas

Valdymo technologijos (6211EX014)

Renaldas Ramanauskas

Projekto autorius

Asist. dr. Marius Mikolajūnas

Vadovas

Recenzentas / Recenzentė

Panevėžys, 2025



Kauno technologijos universitetas

Panevėžio technologijų ir verslo fakultetas

Renaldas Ramanauskas

Elektroencefalografijos signalų panaudojimo įrangai valdyti galimybių tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

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

Renaldas Ramanauskas

Patvirtinta elektroniniu būdu



Kauno technologijos universitetas
Panevėžio technologijų ir verslo fakultetas

TVIRTINU
TVKC vadovė
Doc. dr. Nida Kvedaraitė

Baigiamojo magistro projekto užduotis

Diplomantui **Renaldui Ramanauskui**

Baigiamojo projekto tema (lietuvių kalba)	Elektroencefalografijos signalų panaudojimo įrangai valdyti galimybių tyrimas
--	--

Baigiamojo projekto tema (anglų kalba)	Research of the Feasibility of Using Electroencephalography Signals to Control Equipment
---	---

Patvirtinta 2025 m. balandžio 14 d. dekanų potvarkiu Nr. V25-13-12

Parengto baigiamojo projekto įkėlimo į Moodle aplinką terminas iki 2025 m. gegužės 29 d.

Duomenys, reikalavimai ir sąlygos baigiamajam projektui

Tyrimo objektas – elektroencefalografijos signalai.

Tikslas - ištirti elektroencefalografijos signalų panaudojimo valdymui galimybes.

Baigiamojo projekto užduotys / uždaviniai, kurie turi būti atskleisti projekte:

1. Išnagrinėti pagrindinius elektroencefalografijos signalų matavime atsirandančius trikdžius.
2. Išnagrinėti elektroencefalografijos signalų požymių pagal jų kilmę išskyrimo metodus.
3. Ištirti ir palyginti vertikalius, horizontalius akių judesius ir mirksnius elektroencefalografijos duomenyse.
4. Ištirti akių būsenos, judesių ir mirksnių aptikimą bei valdymo signalų kūrimo galimybes remiantis elektroencefalografijos duomenimis.

Vadovas

Asist. dr. Marius Mikolajūnas

(vadovo pareigos, vardas, pavardė, parašas)

Užduotį gavau

Renaldas Ramanauskas

(studento vardas, pavardė, parašas)

2025 m. balandžio 17 d.

Ramanauskas, Renaldas. Elektroencefalografijos signalų panaudojimo valdymui tyrimas. Magistro studijų baigiamasis projektas / vadovas asist. dr. Marius Mikolajūnas; Kauno technologijos universitetas, Panevėžio technologijų ir verslo fakultetas.

Studijų kryptis ir sritis: elektronikos inžinerija, technologijos mokslai.

Reikšminiai žodžiai: elektroencefalografija (EEG), signalų apdorojimas, trikdžių šalinimas, nepriklausomų komponentų analizė (ICA), akių judesių aptikimas, priverstinis akių mirksnis, horizontalūs akių judesiai, vertikalūs akių judesiai, užmerktų akių aptikimas.

Panevėžys, 2025. 64 p.

Santrauka

Šio projekto tikslas – ištirti elektroencefalografijos signalų panaudojimo valdymui galimybes. Uždaviniai, kurie iškelti tikslui pasiekti: išnagrinėti pagrindinius elektroencefalografijos signalų matavime atsirandančius trikdžius; išnagrinėti elektroencefalografijos signalų požymių pagal jų kilmę išskyrimo ir klasifikavimo metodus bei panaudojimo galimybes; palyginti vertikalius, horizontalius akių judesius ir mirksnius elektroencefalografijos duomenyse; ištirti akių mirksnių, judesių ir būsenos aptikimo bei valdymo signalų kūrimo galimybes iš elektroencefalografijos duomenų.

Projekto struktūra: teorinė dalis, eksperimentinė dalis, tiriamoji dalis, išvados ir literatūros sąrašas.

Naudota programinė įranga: „Python“ 3.10.12; „Brainaccess SDK“.

Gautos išvados. EEG signalų artefaktai skirstomi į vidinius: širdies ritmo, akių judesių, raumenų veiklos ir išorinius – blogas elektrodo ir odos kontaktas prastas elektrodo laidumas. Šiems artefaktams aptikti gali būti naudojami tokie metodai kaip ICA, DTW, amplitudės slenksčio ir kt. EEG požymių išskyrimo metodai gali būti skirstomi į šias kategorijas: laiko domeno (signalų fraktalų analizavimas ir statistiniai požymiai), dažnio srities (*Furjė* transformacija ar galios spektrinis tankis), dekompozicijos (bangelių transformacija, empirinio režimo skaidymas ar nepriklausomų komponentų analizė) ir erdvinio domeno (CSP algoritmas ir jo variacijos). EEG požymiams klasifikuoti naudojami tokie algoritmai: mašininio mokymo (SVM, CNN, DBN, LSTM, GAN) ir analizės (LDA) metodai. Dažniausiai „žmogaus-mašinos“ sąsajas pagrįstos EEG duomenų interpretavimu naudojamas judesių, emocijų ar nuovargiui atpažinti. Palyginus vertikalius, horizontalius akių judesius ir mirksnius EEG duomenyse, nustatytas skirtumas 20–45 Hz dažnių juostoje – aptinkamos priverstinių akių mirksnių viršūnės, kai naudojamas ICA metodas kartu su šios dažnių juostos PSD skaičiavimu ir yra mažesnės nei $0,1 \mu V^2/Hz$, vertikalių akių judesių – didesnės nei $0,1 \mu V^2/Hz$. Akių mirksnius efektyviausiai galima aptikti taikant ICA metodą kartu su 1,5–12 Hz dažnių juostos PSD skaičiavimu. Remiantis aptiktais mirksniais ir akių judesiais, sukurtas algoritmas, kuris šią informaciją pavertė valdymo signalais. Algoritmo vidutinis efektyvumas aptinkant akių mirksnius ir vertikalius judesius, kai nėra dviejų kanalų – 93,93 proc.

Ramanauskas, Renaldas. Research of the Feasibility of Using Electroencephalography Signals to Control Equipment. Master's Final Degree Project / supervisor assist. dr. Marius Mikolajūnas; Panevėžys Faculty of Technologies and Business, Kaunas University of Technology.

Study field and area: Electronics Engineering, Technology Sciences.

Keywords: electroencephalography (EEG), signal processing, artifact removal or noise removal, independent component analysis (ICA), eye movement detection, forced eye blink, horizontal eye movements, vertical eye movements, closed eyes detection.

Panevėžys, 2025. 64 pages.

Summary

Project objective – To investigate the possibilities of using EEG signals for control purposes. Tasks: Analyze the main artifacts that occur during EEG signal measurement; Examine methods for extracting and classifying EEG signal features based on their origin and assess their applicability; Compare vertical and horizontal eye movements and blinks in EEG data; investigate the possibilities of detecting eye blinks, movements, and states, and generating control signals from EEG data.

Project structure: theoretical part, experimental part, research part, conclusions, and list of references.

Software used: “Python” 3.10.12; “BrainAccess SDK”.

Conclusions obtained: EEG signal artifacts are categorized as internal (heart rate, eye movements, muscle activity) and external (poor electrode-to-skin contact, low electrode conductivity). Methods such as ICA, DTW, amplitude thresholding, and others can be used to detect these artifacts. EEG feature extraction methods fall into the following categories: time domain (fractal analysis of signals and statistical features), frequency domain (*Fourier* transform or power spectral density), decomposition (wavelet transform, empirical mode decomposition, or independent component analysis), and spatial domain (CSP algorithm and its variations). For EEG feature classification, algorithms used include machine learning methods (SVM, CNN, DBN, LSTM, GAN) and analytical methods (LDA). Human-machine interfaces based on EEG data interpretation are most commonly used for recognizing movements, emotions, or fatigue. A comparison of vertical and horizontal eye movements and blinks in EEG data showed differences in the 20–45 Hz frequency band – peaks of forced eye blinks were detected using the ICA method along with PSD calculation in this frequency band, with values lower than $0.1 \mu\text{V}^2/\text{Hz}$, whereas vertical eye movements showed values greater than $0.1 \mu\text{V}^2/\text{Hz}$. Eye blinks can be most effectively detected using the ICA method combined with PSD calculation in the 1.5–12 Hz frequency band. Based on the detected blinks and eye movements, an algorithm was developed that converted this information into control signals. The algorithm achieved an average effectiveness of 93.93 proc. in detecting eye blinks and vertical movements when two channels were not available.

Turinys

Paveikslų sąrašas	9
Santrumpų ir terminų sąrašas	11
Įvadas.....	12
1. EEG duomenų analizės kelias	13
1.1. EEG duomenų surinkimas	14
1.2. EEG artefaktai ir ne smegenų veiklos signalai	15
1.2.1. ECG artefaktai	16
1.2.2. EOG artefaktai	17
1.2.3. EMG artefaktai	19
1.2.4. Išoriniai ne smegenų veiklos sukelti signalai	21
1.3. EEG požymių išskyrimas	21
1.4. EEG požymiai pagal laiko sritį	22
1.4.1. Autoregresinis modeliavimas (AR)	22
1.4.2. Signalų fraktalų analizavimas	23
1.4.3. Statistiniai požymiai	24
1.5. EEG požymiai pagal dažnio sritį	24
1.5.1. <i>Furjė</i> transformacija	24
1.5.2. Galios spektrinis tankis	24
1.6. Požymių išskyrimas naudojant dekompoziciją	25
1.6.1. Bangelių transformacija	25
1.6.2. Empirinis režimų skaidymas	26
1.6.3. Nepriklausomų komponentų analizė	27
1.6.4. Erdvinės srities požymių išskyrimas	28
1.7. EEG požymių klasifikavimas	28
1.7.1. Tiesinė diskriminantinė analizė	29
1.7.2. Konvoliucinis neuroninis tinklas	29
1.7.3. Gilių įsitikinimų tinklas	30
1.7.4. Pasikartojantis neuroninis tinklas	31
1.7.5. Pagalbinių vektorių mašina	32
1.7.6. Tinklas su pasipriešinimu	32
2. Akių mirksnių, judesių ir būsenų aptikimas.....	34
2.1. Duomenų surinkimas ir apdorojimas	34
2.2. Priverstinių akių mirksnių aptikimas	38
2.3. Trumpiausio galimo duomenų intervalo akių mirksniais aptikti radimas	43
2.4. Skirtingų akių, mirksnių atpažinimas	45
2.5. Horizontalių ir vertikalų akių judesių atpažinimas	47
2.6. Užmerktų ir atmerktų akių aptikimas	50
2.7. Gauti rezultatai	52
3. Valdymo signalų kūrimas iš elektroencefalografijos duomenų	53
3.1. Valdymo algoritmo aprašymas	53
3.2. Valdymo algoritmo testavimas	56
3.3. Algoritmo pritaikymas įrangai valdyti	58
Išvados	59
Literatūros sąrašas	60

Lentelių sąrašas

1 lentelė. Išmatuotų potencialų palyginimas [17]	15
2 lentelė. Požymių išskyrimo metodai, naudoti „žmogaus-mašinos“ sąsajai valdyti ir išanalizuoti mokslinėje literatūroje nuo 2009 m. iki 2019 m. [2]	22
3 lentelė. ICA metodo taikyto trikdžiams šalinti rezultatai [46]	27
4 lentelė. EEG signalų klasifikacijos metodai naudoti „žmogaus-mašinos“ sąsajai valdyti ir išanalizuoti mokslinėje literatūroje nuo 2009 m. iki 2019 m. [2].....	29
5 lentelė. LDA algoritmo efektyvumo palyginimas su kitais metodais[50]	29
6 lentelė. Nuovargio atpažinimas vairuojant [51]	30
7 lentelė. EEG matavimo prietaiso „BrainAccess MINI“ techniniai duomenys [61]	34
8 lentelė. Gauti akių mirksnius indikuojančių viršūnių kiekiai atliekant pirmą bandymą.....	38
9 lentelė. Gauti kurtozės ir koreliacijos rezultatai.....	41
10 lentelė. Algoritmo aptikti akių mirksnius indikuojančių viršūnių kiekiai, naudojant skirtingus duomenų intervalus	44
11 lentelė. Algoritmo veikimo rezultatai kai vienas kanalas ignoruojamas.....	57
12 lentelė. Algoritmo veikimo rezultatai kai du kanalai ignoruojami	57

Paveikslų sąrašas

1 pav. EEG matavimų rezultatų palyginimas naudojant sausus ir gelio elektrodus [17].....	14
2 pav. Sausų ir gelio elektrodų rezultatų koreliacija, matuojant skirtingose dažnių juostose (čia EC – akys atmerktos, o EO – akys užmerktos) [18].....	15
3 pav. ECG trikdžiai EEG matavime [21]: a) ECG trikdžių pavyzdys trijuose elektroduose; b) ECG trikdžiai po 10 Hz aukšto dažnio filtro	16
4 pav. ECG trikdžių pašalinimo iš EEG metodų palyginimas [22]	17
5 pav. EOG trikdžiai [25].....	18
6 pav. Skirtumas tarp tiesinės koreliacijos ir DTW [30].....	19
9 pav. EMG trikdžių pašalinimo rezultatai [27].....	20
10 pav. Varžos sudedamosios dalys [20]	21
11 pav. Tyrime naudoto autoregresinio modelio tikslumas [6]	23
12 pav. Bangelių transformacija atvaizduota grafiškai [42]	25
13 pav. Empirinio režimų skaidymas atvaizduota grafiškai [44].....	26
14 pav. ICA metodo veikimo pavyzdys [47]	27
15 pav. LSTM tinklo atminties celės schema [56].....	31
16 pav. Vienas iš GAN tinklo panaudojimo būdų [7].....	32
17 pav. EEG elektrodų pozicijos pagal 10-20 sistemą [62]	35
18 pav. Nuskaityti EEG duomenys, pirmas bandymas	35
19 pav. EEG duomenų dažnių pasiskirstymas, atvaizduotas naudojant <i>Furjė</i> transformaciją	36
20 pav. EEG duomenų dažnių pasiskirstymas išfiltravus dažnius, atvaizduotas naudojant <i>Furjė</i> transformaciją.	37
21 pav. Pirmo bandymo nuskaityti EEG duomenys po filtravimo.	38
22 pav. Akių mirksnių viršūnių aptikimas, pirmas bandymas.	39
23 pav. Pirmo bandymo EEG duomenų 1,5–12 Hz dažnių juostos PSD visuose kanaluose.....	40
24 pav. Pirmo bandymo visų EEG kanalų 1,5–12 Hz dažnių juostos PSD suma.....	40
25 pav. Pirmo bandymo EEG duomenys pritaikius ICA metodą ir suskaičiavus PSD.	41
26 pav. Mirksniai be pauzių naudojant tik amplitudės ribos aptikimo metodą	42
27 pav. Mirksniai be pauzių skaičiuojant išfiltruoto EEG signalo bendrą 1,5–12 Hz PSD.....	42
28 pav. Mirksniai be pauzių naudojant ICA metodą.....	43
29 pav. Mirksniai be pauzių skaičiuojant ICA komponento su EEG akių veikla 1,5– 12 Hz PSD..	43
30 pav. Gauti rezultatai kai naudojant algoritmą aptikti akių mirksnius kai duomenų intervalas yra 10s, akių mirksniai be pauzės	44
31 pav. Gauti rezultatai kai naudojant algoritmą aptikti akių mirksnius kai duomenų intervalas yra 12s, akių mirksniai su pauze.....	45
32 pav. Skirtingų akių mirksnių palyginimas	46
33 pav. Skirtingų akių mirksnių palyginimas tarp EEG kalanų.....	46
34 pav. Skirtingų akių judesių atpažinimas	47
35 pav. PSD skaičiavimas 20–45 Hz dažnių juostai, ICA duomenims	48
36 pav. DWT metodo pritaikymas siekiant atskirti skirtingus akių judesius.....	48
37 pav. Horizontalių akių judesių aptikimas.....	49
38 pav. Horizontalių akių judesių aptikimas naudojant DWT	50
39 pav. Užmerktų akių aptikimas 9–12 Hz dažnių juostoje.	51
40 pav. Užmerktų akių aptikimas 9–12 Hz dažnių juostoje skaičiuojant PSD.....	51
41 pav. Užmerktų akių aptikimas 9–12 Hz dažnių juostoje skaičiuojant PSD.....	52

42 pav. Algoritmas skirtas sukurti valdymo signalas iš akių sukeltos elektrinės veiklos aptikti pirmas dalis.....	54
43 pav. Algoritmas skirtas sukurti valdymo signalas iš akių sukeltos elektrinės veiklos aptikti antra dalis.....	55
44 pav. Algoritmas skirtas sukurti valdymo signalas iš akių sukeltos elektrinės veiklos.....	56
45 pav. Kanalų įtaką algoritmo veiksmingumui	57
46 pav. EEG signalų panaudojimas valdymui, funkcinė schema	58

Santrumpų ir terminų sąrašas

Santrumpos:

EEG – elektroencefalografija;

ECG – elektrokardiografija (angl. *electrocardiography*);

EOG – elektrookulografija;

EMG – elektromiografija;

ERP – su įvykiu susijęs potencialas (angl. *event related potential*);

N75 – neigiama vizualios stimuliacijos atsako žyma, pasireiškianti ties 75 milisekundėmis;

P100 – teigiama vizualios stimuliacijos atsako žyma, pasireiškianti ties 100 milisekundėmis;

N145 – teigiama vizualios stimuliacijos atsako žyma, pasireiškianti ties 145 milisekundėmis;

IEC – tarptautinė elektrotechnikos komisija (angl. *the international electrotechnical commission*);

PSD – galios spektrinis tankis (angl. *power spectral density*).

Terminai:

Fraktalas (lot. *fractio* – trupmena) – geometrinis objektas, kurio pagrindinės savybės nepriklauso nuo mastelio. Tai fragmentuota geometrinė figūra, kurią galima padalyti į mažesnes dalis, apytiksliai panašias į visą objektą. Fraktalo matmuo nėra sveikasis skaičius [1].

