

KAUNO TECHNOLOGIJOS UNIVERSITETAS  
VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

IGNAS MARTIŠIUS

**DUOMENŲ SURINKIMO IR SIGNALŲ  
APDOROJIMO ALGORITMAI SMEGENŲ –  
KOMPIUTERIO SĄSAJAI**

Daktaro disertacijos santrauka  
Technologijos mokslai, Informatikos inžinerija (07T)

2016, Kaunas

Disertacija rengta 2011-2016 metais Kauno technologijos universiteto informatikos fakultete programų inžinerijos katedroje.

### **Mokslinis vadovas:**

Prof. dr. Robertas DAMAŠEVIČIUS (Kauno technologijos universitetas, technologijos mokslai, informatikos inžinerija – 07T)

### **Informatikos inžinerijos mokslo krypties disertacijos gynimo taryba:**

prof. habil. dr. Rimvydas SIMUTIS (Kauno technologijos universitetas, technologijos mokslai, informatikos inžinerija – 07T) – **pirmininkas**;

prof. dr. Aleksandr BULATOV (Lietuvos sveikatos mokslų universitetas, biomedicinos mokslai, biologija – 01B);

doc. dr. Arnas KAČENIAUSKAS (Vilniaus Gedimino technikos universitetas, technologijos mokslai, informatikos inžinerija – 07T);

doc. dr. Olga KURASOVA (Vilniaus universitetas, technologijos mokslai, informatikos inžinerija- 07T);

prof. dr. Bart VANRUMSTE (Katalikiškasis Leuven universitetas, technologijos mokslai, informatikos inžinerija – 07T).

Disertacija bus ginama viešame informatikos inžinerijos mokslo krypties disertacijos gynimo tarybos posėdyje 2016 m. balandžio 22 d. 10 val. Kauno technologijos universitete, Disertacijų gynimo salėje.

Adresas: K. Donelaičio g. 73-403, 44249 Kaunas, Lietuva. Tel. (370) 37 300 042; faks. (370) 37 324 144; el. paštas doktorantura@ktu.lt.

Disertacijos santrauka išsiųsta 2016 m. kovo 22 d. Su disertacija galima susipažinti internetinėje svetainėje <http://ktu.edu> ir Kauno technologijos universiteto bibliotekoje (K. Donelaičio g. 20, 44239 Kaunas).

KAUNAS UNIVERSITY OF TECHNOLOGY  
VILNIUS GEDIMINAS TECHNICAL UNIVERSITY

IGNAS MARTIŠIUS

**DATA ACQUISITION AND SIGNAL  
PROCESSING METHODS FOR BRAIN –  
COMPUTER INTERFACES**

Summary of Doctoral Dissertation  
Technological sciences, informatics engineering (07T)

2016, Kaunas

Doctoral dissertation was prepared in Kaunas University of Technology, Faculty of Informatics, Department of Software Engineering, during the period of 2011–2016.

**Scientific supervisor:**

prof. dr. Robertas DAMAŠEVIČIUS (Kaunas University of Technology, technology sciences, informatics engineering – 07T)

**Dissertation Defence Board of Informatics Engineering Science Field:**

prof. habil. dr. Rimvydas SIMUTIS (Kaunas University of Technology, technology sciences, informatics engineering – 07T) – **chairman**;

prof. dr. Aleksandr BULATOV (Lithuanian University of Health Sciences, biomedical engineering, biology – 01B);

doc. dr. Arnas KAČENIAUSKAS (Vilnius Gediminas Technical University, technology sciences, informatics engineering – 07T);

doc. dr. Olga KURASOVA (Vilnius University, technology sciences, informatics engineering – 07T);

prof. dr. Bart VANRUMSTE (Catholic University of Leuven, technology sciences, informatics engineering – 07T).

The official defence of the dissertation will be held at 10 a.m. on 22 April, 2016 at the public meeting of Dissertation Defence Board of Informatics Engineering Science Field in the Disertacion Defence Hall at Kaunas University of Technology.

Address: K. Donelaičio St. 73-403, 44249 Kaunas, Lithuania. Tel. no. (+370) 37 300 042; fax. (+370) 37 324 144; e-mail doktorantura@ktu.lt.

Summary of doctoral dissertation was sent on 22 March, 2016. The doctoral dissertation is available on the internet <http://ktu.edu> and at the library of Kaunas University of Technology (K. Donelaičio St. 20, 44239 Kaunas, Lithuania).

## 1. ĮŽANGA

labas

Informacijos įvedimo bei perdavimo kompiuteriams metodai keitėsi nuo perforuotų kortelių iki liečiamų ekranų ir kalbos atpažinimo. Nuolat siekiama sukurti kiek įmanoma natūralesnį bei patogesnį informacijos perdavimo būdą [Jacko, 2012].

Visai neseniai mokslo pasaulio dėmesį patraukė naujas informacijos perdavimo būdas.

Elektroencefalografija yra technologija, naudojama medicinoje smegenų būklei tirti, tačiau iškelta idėja, kad šias smegenų bangas galima panaudoti valdymo signalų perdavimui.

Net vienos smegenų siunčiamos komandos atpažinimas besikeičiančiame, triukšmų pilname signale iki šiol atrode neįtikėtinais sudėtinga problema, tačiau neurologijoje žinoma, kad kai kuriuos elektroencefalogramos (EEG) signalus žmogus geba valdyti valingai. Tai leidžia panaudoti šias bangas komandų perdavimui.

Tiesioginei smegenų– kompiuterio sąsajai (*angl.* Brain – Computer Interface) tirti gimė tarpdisciplininė tyrimų sritis, apimanti mediciną, psichologiją, matematiką bei informatiką ir tirianti žmogaus smegenų bangų panaudojimą valdymo signalams generuoti. Pirmasis šios technologijos prototipas sukurtas dr. Vidalo [Vidal, 1973]. Sistema sukurta siekiant padėti neįgaliesiems pacientams.

Viso pasaulyje priskaičiuojama apie 1 mln. pacientų, dėl įvairių priežasčių (sklerozės, širdies smūgio ar cerebrinio paralyžiaus) negalinti valdyti raumenų, tačiau psichiškai visiškai sveikų. Šie žmonės tampa įkalinti savo kūnuose, be galimybės bendrauti su pasauliu. Tiesioginė smegenų – kompiuterio sąsaja arba šia technologija paremtos išmanios sąsajos galėtų būti panaudotos pagerinti tokių žmonių gyvenimo kokybei [Cincotti et al., 2008]. Tokia sąsaja gali būti panaudota ne vien neįgaliesiems, bet ir kaip papildomas duomenų įvedimo kanalas sveikiesiems. Juo galima valdyti kompiuterinius žaidimus, suteikti papildomą realizmą praturtintos realybės taikymuose, prietaisų valdymui, nuovargio bei streso matavimui ir kt.

Nepaisant naujausių šios srities atradimų, išlieka daugybė problemų - aukšta EEG registravimo įrangos kaina, ilgas šios įrangos paruošimo darbui laikas, nepatogumas naudoti. Dėl šios priežasties, nė viena smegenų – kompiuterio sąsajos sistema kol kas netapo komerciškai sėkminga. Jei neįgalus žmogus geba valdyti bent vieną kūno raumenį, šiuo paremta sąsaja dažniausiai yra efektyvesnė nei bet kuri smegenų – kompiuterio sąsajos technologija.