Ivadas

EEG signalų analizė – tai vienas iš būdų, leidžiančių gilintis į smegenų veiklos mechanizmus. Tačiau, nepaisant to, kad EEG tyrimai yra atliekami jau daugelį metų, vis dar yra neatsakytų klausimų, tokių kaip signalų triukšmo panaikinimas, pasikartojančios struktūros atpažinimas ir derinimas individualiam asmeniui. Temos aktualumą rodo išaugęs mokslinių publikacijų skaičius, t. y. nuo 59 tūkstančių 2020 m. iki 74 tūkstančių 2024 m. Didelį susidomėjimą smegenų veiklos analize ir valdymo galimybėmis taip pat rodo šia tyrimų kryptimi pagrįstų technologijų, tokių kaip „Neuralink“, kūrimas. Šiame tyrime bus analizuojamos galimybės panaudoti EEG būdu nuskaitytus signalus valdyti įrangą.

Tyrimo objektas – elektroencefalografijos signalai.

Projekto tikslas – ištirti elektroencefalografijos signalų panaudojimo valdymui galimybes.

Uždaviniai:

1. Išnagrinėti pagrindinius elektroencefalografijos signalų matavime atsirandančius trikdžius.
2. Išnagrinėti elektroencefalografijos signalų požymių pagal jų kilmę išskyrimo ir klasifikavimo metodus bei panaudojimo galimybes.
3. Palyginti vertikalius, horizontalius akių judesius ir mirksnius elektroencefalografijos duomenyse
4. Ištirti akių mirksnių, judesių ir būsenos aptikimo bei valdymo signalų kūrimo galimybes iš elektroencefalografijos duomenų.

Tyrimo metodai – mokslinių altinių analizė, eksperimentai.

Konferencijoje(-jose) skaityti pranešimai:

Ramanauskas, Renaldas. Elektrookulografijos signalų panaudojimas valdymui. 24-oji studentų mokslinių darbų konferencija „Technologijų ir verslo aktualijos“. Panevėžys: Kauno technologijos universiteto Panevėžio technologijų ir verslo fakultetas, 2024 m. lapkričio 22 d.

Autoriaus publikuotų straipsnių bibliografinis sąrašas:

Ramanauskas, Renaldas; Mikolajūnas, Marius. Elektrookulografijos signalų panaudojimo valdymui galimybių tyrimas // Technologijų ir verslo aktualijos – 2024: studentų mokslinių darbų konferencijos pranešimų medžiaga, Lietuva, Panevėžys, 2024 m. lapkričio 22 d. / Kauno technologijos universiteto Panevėžio technologijų ir verslo fakultetas. Kaunas: Kauno technologijos universitetas. ISSN 2538-8045. 2024, p. 350–357.

1. EEG duomenų analizės kelias

Nors EEG tradiciškai naudojama medicininėms diagnozėms, pavyzdžiui, epilepsijai aptikti ar miego būsenoms stebėti, pastaraisiais dešimtmečiais ši technologija pradėta taikyti ir interaktyviosiose sistemose, įskaitant sąsajas, kurios leidžia valdyti įrenginius naudojant smegenų bangas.

EEG pagrindu veikiančios „žmogaus-mašinos“ sąsajos arba BCI (angl. *brain-computer interface*) suteikia galimybę tiesiogiai perduoti informaciją iš smegenų į kompiuterį ar kitą įrenginį be fizinio sąveikavimo [2]. Tokios sąsajos nuskaito ir interpretuoja smegenų bangas, suteikdamos vartotojui galimybę valdyti įrenginius, pavyzdžiui, neįgaliesiems skirtas kėdes ar kompiuterio programas.

EEG panaudojimo valdymui principas yra pagrįstas vartotojų gebėjimu generuoti tam tikrus smegenų būsenų modelius, kuriuos galima atpažinti naudojant EEG. Pavyzdžiui:

- motorinė vaizduotė: kai asmuo įsivaizduoja judesį (pavyzdžiui, rankos ar kojos judinimą), smegenyse suaktyvinami tie patys regionai, kurie fiziškai dalyvautų atliekant tą judesį; elektrinė veikla sukelta šiose aktyviose zonose gali būti nuskaityta ir panaudota kaip komanda įrenginiui [3, 4, 5];
- dėmesio koncentracija: analizuojama subjekto dėmesio būseną, atpažįstamos jo emocijos, t. y. ar jis pavargęs, ar mieguistas, ir pagal tai suformuojamos komandos [6, 7].

EEG technologijos taikymas tiek medicinos, tiek valdymo sistemų srityje reikalauja efektyvaus duomenų analizės proceso. Tai svarbu EEG pagrindu veikiančiose „žmogaus-mašinos“ sąsajose, nes reikalauja aiškių komandų formulavimo, kurios transformuotų smegenų bangas į konkrečius veiksmus, suteikiant vartotojams naujų galimybių.

Efektyvi EEG duomenų analizė apima kelis svarbius etapus, užtikrinančius, kad surinkta informacija galėtų būti tiksliai analizuojama ir interpretuojama:

- duomenų rinkimas;
- signalų apdorojimas;
- požymių išskyrimas;
- požymių klasifikacija ar analizė;

Duomenų rinkimas. Šiame etape naudojamas EEG įrenginys su keliais elektrodais, skirtais užfiksuoti elektrinę veiklą, vykstančią smegenyse. Elektrodai dažnai išdėstomi taikant standartizuotas sistemas, tokias kaip 10-20 arba 10-10 [8, 9]. Šie skaičiai – tai atstumas tarp elektrodų, išreikštas procentais nuo žmogaus kaukolės perimetro.

Signalų apdorojimas. EEG signalai dažnai būna triukšmingi dėl artefaktų, atsirandančių dėl širdies veiklos, akių judesių ar išorinių elektrinių trukdžių. Apdorojimo etapai apima:

- filtravimą – taikomi juostiniai filtrai, duomenų dažnių juostoms (alfa, beta, delta, gama ir teta bangos) išsaugoti [10, 11, 12];
- artefaktų atmetimą – naudojamos technikos, pavyzdžiui, nepriklausoma komponentų analizė (ICA) kuri gali būti naudojama ne smegenų veiklos komponentams identifikuoti ir pašalinti [13];

Požymių išskyrimas. Šiame etape apdoroti EEG signalai paverčiami matuojamų požymių rinkiniu, kuris atspindi smegenų veiklą. Keli galimi požymiai: galios spektro tankis, signalų amplitudė ar panašumas tarp signalų, gautų iš skirtingų smegenų sričių [14].

Požymių klasifikacija ar analizė. Taikomi įvairūs mašininio mokymosi ar giluminio mokymosi algoritmai, tokie kaip: CNN (angl. *convolutional neural network*) [15], DBN (angl. *deep belief network*) [15], LSTM (angl. *long short term memory*) [15], SVM (angl. *support vector machine*) [15], GAN (angl. *generative adversarial network*) [7], taikomi išskirtiems požymiams analizuoti.

1.1. EEG duomenų surinkimas


EEG matavimuose dažniausiai naudojami dviejų rūšių elektrodai: sausi ir gelio.

Gelio elektrodams reikalingas specialus galvos odos paruošimas – plaukų pašalinimas ir gelio tepimas. Gelis padaro šiuos elektrodus netinkamus ilgalaikiam naudojimui, nes gelis laikui bėgant džiūsta. To pasekmė – elektrodo-galvos odos kontakto varžos didėjimas. Penkių valandų bėgyje gelio elektrodų varža padidėja nuo 4 k Ω iki 18 k Ω , tuo tarpu sausų elektrodų varža išlieka pastovi – tarp 7–8 k Ω [16].

Sausiems EEG elektrodams gelis ir specialus odos paruošimas nebūtinai. Sausų elektrodų varža išlieka pastovi ir juos lengviau įtaisyti ant matavimo vietų. Tai padaro šiuos elektrodus pranašesnius ilgalaikiam naudojimui ne EEG tyrimų tikslais.

Varža yra svarbus aspektas EEG matavimuose, nes ji tiesiogiai veikia signalo kokybę ir matavimo tikslumą. EEG signalų matavimo metu elektrodai dedami ant galvos odos, siekiant užfiksuoti labai mažus smegenų elektros aktyvumo signalus. Šių elektrodų ir odos sąlyčio taškuose atsirandanti varža gali daryti įtaką gautiems signalams (žr. 1 pav.).

Mokslininkai atliko EEG matavimus vienu metu naudojant sausus ir gelio elektrodus ir išmatavo tris skirtingus vizualaus atsako potencialus: N75, P100, N145 (žr. 1 pav.) [17].



1 pav. EEG matavimų rezultatų palyginimas naudojant sausus ir gelio elektrodus [17]

2D interpoliuotas trijų pagrindinių vizualaus atsako potencialų smailių topografinis žemėlapis (normalizuotas iki atitinkamos didžiausios amplitudės) pateiktas 1 paveiksle. Gautų rezultatų koreliacija siekia $1,7 \pm 0,7 \mu\text{V}$ [17] (žr. 1 lentelę).


1 lentelė. Išmatuotų potencialų palyginimas [17]

VEP	Potencialas, μV	Potencialas, μV
N75	$14,8 \pm 4,1$	$13,8 \pm 3,0$
P100	$25,8 \pm 7,6$	$23,5 \pm 6,2$
N145	$14,2 \pm 6,8$	$13,3 \pm 4,9$

Rezultatai rodo, kad skirtumas tarp sausų ir gelio elektrodų mažesnis nei 10 proc. (žr. 1 lentelę). Šis skirtumas atsirandą dėl papildomo triukšmo, kurio nėra gelio elektroduose ir kuris generuojamas sausuose elektroduose [17].

Taip pat tyrėjai tarpusavyje lygino sausų ir gelio elektrodų matavimų rezultatus kai tyrimo subjektas atmerkia bei užmerkia akis. Nustatyta 85 proc. (didesnė nei $p > 0,05$) gautų rezultatų koreliacija [18] (žr. 2 pav.).

2 paveiksle pavaizduota vidutinė sausų ir gelio elektrodų signalų koreliacija, kai subjekto akys užmerktos / atmerktos, dažnių juostose: delta (1,5–3,5 Hz), teta (4–7,5 Hz), alfa (8–12 Hz), beta 1 (13–16 Hz), beta 2 (13–21 Hz), beta 3 (21–32 Hz), gama (35–45 Hz). Iš 2 paveikslą galima matyti, kad mažiausia koreliacija tarp sausų ir gelio elektrodų yra tuomet, kai EEG matavimai daromi delta dažnių juostoje.



2 pav. Sausų ir gelio elektrodų rezultatų koreliacija, matuojant skirtingose dažnių juostose (čia EC – akys atmerktos, o EO – akys užmerktos) [18]

Dar vienas tyrimas parodė [19], kad didžiausias skirtumas (galios spektrinis tankis – $3 \mu V^2/Hz$) tarp sausų ir gelio elektrodų matomas esant 1,1 Hz dažniui kai subjekto akys užmerktos ir jis yra ramybės būsenoje. Kai matuojama didesniame 2,1 Hz dažnyje, skirtumas tarp išmatuotų rezultatų neviršija galios spektrinio tankio vertės – $1,4 \mu V^2/Hz$ [19].

1.2. EEG artefaktai ir ne smegenų veiklos signalai

EEG matavimai gali būti paveikti įvairių trikdžių, trukdančių tiksliai smegenų elektros aktyvumo įrašymui. Tai turi tiesioginę įtaką valdymui, nes kuo mažiau trikdžių, tuo lengviau atpažinti EEG bangų struktūras. Šie trikdžiai paprastai skirstomi į šias kategorijas [26]:


- ECG artefaktai – širdies veiklos sukelti elektriniai signalai, ypač kai elektrodai yra arti kaklo;

- EOG artefaktai – akių judesiai ir mirksėjimas, sukuriantys elektros laukus;
- EMG artefaktai – raumenų elektros aktyvumas, ypač veido ir kaklo raumenų, sukeliantis aukšto dažnio signalus;
- išoriniai ne smegenų veiklos sukelti signalai – elektrodo varža – blogas elektrodo ir odos kontaktas ar prastas elektrodų laidumas gali sukelti nestabilumą ir triukšmą įrašuose; elektroninės įrangos triukšmas – įrašymo įrangos sukelti artefaktai, pavyzdžiui, stiprintuvo triukšmas arba skaitmeninio konvertavimo klaidos.

1.2.1. ECG artefaktai

Širdies dūžiai sukuria elektros impulsus, kurie gali būti pakankamai stiprūs, kad juos užfiksuotų ant galvos odos uždėti EEG elektrodai. Šie trikdžiai ryškiausiai matomi iš EEG matavimų atliktų su elektrodais arti miego arterijų (tarp ausies ir akių) [21].

Dėl širdies veiklos EEG įrašė atsirandančios viršūnės ar bangos, kurios vizualiai primena ECG signalą, gali būti klaidingai interpretuojamos kaip smegenų veiklos signalai. Dėl šios priežasties siekiama juos išfiltruoti (žr. 3 pav.).




3 pav. ECG trikdžiai EEG matavime [21]: a) ECG trikdžių pavyzdys trijuose elektroduose; b) ECG trikdžiai po 10 Hz aukšto dažnio filtro

3 paveikslo *a* dalyje pavaizduotas EEG signalas su ECG trikdžiais, o *b* dalyje – EEG signalas nufiltruotas su 10 Hz aukšto dažnio filtru. Pasikartojančias viršūnes (žr. 3 pav., *a*) sukelia širdies dūžiai.

Mokslininkai atliko dažnai naudojamų ECG trikdžių filtravimo metodų, t. y. ICA (angl. *independent component analysis*) ir EEMD (angl. *ensemble empirical mode decomposition*), bei retos išvestinės taikymo metodo (angl. *sparse derivative method*, SDM) tarpusavio palyginimus (žr. 4 pav.) [22].

4 paveiksle matomas gauto triukšmo SNR (angl. *signal to noise ratio*) palyginimas, priklausomai nuo to kaip arti taškai yra nuo tendencijos linijos RMSE (angl. *root mean square error*). Gauti rezultatai rodo, kad retos išvestinės metodas nufiltruoja didesnę ECG signalo dalį nei EEMD + ICA metodai.

Tyrime apskaičiuota koreliacija tarp tikrųjų ir išfiltruotų EEG signalų: naudojant retosios išvestinės metodą ji siekia $0,97 \pm 0,02$, o naudojant EEMD + ICA metodus – $0,8 \pm 0,12$ [22].



4 pav. ECG trikdžių pašalinimo iš EEG metodų palyginimas [22]

Darytina išvada, kad SDM gauti rezultatai turi mažesnę variaciją ir yra tikslesni už EEMD + ICA metodus.

1.2.2. EOG artefaktai

EOG trikdžiai EEG matavimuose kyla dėl akių judesių ir mirksėjimo. Tai vienas iš biologinių trikdžių šaltinių, kuris gali iškraipyti ar trukdyti atlikti matavimus.

Įprastai akių judesių trikdžiai įvyksta apie 20 kartų per minutę ir trunka nuo 50 iki 500 milisekundžių [23]. Akių judesių trikdžiai matomi EEG 8–12 Hz dažnyje [25]. Vidutinis intervalas tarp EOG trikdžių 0,5–4 s, o jų amplitudė siekia 0–650 μ V [25] (žr. 5 pav.).


Palyginti su įprasta EEG signalų amplitudė (45–100 μ V [25]) EOG signalų amplitudė (0–650 μ V [25]) didesnė, todėl gali užgožti visus kitus EEG signalus. Akių mirksnių intervalus pašalinus iš EEG, prarandama nuo 0,4 iki 10 procentų signalų informacijos. Dėl šios priežasties siekiama šiuos signalus išfiltruoti arba, dėl jų skirtumo nuo visų kitų EEG signalų, panaudoti valdymui.

EOG trikdžių pavyzdys matomas 1,5 s ir 4,3 s (žr. 5 pav.). 5 paveiksle pavaizduotas EEG signalas be trikdžių ir EEG signalas su EOG trikdžiais.

Kai akys lengvai užmerktos ir horizontaliai įvyksta maži akių judesiai be stimuliacijos, EEG parodo teigiamus potencialus nuo 50–100 μ V [23]. Kai akys lengvai užmerktos ir vertikalčiai įvyksta maži akių judesiai be stimuliacijos, EEG parodo teigiamus potencialus nuo 150–290 μ V [23].

Kai akys atmerktos ir įvyksta natūralus mirksnis (t. y. akies vokas nusileidžia 9–15 laipsnių kampu per 50–70 milisekundžių, o akis pasisuka 1–4 laipsniu kampu žemyn ir 1–3 laipsnių kampu link nosies) EEG parodo teigiamus potencialus 250–490 μ V. Kai akys atmerktos ir įvyksta priverstinis mirksnis (t. y. akies vokas nusileidžia 15–40 laipsnių per 50–70 milisekundžių, o akis pasisuka 5–30 laipsnių į viršų) EEG parodo teigiamus potencialus 600–1100 μ V [23].

EOG signalų amplitudė (0–650 μ V [25]) didelė, palyginti su visų kitų EEG signalų amplitudė (45–100 μ V [25]), todėl šio tipo signalus yra lengva atpažinti.



5 pav. EOG trikdžiai [25]

Dėl didelės amplitudės EOG, palyginti su visų kitų EEG, signalų amplitude vienas iš metodų artefaktams EOG aptikti yra amplitudės slenksčio metodas. Šis metodas klasifikuoja EEG epochą į EEG epochą, turinčią EOG artefaktą ar jo dalį, kai signalo amplitudė viršija nustatytą ribą. Metodo trūkumai: neaptinka EOG artefaktų, jei nepasiekta nustatyta amplitudė. Dėl akių mirksnių trukmės (50 iki 500 milisekundžių [23]) ir įvairumo sunku nustatyti EOG artefakto trukmę [29]. Bet kokie trikdžiai kurie viršija nustatyta amplitudės ribą interpretuojami kaip EOG trikdžiai.


Kitas naudojamas metodas EOG artefaktams aptikti vadinamas tiesinės koreliacijos, arba šablono atitikimo (angl. *template matching*), metodu. Naudojant šį metodą skaičiuojamas taškų pozicijų panašumas šablono ilgio intervale. Kai surandamas intervalas, kurio panašumo koeficientas didesnis nei nurodytas, laikoma, kad šis intervalas turi EOG artefaktą [29].

DTW (angl. *dynamic time wrapping*) – tai alternatyva tiesinės koreliacijos metodui (žr. 6 pav.). Šis metodas naudojamas mažinti su laiku susijusius formos skirtumus tarp bet kokio tiriamo įvykio ir šablono. Tai daroma iškraipant įvykio laiko ašį netiesiniu būdu taip, kad būtų pasiekta maksimali įmanoma formos koreliacija su šablonu. Laiko normalizacija apskaičiuojama kaip minimalus likutinis atstumas tarp dviejų formų [30]. Normalizacija atliekama tam, kad bet koks dažnio ar laiko nukrypimas būtų pakeistas EEG bangos formą.

6 paveiksle „T“ – tai šablonas, naudojamas EOG artefaktams atpažinti, o „S“ – EEG signalas. Pagrindinis skirtumas tarp tiesinės koreliacijos metodo ir DTW yra tas, kad DTW normalizuoja bangą, atsižvelgdamas į galimus jos formos skirtumus dėl EEG dažnio ar bangos trukmės nukirpimų [30] (žr. 6 pav.).


RMSE (angl. *root mean square error*) dar vienas metodas, kuris gali būti naudojamas EOG artefaktams aptikti. Jis pagrįstas statistine analize, parodančią kaip arti nuo tendencijos linijos yra taškų pasiskirstymas [31]. Šis metodas taip pat naudojamas analizuoti kitų metodų efektyvumą šalinant EEG artefaktus [20, 27].

MSDW(angl. *multiple sliding window*) – šis metodas veikia taip : kiekvienam laiko taškui atliekamas skaičiavimas intervalams nuo m iki M (čia m – minimalus naudojamo intervalo ilgis, s ; o M – maksimalus naudojamo intervalo ilgis, s). Šiame intervale turi būti išpildytos sąlygos: EEG viršūnių ir įdubų skaičius turi sutapti su nustatytu ir visos signalo reikšmių išvestinės turi tilpti į nustatytą intervalą. Nustatymai šiam metodui gaunami iš norimo nustatyti artefakto pavyzdžių [29].



6 pav. Skirtumas tarp tiesinės koreliacijos ir DTW [30]

7 paveiksle grafiškai iliustruotas kiekvienas aprašytas metodas, naudotas EOG artefaktams nufiltruoti, pradedant nuo 0 EEG epochų iki visų EEG epochų [29].




7 pav. Metodų naudojamų ECG aptikti palyginimas [29]

Iš grafiko (žr. 7 pav.) matyti, kad naudojant MSDW metodą buvo gauta daugiausiai teisingų rezultatų, o tuo tarpu naudojant RMSE ir tiesinės koreliacijos metodus – mažiausiai teisingų rezultatų.

1.2.3. EMG artefaktai

EMG trikdžius sukelia bet kokia raumenų veikla: kalbėjimas, rijimas, matavimo zonos tempimas ar susitraukimas (žr. 8 pav.) EEG elektrodo prijungimo vietoje. Įprastai šie trikdžiai turi platų pasiskirstymą dažnių juostoje, t. y. 0 Hz iki >200 Hz [28].

Priklausomai nuo to, kiek individualūs raumenys susitraukia, pasikeičia EMG ir trikdžio forma, bei amplitudė. Dėl šios priežasties yra sunku atpažinti šio tipo trikdžius, palyginti su periodiškais ECG ar didelės amplitudės (0–650 μV [25]) EOG trikdžiais [28].




8 pav. EMG trindžių pavyzdys [42]

8 paveiksle juodai apibraukta dalis – tai EEG signalai su EMG trikdžiais: čia y ašis – EEG kanalai, x ašis – laikas.

Mokslininkai sugeneravo EMG artefaktus, naudojant atsitiktinį triukšmą, kuris buvo filtruojamas juostiniais filtrais nuo 20 iki 60 Hz ir turėjo atsitiktinę trukmę tarp 0,3–0,8 s (tokia pat kaip ir tikruose EEG) [27].

Tyrėjai bandė pašalinti EMG trikdžius naudodami tris metodus: CCA-EMD (angl. *canonical correlation-analysis empirical mode decomposition*), WT (angl. *wavelet transform*) ir jų siūlomą inovaciją – SuBAR (angl. *surrogates-based artifact removal*) (žr. 9 pav.) [27]




9 pav. EMG trikdžių pašalinimo rezultatai [27]

9 paveiksle pavaizduoti EMG trikdžių pašalinimo rezultatai, naudojant viršuje minėtus metodus. X ašis – SNR (angl. *signal to noise ratio*) – tai santykis tarp EEG signalo be ir su trikdžiais, Y ašis – RRMSE (angl. *relative root mean square error*) – tai nukrypimas nuo tendencijos linijos išreikštas procentais. Iš grafikų (žr. 9 pav.) galima spręsti, kad didžiausią dalį trikdžių pašalino mokslininkų siūlomas SuBAR metodas [27].

1.2.4. Išoriniai ne smegenų veiklos sukelti signalai

Didelė elektrodo varža gali sukelti signalo silpnėjimą. Dėl to gali būti sunku užfiksuoti smulkias smegenų veiklos detales. EEG signalo tikslumas atspindi tikrąją smegenų veiklą ir yra aukštesnis kai elektrodo varža maža. Didelė varža gali iškraipyti EEG signalą, veikiant tiek jo amplitudę, tiek dažnio charakteristikas.

Siekiant išgauti kuo tikslesnį EEG signalą, siekiama sumažinti varžą Z_1 (žr. 10 pav.) [20].



10 pav. Varžos sudedamosios dalys [20]

Tarp sausų ir gelio elektrodų varžos Z_{se} ir Z_{se} skiriasi (žr. 10 pav.). Šis skirtumas atsiranda dėl išskirtinos šių elektrodų konstrukcijos ir dėl gelio buvimo ar nebuvimo (priklausomai nuo elektrodo tipo).

$$Z_1 = Z_s + Z_{se} + Z_e; \quad (1)$$

čia Z_s – odos varža, Ω ; Z_{se} – elektrodo kontakto su oda varža, Ω ; Z_e – elektrodo varža, Ω ; Z_1 – bendra elektrodo varža, Ω .

Daugumai EEG signalų gauti naudojami stiprintuvai turi $Z_{in,Amp}$ lygia 100 M Ω . Mažiausią varžą turintys elektrodai – gelio elektrodai, kurių Z_1 žemesnė nei 100 k Ω [20].

EEG signalą gali paveikti ir išoriniai trikdžiai, tokie kaip:

- pradinis triukšmas (angl. *baseline noise*), atsirandantis dėl EEG įrangos judėjimo kai juda pats žmogus, kuriam atliekamas EEG signalų matavimas;
- šiluminis triukšmas, atsirandantis dėl stiprinimo elektronikos ir odos elektrodo sąsajos trikdžių [28].

Priimtina, kad išorinių trikdžių vertė atliekant EEG matavimus turi būti mažiau nei 2 μV_{rms} 1–100 Hz dažnyje [18]. Pagal IEC80601 standartą medicininei įrangai priimtina išorinių trikdžių vertė dažnyje nuo 0,5 iki 100 Hz yra 0,5 μV_{rms} [18].

1.3. EEG požymių išskyrimas

Sekantis po signalo apdorojimo einantis žingsnis – požymių išskyrimas. Vis dažniau tyrėjams tenka dirbti su dideliais duomenų kiekiais, ypač siekiant apmokyti neuroninius tinklus. Dėl to vienas iš pagrindinių požymių išskyrimo tikslų – duomenų kiekio sumažinimas, neprarandant reikalingos informacijos. Tai leidžia padidinti mašininio mokymosi ir dirbtinio intelekto algoritmų efektyvų naudojimą duomenų klasifikavime ir interpretavime [32].

EEG požymiai gali būti skirstomi į šias grupes [14]:

- laiko domeno – apima signalo analizę laiko atžvilgiu, leidžiant kiekybiškai įvertinti kaip signalas keičiasi laikui bėgant; pavyzdžiui, autoregresinis modeliavimas, *Higuchi* algoritmas ar statistiniai požymiai;
- dažnio srities – šie metodai tiria signalą pagal dažnio turinį; pavyzdžiui, galios spektrinis tankis ar *Furjė* transformacija;
- erdvinis domeno – apima EEG signalų erdvinių modelių analizę atsižvelgiant į elektrodų pozicijas ant subjekto.

Autoriai apibendrina informaciją [61] ir savo tyrimuose pateikė EEG požymiams išskirti ir „žmogaus-mašinos“ sąsajai valdyti nuo 2009 m. iki 2019 m. mokslinėje literatūroje aprašytus metodus (žr. 2 lentelę).

2 lentelė. Požymių išskyrimo metodai, naudoti „žmogaus-mašinos“ sąsajai valdyti ir išanalizuoti mokslinėje literatūroje nuo 2009 m. iki 2019 m. [2]

Trikdžio tipas	Publikacijų skaičius, vnt.	Dalis visumos, %
PSD (galios spektrinis tankis)	23	18
FT (<i>Furjė</i> transformacija)	20	16
CSP (bendrieji erdviniai požymiai)	18	14
WT (bangelių transformacija)	8	6
Fraktalinės dimensijos	7	6
ICA (atskirų komponentų analizė)	7	6
AR (autoregresinis modeliavimas)	4	3
CCA (kanoninės koreliacijos analizė)	3	2
Unikalūs algoritmas	3	2
Statistiniai požymiai	3	2
Kita	10	8
Keli metodai naudojami kartu	13	10

Populiariausi metodai (žr. 2 lentelę): PSD metodas, kuris apibūdina signalo stiprumo pasiskirstymą dažnio srityje ir FT (angl. *fourier transform*) metodas, kuris išskaido EEG signalą į paprastesnius komponentus.

1.4. EEG požymiai pagal laiko sritį


Laiko srities požymių išskyrimas iš EEG duomenų apima specifinių signalo charakteristikų analizę ir kiekybinį įvertinimą tiesiogiai laiko srityje.

1.4.1. Autoregresinis modeliavimas (AR)

Autoregresiniai modeliai yra grindžiami prielaida, kad praeities reikšmės turi įtakos dabarties reikšmėms. Šie modeliai remiasi tik praeities laikotarpio reikšmių analize, siekiant nuspėti dabartinės reikšmės. Tai tiesinis modelis, kuriame dabartinio laikotarpio reikšmės yra praeities rezultatų suma, padauginta iš skaitinio koeficiento. Autoregresinio modelio numeris – tai skaičius praeities reikšmių, kuriomis AR modelis remiasi prognozuojant būsimas reikšmes.

Atliktame tyrime [6] buvo panaudotas autoregresinis modeliavimas požymiams išskirti, siekiant iš EEG surinktų duomenų įvertinti vairuotojų nuovargį. Tyrime dalyvavo 43 subjektai nuo 18 iki 55 metų amžiaus. EEG duomenys buvo surinkti prieš subjektams atliekant vairavimo užduotis ir po jų. EEG duomenys palyginti tarpusavyje, norint nustatyti subjektų nuovargio lygį. Naudojant autoregresinį modeliavimą požymių išskyrimui neuroninis tinklas teisingai atpažino nuovargį 83,6 procentų atvejų [6].

Nuovargio atpažinimo tikslumas kito priklausomai nuo AR numerio (žr. 11 pav.)



11 pav. Tyrime naudoto autoregresinio modelio tikslumas [6]

Iš 11 paveikslo galima matyti, kad AR modelis buvo efektyviausias, kai rėmėsi penkiomis paskutinėmis reikšmėmis [28].

1.4.2. Signalų fraktalų analizavimas

Higuchi metodas, kurį sukūrė Higuchi ir kt. [33], yra matematinės analizės metodas naudojamas signalo fraktalams analizuoti. Šio matmens sąvoka naudojama, siekiant įvertinti sudėtingumą arba nereguliarumą modeliuose ir struktūrose, kurie yra iš savęs panašūs skirtinguose masteliuose. *Higuchi* metodas ypač naudingas signalų apdorojimo, neurologijos ir fizikos srityse, kur jis padeda suprasti sudėtingų sistemų dinamiką [33].

Šis metodas originalią duomenų seriją laiko intervale paverčiant į keletą naujų duomenų serijų. Kiekviena duomenų serija gaunama iš originalios, pasirenkant taškus skirtingais intervalais. Tada šių naujų duomenų serijų skirtumas matuojamas pagal tam tikrą algoritminę taisyklę, apibrėžtą Higuchi, kuri iš esmės įvertina, kaip matuojamos duomenų serijos skirtumas keičiasi priklausomai nuo mastelio. Šis procesas kartojamas naudojant įvairius mastelius (matavimo intervalus). Fraktalinis matmuo apskaičiuojamas remiantis tuo, kaip šių serijų skirtumas keičiasi priklausomai nuo intervalo dydžio [33].

Fraktalų analizavimas gali būti taikomas subjekto skausmui identifikuoti. Mokslininkai parodė, kad naudojant šį metodą galima nustatyti ar subjektas jaučia skausmą 84,2 proc. tikslumu. Šis tyrimas taip pat parodė, kad skausmui identifikuoti didesniu kaip 80 proc. tikslumu užtenka trijų elektrodų [34].

1.4.3. Statistiniai požymiai

Keli galimi statistiniai požymiai EEG signalams analizuoti:

Vidurkis [35]:

- aprašymas – atspindi EEG signalo amplitudės vidutinę vertę per tam tikrą laikotarpį;
- svarba – naudinga nustatant bendrą tam tikros smegenų srities aktyvumo lygį.

Standartinis nuokrypis [35]:

- aprašymas – variacijos kvadrato šaknis, atspindinti EEG signalo verčių išsibarstymą;
- svarba – padeda suprasti smegenų veiklos kintamumą.

Norma [36]:

- aprašymas – visų signalo amplitudės verčių kvadratų sumos šaknis;
- svarba – naudojama ligoms diagnozuoti, taikant mašininio mokymosi algoritmus.

Hjorth parametrai [37]:

- aprašymas – apima signalo aktyvumą, apibrėžtą kaip signalo variaciją laike, ir judrumą, apibrėžta kaip signalo dažnio pokytį laike, bei sudėtingumą, apibrėžta kaip signalo panašumą sinusoidei;
- svarba – suteikia įžvalgų apie signalo bangų formos sudėtingumą ir dažnių charakteristikas, naudingas charakterizuojant įvairias smegenų būsenas.

1.5. EEG požymiai pagal dažnio sritį

Dažnio srities EEG analizėje signalai transformuojami iš laiko srities į dažnio sritį, naudojant matematinius metodus, tokius kaip *Furjė* transformaciją. Tai leidžia mokslininkams tirti galios pasiskirstymą įvairiose dažnių juostos (pvz., delta, teta, alfa, beta, gama) EEG duomenyse, taip pat naudinga identifikuojant kintančią veiklą, suprantant smegenų būsenas ir diagnozuojant neurologines būkles, atskleidžiant dominuojančius dažnius ir jų galią smegenų veikloje.

1.5.1. *Furjė* transformacija

Furjė transformacija – tai matematinis metodas, naudojamas išskaidyti EEG signalą į paprastesnius komponentus, tokius kaip dažnių juostos.

Furjė transformacija naudojama EEG skirstoma į greitąją *Furjė* transformaciją, (angl. *fast fourier transform*, FFT) ir diskretinę *Furjė* transformaciją (angl. *discrete fourier transform*, DFT).

FFT – greitas algoritmas DFT apskaičiuoti. Šie algoritmai yra naudojami sąsajai tarp signalo laiko domeno ir dažnio domeno rasti. Dažniausiai šis metodas naudojamas įvairioms ligoms diagnozuoti:

- demencija diagnozuota 86,3 proc. tikslumu [38];
- epilepsijos priepuoliai diagnozuoti 98,47 proc. tikslumu (požymiai išskirti naudojant FFT ir mašininio mokymo algoritmus [39]).

1.5.2. Galios spektrinis tankis

Galios spektrinis tankis (angl. *power spectral density*, PSD) – apibūdina kaip signalo aktyvumas pasiskirsto dažnio srityje [41].

Mokslininkai atlikto EEG signalų PSD skaičiavimus, siekiant subjektams nustatyti pokyčius teta, alfa, beta ir gama dažnių juostose, atliekant kognityvines užduotis, tokias kaip: trumpalaikės atminties ar simbolių sekos atpažinimo testai. Buvo rasta, kad alfa, beta ir gama dažnių juostos reikšmingai koreliavo su gerais testų rezultatais. Pradiniai EEG rodikliai ir teta dažnių juostos rodikliai atliekant bet kokius kognityvinius testus nebuvo susiję su gerais testų rezultatais. [41]

Subjektai įsivaizdavo judėjimą pirmyn, atgal, į kairę, į dešinę, taip pat vandenį, miega, maistą, alkį. Mokslininkai siekė atpažinti šiuos veiksmus iš EEG duomenų. Tyrėjai išskyrė EEG į smulkesnius dažnio komponentus naudodami greitą *Furjė* transformaciją, jie apskaičiavo PSD kiekvienam iš šių komponentų. Panaudodami mašininį mokymą teisingi rezultatai buvo gauti vidutiniškai 72,5 proc. atvejų [3].

1.6. Požymių išskyrimas naudojant dekompoziciją


Požymių išskyrimas naudojant dekompoziciją naudingas, nes leidžia vienu metu atlikti ir signalų filtravimą ir požymių išskyrimą. Požymių išskyrimas naudojant dekompoziciją veikia taip:

- signalas dekomponuojamas pasirinktu metodu;
- pasirenkamas norimas komponentas ar komponentai;
- atmetami nepageidaujami komponentai.