### 1.1. Darbo objektas

Šio darbo objektas yra tiesioginės smegenų – kompiuterio sąsajos architektūros sukūrimas, naudojantis EEG signalą valdymui.

### 1.2. Darbo tikslas

Šio darbo tikslas yra EEG signalo apdorojimo ir klasifikavimo algoritmų tyrimas bei tiesioginės smegenų – kompiuterio sąsajos sistemos architektūros sukūrimas.

### 1.3. Darbo uždaviniai

Darbo uždaviniai yra šie:

1. Atlikti naujausių neurotechnologijos mokslo metodų bei atradimų apžvalgą. Apžvelgti šiuolaikinių BCI struktūrą.
2. Pasiūlyti EEG signalo triukšmų šalinimo metodą.
3. Pasiūlyti požymių išskyrimo algoritmą BCI sąsajai.
4. Pasiūlyti klasifikavimo metodą BCI sąsajai.
5. Sukurti veikiančią sistemos prototipą, panaudojant pasiūlytus metodus.

### 1.4. Mokslinis naujumas

Darbe pasiekti šie nauji rezultatai:

1. Pasiūlytas naujas klasėms adaptyvus signalo triukšmų šalinimo algoritmas, skirtas EEG duomenims apdoroti.
2. Siekiant pagerinti požymių išskyrimo kokybę, EEG signalo apdorojimui panaudota bangelių atomų (*angl.* Wave Atom) transformacija. Patikrinus šį metodą su standartizuotais duomenų rinkiniais įrodyta, kad jis geba kokybiškai išskirti reikšmingus požymius, taip pat sumažindamas apdorojamų duomenų kiekį.
3. Pasiūlytas naujas netiesinis operatorius, pavadintas homogeniniu daugiamačiu polinominiu operatoriumi (HDPO), skirtas signalo požymių išskyrimui. Įrodyta, kad šis operatorius tinkamas EEG požymių išskyrimui.
4. Sukurtas spartus dirbtinio neuroninio tinklo klasifikatoriaus apmokymo algoritmas su laikiniu apribojimu. Šis algoritmas tinkamas realaus laiko BCI sistemos, kurioms reikia nuolat iš naujo apmokyti klasifikatorių.

5. Pasiūlytas metodas signalo fazinės erdvės konstravimui, naudojant laiko delsos kaip realaus skaičiaus parametą.
6. Pasiūlyti metodai buvo išbandyti praktiškai naudojant tipinius EEG duomenų rinkinius ir gauti rezultatai lenkia arba nenusileidžia kitų autorių rezultatams su tais pačiais duomenų rinkiniais
7. Sukurta BCI prototipo sistema, panaudojanti Emotiv EPOC elektroencefalogramos registravimo įrenginį bei bangelių atomų transformacijos metodą.

### **1.5. Darbo rezultatų praktinė vertė**

Tiesioginė smegenų – kompiuterio sąsaja (BCI) gali būti pritaikyta neigaliams asmenims, pagerinti jų gyvenimo kokybę, bei sveikiesiems, kaip papildomas duomenų įvedimo kanalas.

Šiuo metu naudojamos BCI sistemos yra sudėtingos, brangios ir orientuotos į laboratorinę aplinką. Tai apsunkina jų vartojimą buitinėse sąlygose.

BCI sistemoms būtinas teisingas smegenų bangų klasifikavimas. Sukurti algoritmai leidžia pagerinti klasifikavimo kokybę, taigi yra naudingi kuriant BCI sistemas.

Efektyvios sistemos architektūros, tinkančios pigiems mėgėjiškiems bevielams įrenginiams, sukūrimas padarytų šią sistemą prieinama pirmiausia neigaliams vartotojams, negalintiems naudoti kitų sąsajų bendravimui.

### **1.6. Ginami teiginiai**

1. Kadangi EEG signalai yra netiesiški ir nestacionarūs, jų klasifikavimui reikalingi sudėtingi požymių išskyrimo metodai. Panaudota bangelių atomų transformacija sumažina požymių sudėtingumą bei pasiekia gerus šių požymių klasifikavimo rezultatus.
2. EEG signalui apdoroti pasitelkti netiesiniai operatoriai. Sukurtas naujas parametrizuotas netiesinių signalų operatorius. Naudojant standartinius duomenų rinkinius, pasiektas 94% klasifikavimo tikslumas.
3. BCI klasifikatoriams reikalingas nuolatinis pakartotinis apmokymas. Šiam tikslui pasiūlytas balsuojančio perceptrono klasifikatorius su laiko apribojimu. Šis metodas tinkamas realaus laiko BCI sistemų kūrimui.

4. BCI srities analizė parodė, kad nors pigūs mėgėjiško tipo įrenginiai nepajėgūs kokybiškai registruoti smegenų bangų signalų, juos galima efektyviai panaudoti tokio tipo sistemų kūrime. Sukurta 3 klasių BCI sistema, paremta SSVEP bei Emotiv EPOC įrenginiu. Šia sistema pasiektas geras naudojamumo ir tikslumo rodiklis.

### **1.7. Mokslinis pripažinimas**

Darbo tema paskelbta 15 straipsnių, iš jų 4 straipsniai – žurnaluose, įtrauktuose į "ISI Web of Science" su citavimo indeksu, 5 straipsniai – "ISI Web of Science" be citavimo indekso, 6 straipsniai - konferencijų pranešimų medžiagoje.

Tyrimų rezultatai pristatyti tiek užsienyje bei Lietuvoje vykusiose tarptautinėse konferencijose:

1. 11th International conference on Artificial intelligence and soft computing, ICAISC 2012;
2. 18th International conference on information and software technologies, ICIST 2012;
3. 18th International conference Electronics 2014, Palanga;
4. 15th International PhD Workshop OWD 2013, Wisla

### **1.8. Disertacijos struktūra**

Disertaciją sudaro 5 skyriai bei literatūros sąrašas.

Pirmame disertacijos skyriuje aprašomas tyrimo aktualumas, tyrimo objektas, sprendžiama problema, darbo tikslai ir uždaviniai, pateikiami ginami teiginiai ir praktinė pasiektų rezultatų reikšmė, pristatoma disertacijos struktūra.

Antrasis bei trečiasis skyriai yra apžvalginiai. Antrajame skyriuje analizuojama EEG signalo prigimtis ir anatomicinis pagrindas, BCI sąsajoje naudojamų EEG signalų pobūdis ir charakteristikos, BCI sąsajų valdymo paradigmos, praktiniai EEG signalų registravimo aspektai, triukšmo EEG signale šaltiniai, pristatoma BCI sistemų skirstymas, aptariami technologiniai ir netechnologiniai BCI sistemų apribojimai.

Trečiame disertacijos skyriuje analizuojami praktiniai BCI sistemų projektavimo aspektai, įskaitant tipinę BCI sistemų architektūrą, svarbiausius EEG signalo apdorojimo etapus (pradinį apdorojimą, signalo filtravimą, požymių išgavimą, klasifikavimą), BCI sistemų efektyvumo vertinimo metodus.

Ketvirtame disertacijos skyriuje aprašomi pasiūlyti metodai ir jų validavimui naudojami tipiniai EEG duomenų rinkiniai. Pateikiami atliktų eksperimentų rezultatai, aprašoma disertanto sukurta eksperimentinė 3 valdymo klasių BCI sistema, leidžianti praktiškai pademonstruoti pagrindinius BCI sistemų kūrimo principus, o taip pat atlikti tokių sistemų mokslinius tyrimus. Sistemoje naudojamas bangelių atomų transformacijos metodas, pritaikytas EEG signalų apdorojimui. Pasiękti rezultatai rodo, kad nagrinėti EEG signalų apdorojimo ir klasifikavimo metodai gali būti naudojami realioje BCI sistemoje, o 3 valdymo klasių BCI sistema gali būti praktiškai naudojama nesudėtingoms užduotims atlikti (pvz., valdyti virtualaus objekto judėjimą dvimatėje plokštumoje).

Penktajame skyriuje pateikiamos darbo išvados.

## 2. ELEKTROENCEFALOGRAFIJOS PAGRINDAI

Žmogaus smegenys sudarytos iš  $10^{12}$  neuronų. Neuronai sujungti vienas-su-daug arba daug-su-daug ryšiais, panašiai kaip loginiai elementai skaitmeninėje mikroschemoje [Buzsaki, 2006].

Skirtingi smegenų regionai atsakingi už skirtingus žmogaus kūno bei kognityvinius veiksmus, tačiau visi jie sujungti į vieną bendrą tinklą informacijos apsikeitimui.

Smegenų žievė yra išorinis, 2-4 mm storio smegenų sluoksniu tiesiai už kaukolės kaulo. Ši smegenų dalis atsakinga už tokias žmogaus kūno funkcijas kaip mastymas, kalba, sąmonė, atmintis, dėmesys ir kiti aukšto lygmens mastymo procesai. Žievė pagal savo atliekamas funkcijas dažnai dalinama į motorinę sritį, somatosensorinę sritį, vizualinę sritį ir pan.

Smegenų neuronai informaciją perduoda elektriniais impulsais, sukuriamais nervinių ląstelių. Pagrindinis elektroencefalogramos (EEG) signalo šaltinis yra smegenų žievės neuronų impulsai. Perėjęs kaukolę ir minkštuosius audinius, šis signalas gali būti užregistruojamas jautriais prietaisais, ant paciento galvos pritaisius elektrodus, matuojančius elektrinių potencialų skirtumą. Tam, kad signalas būtų aptinkamas, būtina daugelio greta esančių neuronų aktyvacija vienu metu, todėl EEG signalas nėra vieno neurono generuojamas impulsas, bet daugelio neuronų aktyvacijos suminis signalas. Encefalografija yra metodas elektros potencialams skirtingose smegenų srityse aptikti ir juos atvaizduoti grafiškai.

EEG įrašymas dažniausiai vyksta neinvaziniu būdu, naudojant mažus elektrodus su metalo plokšte. Dažniausiai naudojami nepoliarizuojantys sidabro chlorido elektrodai. EEG signalo įtampa yra 5-10  $\mu\text{V}$  ei-

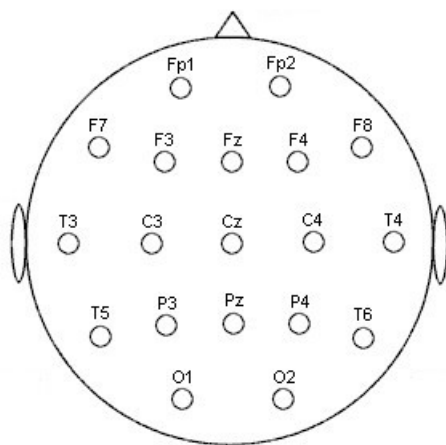
lės, todėl elektrodai bei stiprintuvai privalo būti ypač jautrūs. Signalas skaitmenizuojamas ir išsaugomas peržiūrai bei analizei kompiuteryje.

Kadangi EEG skirtinguose smegenų regionuose rodo tai smegenų sričiai būdingus signalus, būtina įrašinėjant atsižvelgti į elektrodo vietą galvoje.

Norint standartizuoti elektrodų išdėstymą, Tarptautinė Elektroencefalografijos ir Klinikinės neurologijos Federacija (IFSECN) priėmė Jasper [Jasper, 1958] pasiūlytą sistemą, vadinamą 10–20, pavaizduotą 2.1 pav.

"10" bei "20" reiškia, kad elektrodai išdėstomi kas 20% kairės – dešinės bei priekio–galo atžvilgiu žmogaus galvoje lanku, nutolusiu nuo nosies bei (inion) taškų 10% galvos lanko ilgiu.

Ši sistema leidžia standartizuoti ir sistemingai tirti bei palyginti EEG duomenis. Elektrodai sistemoje pažymimi raidėmis, atitinkančiomis po jais esančias smegenų sritis: F – frontalinę, C – centrinę, P – parietalinę, T – temporalinę, O – oksipitalinę. Skaičius esantis po raidės žymi elektrodo padėtį.



**2.1 pav.:** Tarptautinė 10–20 elektrodų išdėstymo sistema

Išmatuojamas EEG aktyvumas gali būti skirstomas į spontaniškus ir su įvykiais susietus potencialus. Spontaninis EEG stebimas, kai pacientas nestimuliuojamas. Toks aktyvumas gali parodyti protines būsenas, tokias kaip susikaupimą, judesių planavimą, skaičiavimą mintyse.

Su įvykiais susieti potencialai (*angl.* event-related potentials,

ERP) skiriasi nuo spontaniškų, nes atsiranda tik išoriškai stimuliuojant pacientą. Šių įvykių analizė atliekama tiriant EEG laiko intervale iškart po stimulo pasirodymo. Stimuliavimui gali būti naudojamas garso signalas, šviesos šaltinis, fizinis (somatosensorinis) kontaktas ir pan.

Stimuliuojama dažniausiai pakartotinai keletą ar kelias dešimtis kartų. Su įvykiais susietų potencialų amplitudė yra apie 10 kartų mažesnė už spontaninio EEG foną, todėl jam aptikti atliekamas daugelio bandymų vidurkinimas.

Sukeltieji potencialai (*angl.* Evoked potentials) yra su įvykiais susietų potencialų poaibis, sukeliamas dėmesio sutelkimo į tam tikrą periodinę stimuliaciją (vaizdinę [Raudonis et al., 2008], garsinę [Rance et al., 1995], somatosensorinę ir pan.), ir EEG signale pasireiškia tuose pačiuose dažnių spektro ruožuose, kaip ir stimuliuojantis signalas. Tai gali būti paaiškinama smegenų neuronų apdorojamos informacijos ir jų aktyvacijos sutapimu, pvz.: stebint mirksintį šviesos šaltinį, virš oksipitalinėje smegenų srityje, atsakingoje už vaizdo apdorojimą, stebimas su stimuliavimu sutampančio dažnio signalas.

Atlikta keletas tyrimų, rodančių padidėjantį aktyvumą sukeltą mirgančio vaizdinio stimulo, kai pacientas atkreipia į jį dėmesį [Bi et al., 2013]. Šie tyrimai parodė, kad pacientui pateikus keletą skirtingu dažniu mirksinčių stimulų, didesnę pokytį EEG signalui sukelia tas, į kurį tuo metu nukreiptas paciento dėmesys. Šį signalą taip pat įtakoja stimulo spalva [Shyu et al., 2013], atstumas tarp skirtingų stimulų [Resalat et al., 2012], jų forma. Taigi dėmesio atkreipimas gali būti panaudojamas tiesioginei smegenų-kompiuterio sąsajai kurti.