1.6.1. Bangelių transformacija

Bangelių transformacija įprastai skirstoma į dvi kategorijas: diskretinė bangelių transformacija (angl. *discrete wavelet transform*) ir nuolatinė bangelių transformacija (angl. *continuous wavelet transform*). Skirtumas tarp šių transformacijų tas, kad diskretinė bangelių transformacija taikoma tik nustatytais intervalais ir nustatytą iteracijų kiekį, tuo tarpu nuolatinė bangelių transformacija taikoma visiems įmanomiems taškams. Dėl šios priežasties diskretinė bangelių transformacija naudojant kompiuterinę įrangą apskaičiuojama greičiau.

Bangelių transformacija (angl. *wavelet transform*) – matematinis įrankis, naudojamas signalų signalams skirtinguose masteliuose ar rezoliucijose analizuoti ir apdoroti. Skirtingai nuo tradicinės *Furjė* transformacijos, kuri skaido signalą į jo sudedamąsias sinusoides, bangelių transformacija dekomponuoja signalus į bangeles – mažas bangas, kurios auga ir nyksta per ribotą laiko tarpą (žr. 12 pav.).



12 pav. Bangelių transformacija atvaizduota grafiškai [42]

Bangelių transformacija suskirsto signalą x_n į signalų seriją $x_n[X_L^N, X_H^N, X_H^{N-1}, \dots, X_H^1]$, naudojant aukštą filtrą (angl. *high pass*), kuris 12 paveiksle pažymėtas kaip „HP“, ir žemą filtrą (angl. *low pass*),

kuris 12 paveiksle pažymėtas kaip „LP“. Žemo filtro reikšmės kinta priklausomai nuo skaliavimo arba vidurkio funkcijos. Tuo tarpu aukšto filtro reikšmės kinta priklausomai nuo naudojamos bangelės funkcijos [42].

Mokslininkai naudojo bangelių transformaciją akių mirksniams aptikti. Tai buvo daroma pritaikant DWT metodą EEG signalams ir naudojant neuroninį tinklą rezultatams analizuoti. Šiuo būdu akių mirksniai buvo atpažinti 99,414 procentų tikslumu per 0,0209 sekundes [43].


1.6.2. Empirinis režimų skaidymas

Empirinis režimų skaidymas (angl. *empirical mode decomposition*, EMD) – tai metodas, naudojamas sudėtingam signalui skaidyti į jį sudarančias dalis, vadinamas būdingomis režimo funkcijomis (angl. *intrinsic mode functions*, IMF).

IMF turi tenkinti tokias sąlygas: funkcijos viršūnių / įdubų skaičius ir nulio ašies kirtimų skaičius turi būti lygus arba skirtis daugiausiai vienetu. Bet kuriame taške intervalo apibrėžto tarp funkcijos viršūnių / įdubų reikšmių vidurkis turi būti lygus nuliui [44].

- vietinių ekstremumų nustatymo procesas – pirmiausia naudojant EMD nustatomos visos signalo viršūnės ir įdubos (žr. 13 pav.);
- sijojimo procesas – iteracinio proceso metu išfiltruojamas aukščiausio dažnio komponentas; apima vietinių ekstremumų identifikavimą ir jų sujungimą, sukuriant „apvaskalą“ (žr. 13 pav.), kurio vidurkis atimamas iš pradinio signalo, paliekant žemesnio dažnio komponentą;
- kartojimo procesas – šie veiksmai kartojami tol, kol likusiame signale nebelieka ekstremumų ir išpildytos IMF sąlygos.

Po duotos garsinės komandos subjektas įsivaizduoja judėjimą, o tyrėjai tuo tarpu duoda komandą išoriniam skeletui judėti. Gauti EEG duomenys buvo analizuojami EMD ir „Butterworth“ filtru. Tuomet buvo panaudotas algoritmas, gebantis nustatyti kada subjektas pradeda įsivaizduoti judėjimą.



13 pav. Empirinio režimų skaidymas atvaizduota grafiškai [44]


Pirmo subjekto EMD išanalizuotuose duomenyse judėjimo pradžia buvo aptikta per $0,111 \pm 0,224$ s tuo tarpu naudojant „Butterworth“ filtrą per $0,165 \pm 0,292$ s [45].

1.6.3. Nepriklausomų komponentų analizė

Nepriklausomų komponentų analizė (angl. *independent component analysis*, ICA) – tai metodas individualiems signalams iš daugialypių signalų išgauti. Šis metodas yra veiksmingas kai signalai būna sugeneruoti skirtingų šaltinių (žr. 14 pav.). Metodas gali būti taikomas, išpildžius tam tikras sąlygas [47].

- signalų šaltiniai turi būti statistiškai vienas nuo kito nepriklausomi; tai reiškia, kad būtina turėti du vienas nuo kito nepriklausomus signalus s_1 ir s_2 , kitaip tariant, informacija apie signalą s_1 nesuteikia informacijos apie signalą s_2 , ir atvirkščiai [47];
- individualūs signalai turi ne gausinį pasiskirstymą; gausinių reikšmių iš esmės yra neįmanoma atskirti naudojant ICA metodą [47];
- egzistuoja galimybė invertuoti daugialypio įėjimo signalo matricą; tai iš esmės reiškia, kad yra matematinis sprendimas, kuris leidžia atskirti komponentus s iš sumaišytų signalų x [47].

14 paveiksle parodyti du signalai s_1 ir s_2 apjungti signalai x_1 bei x_2 , ir išskaičiuoti signalai s_1 bei s_2 , naudojant ICA metodą.



14 pav. ICA metodo veikimo pavyzdys [47]

ICA metodas buvo naudojamas prieš tai minėtame tyrime. ICA algoritmas naudojamas trikdžiams, tokiems kaip akių judesiai, širdies ritmas ir t. t., pašalinti [22].

Ši metodą naudojant požymiams išskirti ir gautus duomenis apdoroti naudojant neuroninius tinklus, galima iš karto pašalinti visus trikdžius. Toks procesas analizuotas tyrime [46] (žr. 3 lentelę). Šiame tyrime buvo pritaikytas ICA algoritmas ir išskirti požymiai buvo klasifikuoti naudojant neuroninius tinklus: SVM (angl. *support network Mžmachine*) ir ANN (angl. *artificial neural network*) [46]. Šių tinklų rezultatus patikrino patys tyrėjai ir įvertino jų tikslumą. Rezultatai parodyti 3 lentelėje.

3 lentelė. ICA metodo taikyto trikdžiams šalinti rezultatai [46]

Trikdžio tipas	SVM tikslumas, %	ANN tikslumas, %
Akies mirksnis	100	100
Horizontalus akies judesys	94,81	93,51
Širdies dūžiai	96,7	93,51
Kiti	96,53	90,68
Nervų signalai	96,31	98,1

Iš gautų rezultatų lentelėje 3 matoma, kad SVM pašalina trikdžius efektyviau nei ANN.

1.6.4. Erdvinės srities požymių išskyrimas

EEG erdvinės srities požymių išskyrimas identifikuoja informaciją iš EEG signalų, remiantis jų pasiskirstymu tarp matavimo taškų (elektrodų pozicijų ant galvos odos). Erdvinės srities požymių tikslas yra surasti kaip skirtingos smegenų sritys sąveikauja tarpusavyje.

CSP (angl. *common spatio-spectral pattern*) algoritmas – naudojamas subjekto vaizdų vizualizacijai atpažinti [4].

Pagrindinis CSP tikslas – pagerinti signalo ir triukšmo santykį dviem skirtingiems matavimo taškams. Vienas matavimo taško rezultatas lyginamas su kito matavimo taško rezultatu, randant panašumą ir skirtumą.

CSP algoritmas turi įvairių variacijų, tokių kaip [4]:

- SCSP (angl. *sparse common spatial pattern*);
- TRSCP (angl. *target-related spatial component pattern*);
- R-CSP (angl. *regularized spatial component pattern*);
- CSSP (angl. *common spatial component pattern*);
- FBCSP (angl. *filter bank spatial somponent pattern*).

Mokslininkai atliko tyrimą, kuriame 7 subjektai įsivaizdavo kairės / dešinės kojos ir rankos judėjimą priklausomai nuo duotos komandos ekrane. Naudotas požymių išskyrimo algoritmas CSP ir jo variacijos, o gauti rezultatai klasifikuoti naudojant SVM (angl. *support vector machine*) algoritmą. Rezultatai parodė, kad CSP, SVM atpažino veiksmą sėkmingai 76,96 proc. atvejų, tuo tarpu SCSP – 78,43 proc., TRSCP – 77,09 proc., R-CSP – 75,29 proc., CSSP – 82,00 proc., FBCSP – 85,64 proc. [4].

1.7. EEG požymių klasifikavimas

Naudojant mašininio mokymosi algoritmus, EEG signalai pagal jų charakteristikas gali būti apdorojami ir klasifikuojami į įvairias klases. Dažniausiai naudojami algoritmai „žmogaus-mašinos“ sąsajoje pateikti 4 lentelėje.

4 lentelė. EEG signalų klasifikacijos metodai naudoti „žmogaus-mašinos“ sąsajai valdyti ir išanalizuoti mokslinėje literatūroje nuo 2009 m. iki 2019 m. [2]

Trikdžio tipas	Publikacijų skaičius, vnt.	Dalis visumos, %
LDA (tiesinė diskriminantinė analizė)	23	31
SVM (pagalbinių vektorių mašina)	20	21
CNN (konvoliucinis neuroninis tinklas)	18	4
<i>Naivus Bayeso</i> algoritmas	8	4
Atsitiktinio miško	7	3
ANN (dirbtinis neuroninis tinklas)	7	3
DBN (gilių įsitikinimų tinklas)	4	2
Gausinio maišyto modelio	3	2
Artimiausio klasterio metodas	3	2
Kita	3	11
Keli metodai naudojami kartu	13	17

Iš 4 lentelėje pateiktų duomenų galima matyti, kad populiariausi metodai: LDA, SVM ir CNN.

1.7.1. Tiesinė diskriminantinė analizė

Tiesinės diskriminantinės analizės (angl. *linear discriminant analysis*, LDA) algoritmo tikslas – sugrupuoti duomenis erdvėje turinčioje mažiau dimensijų. Trys pagrindiniai žingsniai [48]:

- pirmame žingsnyje apskaičiuojamas skirtingų duomenų klasių atskiriamumas (t. y. duomenų taškai suskirstomi į klases pagal atstumą vienas nuo kito ir skaičiuojami šių atstumų vidurkiai);
- antrame žingsnyje skaičiuojamas atstumas tarp kiekvienos individualios klasės atstumų, tarp taškų vidurkio ir kiekvieno taško;
- trečiame žingsnyje duomenys grupuojami taip, kad atstumas tarp skirtingų klasių taškų būtų maksimaliai didelis, o atstumas tarp tos pačios klasės taškų būtų minimalus.

Atliktas tyrimas EEG signalams, atsirandantiems kai judinama kaire / dešinė ranka, atpažinti (žr. 5 lentelę) [50].

5 lentelė. LDA algoritmo efektyvumo palyginimas su kitais metodais[50]

Metodas	ApEn-SVM	CSP-SVM	FFT-SVM	CSP-LDA
Atpažinimo efektyvumas, %	43,06	47,85	75	80

5 lentelėje pirmoje eilutėje pavadinimu „Metodas“ per brūkšnelį išskirti trumpiniai. Pirmas trumpinys – tai metodas, kuris buvo naudojamas požymiams išskirti, o antrasis trumpinys – tai metodas, kuris buvo naudojamas duomenims klasifikuoti. Iš gautų duomenų matyti, kad CSP metodą taikant požymiams išskirti, o LDA metodą jiems klasifikuoti, EEG signalai susiję su individualia ranka buvo atpažinti efektyviausiai [50].

1.7.2. Konvoliucinis neuroninis tinklas

Konvoliucinis neuroninis tinklas (angl. *convolutional neural network*, CNN) – tai neuroninio mokymo būdas naudojamas EEG informacijai klasifikuoti [49].

CNN būdinga architektūra [49]:

1. Konvoliuciniai sluoksniai. Konvoliucinis sluoksnis yra CNN veikimo pagrindas. Konvoliucinis sluoksnis susideda iš kelių ypatybių žemėlapių. Kiekvienas to paties ypatybių žemėlapio neuronas naudojamas informacijai iš prieš tai esančio ypatybių žemėlapio išgauti.
2. „ReLU“ sluoksnis (angl. *rectified linear unit*). Po kiekvienos konvoliucijos operacijos pritaikoma tiesinė reliatyvumo funkcija f įėjimui x , t. y. tokia kaip $f(x) = \tanh(x)$ ar $f(x) = 1 - e^{-x}$.
3. Suliejimo sluoksniai. Sujungimo sluoksnis naudojamas, siekiant sumažinti ypatybių žemėlapių dydį ir pagreitinti informacijos apdorojimą.
4. Visiškai sujungtas sluoksnis. Neuronai visiškai sujungtame sluoksnyje turi ryšį su visais neuronais ankstesniame sluoksnyje. Jų išvestis apskaičiuojama atliekant matricos daugybą, prie kurios pridedamas svoris.

Vienas iš CNN panaudojimo būdų – atpažinti ar subjekto EEG duomenys anomalūs indikuojant, kad subjekto sveikatos būklė nėra gera. Mokslininkai pasiekė 79 proc. tikslumą po 18 mokymo iteracijų [55].

Dar vienas iš CNN panaudojimo būdų – nuovargio atpažinimas. 10 subjektų 22–26 metų amžiaus 90 minučių vairavo stimulatoriuje. 90 proc. surinktų duomenų buvo naudojama CNN apmokyti, likusi dalis – jiems testuoti. Antrame eksperimente buvo testuojama su duomenimis iš kitos duomenų rinkimo sesijos (žr. 6 lentelę) [51].

PSD + SVM – naudotas PSD metodas požymiams išskirti ir SVM tinklas gautiems rezultatams interpretuoti. CSP + SVM – naudotas CSP metodas požymiams išskirti ir SVM tinklas gautiems rezultatams interpretuoti. CNN-1 – tai keturių sluoksnių tinklas, skirtas erdviniais požymiais analizuoti. CNN-2 – tai tinklas, skirtas EEG veiklą vairuojant atpažinti. LSTM – tai pasikartojančio neuroninio tinklo (RNN) variacija. CFCNN – mokslininkų siūloma CNN variacija [51].

6 lentelė. Nuovargio atpažinimas vairuojant [51]

Metodas	1 eksperimentas, Tikslumas, %	2 eksperimentas, tikslumas, %
PSD+SVM	71,35 ± 7,45	68,62 ± 8,83
CSP+SVM	74,56 ± 6,88	72,28 ± 7,14
CNN-1	90,84 ± 3,02	88,16 ± 6,79
CNN-2	95,11 ± 2,24	92,79 ± 3,27
LSTM	92,17 ± 4,62	89,15 ± 6,79
CFCNN	98,25 ± 0,58	96,89 ± 1,21

Iš 6 lentelėje pateiktų duomenų galima spręsti, kad CNN tipo tinklai pranašesni už SVM tipo tinklą atpažįstant nuovargį, nes tiksliausius rezultatus pateikęs tinklas – tai mokslininkų siūlomas CFCNN, o antras pagal tikslumą – CNN-2 [51].

1.7.3. Gilių įsitikinimų tinklas

Gilių įsitikinimų tinklas arba DBN (angl. *deep belief network*) – tai eilė tarpusavyje surištų apribotų Bolcmano mašinų arba RBM (angl. *restricted boltzmann machine*) [52].

Skirtumas tarp įprastų Bolcmano mašinų ir RBM yra tas, kad RBM neleidžia ryšiams būti tarp to paties sluoksnio neuronų. Kitaip tariant, neuronai gali būti jungiami tik tarp skirtingų sluoksnių. Šis apribojimas leidžia RBM mokytis greičiau nei įprastai Bolcmano mašinai [53].

Bolcmano mašina – tai asimetriškai susietų neuronų tinklas, kurį sudaro matomas ir keli paslėpti sluoksniai. *Bolcmano* mašinoje matomi ir paslėpti sluoksniai, kurie tarpusavyje sujungti. Svoriai, kurie nusako ryšio stiprumą tarp dviejų modelio neuronų, modelyje nusako koreliacijai tarp jų [53].


Mokslininkai panaudojo DBN, siekiant atpažinti kada subjektas įsivaizduoja kairės / dešinės rankos judesius. Didžiausias tikslumas buvo pasiektas kai DBN turėjo 6 sluoksnius, jis buvo lygus 95,01 proc. Tyrėjai pastebėjo, kad padidinus sluoksnių skaičių, pvz., 6 ir daugiau, tikslumas pradėjo mažėti [5].

Tyrėjai taip pat, pirmiausia, bandė iš EEG išskirti požymius, naudojant tokius metodus kaip DWT, CSP, PSD ir t. t, o vėliau jau taikyti DBN. Tačiau visais atvejais rezultatų tikslumas buvo mažesnis nei 90 proc. [5].

Dar vienas iš DBN panaudojimo būdų – emocijų atpažinimas. Mokslininkai panaudojo DBN emocijoms atpažinti, pasiektas 86,08 procentų atpažinimo tikslumas [57].

1.7.4. Pasikartojantis neuroninis tinklas

Pasikartojantis neuroninis tinklas arba RNN (angl. *recurrent neural network*) – tai bet koks tinklas, turintis ciklą savo ryšių struktūroje, kas reiškia, kad kai kurių elementų vertė tiesiogiai ar netiesiogiai priklauso nuo paties elemento ankstesnių išvesčių kaip įvesties [54]. Problema su tradiciniais RNN yra ta, kad RNN struktūra gali daryti įtaką tik paskutinėms 10 iteracijų [56]. Šiai problemai išspręsti buvo sukurta šio tinklo variacija su papildoma dalimi LSTM (angl. *long short term memory*), kuri įsimena buvusias reikšmes. Šio tinklo struktūra gali įtakoti paskutines 1 000 iteracijų [56]. Tinklo atminties celė pavaizduota paveiksle žemiau (žr. 15 pav.).