## 2.1. EEG triukšmų šaltiniai

Kiekvienas EEG signalo pasikeitimas, nesukeltas žmogaus smegenų, laikomas triukšmu. Šie triukšmai gali būti biologinės arba techninės prigimtys. Biologinės prigimtys triukšmai:

- Akių mirksėjimo triukšmas
- Širdies pulso triukšmai
- Elektrokardiogramos triukšmas
- Raumenų triukšmas
- Galvos judėjimo triukšmai
- Odos ir prakaitavimo triukšmai

Techniniai triukšmai:

- Elektrodu bei jungiamųjų laidų triukšmai
- 50 Hz elektros linijų triukšmas
- Elektrostatiniai trikdžiai

## 2.2. BCI sistemų klasifikacija

Nėra standartinio apibrėžimo, kas tiksliai yra BCI. Skirtingi autoriai šį terminą aprašo skirtingai, taip keldami neaiškumo mokslinėje literatūroje ir viešojoje erdvėje. [Bayliss, 2001] aprašo BCI sąsają kaip naudojančią išskirtinai smegenų sukurtus signalus, tačiau tokia sistema neleidžia turėti net grįžtamojo ryšio, pvz. kompiuterio ekrano. Šioje disertacijoje BCI sistema laikoma papildomu valdymo kanalu tarp žmogaus ir kompiuterio, kaip ją aprašo [Wolpaw et al., 2002]: "priklausoma BCI sistema yra technologija, keičianti smegenų generuojamus signalus į iš anksto apibrėžtas komandas, skirtas komunikacijai su kitais žmonėmis ar išoriniais prietaisais, nenaudojant kūno raumenų".

Sistemos gali būti skirstomos į sukeltų potencialų ir savireguliacijos BCI. Pirmoji sistemų klasė veikia analizuodama stimuliacijai sukeltus smegenų signalus, pvz.: mirksinčias raides ekrane [Farwell and Donchin, 1988]. Antroji klasė išnaudoja smegenų savireguliacijos funkciją. Pastarojoje, subjektai išmoka valdyti tam tikrus smegenų bangų parametrus, atpažįstamam valdymo signalui gauti.

Invazinis ir neinvazinis skirstymas remiasi tuo, koku būdu ant paciento galvos montuojami elektrodai. Invazinis metodas yra chirurginis, įsodinant elektrodus į neuroninį audinį, ir atliekant vieno neurono srovės matavimą [Kennedy et al., 2000] arba elektrokortikogramos matavimus [Lal et al., 2005].

Neinvaziniai matavimai apima EEG [Vidal, 1973], artimą infraraudonajai spektroskopiją (*angl.* near infrared spectroscopy - NIRS)[Falk et al., 2011], ir funkcinį magnetinį rezonansą [Menon et al., 2013].

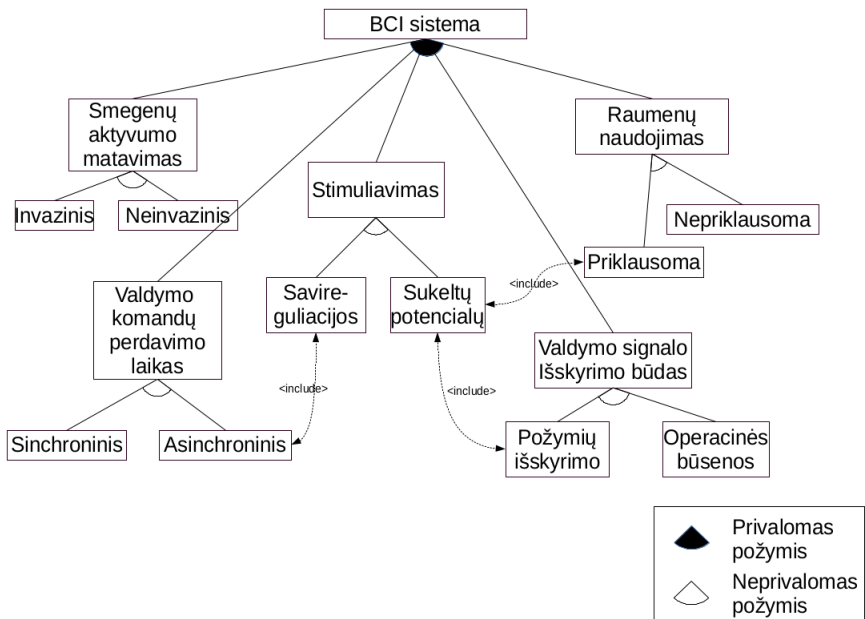
Požymių išskyrimu ir operacine būseną grindžiamas skirstymas paremtas tuo, koku būdu išgaunami valdymo signalai: požymių klasifikavimo BCI sistemos remiasi signalo apdorojimo metodais, išskiriančiais reikšmingus klasifikavimui signalo požymius. Pačiam vartotojui nereikia mokytis valdyti sistemos. Sistemos algoritmas apmokomas atpažinti valdymo signalus pagal konkretaus vartotojo smegenų bangas. Operacinės būsenos BCI sistemoje pacientas išmoka valingai valdyti tam tikrą savo EEG parametrai grįžtamojo ryšio pagalba.

Priklausomos ir nepriklausomos sistemos skirstomos pagal tai, ar sąsajos valdymui reikalingi raumenys. Jei naudojamas grįžtamasis ry-

šys arba regos sutelkimas, sistema laikoma priklausoma. Jei sistemai raumenų naudojimas nereikalingas, ji laikoma nepriklausoma.

Sinchroninės ir asinchroninės BCI sistemos skirstomos pagal tai, ar vartotojas pats nustato, kada perduoti valdymo signalus sąsaja, ar sistema turi tam tikrus laiko intervalus, kuomet įmanoma taip padaryti. Sinchroninė BCI laikoma sistema, leidžianti komunikaciją tik tam tikrais laiko intervalais. Tokiu būdu protinis aktyvumas kontroliuojamas išoriškai, ir duomenys analizuojami tam tikrame laiko intervale. Dauguma šiuolaikinių BCI sistemų yra sinchroninės.

Grafiškai ši klasifikacija gali būti pavaizduota požymių diagrama 2.2 pav. [Damasevicius and Stuiksys, 2009]. Priklausomai nuo stimuliacijos ar savireguliacijos buvimo, kyla apribojimai sistemos priklausomumui bei sinchroniškumui.



2.2 pav.: BCI sistemų klasifikavimo požymių diagrama

### 3. SMEGENŲ-KOMPIUTERIO SĄSAJOS PROJEKTAVIMAS

#### 3.1. Tipinė BCI sistemos struktūra

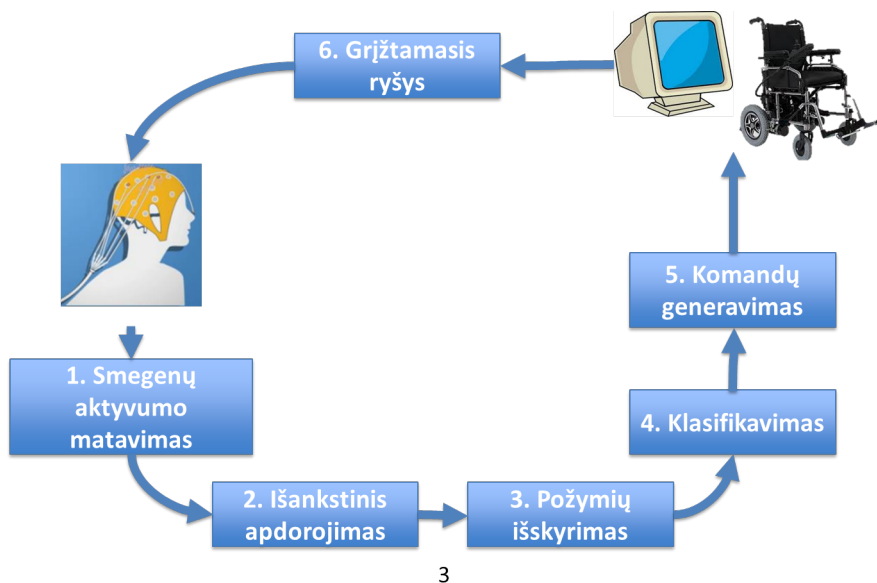
BCI sistemos naudojimą sudaro du etapai:

1. Apmokymo etapas, kuriame:
  - vartotojas išmokomas valdyti savo smegenų bangas (savaiminio reguliavimo BCI sistemos atveju), arba
  - klasifikavimo algoritmo apmokymo, kurio metu sistemos klasifikatorius kalibruojamas kad atskirtų valdymo signalus (požymių išskyrimu grįstos BCI sistemos atveju).
2. Darbinio etapo, kuriame sistema yra naudojama vartotojo.

Šioje disertacijoje didesnis dėmesys skiriamas požymių išskyrimu paremtoms sistemoms, todėl dažniausiai koncentruojamasi ties būtent tokios sistemos veikimu.

Dariniame režime, BCI sistema atlieka šešių veiksmų seką [Mason and Birch, 2003], pavaizduotą 3.1 pav.

1. Smegenų aktyvumo matavimo žingsnyje elektrodai surenka EEG signalą tam tikruose galvos regionuose. Šiame žingsnyje svarbu pasirinkti elektrodų kiekį ir išdėstymą, stiprinimą, analoginį filtravimą bei skaitmeninimą. Pagrindinis EEG signalo aktyvumas yra 0.2 - 40 Hz ribose, todėl atliekamas filtravimas šiame dažnyje. Prieš apdorojimą signalas segmentuojamas fiksuoto ilgio, dažniausiai persidengiančiais, intervalais. Tai leidžia apskaičiuoti signalo vidurkį, taip palengvinant požymių išskyrimą bei klasifikavimą.
2. Išankstinio apdorojimo žingsnyje šalinami signalo triukšmai. Tai atliekama šalinant žinomus signalo triukšmus arba tam tikrus kanalus, taikant skaitmeninio signalo apdorojimo metodus. Dažniausiai naudojami filtrai (FIR bei IIR) bei kiti DSP metodai.
3. Požymių išskyrimo žingsnyje signalas aprašomas keletu svarbią signalo informaciją išsaugančių koeficientų. Šie koeficientai dažnai vadinami signalo požymiais. Požymių išskyrimo metodas dažniausiai charakterizuoja BCI sistemą. Stengiamasi pasirinkti požymius, atsparius triukšmui bei variacijoms tarp skirtingų sistemos vartotojų. Dažniausiai BCI sistemose pasitaikantys požymių išskyrimo metodai yra paremti laikinėmis signalo charakteristikomis, pvz.: signalo



**3.1 pav.:** Tipinės BCI sąsajos funkcionalumas

amplitudės skirtinguose kanaluose naudojimas, autoregresijos parametrai [Wang et al., 2010], Hjorth parametrai [Hjorth, 1970] arba dažnių spektro požymiai, tokie kaip spektro galia, galios tankis.

4. Svarbiausias žingsnis sąsajoje yra teisingai atpažinti valingai valdomus neurofiziologinius parametrus ir juos klasifikuoti. Tai atliekama ankstesniame žingsnyje išskirtai požymių grupei priskiriant vieną iš klasių, dažniausiai žinomų bei aprašytų iš anksto. Klasifikavimui dažniausiai naudojami mašininio mokymo algoritmai, vadinami klasifikatoriais [Verikas and Gelžinis, 2008]. Šiems algoritms iš pradžių pateikiami apmokymo duomenys, susidedantys iš požymių vektoriaus ir šiam vektoriui iš anksto priskirtos žinomos klasės žymės. Tokiu būdu klasifikatorius "išmoksta" priskirti klasę naujam, nežinomam požymių vektoriui. Dažniausiai BCI sistemoje naudojami klasifikatoriai yra:

- tiesiniai klasifikatoriai, tokie kaip tiesinė diskriminantinė analizė (*angl.* linear discriminant analysis - LDA), atraminių vektorių metodas (*angl.* support vector machine - SVM),

- dirbtiniai neuroniniai tinklai, pvz. daugiasluoksnis perceptronas,
- netiesiniai Bayeso klasifikatoriai,
- artimiausio kaimyno klasifikatoriai,
- įvairios klasifikavimo algoritmų kombinacijos.

## 4. METODAI

Pagrindinis disertacijos dėmesys skiriamas požymių išskyrimo algoritams. Šiame skyriuje pasiūlyta keletas naujų požymių išskyrimo metodų, taikytinų BCI sistemose. Sukurti algoritmai buvo testuoti su standartiniais duomenų rinkiniais.

### 4.1. Duomenų rinkiniai

Literatūroje daug kalbama apie standartizuotą eksperimentų rezultatų palyginimą. Dėl šios priežasties, sukurtas Berlyno smegenų - kompiuterio sąsajos projektas (*angl.* Berlin Brain-Computer Interface - BBICI). Šio projekto ribose vykdomas BCI konkursas gali būti laikomas vienu standartizavimo bandymu. Kasmetiniame konkurse pateikiami 3-5 duomenų rinkiniai, suskirstyti į testavimo ir bandymo duomenų imtis. Konkurso tikslas - pateikti algoritmus, gebančius kuo tiksliau suklasifikuoti duotus duomenis. Viso būta 4 tokių konkursų, paskutinis vykdytas 2008 m. Šių konkursų duomenų rinkiniai iki šiol naudojami algoritmų palyginimui. Šiame darbe taip pat naudojami BBICI konkursų duomenys.

### 4.2. BCI konkurso II duomenų rinkiniai Ia bei Ib

Duomenys surinkti iš sveikų pacientų. Pacientų buvo prašoma judinti kursorių kompiuterio ekrane aukštyn ir žemyn, tuo pat metu įrašinėjant jų EEG.