15 pav. LSTM tinklo atminties celės schema [56]

15 paveiksle $h(x)$ – sigmoidinė funkcija; y_{in} ir y_{out} – reguliuoja įrašymą ir informacijos perdavimą į / iš atminties celės. CEC – tai celės dalis, kurioje įrašyta atmintis, ir kurios vidinė reikšmė apskaičiuojama sudauginus $g(x)$ ir y_{in} .

Mokslininkai panaudojo LSTM tinklą emocijoms klasifikuoti, pasiektas 91,08 proc. tikslumas. Tuo tarpu tokie tinklai kaip DBN pasiekė 86,08 proc. ir SVM – 83,99 proc. tikslumus [57].

1.7.5. Pagalbinių vektorių mašina

Pagalbinių vektorių mašina (angl. *support vector machine*, SVM) – tai algoritmas, kuris veikia ieškodamas plokštumos, atskiriančios skirtingų klasių duomenų taškus. Pagalbiniai vektoriai yra duomenų taškai, esantys arčiausiai plokštumos. Ribos paklaida apskaičiuojama šių taškų atžvilgiu [58].


Ribos paklaida yra tarpas tarp plokštumos ir artimiausių kiekvienos klasės duomenų taškų. SVM siekia maksimaliai padidinti šį tarpą, kad padidintų modelio klasifikavimo galimybes. Didesnis tarpas siejamas su mažesniu klasifikavimo klaidų kiekiu [58].

Vienas iš SVM panaudojimo būdų yra žmogaus iš EEG duomenų atpažinimas. Mokslininkai panaudojo LSTM neuroninį tinklą požymiams iš EEG ir „FaceNet“ duomenų bazės apjungtų duomenų išskirti. Šie duomenys buvo klasifikuoti naudojant SVM. Neuroninis tinklas sėkmingai atpažino subjektą 97,87 proc. kartų. Šie rezultatai buvo palyginti su kitais tyrimais atliktais tuo pačiu tikslu. CNN tinklas sėkmingai atpažino subjektą 97,6 procentu kartų, o ANN (angl. *artificial neural network*) – 95,1 procentų kartų [59].

1.7.6. Tinklas su pasipriešinimu

Tinklas su pasipriešinimu (angl. *generative adversarial networks*, GAN) arba neuroninis tinklas su pasipriešinimu susideda iš dviejų atskirų neuroninių tinklų. Tinklo, kuris generuoja rezultatus ir tinklo, kuris juos diskriminuoja. Pirmasis tinklas yra apmokomas kurti naujus netikrus rezultatus iš apmokymo duomenų, o antrasis tinklas tikrina ar gauti rezultatai yra tikri ar ne. Tikslas – apmokyti generuojantį tinklą taip, kad jo kuriami netikri rezultatai būtų neatskiriami nuo tikrų rezultatų [60].

Vienas iš GAN tinklo panaudojimo būdų – prognozuoti būsimus EEG duomenis, juos palyginti su esamais ir nustatyti, ar subjekto būklė yra normali. Mokslininkai siekė nustatyti ar vairuotojas yra mieguistas, pavargęs ir ar jo sveikata yra gera (žr. 16 pav.).



16 pav. Vienas iš GAN tinklo panaudojimo būdų [7]

GAN tinklo sugeneruoti duomenys buvo lyginami su prognozuotais duomenimis. Jeigu duomenų nesutapimas nepakankamas, laikoma, kad vairuotojo būklė yra anomalija ir duodamas perspėjimo signalas [7].

Mokslininkai šiam tikslui naudojo modifikuotą WGAN (modifikuotas GAN tinklas, kurio generatorius yra TCN) ir „forGAN“ (modifikuotas GAN tinklas, kurio generatorius yra RNN) tinklą. Rezultatams įvertinti naudotas MASE (angl. *mean absolute scaled error*) metodas. Gauti rezultatai (žemesnis rezultatas reiškia mažiau klaidingų prognozių): „forGAN“ – 1,001422, WGAN – 0,776666.

2. Akių mirksnių, judesių ir būsenų aptikimas

Šios, eksperimentinės, dalies tikslas yra surasti efektyvius metodus, leidžiančius panaudoti elektrinę veiklą nuskaitytą, naudojant EEG įrangą, valdymui. Šiuo tikslu EEG duomenys gali būti panaudoti įvairiai, tokiais tikslais kaip judesiams, emocijoms ar nuovargiui atpažinti. Specifiniu atveju buvo parinkta akių sukelta veikla kaip tyrimo objektas.

Akių judesiai ir mirksėjimai generuoja elektrinius signalus, kuriuos galima interpretuoti kaip valdymo komandas įvairiose sistemose, pavyzdžiui, neįgaliųjų pagalbinėse technologijose ar žmogaus ir kompiuterio sąsajose. Tam pasitelkiami signalų apdorojimo metodai, tokie kaip *Hjorth* parametrų skaičiavimas ar nepriklausomų komponentų analizės (ICA) metodai.

2.1. Duomenų surinkimas ir apdorojimas

Priverstinių akių mirksnių aptikimas yra užduotis kuriant žmogaus ir kompiuterio sąsajas. Skirtingai nei spontaniniai mirksniai, priverstiniai mirksniai atliekami sąmoningai, todėl jie gali būti naudojami kaip valdymo signalai įvairiose interaktyviose sistemose. Tokia technologija gali būti pritaikoma alternatyvioms komunikacijoms ar vartotojo sąsajoms valdyti.

EEG signalams nuskaityti naudota „Neurotechnology“ gamybos EEG matavimų įranga „BrainAccess MINI“ kartu su „BrainAccess CAP 3.0“. Šio prietaiso techniniai duomenys pateikti 7 lentelėje.

EEG kepurė „BrainAccess CAP 3.0“ turi 34 pozicijas, kuriose gali būti prijungti elektrodai. Šios pozicijos išdėstytos 10-20 sistema (t. y. atstumas tarp elektrodų, kuris išreikštas procentais nuo žmogaus kaukolės perimetro).


7 lentelė. EEG matavimo prietaiso „BrainAccess MINI“ techniniai duomenys [61]

Parametras	Reikšmė
Komunikacijos tipas	„Bluetooth“ 4.2 (BLE)
Kanalų skaičius	8 + atskaitos kanalas
Matavimo dažnis	250 Hz
Įėjimo rezoliucija	24 bit
Įtampa	4 500 mV
Jungties tipas	„Ultra-Mini RF“
Akselerometro ašys	3
Akselerometro matavimo dažnis	50 Hz
Akselerometro matavimo rezoliucija	10 bit

Pirmas bandymas buvo vykdomas su 1 subjektu (27 m. amžiaus vyras) 60 s. Subjektas atliko 31 priverstinį akių mirksnį 10 mirksnių intervalais. Naudotos elektrodų pozicijos „F3“, „F4“, „C3“, „C4“, „P3“, „P4“, „O1“, „O2“. Atskaitos elektrodai „Fp1“ ir „Fp2“ (žr. 17 pav.).


„Fp1“ ir „Fp2“ yra pozicijos, kurios naudojamos kaip atskaitos taškai, nes šiose vietose yra geriausiais subjekto ir elektrodo kontaktas. Visi nuskaityti EEG signalai yra išreikšti kaip šių pozicijų ir specifinio elektrodo skirtumas.

„F3“, ir „F4“ – tai artimiausios galimos elektrodų pozicijos prie akių. „O1“ ir „O2“ – tai yra pozicijos, kuriose elektrinė veikla, sukurta akių, matoma ryškiausiai [63]. „C3“, „C4“, „P3“, „P4“ – pozicijos, apimančios likusias smegenų sritis .




17 pav. EEG elektrodų pozicijos pagal 10-20 sistemą [62]

Matavimų rezultatai pateikti 18 paveiksle.



18 pav. Nuskaityti EEG duomenys, pirmas bandymas


Atlikta šių gautų duomenų (žr. 18 pav.) FFT analizė ir patikrinta, kaip EEG duomenys pasiskirsto dažnių spektre (žr. 19 pav.). Iš 19 paveikslo matyti, kad ties 50 Hz ir 100 Hz riba fiksuojamas reiškinys gali būti sukeltas įrangos 50 Hz dažnio ir jo 100 Hz harmonikos.



19 pav. EEG duomenų dažnių pasiskirstymas, atvaizduotas naudojant *Furjė* transformaciją


Siekiant išfiltruoti signalus, ateinančius ne iš smegenų elektrinės veiklos, buvo panaudotas juostinis 1,5–45 Hz filtras (angl. *bandpass*). Panaudojus juostinį filtrą ties 50 Hz matomos didesnė nei 0,01 amplitudės viršūnė, dėl šios priežasties ties 49,8–50,2 Hz įpjovos filtras, kuris papildomai filtruoja juostinio „bandpass“ filtro nenufiltruotą dažnį (žr. 20 pav.).

Iš 20 paveikslo galima patyti, kad ties 50 Hz nebėra aktyvumo signale.



20 pav. EEG duomenų dažnių pasiskirstymas išfiltravus dažnius, atvaizduotas naudojant *Furjė* transformaciją

Mokslinė literatūra teigia, kad EEG signalai, registruojami tiriant smegenų elektrinę veiklą, pasiskirsto nuo 1,5 Hz iki 45 Hz dažnių diapazone [19]. Dėl šios priežasties siekiama nufiltruoti visus kitus dažnius. Išfiltruoti EEG signalai pavaizduoti 21 paveiksle.



21 pav. Pirmo bandymo nuskaityti EEG duomenys po filtravimo

Iš paveikslėlio 21 galima matyti vizualiai panašios struktūros tris „dešimties viršūnių, pasikartojančias serijas. Šis rezultatas yra panašus į subjekto atliktus akių mirksnius bandyme.

2.2. Priverstinių akių mirksnių aptikimas

Mokslinė literatūra teigia, kad priverstinių akių mirksnių amplitudė ($0\text{--}650\ \mu\text{V}$ [25]) yra didesnė palyginti su kitų EEG signalų amplitudėmis ($45\text{--}100\ \mu\text{V}$ [25]). Taigi teoriškai aptikti akių mirksnius užtektų aptikti viršūnes, kurios viršija nustatytą ribą.


Dėl šios priežasties, siekiant išskirti valdymo signalus iš EEG duomenų, buvo identifikuojamos viršūnės, kurių amplitudės aptikimo riba buvo nustatyta kaip dvi standartinės deviacijos nuo bendro duomenų vidurkio (žr. 22 pav.).

Akių mirksniai pasižymi tiek pozityvia, tiek negatyvia viršūne ir trunka nuo 50 iki 500 milisekundžių [23]. Taigi analizuojamuose duomenyse turėtų būti 31 pozityvi ir 31 negatyvi viršūnė, taip pat ne daugiau kaip viena viršūnė per 50 ms. Gauti rezultatai pateikti 8 lentelėje.

8 lentelė. Gauti akių mirksnius indikuojančių viršūnių kiekiai atliekant pirmą bandymą

Kanalas	„F3“	„F4“	„C3“	„C4“	„P3“	„P4“	„O1“	„O2“
Pozityvios viršūnės	35	30	31	37	35	29	35	21
Negatyvios viršūnės	28	35	37	33	38	33	37	38

Iš 8 lentelės galima matyti, kad nė viename kanale neišpildyta sąlyga: 31 pozityvios ir 31 negatyvios viršūnės. Taip pat viršūnių skaičius, pozicija ir amplitudė tarp kanalų skiriasi. Siekiant sukurti valdymo aplikaciją naudojant šiuos signalus, būtina aptikti akių mirksnius kuo tiksliau. Taigi, siekiama palyginti gautus rezultatus su alternatyva amplitudės aptikimo ribos metodui.



22 pav. Akių mirksnių viršūnių aptikimas, pirmas bandymas

Didžiausias akių mirksnių sukeltas elektrinis aktyvumas matomas 1,5–12 Hz dažnių juostoje. Dėl to akių mirksnius galima aptikti, skaičiuojant šios dažnių juostos signalo PSD laikui bėgant. PSD – tai metodas, kuris parodo dažnių juostos energiją signale. Taigi, naudojant *Welch* metodą, buvo apskaičiuotos PSD vertės laike 1,5–12 Hz dažnių juostai (žr. 23 pav.).


Akių mirksnių aptikimo riba, nustatyta kaip viena standartinė deviacija nuo bendro duomenų vidurkio, yra pažymėta žalia brūkšnine linija. Aptiktos viršūnės pažymėtos raudonu „x“. Gauti viršūnių skaičiai (žr. 23 pav.): „F3“ – 24; „F4“ – 31; „C3“ – 30; „C4“ – 33; „P3“ – 26; „P4“ – 31; „O1“ – 29; „O2“ – 31.

Rastų viršūnių pozicija, amplitudė ir skaičius tarp skirtingų kanalų skiriasi (žr. 23 pav.). Norint panaudoti šią informaciją valdymui, buvo siekiama gauti vieningą akių mirksnių skaičių. Akių mirksnių viršūnės įprastai matomos per visus kanalus, todėl buvo skaičiuota bendra 1,5–12 Hz dažnių juostos PSD visiems kanalams (žr. 24 pav.).


Buvo aptiktos 33 viršūnės, kai subjektas atliko 31 akių mirksnį (žr. 24 pav.). Iš šio rezultato galima spręsti, kad skaičiuojant bendrą 1,5–12 Hz dažnių juostos PSD, randamas tikslesnis akių mirksnių skaičius, palyginti su amplitudės aptikimo ribos metodu (žr. 22 pav.), kuris randa nuo 21 iki 38 akių mirksnius indikuojančias viršūnes tarp EEG kanalų.

Analizuojant bendrą 1,5–12 Hz dažnių juostos PSD, rasti 2 klaidingi teigiami signalai. Todėl, siekiant rasti efektyvesnį būdą priverstiniam akių mirksniams aptikti, tiems patiems EEG duomenims nagrinėti panaudotas ICA (angl. *independent component analysis*) metodas. Tai metodas, kuris

išskiria informaciją pagal jos šaltinius. Šiuo atveju akys veikia kaip atskiras šaltinis, kurio signalus siekiama identifikuoti.



23 pav. Pirmo bandymo EEG duomenų 1,5–12 Hz dažnių juostos PSD visuose kanaluose




24 pav. Pirmojo bandymo visų EEG kanalų 1,5–12 Hz dažnių juostos PSD suma

Kiekvienam išskirtam ICA komponentui buvo skaičiuojama 1,5–12 Hz dažnių juostos PSD, o mirksnio aptikimo riba nustatyta kaip viena standartinė deviacija nuo bendrų duomenų vidurkio (žr. 25 pav.).

Vizualiai į elektrinę veiklą sukeltą akių, panašiausias ICA komponentas pirmame bandyme buvo trečiasis komponentas, t. y. komponentas, turintis viršūnes, kurios panašiausios į tris intervalus po 10 priverstinių akių mirksnių bei vieną papildomą akių mirksnį pabaigoje. Šiame komponente buvo aptiktos 30 priverstinius akių mirksnius indikuojančių viršūnių (žr. 25 pav.). Šis rezultatas yra tikslesnis lyginant su rezultatais nenaudojant ICA metodo, kai buvo aptiktos 33 viršūnės.

Suskaičiavus ICA, gaunama tiek atskirų komponentų, kiek buvo naudojama atskiriems signalams, šiuo atveju kanalams, skaičiuoti. Vizualiai koreliaciją tarp akių mirksnių ir atitinkamo ICA komponento galima pastebėti, tačiau valdymui to nepakanka. Norint panaudoti šį algoritmą valdymui, reikia automatiškai aptikti ICA komponentą, atitinkantį akių judesių sukeltą elektrinę veiklą.



25 pav. Pirmo bandymo EEG duomenys pritaikius ICA metodą ir suskaičiavus PSD

Siekiant rasti metodą, kuriuo būtų galima aptikti reikiamą ICA komponentą, atliktas bandymas skaičiuojant kiekvieno ICA komponento kurtozę (akies judesių komponentai linkę turėti aukštą kurtozės vertę (>3), nes pasižymi tuo, kad yra reti (20 kartų per minutę) ir turi didelę amplitudę (0–650 μV [25]), dėl to jų pasiskirstymas stipriai ne-gausinis.) ir vidutinė *Pearsono* koreliacija su išfiltruotu EEG signalu 1,5–12 Hz dažnių juostoje, kurioje akių veikla ryškiausia (žr. 9 lentelę).

9 lentelė. Gauti kurtozės ir koreliacijos rezultatai

ICA komponento Nr.	1	2	3	4	5	6	7	8
Kurtozė	1,0975	0,7109	2,3808	1,8628	3,1915	2,2409	0,2987	6,5393
<i>Pearsono</i> koreliacija	0,0697	0,0242	0,7767	0,0740	0,0299	0,0299	0,0762	0,0444


Iš 9 lentelės galima matyti, kad ICA komponentas, su elektrine veikla sukelta akių, turi didžiausią *Pearsono* koreliaciją su filtruotais EEG signalais, tuo tarpu šio komponento kurtozės vertė nėra krašutinė.

Siekiant išvengti nereikalingų valdymo signalų, reikia atpažinti tik tuos akių mirksnius, kuriais subjektas sąmoningai siekia perduoti valdymo komandą. Akių mirksniai gali būti klaidingai interpretuojami kaip valdymo signalai, nes žmogus gali juos atlikti nesąmoningai, be ketinimo inicijuoti veiksmą.

Taigi, kad būtų išvengta situacijų, kai atsitiktinis akių judesys ar mirksnis aktyvuoja valdymo veiksmą, valdymo komandos turėtų būti interpretuojamos tik tada, kai subjektas atlieka ne vieną, o seriją akių judesių ar mirksnių. Tuo tikslu buvo įgyvendintas kitas bandymas, kai subjektas atliko mirksnius be pauzių – serijomis.


Subjektas atliko mirksnių serijas be pauzių: 3 kartus po 2 mirksnius; 3 kartus po 3 mirksnius; 3 kartus po 4 mirksnius; 2 kartus po 5 mirksnius. Iš viso buvo atlikti 37 akių mirksniai. Šiuo bandymu taip pat

buvo siekiama patikrinti, kaip anksčiau minėti metodai veikia, kai tarp mirksnių nėra pauzių, naudojant tik amplitudės ribos aptikimo metodą (žr. 26 pav.).



26 pav. Mirksniai be pauzių naudojant tik amplitudės ribos aptikimo metodą

Taikant amplitudės ribos aptikimo metodą kai parinkta aptikimo riba siekia 1,5 standartinės deviacijos nuo vidurkio, o visų EEG kanalų duomenys susumuoti (akių mirksniai matomi per visus EEG kanalus, todėl imamas visų kanalų vidurkis tam, kad sumažinti variacijas EEG signale, kurios atsiranda tarp skirtingų kanalų), rastos 34 pozityvios ir 38 negatyvios viršūnės (žr. 26 pav.).




27 pav. Mirksniai be pauzių skaičiuojant išfiltruoto EEG signalo bendrą 1,5–12 Hz dažnių juostos PSD


Naudojant 1,5–12 Hz dažnių juostos PSD skaičiavimą buvo rasti 30 iš 37 priverstinių akių mirksnių be pauzių (žr. 27 pav.). Kas yra prastesnis rezultatas nei, kai buvo naudotas tik amplitudės aptikimo metodas ir rastos 34 pozityvios ir 38 negatyvios viršūnės (žr. 26 pav.).

Aptinkant akių mirksnius indikuojančias viršūnės ICA komponente su elektrine veikla sukelta akių (kuris turi didžiausią vidutinę *Pearsono* koreliacija – 0,8582). Rastos 36 pozityvios ir 38 negatyvios viršūnės (žr. 28 pav.). Tai yra geresnis rezultatas nei prieš tai naudotų metodų, tačiau visos 37 akių mirksnius indikuojančios viršūnės dar nebuvo rastos nei vienu iš prieš tai minėtų metodų.

Taigi ICA metodas taikomas kartu su artu su 1,5–12 Hz dažnių juostos PSD skaičiavimu (žr. 29 pav.)



28 pav. Mirksniai be pauzių naudojant ICA metodą



29 pav. Mirksniai be pauzių skaičiuojant ICA komponento su EEG akių veikla 1,5–12 Hz dažnių juostoje PSD

Naudojant ICA metodą kartu su 1,5–12 Hz dažnių juostos PSD skaičiavimu buvo rastos visos 37 akių mirksnius indikuojančios viršūnės (žr. 29 pav.). Tai geriausias iki šiol gautas rezultatas. Taigi ši metodiką bus įtraukta į galutinį valdymo algoritmą, skirtą valdymo signalas iš EEG duomenų sukurti.

2.3. Trumpiausio galimo duomenų intervalo akių mirksniais aptikti radimas

ICA metodo tikslas – išskaidyti sudėtinius signalus į statistiškai nepriklausomas komponentes. Kuo didesnis turimų duomenų kiekis, tuo tiksliau galima įvertinti jų statistines savybes ir atskirti komponentus. Tačiau praktiniuose taikymuose svarbu rasti kompromisą tarp duomenų kiekio ir skaičiavimo efektyvumo. Todėl šiuo bandymu buvo siekiama nustatyti minimalų reikalingą duomenų kiekį, kuris užtikrintų metodo veikimą neprarandant aptiktos valdymo signalų informacijos.

Atliktas bandymas, skirtas įvertinti, kaip ICA metodas veikia su skirtingais duomenų kiekiais, bei nustatyti mažiausią duomenų intervalą, kuriame būtų aptinkamos visos akių mirksnius indikuojančios viršūnės. Pirmojo ir antrojo bandymų duomenys palyginti, taikant ICA metodą skirtingiems duomenų kiekiams.

Bandymo įgyvendinimo algoritmas:

- ICA metodas naudojamas su nustatytu duomenų intervalu;

- iš gautų duomenų išfiltruojama dažnių juosta 1,5–12 Hz;
- skaičiuojama kiekvieno gauto ICA komponento *Pearsono* koreliacija su kiekvienu EEG kanalu; komponentas, kuris turi didžiausią vidutinę koreliaciją, priskiriamas pirmajam komponentui, t. y. priimamas kaip ICA komponentas 1;
- skaičiuojama nustatymo duomenų intervalo PSD;
- aptinkamos viršūnės, kurios yra nutolusios per vieną standartinį nuokrypį nuo intervalo vidurkio; per 50 ms laiko tarpą gali būti aptikta tik viena viršūnė.


Rezultatai pateikti 10 lentelėje. Joje galima matyti, kad mažiausias duomenų intervalas kai algoritmas aptiko visus akių mirksnius sėkmingai pirmuoju atveju yra 12 s, antruoju – 14 s. Kai akių mirksniai atilikti su pauze, klaidingai aptiktos viršūnės atsiranda prie ilgesnių intervalų nei, kai akių mirksniai atliekami be pauzės.

10 lentelė. Algoritmo aptikti akių mirksnius indikuojančių viršūnių kiekiai, naudojant skirtingus duomenų intervalus

Kai akių mirksniai buvo atliekami be pauzės (1 bandymas)								
Duomenų intervalas, s	16	14	12	10	8	6	4	2
Aptiktos viršūnės, vnt.	37	37	37	35	36	34	32	46
Klaidingai aptiktos viršūnės, vnt.	0	0	0	0	0	0	0	21
Kai akių mirksniai buvo atliekami su pauze (2 bandymas)								
Duomenų intervalas, s	16	14	12	10	8	6	4	2
Aptiktos viršūnės, vnt.	31	31	30	30	30	26	26	36
Klaidingai aptiktos viršūnės, vnt.	0	0	1	2	2	0	2	10

Iš gautų duomenų (žr. 10 lentelę) galima spręsti, kad algoritmas efektyvesnis akių mirksniams aptikti, kai jie atliekami du ar daugiau kartų be pauzės. Tai palanku valdymo veiksams atlikti, nes padeda išvengti klaidingų valdymo komandų – valdymo signalai nebus generuojami, kai akių mirksniai yra vienetiniai.

Algoritmo veikimo pavyzdys pateiktas 30 ir 31 paveiksluose.




30 pav. Gauti rezultatai, kai naudojant algoritmą aptikti akių mirksnius kai duomenų intervalas yra 10 s, akių mirksniai be pauzės

Kai parinktas duomenų intervalas yra 10 s ir 12 s. Raudono spalvos punktyrinė linija indikuoja duomenų intervalo ribas, žalios spalvos punktyrinė linija – vieną standartinę deviaciją tame intervale.

30 paveiksle galima matyti, kad viršūnės, kurios nėra aptinkamos atsiranda paskutinėje akių mirksnių serijoje ties 49–55 s. Taip atsitinka tuomet, kai akių mirksnių serija pertraukia intervalo ribą.

Iš 31 paveikslo galima matyti, kaip atrodo duomenys, kai algoritmo veikimo intervalas 12 s. Antroje ir trečioje akių mirksnių serijose aptinkami visi mirksniai, tuo tarpu pirmojoje serijoje viršūnių amplitudė sumažėja, palyginti su kitomis, todėl ne visi akių mirksniai yra aptinkami.



31 pav. Gauti rezultatai kai naudojant algoritmą aptikti akių mirksnius kai duomenų intervalas yra 12 s, akių mirksniai su pauze

Atsižvelgiant į gautus bandymo duomenis (žr. 10 lentelę), galima daryti išvadą, kad viršuje taikytas algoritmas yra veiksmingesnis aptinkant akių mirksnius, kai jie atliekami du ar daugiau kartų be pauzės.

2.4. Skirtingų akių, mirksnių atpažinimas


Viena iš galimų valdymo signalų generavimo variacijų, naudojantis EEG duomenimis, yra skirtingų akių mirksnių atpažinimas. Siekiant tai ištirti, buvo atliktas toks eksperimentas: subjektas atliko 10 kairės akies, 10 dešinės akies ir 10 abiejų akių mirksnių. Eksperimento tikslas – išanalizuoti, kaip skirtingi mirksniai atsispindi EEG duomenyse, ir nustatyti, ar jie pasižymi bruožais, kuriuos būtų galima panaudoti valdymo komandoms kurti.

Gautiems duomenims pritaikius ICA kartu su PSD metodu tiek 1,5–12 Hz (dažnių juosta, kurioje ryškiausiai matomi akių mirksniai) ir 13–45 Hz (dažnių juostai, kurioje akių mirksnių sukelta veikla nėra matoma) dažnių juostoms. Rezultatai pateikti 31 paveiksle.

Pirmame grafike (žr. 32 pav.) 0–13 s intervale, kuriame atlikti kairės akies akių mirksniai, rastos 10 viršūnių. Tuo tarpu intervale 15–27 s, kuriame atlikti dešinės akies mirksniai, rastos 7 viršūnės ir paskutiniame 30–40 s intervale, kuriame buvo atlikti abiejų akių mirksniai, rastos 10 viršūnių.

Vienos akies mirksnių viršūnės patenka į tą patį amplitudės diapazoną (0,8–3 ICA vnt.), kaip ir abiejų akių mirksnių viršūnės, taigi, remiantis amplitudės matavimais, šių akių mirksnių atskirti naudojant esamus metodus nepavyko.


Antrasis grafikas (žr. 32 pav.) rodo elektrinę veiklą 13–45 Hz dažnių juostoje, kuri atspindi skirtumus tarp kairės ir dešinės akies mirksnių, nesusijusius su pačių akių sukelta elektrine veikla. Vis dėlto, reikšmingų koreliacijų tarp skirtingų akių mirksnių tipų ir šios dažnių juostos viršūnių nustatyta nebuvo.



32 pav. Skirtingų akių mirksnių palyginimas

Skirtingi akių mirksniai turėtų sukelti skirtingo stiprumo elektrinį aktyvumą tarp smegenų regionų, todėl juos įmanoma atpažinti, analizuojant skirtumus tarp EEG kanalų.

Tuo tikslu buvo skaičiuotas elektrodų porų „P3“ ir „P4“; „C3“ ir „C4“; „F3“ ir „F4“; „O1“ ir „O2“. signalo skirtumas. Šį skirtumą išreikšti naudotas PSD metodas, kuris parodo kaip signalo dažnio energija pasiskirsto įvairiuose dažniuose, specifiskai 1,5–12 Hz dažnių juostai, kurioje ryškiausiai matoma akių sukelta veikla (žr. 33 pav.).



33 pav. Skirtingų akių mirksnių palyginimas tarp EEG kanalų


Iš 33 paveiksle pateiktos koreliacijos tarp akių mirksnių atlikta viena akimi ir skirtumo tarp elektrinės veiklios amplitudės 1,5–12 Hz dažnių juostoje nėra. Taigi naudojant amplitudės ribos metodą su skirtumo tarp šių regionu apskaičiavimu, aptikti šiuos mirksnius nepavyko.

2.5. Horizontalių ir vertikalų akių judesių atpažinimas

Šio tyrimo etapo tikslas – identifikuoti skirtingo tipo akių judesius tuose pačiuose duomenyse kaip atskirus valdymo signalus. Tai atlikus, atsirastų galimybė turėti daugiau skirtingų valdymo komandų.

Bandymas buvo atliktas, siekiant palyginti, priverstinius akių mirksnius bei horizontalius ir vertikalūs akių judesius. Subjektas atliko: 11 priverstinių akių mirksnių po 8 s pauzės, 5 akių judesius iš viršaus į apačią ir 5 – iš apačios į viršų, o po dar vienos 8 s pauzės – 5 akių judesius iš kairės į dešinę ir 5 – iš dešinės į kairę. Rezultatai po 1,5–12 Hz dažnių juostos PSD skaičiavimo pritaikius ICA metodą pateikti 34 paveiksle. Aptikimo riba nustatyta kaip viena standartinė deviacija.

Iš 34 paveikslo matyti, kad priverstiniai akių mirksniai ir vertikalūs akių judesiai turi panašią amplitudę, t. y. akių mirksnių – 1,27–4,52 ICA vnt., o vertikalūs akių judesiai – 1,26–8,34 ICA vnt. Horizontalūs akių judesiai nebuvo aptikti. Iš to galima daryt išvadą, kad ši metodika nėra tinkama horizontaliems akių judesiams aptikti.




34 pav. Skirtingų akių judesių atpažinimas

Vertikalūs ir horizontalūs akių judesiai, kitaip nei akių mirksniai, naudoja skirtingas raumenų grupes. Siekiant aptikti šią skirtingą raumenų veiklą, buvo skaičiuojamas tų pačių duomenų signalo galios spektrinis tankis (PSD) 20–45 Hz dažnių juostoje, t. y. dažnių juostoje, kurioje akių mirksniai nesukelia aktyvumo Gautos didesnės nei 0,01 ICA vnt. viršūnės toje bandymo dalyje (28–47 s), kurioje atlikti vertikalūs akių judesiai (žr. 35 pav.).

Iš 34 ir 35 paveikslų galima spręsti, kad vertikalūs akių judesiai nuo priverstinių akių mirksnių skiriasi aktyvumu 20–45 Hz dažnių juostoje. Priverstinių akių mirksnių viršūnės šioje dažnių juostoje neaptinkamos, o tuo tarpu vertikalų akių judesiai turi didesnę nei 0,01 ICA, vnt. amplitudę.


Siekiant teisingai įvertinti gautus rezultatus, reikia naudoti daugiau nei vieną analizės metodą. Skirtingi metodai gali padėti rasti prieš tai neaptiktus signalų aspektus. Palyginimui skirtingiems akių judesiams aptikti buvo pritaikytas DWT (angl. *discrete wavelet transform*) metodas. Rezultatai pateikti 36 paveiksle.



35 pav. PSD skaičiavimas 20–45 Hz dažnių juostoje, ICA duomenims

DWT – tai signalų apdorojimo metodas, naudojamas signalams skirtinguose dažniuose ir laiko masteliuose analizuoti. Šis metodas naudojamas kartu su specialiomis funkcijos – bangelėmis, kurios padeda „atskleisti“ signalo charakteristikas.

Iš bandytų bangelių variacijų efektyviausia DWT metodui buvo „db“ (angl. *daubechies*) bangelė su 4 nykstančiais tarpais. Tai reiškia, kad signalas suskaidomas į 4 dažnių lygius. Šiuo atveju grafike pavaizduotas tas lygis, kuriame vertikalių akių judesių veikla buvo matoma ryškiausiai (žr. 36 pav.).




36 pav. DWT metodo pritaikymas siekiant atskirti skirtingus akių judesius

36 paveiksle pirmas grafikas rodo gautus duomenis, pritaikius DWT 20–45 Hz dažnių juostoje. Akių judesių sukelta elektrinė veikla ryškiausiai matoma „O1“ ir „O2“ kanaluose todėl, kad šis metodas buvo pritaikytas šiems regionams. Rezultatas gaunamas panašus kaip ir skaičiuojant ICA komponento 20–45 Hz dažnių juostos PSD, t. y. randami penki intervalai, kuriuose signalo amplitudė didesnė nei kelios standartinės deviacijos nuo vidurkio.

Kodo vykdymo laikas – 3,17 s. Tuo tarpu ICA kartu su PSD algoritmo veikimo laikas siekė 0,65 s, t. y. 4,8 karto jis greitesnis. Išvada – ICA ir PSD metodų kombinacija pranašesnė.

Ties laiko intervalu (55–75 s), kuriame buvo atlikti horizontalūs akių judesiai, didesnio aktyvumo nei 1 standartinė deviacija nuo vidurkio nebuvo. Kas iliustruoja, kad pasikartojančius horizontalių akių judesius, naudojant viršuje minėtus metodus, aptikti nepavyko.

Tiek naudojant DWT, tiek ICA kartu su PSD, horizontalūs akių judesiai nebuvo aptikti. Taigi, siekiant juos aptikti, buvo suskaičiuotas skirtumas tarp „F3“ ir „F4“ kanalų. Tai buvo daroma todėl, kad akių judesių metu atsirandantys potencialų pokyčiai pasireiškia kaip asimetrija tarp šių dviejų kanalų, kas teoriškai turėtų leisti aptikti horizontalius akių judesius. Rezultatai pateikti 37 paveiksle.



37 pav. Horizontalių akių judesių aptikimas

37 paveiksle pirmas grafikas vaizduoja skirtumą tarp „F3“ ir „F4“ kanalų, raudonos spalvos brūkšninė linija nusako aptikimo ribą ties 3 standartinėmis deviacijomis nuo vidurkio. Antras grafikas iliustruoja 1–12 Hz dažnių juostoje PSD skaičiavimo rezultatus, čia raudonos spalvos brūkšninė linija rodo aptikimo ribą ties dviem standartinėmis deviacijomis nuo duomenų vidurkio.

Pirmame grafike (žr. 37 pav.) laiko intervale ties 55–75 s, kuriame atlikti 10 horizontalių akių judesių, aptiktos 8 pozityvios ir 14 negatyvių viršūnių, tuo tarpu skaičiuojant PSD – 9 viršūnės.

Likusių bandymo intervaluose viršūnės aptinkamos klaidingai, t. y. nenaudojant PSD – 5 pozityvios ir 6 negatyvios, o naudojant – 5 klaidingos viršūnės.


Iš 37 paveiksle pateiktų rezultatų galima spręsti, kad skaičiuojant „F3“ ir „F4“ kanalų skirtumą 1–12 Hz dažnių juostoje, PSD horizontalūs akių judesiai aptinkami efektyviau, nei vien tik skaičiuojant „F3“ ir „F4“ kanalų skirtumą.

Kyla klausimas, ar galima optimizuoti horizontalių akių judesių aptikimą, išvengiant viršūnių, kurios klaidingai aptinkamos? Tuo tikslu buvo panaudotas DWT metodas tiems patiems duomenims, t. y. „F3“ ir „F4“ kanalų skirtumui.

Iš bandytų bangelių variacijų „db“ bangelė su 6 nykstančiais tarpais buvo efektyviausia. Naudojant šią bangelės variaciją buvo rastas mažiausias klaidingai aptiktų viršūnių kiekis bei didžiausias teisingai aptiktų viršūnių kiekis (žr. 38 pav.).