Pacientams buvo pateikiamas grįžtamasis ryšys, priklausomai nuo jų lėtųjų žievinių potencialų Cz kanale. Potencialo padidėjimas sukeldavo kursoriaus judėjimą į viršų, o mažėjimas - žemyn. Kiekvienas bandymas truko 6 sekundes. Kiekvieno bandymo metu, ekrano viršuje arba apačioje būdavo pavaizduojamas ryškus taikiny, kurį pacientas turėdavo pasiekti kursoriumi. Vaizdavimas prasidėdavo prabėgus 0.5 sekundės nuo testo pradžios ir būdavo rodomas iki testo galo. Grįžtamasis ryšys pateikiamas nuo 2 sekundės iki 5.5 sekundės. Duomenyse pateikiamas tik šis 3.5 sekundės trukmės laiko intervalas. Diskretizavimo dažnis 256 Hz. Viso 268 bandymai su 5 skirtingais žmonėmis. Tikslas - atskirti,

kada kursorius judinamas žemyn, o kada - aukštyn.

### 4.3. BCI konkurso II duomenų rinkinys IV

Duomenys surinkti iš sveikų pacientų be grįžtamojo ryšio. Pacientui reikėjo klaviatūra rinkti laisvai pasirinktą tekstą kairiuoju ir dešiniuoju rodomuoju pirštu. Tikslas - atskirti, kuria ranka, kaire ar dešine, buvo ruošiamasi rašyti. Viso pateikiami 416 bandymų.

### 4.4. Klasėms adaptyvus signalo triukšmų šalinimas

Atliekant signalo triukšmų šalinimą, tiesiniai metodai, tokie kaip FIR filtrai, turi neigiamų pasekmių, ypač esant siaurai filtruojamų dažnių juostai. todėl dažnai naudojami netiesiniai triukšmų šalinimo metodai, pasitelkiant bangelių (*angl.* wavelet) transformacijas.

Triukšmų šalinimas bangelių transformacijomis remiasi prielaida, kad ribotas skaičius žemo dažnio transformacijos koeficientų neša pagrindinę signalo informaciją. Jų atrinkimui pasinaudojama slenkstine funkcija, atrenkančia šalinamus aukšto dažnio transformacijos koeficientus, tačiau paliekančia tuos, kuriuose sukonzentruota signalo informacija. Tikslus slenkstinės funkcijos parinkimas išlieka aktualia problema bangelių transformacijose.

Triukšmų šalinimo rezultatus galima pagerinti, jei slenkstinė funkcija pasirenkama individualiai kiekvienai signalo dažnių juostai. Tokie metodai naudojami šiuolaikinėse sistemose, pvz. SureShrink [Donoho, 1995].

Mūsų pasiūlyto metodo naujumas yra klasėms adaptyvus nutriukšminimo metodas optimaliam slenkstinės funkcijos parametų parinkimui. Parametrai parenkami remiantis atstumu tarp iš anksto žinomų testinių duomenų rinkinio klasių.

Tarkime kad stebimas signalas  $X(t) = S(t) + N(t)$ , susideda iš tikrojo signalo su pridėtinio triukšmu  $N(t)$  laiko momentu  $t$ . Jei  $T(\cdot)$  bei  $T^{-1}$  – tiesioginės bei atvirkštinės transformacijos operatoriai. Taip pat jei  $H(Y, \Lambda)$  – triukšmo šalinimo operatorius su parametų rinkiniu  $\Lambda = (\lambda_1, \lambda_2, \dots, \lambda_k)$ , tuomet nutriukšminimo algoritmą galima aprašyti šiais žingsniais:

1. Apskaičiuoti DSP transformaciją signalui su triukšmu  $X(t) : Y = T(X)$ ;
2. Atlikti parametų atrinkimą dažnių spektre  $\hat{Y} = H(Y, \Lambda)$ ;
3. Apskaičiuoti atvirkštinę transformaciją, gaunant nutriukšmintą signalą  $\hat{S}(t)$ .

Šis algoritmas gali veikti prastai, jei signalas bei triukšmas turi daug komponentų, kaip EEG signale. Slenkstinės funkcijos pasirinkimas taip pat problematiškas dėl literatūroje siūlomų funkcijų bei jų parametrų kiekio. Norint išspręsti šią problemą, reikia algoritmui suteikti adaptyvumo. Klasėms adaptyvus signalo triukšmų šalinimo algoritmas aprašomas taip: tarkime kad  $P$  bei  $Q$  yra teigiama ir neigiama klasės dviejų klasių duomenų rinkinyje. Jei  $D(X_P, X_Q)$  yra atstumo tarp duomenų rinkinio  $X_P$  bei  $X_Q$ , priklausančių  $P$  bei  $Q$  klasėms. Slenkstinės funkcijos parametrus optimizuojame kiekvienai dažnių komponentei  $f$  atskirai, kai tikslo funkcija yra 1

$$\Psi(X_P, X_Q) = \max_{\Lambda} D(H(T(X_P), \Lambda), H(T(X_Q), \Lambda)). \quad (1)$$

čia  $D$  – atstumas tarp klasių. Šiam atstumui skaičiuoti naudojamos Fisherio bei Hellingerio atstumo metrikos.

Pasiūlyto triukšmų šalinimo metodo žingsniai yra:

1. Pritaikyti signalui bangelių transformaciją;
2. Kiekvienai dažnių juostai  $f$ :
  - maksimizuoti atstumą tarp teigiamos bei neigiamos klasių komponentių, parenkant slenkstinės funkcijos parametrų rinktinį  $\Lambda$ ;
  - išsaugoti  $\Lambda$  vertę, duodančią didžiausią atstumą  $\Lambda_{max}$ .
3. Atlikti reikšmių išmetimą remiantis  $\Lambda_{max}$  funkcijos koeficientais;
4. Gauti signalą be triukšmų, atliekant atvirkštinę bangelių transformaciją.

Eksperimentai buvo atlikti optimizuojant parametrus populiarioms literatūroje siūlomoms slenkstinėms funkcijoms. Panaudotas BB-CI Ia duomenų rinkinys, atlikta 5 kartų kryžminė validacija. Klasifikavimas atliktas atraminių vektorių metodu (SVM). Klasifikavimo kokybei nustatyti matuota F reikšmė (F - measure), plotas po kreive (area under the curve, AUC), vidutinis tikslumas. Rezultatai su Fisherio atstumu pateikti 1 lentelėje. Gauti rezultatai yra panašūs, o kai kuriais atvejais pralenkia kitų autorių gautus rezultatus su šiuo duomenų rinkiniu.

Šiuo metodu gauti rezultatai nenusileidžia kitų autorių rezultatams su šiuo duomenų rinkiniu.

**1 lentelė:** Eksperimento rezultatai su Fisher atstumo metrika

Slenkstinė funkcija	Parametrų kiekis	F	AUC	Vid. tikslumas
Nenaudota	-	80.36	90.06	91.45
Kieta	1	83.84	91.53	92.60
Minkšta	1	78.18	88.60	89.97
Norouzzadeh	1	79.16	87.76	90.07
Hyperbolinė	1	81.42	88.60	91.26
Hyper	2	85.37	90.87	91.44
Mrazek	2	74.65	87.23	89.71
<b>Yang</b>	<b>3</b>	<b>88.79</b>	<b>94.45</b>	<b>94.64</b>
<b>Atto</b>	<b>3</b>	<b>88.16</b>	<b>94.38</b>	<b>94.67</b>

#### 4.5. Bangelių atomų transformacijos pritaikymas

Siekiant efektyvaus EEG signalų klasifikavimo, būtinas požymių erdvės sumažinimas. Kadangi BCI sistemos yra priklausomos nuo vartotojo būsenos (nuovargio, streso), sistemos klasifikatoriaus apmokymo žingsnį reikia periodiškai kartoti. Naudojant didelius duomenų rinkinius, požymių erdvės sumažinimas išsprendžia ilgo apmokymo laiko problemą.