Iš 38 paveikslo taip pat matyti, kad intervale, kuriame buvo atlikti horizontalūs akių judesiai (55–75 s), aptiktos 8 viršūnės, indikuojančios akių judesius. Klaidingai aptiktų viršūnių nebuvo. Palyginus su PSD metodu (žr. 37 pav.), kuriuo buvo aptikti 9 iš 10 horizontalūs akių judesiai, šis metodas mažiau efektyvus aptinkant šiuos judesius. PSD metodas aptiko 5 viršūnes klaidingai.

Žiūrint iš valdymo perspektyvos, PSD metodo naudojimas lemia klaidingai aptiktų viršūnių koreliaciją su priverstiniais akių mirksniais ir vertikaliais akių judesiais (žr. 35 ir 34 pav.). Šiuose grafikuose nėra koreliacijos tarp horizontalių akių judesių ir aptinkamų viršūnių. Taigi klaidingai PSD metodu aptiktas viršūnes galima atmesti.



38 pav. Horizontalių akių judesių aptikimas naudojant DWT

Rezultate, skaičiuojant „F3“ ir „F4“ kanalų skirtumą PSD metodu, horizontalūs akių judesiai aptinkami efektyviausiai, t. y. aptinkamas didžiausias teisingų viršūnių skaičius, o klaidingos viršūnės atmetamos.

2.6. Užmerktų ir atmerktų akių aptikimas


Siekiant gauti daugiau valdymo signalų iš EEG duomenų, buvo bandoma aptikti intervalus kai subjekto akys užmerktos ir atmerktos. Atliktame bandyme tas pats subjektas 70 s intervale užmerkė akis 5 kartus ir po pauzės atmerkė.

Moksliniai šaltiniai teigia, kad didžiausias EEG aktyvumas kai subjekto akys užmerktos pastebimas „O1“ ir „O2“ zonoje ties 9–12 Hz dažnio riba [63]. Būtent dėl to ši dažnių juosta yra išfiltruojama (žr. 39 pav., pirmas grafikas). Papildomai sugeneruotas grafikas, indikuojantis aptiktus užmerktų akių intervalus (žr. 39 pav. antras grafikas).

Intervalo aptikimo sąlygos:


- EEG signalas viršija 1 standartinę deviaciją, kai maksimalus tarpas iki kito duomenų taško, kuris taip pat viršija 1 standartinę deviaciją, yra 200 duomenų taškų, t. y. 0,8 s;
- gautas intervalas ilgesnis nei 750 duomenų taškų, t. y. 3 s.

Rezultate rasti 6 intervalai (žr. 39 pav.). Taip pat nustatytas skirtumas tarp pozityvių ir negatyvių EEG signalo reikšmių, kurios sukuria užmerktų akių asimetriją identifikuojant intervalus. Dėl šių priežasčių, papildomai gautiems duomenims, pritaikytas PSD metodas.



39 pav. Užmerktų akių aptikimas 9–12 Hz dažnių juostoje

Tiems patiems duomenims 9–12 Hz dažniu juostai pritaikytas PSD skaičiavimas „O1“ ir „O2“ regionams. (žr. 40 pav., pirmas grafikas).



40 pav. Užmerktų akių aptikimas 9–12 Hz dažnių juostoje skaičiuojant PSD metodu


Intervalo aptikimo sąlygą: EEG signalas viršija 0,1 standartinę deviaciją, kai maksimalus tarpas iki sekančio duomenų taško kuris taip pat viršija 0,1 standartinę deviaciją yra 20 duomenų taškų (žr. 40 pav., antras grafikas).

Rezultate rasti visi 5 intervalai kai subjektas buvo užmerkęs akis. Taip pat nebereikia atsižvelgti į pozityvių ir negatyvių reikšmių asimetriją. Algoritmas baigė veikti per 0,417 s.

Darytina išvada, kad taikant PSD metodą intervalams aptikti, gaunami tikslesnis rezultatas nei nenaudojant PSD metodo.

Palyginimui, užmerktų akių intervalams aptikti panaudoti *Hjorth* parametrai – aktyvumas, mobilumas ir sudėtingumas (žr. 41 pav.). 41 paveiksle „A“, „B“ ir „C“ grafikuose parodyti užmerktų akių aptikimo intervalai, taikant *Hjorth* parametrus. Visi 5 užmerktų akių intervalai rasti skaičiuojant tik *Hjorth* mobilumą, algoritmas baigė veikti po 0,498s.

Naudojant tiek PSD metodą, tiek *Hjorth* mobilumo skaičiavimą 9–12 Hz dažnių juostai, rasti visi 5 užmerktų akių intervalai, tačiau PSD algoritmo veikimo laikas 16 proc. trumpesnis.



41 pav. Užmerktų akių aptikimas 9–12 Hz dažnių juostoje skaičiuojant PSD

Dėl tos priežasties galima teigti, kad valdymo tikslu PSD skaičiavimo metodas yra pranašesnis.

2.7. Gauti rezultatai

Akių mirksniai efektyviausiai aptikti taikant ICA metodą kartu su 1,5–12 Hz dažnių juostos PSD skaičiavimu. Naudojant šią metodiką, akių mirksniai turi būti atliekami serijomis – po du ar daugiau mirksnių.

Palyginus vertikalius, horizontalius akių judesius ir mirksnius EEG duomenyse, nustatytas skirtumas 20–45 Hz dažnių juostoje, t. y. aptinkamos priverstinių akių mirksnių viršūnės, naudojant ICA metodas kartu su šios dažnių juostos PSD skaičiavimu, yra mažesnės nei $0,1 \mu V^2/Hz$, vertikalinių akių judesių – didesnės nei $0,1 \mu V^2/Hz$.

Horizontalūs akių judesiai efektyviausiai aptikti, skaičiuojant „F3“ ir „F4“ kanalų skirtumą 1–45 Hz dažnių juostoje PSD metodu. Užmerktų ir atmerktų akių atpažinimas efektyviausiai atliktas skaičiuojant „O1“ ir „O2“ kanalų skirtumą 9–12 Hz dažnių juostoje irgi PSD metodu.

3. Valdymo signalų kūrimas iš elektroencefalografijos duomenų

Siekiant elektrinę veiklą sukeltą akių panaudoti signalams valdyti, taikant 2.2, 2.3, 2.5, 2.6 skyriuose analizuotus akių judesių, mirksnių ir užmerktų akių aptikimo metodus, sukurtas algoritmas (žr. 42 ir 43 pav.).


3.1. Valdymo algoritmo aprašymas

Žemiau pateiktas žodinis valdymo algoritmas, kuris suskirstytas į tris dalis: 1 – „START“ valdymo komandos įjungimas / išjungimas, 2 – priverstinių akių mirksnių ir vertikalų judesių aptikimas, 3 – horizontalų akių judesių aptikimas.


Žodinis algoritmo veikimo algoritmas:

1. **Algoritmo dalis, kuri įjungia / išjungia „START“ valdymo komandą.** Nuskaitomi EEG duomenys. Šiems duomenims taikomi filtrai: 50, 100 Hz „Notch“ ir 1–45 Hz „Bandpass“. „O1“ ir „O2“ kanalų duomenys sumuojami ir skaičiuojamas rezultatas taikant PSD metodą. Randami visi taškai, kurie yra aukščiau 0,1 standartinės deviacijos linijos. Jei prieš ir po aptikto duomenų taško yra kitas duomenų taškas 30 duomenų taškų intervale – visi taškai tarp rastų duomenų taškų nustatomi į 1. Jei ne, duomenų taškas pašalinamas iš eilės. Jei rastas taškų intervalas ilgesnis nei 3 s, įjungiamas „START“ valdymo signalas. Jei „START“ valdymo signalas jau buvo įjungtas, tuomet išjungiamas.
2. **Algoritmo dalis, kuri aptinka priverstinius akių mirksnius ir vertikalūs judesius.** Visiems duomenims pritaikomas ICA metodas. Skaičiuojama *Persono* koreliacija tarp visų ICA komponentų ir EEG kanalų. Randamas ICA komponentas, turintis didžiausią koreliaciją su EEG kanalais. Rastas ICA komponentas pastatomas į pirmąją pozicijos eilę. Skaičiuojama pirmo ICA komponento 1,5–12 Hz ir 20–45 Hz dažnių juostos PSD. Viršūnių aptikimo riba 1,5–12 Hz dažnių juostai nustatoma kaip 1 standartinė deviacija, 20–45 Hz dažnių juostai – kaip 2 standartinės deviacijos. Viršūnės aptinkamos tik duomenų intervale po „START“ signalo įjungimo. Kai aptiktos dvi ar daugiau viršūnių, nutolusių viena nuo kitos mažiau nei per 1 s, 1,5–12 Hz dažnių juostoje, o tame pačiame intervale 20–45 Hz dažnių juostoje nėra aptiktų viršūnių – laikoma, kad priverstiniai akių mirksniai yra aptikti. Jei tame pačiame intervale 20–45 Hz dažnių juostoje yra aptiktų viršūnių – laikoma, kad vertikalūs akių judesiai aptikti.
3. **Algoritmo dalis, kuri aptinka horizontalūs akių judesius.** Skaičiuojamas skirtumas tarp „F3“ ir „F4“ kanalų, aptinkamos viršūnės didesnės nei 1 standartinė deviacija nuo vidurkio intervale, kurio pradžia apibrėžė „START“ komanda. Jei aptikta viršūnė yra prie kitos viršūnės vieno duomenų taško atstumu – viršūnės pozicija paliekama masyve, jei ne – pašalinama iš masyvo. Likusios viršūnės interpretuojamos kaip horizontalūs akių judesiai.

Žodinis algoritmas pateiktas grafiškai (žr. 42 ir 43 pav.).



42 pav. Algoritmas skirtas sukurti valdymo signalas iš EEG duomenų aptikti pirmas dalis



43 pav. Algoritmas skirtas sukurti valdymo signalas iš EEG duomenų aptikti pirmas dalis


Algoritmas pritaikomas 3.2 skyriuje.

3.2. Valdymo algoritmo testavimas

Algoritmo veikimui patikrinti, atliktas dar vienas bandymas, kurio metu subjektasakis laikė užmerkęs ilgiau nei 3 sekundes ir atlikto tokius veiksmus: du akių mirksniai be pauzės, du vertikalūs akių judesiai be pauzės, du ar daugiau horizontalūs akių judesiai be pauzės.

44 paveiksle pavaizduoti grafikai, informacija iš kurių buvo naudojama valdymo signalams formuoti, taikant 42 ir 43 paveiksluose aprašytą valdymo algoritmą. Nuo viršaus į apačią: ICA komponento 1,5–12 Hz dažnių juostos PSD; ICA komponento 20–12 Hz dažnių juostos PSD; filtruotų EEG duomenų 9–12 Hz dažnių juostos PSD; filtruotų EEG duomenų „F3“ ir „F4“ kanalų skirtumo PSD.

Paskutinis grafikas indikuoja aptiktus valdymo signalus, čia „A“ – aptiktos priverstinių akių mirksnių serijos; „B“ – aptiktos vertikalųjų akių judesių serijos; „C“ – aptiktos horizontaliųjų akių judesių serijos; D – aptikti užmerktų akių intervalai.



44 pav. Algoritmas skirtas valdymo signalas iš akių sukeltos elektrinės veiklos sukurti

Iš valdymo signalų aptikimo grafiko (žr. 44 pav.) matyti, kad aptikti: visi priverstiniai akių mirksniai, horizontaliųjų ir vertikalųjų mirksnių serijos bei užmerktų akių intervalai.

Algoritme atmerktų ir užmerktų akių intervalams ir horizontaliems akių judesiams aptikti naudoti specifiniai kanalai. Jei vienas iš kanalų praranda kontaktą, jame suformuoti valdymo signalai algoritmo neaptinkami. Tuo tarpų priverstiniai akių mirksniai ir vertikalūs akių judesiai prie specifinių kanalų neprišiti, todėl vieno kanalo praradimas netūrėtų jiems daryti didelę įtaką.

Aukščiau pateiktai prilaidai patikrini, atliktas dar vienas bandymas, kuriame buvo pašalinti kiekvieno individualaus kanalo duomenys. Rezultatai pateikti 11 lentelėje.

11 lentelė. Algoritmo veikimo rezultatai kai vienas kanalas ignoruojamas

Kanalas	„F3“	„F4“	„C3“	„C4“	„P3“	„P4“	„O1“	„O2“	Viso
Neaptikti signalai	1	1	0	1	0	0	0	1	4
Klaidingai aptikti signalai	0	1	0	0	0	0	0	0	1


Iš 11 lentelės matyti, kad dažniausiai pasitaikanti klaida, kai nėra vieno kanalo – neaptinkamas signalas.

Antra bandymų iteracija vykdyta iš EEG duomenų pašalinant du kanalus. Tai buvo atlikta visoms įmanomoms kanalų kombinacijoms. Rezultatai pateikti 12 lentelėje, kurioje rezultatai sugrupuoti pagal naudotas EEG kanalų grupes, t. y. „F“, „C“, „P“ ir „O“.

12 lentelė. Algoritmo veikimo rezultatai kai du kanalai ignoruojami

Kanalai	„F“	„C“	„P“	„O“	Viso
Neaptinka	9	3	2	5	19
Aptinka klaidingai	16	13	9	11	49

Iš 12 lentelėje pateiktų duomenų matyti, kad dažniausiai pasitaikanti klaida – klaidingai identifikuotas signalas. Tuo tarpu didžiausias klaidų kiekis buvo tuomet, kai pašalintas „F3“ ir / arba „F4“ kanalai, o mažiausias – kai „P3“ ir / arba „P4“ kanalai. Bendras algoritmo veiksmingumas po dviejų kanalų praradimo, priklauso nuo kanalo grupės, pavaizduotas 45 paveiksle.




45 pav. Kanalų įtaką algoritmo veiksmingumui

45 paveiksle pavaizduota stulpelinė procentinė išraiška, kiek buvo aptiktų signalų, kur 100 procentų yra visi galimi signalai, kai bent vienas iš pašalintų kanalų yra iš nurodyto regiono. Iš grafiko matyti, kad mažiausia įtaką algoritmo veikimui daro – „P“ kanalai, didžiausią – „F“ kanalai.

3.3. Algoritmo pritaikymas įrangai valdyti

Akių judesiais galima valdyti įvairias sistemas. EEG įranga fiksuoja tiek smegenų, tiek akių sukeltą elektrinę veiklą, todėl iš gautų duomenų galima aptikti akių judesius ir juos panaudoti kaip valdymo komandas.

46 paveiksle pavaizduota EEG signalų panaudojimo įrangai valdyti funkcinė schema, naudojant „Neurotechnology“ įmonės „BrainAccess MINI“ nuskaitymo įrangą.



46 pav. EEG signalų panaudojimas valdymui (funkcinė schema)

Nuskaityti EEG duomenys siunčiami per „Bluetooth“ ryšį ir yra pasiekiami naudojant C, C++ arba „Python“ programavimo sąsają. Jie gali būti interpretuojami pasitelkiant tokius algoritmus kaip (žr. 42 pav.) ir (žr. 43 pav.). Sukurti valdymo signalai gali būti perduodami įrangai tokiais protokolais kaip TCP/IP, „Bluetooth“ ir t. t.

Vienas iš galimų pritaikymo būdų – apšvietimo ar buitinių prietaisų valdymas. Pavyzdžiui, dvigubas mirksėjimas gali įjungti / išjungti apšvietimą kambaryje, o ilgesnė mirksnių serija – įjungti virdulį ar kitą įrenginį. Suformuoti valdymo signalai taip pat gali būti naudojami termostatui reguliuoti (pvz., du akių mirksniai be pauzės – temperatūrai padidinti, o du horizontalūs akių judesiai – sumažinti). Vartotojai gali patogiai be fizinio kontakto su įrenginiu reguliuoti namų šildymą ar vėsinimą.

Taip pat, EEG įranga su akių mirksėjimo atpažinimu gali leisti valdyti televiziją ar garso sistemą. Akių judesių deriniai gali būti naudojami kanalams perjungti, garso lygiui reguliuoti ar muzikos grojaraščiams pasirinkti. Tokie sprendimai atveria naujas galimybes naudotis moderniomis technologijomis.

Išvados

1. EEG signalų artefaktai skirstomi į vidinius: širdies ritmo, akių judesių, raumenų veiklos ir išorinius – blogas elektrodo ir odos kontaktas prastas elektrodo laidumas. Šiems artefaktams aptikti gali būti naudojami tokie metodai kaip ICA, DTW, amplitudės slenksčio ir kt.
2. EEG požymių išskyrimo metodai gali būti skirstomi į šias kategorijas: laiko domeno (signalų fraktalų analizavimas ir statistiniai požymiai), dažnio srities (*Furjė* transformacija ar galios spektrinis tankis), dekompozicijos (bangelių transformacija, empirinio režimo skaidymas ar nepriklausomų komponentų analizė) ir erdvinio domeno (CSP algoritmas ir jo variacijos). EEG požymiams klasifikuoti naudojami tokie algoritmai: mašininio mokymo (SVM, CNN, DBN, LSTM, GAN) ir analizės (LDA) metodai. Dažniausiai „žmogaus-mašinos“ sąsajas pagrįstos EEG duomenų interpretavimu naudojamas judesiams, emocijoms ar nuovargiui atpažinti.
3. Palyginus vertikalius, horizontalius akių judesius ir mirksnius EEG duomenyse, nustatytas skirtumas 20–45 Hz dažnių juostoje – aptinkamos priverstinių akių mirksnių viršūnės, kai naudojamas ICA metodas kartu su šios dažnių juostos PSD skaičiavimu ir yra mažesnės nei $0,1 \mu V^2/Hz$, vertikalių akių judesių – didesnės nei $0,1 \mu V^2/Hz$.
4. Akių mirksnius efektyviausiai galima aptikti taikant ICA metodą kartu su 1,5–12 Hz dažnių juostos PSD skaičiavimu. Remiantis aptiktais mirksniais ir akių judesiais, sukurtas algoritmas, kuris šią informaciją pavertė valdymo signalais. Algoritmo vidutinis efektyvumas aptinkant akių mirksnius ir vertikalius judesius, kai nėra dviejų kanalų – 93,93 proc.