Bangelių atomų transformacija (angl. Wave Atom Transform – WAT.) [Demanet and Ying, 2007] atlieka multirezoliucinę signalo analizę. Bangelių atomai yra atskiras bangelių transformacijos variantas, galintis aprašyti signalą mažesniu koeficientų skaičiumi.

Kiek mums žinoma, ši transformacija pirmą kartą panaudota analizuojant EEG signalus.

Požymių klasifikavimui panaudotas tiesioginio sklidimo dirbtinis neuroninis tinklas. Eksperimente matuotas klasifikavimo tikslumas, F1 metrika bei tinklo apmokymo laikas. Klasifikavimo rezultatai pateikiami 2 lentelėje. Palyginimui pateikiami neapdorotų duomenų (RAW) bei diskrečiosios kosinusinės transformacijos koeficientų (DCT) klasifikavimo rezultatai.

Iš 2 lentelės matyti, kad bangelių atomų transformacijos naudojimas gali sumažinti tinklo apmokymo laiką bei padidinti tikslumą, lyginant su kitomis požymių išskyrimo transformacijomis. Gauti rezultatai

## 2 lentelė: Klasifikavimo tikslumo ir apmokymo spartos palyginimas

Požymiai	neuronų sk.	Tikslumas, %	F1	Laikas, s
RAW	5	84	0.84	11906
DCT	15	85	0.85	40
WAT	2	<b>90</b>	<b>0.90</b>	<b>1.1</b>

taip pat atitinka kitų autorių gautus rezultatus, taigi galima teigti, kad transformacija sumažina duomenų rinkinį, neprarasdama reikalingos klasifikavimui signalo informacijos.

### 4.6. Netiesinių operatorių taikymas

Pastaruoju metu BCI literatūroje daug dėmesio susilaukė netiesiniai operatoriai, tokie kaip Teager-Kaiser energijos operatorius (TKEO). Šis metodas gerai aptinka aukšto dažnio mažos amplitudės dedamąsias analizuojamame signale. Šis energijos operatorius kartu atsižvelgia ir į signalo amplitudę ir į dažnį.

TKEO operatorius gali būti apibendrinamas homogeniniu daugia- mačiu polinominiu operatoriumi (HDPO)  $\Psi_m^k[x(t)]$ , kur antros eilės HDPO gali būti aprašomas lygtimi 2.

$$\Phi_k^2[x(n)] = \sum_{i=-z}^z \sum_{j=-z}^z A_{ij} x(n+i)x(n+j), \quad (2)$$

kur  $z = \lfloor m/2 \rfloor$ , ir  $A$  yra koeficientų matrica.

Trečios eilės HDPO gali būti aprašomas 3:

$$\Phi_k^3[x(n)] = \sum_{i=-z}^z \sum_{j=-z}^z \sum_{k=-z}^z A_{ijk} x(n+i)x(n+j)x(n+k). \quad (3)$$

Operatorius pasižymi šiomis savybėmis:

- Simetrija. Signalo apsukimas laike nepakeičia rezultato;
- Operatorius nepraranda reikšmės, signalui pereinant 0.
- Sudėtingumas. Operatoriaus sudėtingumas yra  $O(m^k)$ .

Eksperimentui panaudotas duomenų rinkinys Ia. Palyginimui signalas apdorotas šiais operatoriais: TKEO , TKEO-Volterra, VTEO, VTEO-Volterra, DEO bei mūsų pasiūlytu HDPO. Rezultatai pavaizduoti 3 lentelėje

**3 lentelė:** Eksperimento, naudojant skirtingus polinominius operatorius rezultatai

Operatorius	Klasifikavimo kokybė				
	Tikslumas.	Prec.	Rec.	F1	AUC
Jokio	0.7800	0.7462	0.8501	0.7891	0.9018
TKEO	0.4740	0.4805	0.7527	0.5849	0.4670
TKEO-Volterra	0.5931	0.5657	0.7889	0.6583	0.5428
VTEO	0.5635	0.5415	0.8051	0.6466	0.6500
VTEO-Volterra	0.4813	0.4207	0.5330	0.4214	0.1381
DEO	0.5262	0.5160	0.7202	0.6063	0.5851
<b>HMPO (3)</b>	<b>0.8283</b>	<b>0.8042</b>	<b>0.8727</b>	<b>0.8349</b>	<b>0.8450</b>

Šio eksperimento rezultatai parodo, kad 3-ios eilės netiesiniai operatoriai, tokie kaip HDPO gali išgauti geresnius požymio išskyrimo rezultatus nei 2-osios eilės operatoriai.

#### 4.7. Signalų fazinės erdvės konstravimas, naudojant realiųjų skaičių laiko delsos parametą

Kaip jau minėta, EEG signalas gali būti laikomas chaotišku ir dažniausiai yra analizuojamas netiesiniais metodais.

Mes pasiūlėme metodą signalo fazės erdvės konstravimui, naudojant realiuosius skaičius. Šis metodas praplečia klasikinę fazinės erdvės konstravimo modelį.

#### 4.8. Realios laiko balsuojančio perceptrono apmokymo algoritmas

Siekiant spartesnio klasifikatoriaus apmokymo, buvo pasiūlytas balsuojančio perceptrono – vieno dirbtinio neuroninio tinklo variantų - apmokymas su laikiniais apribojimais. Eksperimente taip pat buvo tirtas duomenų rinkinio sumažinimas gretimų reikšmių vidurkinimo (subsamp-

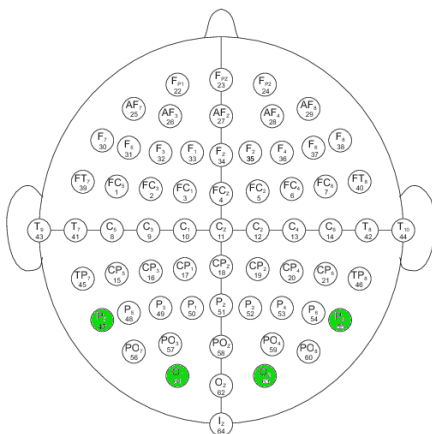
ling) bei atrinkimo (row sampling) metodais.

Rezultatai parodė, kad duomenų rinkinio sumažinimas iki tam tikros ribos, gali pagreitinoti tinklo apmokymą, ženkliai nesumažinant klasifikavimo kokybės. Klasifikavimo rezultatai taip pat nenukenčia nuo apmokymo laiko apribojimų, kadangi šis metodas neleidžia tinklui per daug prisitaikyti prie duomenų.

#### 4.9. Pasiūlyta sistemos architektūra

Šiame skyriuje aprašomas sistemos prototipas, sukurtas remiantis ankstesniuose skyriuose pasiūlytais metodais. Prototipo kūrimo tikslas – sukurti draugišką vartotojui sistemą už prieinamą kainą, galinčią sugeneruoti 3 valdymo komandas būtiniausiai asmens veiklai užtikrinti, pvz. neįgaliojo vežimėliui valdyti.