Literatūros sąrašas

1. TUMELIS, J. ir kt. *Visuotinė lietuvių enciklopedija* [interaktyvus]. Vilnius: Mokslo ir enciklopedijų leidybos centras, 2015 [žiūrėta 2024-04-10]. Prieiga per: <https://www.vle.lt/straipsnis/fraktalas/>.
2. VÄRBU, K., et al. Past, present, and future of EEG-based BCI applications. *Sensors* [interaktyvus]. 2022, 22(9), 3331 [žiūrėta 2024-05-04]. Prieiga per: <https://doi.org/10.3390/s22093331>.
3. TIWARI, S., et al. Machine learning approach for the classification of EEG signals of multiple imagery tasks. *11th International Conference on Computing, Communication and Networking Technologies (ICCCNT)* [interaktyvus]. 2020, 49239 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.1109/ICCCNT49239.2020.9225291>.
4. LIANG, W., et al. Variance characteristic preserving common spatial pattern for motor imagery BCI. *Human Neuroscience* [interaktyvus]. 2023, 17, 1243750 [žiūrėta 2024-04-12]. Prieiga per: <https://doi.org/10.3389/fnhum.2023.1243750>.
5. CHENG, L., et al. A motor imagery EEG feature extraction method based on energy principal component analysis and deep belief networks. *IEEE Access* [interaktyvus]. 2020, 8, 21453–21472 [žiūrėta 2024-05-02]. Prieiga per: <https://doi.org/10.1109/ACCESS.2020.2969054>.
6. CHAI, R., et al. Driver fatigue classification with independent component by entropy rate bound minimization analysis in an EEG-based system. *IEEE Journal of Biomedical and Health Informatics* [interaktyvus]. 2017, 21, 3 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.1109/JBHI.2016.2532354>.
7. TAKASAKI, K., et al. GAN-based EEG forecasting for attaining driving operations. *IEEE Intelligent Vehicles Symposium (IV)* [interaktyvus]. Japonija: Tokijas, 2023, 1–7 [žiūrėta 2024-05-04]. Prieiga per: <https://doi.org/10.1109/IV55152.2023.10186750>.
8. JOHN, G. W. *Medical Instrumentation Application and Design*. United States of America: Wiley, 2009. ISBN-13978-0471-67600-3.
9. MARK, R. N. 10-10 electrode system for EEG recording. *Clinical Neurophysiology* [interaktyvus]. 2018, 129(9), 1103 [žiūrėta 2024-03-25]. Prieiga per: <https://doi.org/10.1016/j.clinph.2018.01.065>.
10. AHOSLA, K., et al. A comparative analysis of signal processing and classification methods for different applications based on EEG signals. *Biocybernetics and Biomedical Engineering* [interaktyvus]. 2020, 40, 649–690 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.1016/j.bbe.2020.02.002>.
11. WIDMANN, A., SCHRÖGER E. Filter effects and filter artifacts in the analysis of electrophysiological data. *Biocybernetics and Biomedical Engineering* [interaktyvus]. 2012, 3, 233 [žiūrėta 2024-04-10] Prieiga per: <http://10.3389/fpsyg.2012.00233>.
12. GONCALES, L. J., FARIAS, K., KUPSSINSKU, L., SEGALOTTO, M. The effects of applying filters on EEG signals for classifying developers' code comprehension. *Journal of applied Research and Technology* [interaktyvus]. 2021, 19(6), 584–602 [žiūrėta 2024-04-10]. Prieiga per: Researchgate.
13. ONTON, J. MAKEIG, S. Information-based modeling of event – Related brain dynamics. *Progress in Brain Research* [interaktyvus]. 2006 [žiūrėta 2024-04-10]. Prieiga per: ScienceDirect.

14. SIGH, A. K., KRISHNAN, S. Trends in EEG signal feature extraction applications. *Artificial Intelligence* [interaktyvus]. 2022, 5 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.3389/frai.2022.1072801>.
15. CRAIK, A., et al. Deep learning for electroencephalogram (EEG) classification tasks: A review. *Journal of Neural Engineering* [interaktyvus]. 2019, 16, 031001 [žiūrėta 2024-05-01]. Prieiga per: <https://doi.org/10.1088/1741-2552/ab0ab5>.
16. CHIN-TENG, L., et al. Novel dry polymer foam electrodes for long-term EEG measurement. *IEEE Transactions on Biomedical Engineering* [interaktyvus]. 2011, 58, 5 [žiūrėta 2024-03-10] Prieiga per: IEEE Xplore.
17. PATRIQUE, F., UWE, G., ELLEN, Z., JENS, H. Simultaneous dry and gel-based high-density electroencephalography recordings. *Sensors* [interaktyvus]. 2023, 23, 9745 [žiūrėta 2024-03-10] Prieiga per: EBSCOhost.
18. SARAH, N. W., LESLIE, H., SHERLINNOEL, L., FORDAND, D. D. Validation of a wireless dry electrode system for electroencephalography. *Journal of NeuroEngineering and Rehabilitation* [interaktyvus]. 2015, 12, 95 [žiūrėta 2024-03-25]. Prieiga per: <https://10.1186/s12984-015-0089-2>.
19. PATRIQUE, F., CARLOS, F., EKO, S., FRANK, Z., JENS, H. A high-density 256-channel cap for dry electroencephalography. *Human Brain Mapping* [interaktyvus]. 2021, 43(4), 1295–1308 [žiūrėta 2024-03-25]. Prieiga per: <https://10.1002/hbm.25721>.
20. SHAD, E. H. T., MOLINAS, M., YTTERDAL, T. Impedance and noise of passive and active DryEEG electrodes: A review. *IEEE Sensors Journal* [interaktyvus]. 2020, 20, 24 [žiūrėta 2024-03-10]. Prieiga per: Research Gate.
21. ISTLER, R. J. A novel method for ECG artifact removal from EEG without simultaneous ECG. *44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* [interaktyvus]. Glasgow, 2022, 3582–3585 [žiūrėta 2024-04-10]. Prieiga per: IEEEExplore.
22. KWANG, J. L., CJANKI, P., BOREOM, L. Elimination of ECG artifacts from a single-channel EEG using sparse derivative method. *IEEE International Conference on Systems, Man, and Cybernetics* [interaktyvus]. 2015, 2384–2389 [žiūrėta 2024-04-10]. Prieiga per: IEEEExplore.
23. MASAKI, I., CHRISTOPH, K., ANDREAS, V. A., RICHARD, C. B., ARUN, N. K., YANNING, H. H., HANS, O. L., JOHN, L. Effects of eyelid closure, blinks, and eye movement on the electroencephalogram. *Clinical Neurophysiology* [interaktyvus]. 2005, 116, 878–885 [žiūrėta 2024-03-10]. Prieiga per: ScienceDirect.
24. JAMMISSETTY, Y., LAKHAN, D. S. Circulant singular spectrum analysis and discrete wavelet transform for automated removal of EOG artifacts from EEG signals. *Sensors* [interaktyvus]. 2023, 23, 1235 [žiūrėta 2024-03-10]. Prieiga per: <https://doi.org/10.3390/s23031235>.
25. MARCIN, J., MARCIN, K., ANDRZEJ, M. Implementation of a convolutional neural network for eye blink artifacts removal from the electroencephalography signal. *Neuroscience* [interaktyvus]. 2022, 16, 782367 [žiūrėta 2024-03-10]. Prieiga per: <https://doi.org/10.3389/fnins.2022.782367>.
26. XIAO, J., GUI-BIN, B., ZEAN, T. Removal of artifacts from EEG signals: A review. *Sensors* [interaktyvus]. 2019, 19, 987 [žiūrėta 2024-03-10]. Prieiga per: <https://10.3390/s19050987>.

27. CHAVEZ, M., et al. Surrogate-based artifact removal from single-channel EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* [interaktyvus]. 2018, 28(3), 540–550 [žiūrėta 2024-04-29] Prieiga per: <https://doi.org/10.1109/TNSRE.2018.2794184>.
28. CARLO, J. D., DONALD, G., MIKHAIL, K. B., SERGE, H. Filtering the surface EMG signal: Movement artifact and baseline noise contamination. *Journal of Biomechanics* [interaktyvus]. 2010, 43, 1573–1579 [žiūrėta 2024-03-10]. Prieiga per: ScienceDirect.
29. WON-DU, C. A., HO-SEUNG, C. A., KIWOONG, K. B., CHANG-HWAN, I. Detection of eye blink artifacts from single prefrontal channel electroencephalogram. *Computer Methods and Programs in Biomedicine* [interaktyvus]. 2016, 124, 19–30 [žiūrėta 2024-03-10]. Prieiga per: ScienceDirect.
30. ARDALAN, A., KAMRAN, K. D., REINHARD, G. B., HAMID, A. M., FABRICE, W. Detection of EEG transients in neonates and older children using a system based on dynamic time – Warping template matching and spatial dipole clustering. *NeuroImage* [interaktyvus]. 2009, 48, 50–62 [žiūrėta 2024-03-10]. Prieiga per: ScienceDirect.
31. HOLDSON, O. T. Root-mean-square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development* [interaktyvus]. 2022 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.5194/gmd-15-5481-2022>.
32. SUBASI, A. Practical guide for biomedical signals analysis using machine learning techniques. *A MATLAB Based Approach* [interaktyvus]. 2019, 193–275 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.1016/B978-0-12-817444-9.00004-0>.
33. WANLIS, J., WANLIS, G. Efficient calculation of fractal properties via the higuchi method. *Nonlinear Dyn* [interaktyvus] 2022, 109, 2893–2904 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.21203/rs.3.rs-756319/v1>.
34. ANDERSON, K., et al. Markers of central neuropathic pain in higuchi fractal analysis of EEG signals from people with spinal cord injury. *Neuroscience* [interaktyvus]. 2021, 15, 705652 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.3389/fnins.2021.705652>.
35. PICARD, R. W., et al. Toward machine emotional intelligence: analysis of affective physiological state. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [interaktyvus]. 2001, 23, 10 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.1109/34.954607>.
36. AISHARABI, K., et al. EEG-based clinical decision support system for Alzheimer's disorders diagnosis using EMD and deep learning techniques. *Human Neuroscience* [interaktyvus]. 2023, 17, 1190203 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.3389/fnhum.2023.1190203>.
37. SAFI, M. S., et al. Early detection of Alzheimer's disease from EEG signals using Hjorth parameters. *Biomedical Signal Processing and Control* [interaktyvus]. 2021, 65, 102338 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/2021.10.1016/j.bspc.2020.102338>.
38. MILIADOUS, A., et al. Alzheimer's disease and frontotemporal dementia: A robust classification method of EEG signals and a comparison of validation methods. *Diagnostics* [interaktyvus]. 2021, 11(8), 1437 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.3390/diagnostics11081437>.
39. LI, M., CHEN, W. FFT-based deep feature learning method for EEG classification. *Biomedical Signal Processing and Control* [interaktyvus]. 2021, 66, 102492 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.1016/j.bspc.2021.102492>.
40. SMITH, J. O. *Spectral Audio Signal Processing* [interaktyvus]. W3K Publishing, 2011 [žiūrėta 2024-04-10]. ISBN 978-0-9745607-3-1. Prieiga per: <https://ccrma.stanford.edu/~jos/sasp/>.

41. FOY, G. J., FOY, R. M. Dynamic changes in EEG power spectral densities during nih-toolbox flanker, dimensional change card sort test and episodic memory tests in young adults. *Human Neuroscience* [interaktyvus]. 2020, 14, 158 [žiūrėta 2024-04-10]. Prieiga per: <https://doi.org/10.3389/fnhum.2020.00158>.
42. BABAJ, N. Wavelets for EEG analysis. *IntechOpen* [interaktyvus]. 2020 [žiūrėta 2024-04-10]. Prieiga per: <http://dx.doi.org/10.5772/intechopen.94398>.
43. POSTALCIOGLU, S. Wavelet transform based feature extraction for EEG signal classification. *WSEAS Transactions on Computers* [interaktyvus]. 2021, 20, 199–206 [žiūrėta 2024-04-12]. Prieiga per: <https://doi.org/10.37394/23205.2021.20.21>.
44. SALANKAR, N. et al. Emotion recognition from EEG signals using empirical mode decomposition and second-order difference plot. *Biomedical Signal Processing and Control* [interaktyvus]. Turkija: Izmir, 2018 [žiūrėta 2024-04-12]. Prieiga per: Researchgate.
45. ORTIZ, M., et al. Analysis of the EEG rhythms based on the empirical mode decomposition during motor imagery when using a lower-limb exoskeleton. A case study. *Neurorobotics* [interaktyvus]. 2020, 14, 48 [žiūrėta 2024-04-12]. Prieiga per: <https://doi.org/10.3389/fnbot.2020.00048>.
46. RADÜNTZ, T., et al. Automated EEG artifact elimination by applying machine learning algorithms to ICA-based features. *Journal of Neural Engineering* [interaktyvus]. Berlynas: Nöldnerstr, 2017, 14, 046004 [žiūrėta 2024-05-09]. Prieiga per: <https://doi.org/10.1088/1741-2552/aa69d1>.
47. NAIK, R. G. et al. An overview of independent component analysis and its applications. *Informatica* [interaktyvus]. 2011, 35, 63–81 [žiūrėta 2024-04-09]. Prieiga per: ResearchGate.
48. THARWAT, A., et al. Linear discriminant analysis: A detailed tutorial. *AI Communications* [interaktyvus]. 2017. 30(2) 169–190 [žiūrėta 2024-05-12]. Prieiga per: <https://doi.org/10.3233/AIC-170729>.
49. MAO, W. L. EEG dataset classification using CNN method. *Journal of Physics: Conference Series* [interaktyvus]. 2020, 1456, 012017 [žiūrėta 2024-05-02]. Prieiga per: IOPScience.
50. WANG, L., et al. EEG classification based on common spatial pattern and LDA. *International Conference on Artificial Life and Robotics* [interaktyvus]. Japonija: Oita Beppu, 2020 [žiūrėta 2024-05-02]. Prieiga per: Alife-robotics.
51. ZHONGE, G., et al. A Coincidence-filtering-based approach for CNNs in EEG-based Recognition. *IEEE Transactions on Industrial Informatics* [interaktyvus]. 2019, 16, 7159–7167 [žiūrėta 2024-05-12]. Prieiga per: <https://doi.org/10.1109/TII.2019.2955447>.
52. AL-SAEIGH, A., et al. Deep learning for motor imagery EEG-based classification: A review. *Biomedical Signal Processing and Control* [interaktyvus]. 2021, 63, 102172 [žiūrėta 2024-05-02]. Prieiga per: <https://doi.org/10.1016/j.bspc.2020.102172>.
53. KANAPULI, S. S. et al. A review of deep learning models for medical diagnosis. *Machine Learning, Big Data, and IoT for Medical Informatics* [interaktyvus]. 2021, 389–404 [žiūrėta 2024-05-02]. Prieiga per: <https://doi.org/10.1016/B978-0-12-821777-1.00007-0>.
54. JURAFSKY, D., MARTIN, H. J. *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics and Speech Recognition* [interaktyvus]. Third Edition Draft, 2024, 3, 187–237 [žiūrėta 2024-05-02]. Prieiga per: Stanford edu.

55. SYAMSUNDARARAO, T., et al. An efficient signal processing algorithm for detecting abnormalities in EEG signal using CNN. *Contrast Media & Molecular Imaging* [interaktyvus]. 2022, 1502934 [žiūrėta 2024-05-02]. Prieiga per: <https://doi.org/10.1155/2022/1502934>.
56. STAUDEMEYER, C. R., MORRIS, R. E. Understanding LSTM – A tutorial into long short-term memory recurrent neural networks. *Neural and Evolutionary Computing* [interaktyvus]. 2019 [žiūrėta 2024-05-02]. Prieiga per: <https://doi.org/10.48550/arXiv.1909.09586>.
57. XIABING, D. ir kt. An efficient LSTM network for emotion recognition from multichannel EEG signals. *IEEE Transactions on Affective Computing* [interaktyvus]. 2022, 13, 3 [žiūrėta 2024-05-02]. Prieiga per: IEEEExplore.
58. CERVANTES, J., et al. A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing* [interaktyvus]. 2020, 408, 189–215 [žiūrėta 2024-05-02]. Prieiga per: <https://doi.org/10.1016/j.neucom.2019.10.118>.
59. BOUALLEGUE, G., et al. EEG person identification using facenet, LSTM-RNN and SVM. *International Multi-Conference on Systems, Signals & Devices* [interaktyvus]. Sousse: Tunisia 2020, 22–28 [žiūrėta 2024-05-02]. Prieiga per: <https://doi.org/10.1109/SSD49366.2020.9364129>.
60. KRISHNA, G., et al. *Improving EEG Based Continuous Speech Recognition Using GAN* [interaktyvus]. Texas: Austin, 2020 [žiūrėta 2024-05-02]. Prieiga per: <https://doi.org/10.48550/arXiv.2006.01260>.
61. *Brainaccess-MINI Electroencephalograph User Manual* [interaktyvus]. 2024 [žiūrėta 2024-09-36]. Prieiga per: www.brainaccess.ai.
62. GOMZALO, M. R., et al. *Study of Resting-State Functional Connectivity Networks Using EEG Electrodes Position As Seed* [interaktyvus]. 2018 [žiūrėta 2024-10-02]. Prieiga per: <https://doi.org/10.3389/fnins.2018.00235>.
63. HOHAIA, W., et al. Occipital alpha-band brain waves when the eyes are closed are shaped by ongoing visual processes. *Scientific Reports* [interaktyvus]. 2022, 12, 1194 [žiūrėta 2025-03-02]. Prieiga per: <https://doi.org/10.1038/s41598-022-05289-6>.