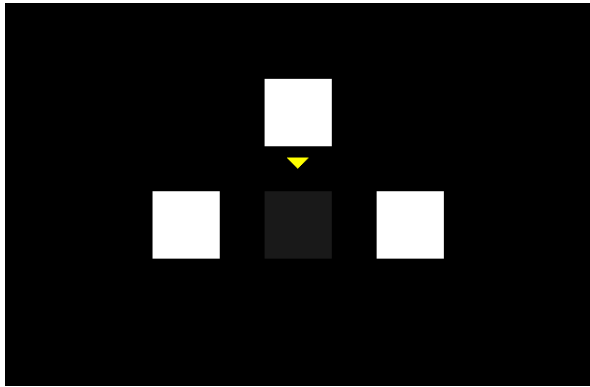
Sistema veikia nepertraukiamai, ir pati nusprendžia, kada vartotojas išduoda valdymo signalus o kada ne, t.y. turi valdymo būseną, kai generuojami valdymo signalai, ir laukimo būseną, kai vartotojas gali užsiimti kitais veiksmiais, negeneruodamas valdymo signalų. Šiai sistemai pasirinktas Emotiv EPOC elektroencefalogramos registravimo įrenginys, galintis efektyviai registruoti EEG signalus oksipitalinėje smegenų dalyje. Eksperimento metu naudoti duomenys, gaunami iš 4 sensorių. Jų išdėstymas pavaizduotas 4.1 pav. Valdymui pasirinkta dėmesiu valdomų sukeltų potencialų (*angl.* Steady State Visually Evoked Potentials – SSVEP) paradigma. Kūrimui panaudota OpenVIBE platforma bei BBCI Matlab įrankiai.



4.1 pav.: Sensorių išdėstymas SSVEP sąsajos eksperimente

Pilnas sistemos naudojimas realizuojamas 4 OpenVibe platformos scenarijais, apimančiais šias dalis:

1. Pasiruošimo scenarijus skirtas įsitikinti, ar EEG signalas kokybiškai įrašomas visuose kanaluose
2. Apmokymo duomenų surinkimo scenarijus skirtas surinkti duomenų imtį iš vartotojo, kuri vėliau panaudojama klasifikavimo algoritmo apmokymui. Siekiama surinkti kiek galima daugiau duomenų, todėl pasirinkta atlikti 20 bandymų kiekvienai klasei, taigi viso 60 bandymų, atsitiktine tvarka. Tai atliekama pasitelkiant grafinę sąsają, pavaizduotą 4.2 pav.

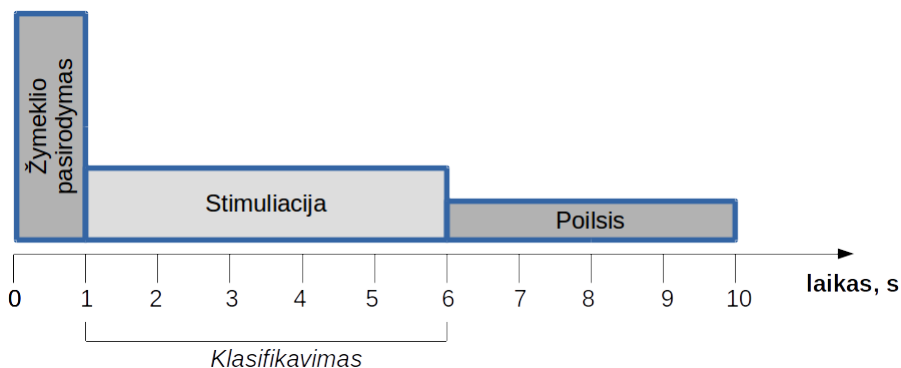


**4.2 pav.:** Apmokymo duomenų surinkimo grafinė sąsaja

Sąsają sudaro skirtingu dažniu mirksintys balti kvadratiniai taikiniai bei geltona rodyklė - indikatorius, rodomi kompiuterio LCD ekrane. Eksperimentiškai trims klasėms pasirinkti atitinkamai 30 Hz, 20 Hz bei 12 Hz stimuliavimo dažniai. Kiekvienas bandymas trunka 10 s. Testo eiga pavaizduota 4.3

Prasidėjus bandymui, geltonas indikatorius nurodo vartotojui, į kurį taikinį atkreipti savo dėmesį. Vartotojo EEG signalai, kartu su klasės žymėmis bei laikine informacija išsaugomi kompiuteryje.

3. Klasifikatoriaus apmokymo etape duomenys surinkti ankstesniame žingsnyje yra apdorojami. Tam atrenkami reikalingi kanalai, signalas segmentuojamas, šalinami triukšmai bei išskiriami požymiai. Požymių išskyrimui panaudojama bangelių atomų transformacija. Eksperimente naudojami atraminių vektorių bei tiesinės diskriminantinės analizės klasifikatoriai. Šie klasifikatoriai geba atskirti



**4.3 pav.:** Testo eiga, išdėstyta laike

tik dvi klases, todėl trijų klasių problemai spręsti jie yra apmokomi visi-prieš-vieną metodu, t.y. panaudojami 3 vienodi klasifikatoriai, atskiriantys kiekvieną iš trijų klasių individualiai.

4. Realus laiko veikimo scenarijus leidžia išbandyti sistemos veikimą. Vartotojui pateikiama sąsaja, vaizduojanti "kosminį laivą", sudarytą iš trijų skirtingu dažniu mirksinčių taikinių - "variklių" - kvadratų bei "patrankos" - trikampio. Laivas gali suktis kairėn, dešinėn, bei šaudyti, sukoncentravus dėmesį į atitinkamai kairįjį, dešinįjį arba centrinį taikinį. Fiksuotais laiko intervalais greta laivo atsiranda raudonas apvalus taikinyss. Šis taikinyss sukuriama atsitiktinėje pozicijoje. Žaidimo tikslas yra pasukti laivą reikiama kryptimi ir nušauti taikinį.

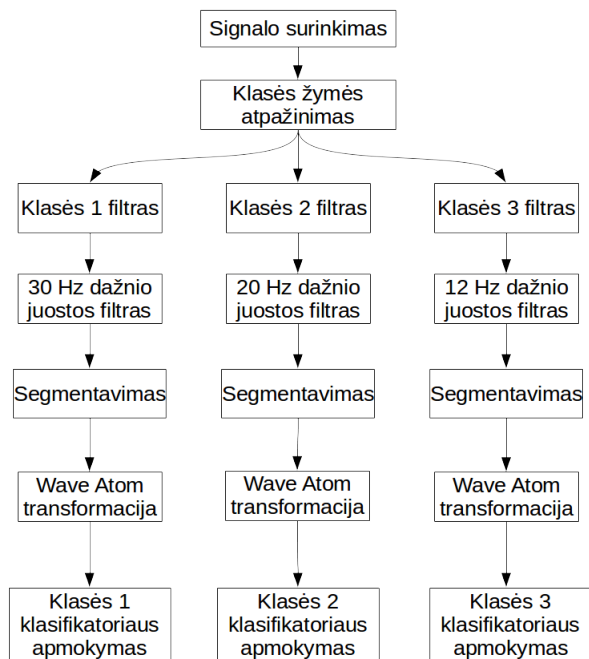
Eksperimentas atliktas su dviem vartotojais, pažymėtais V1 ir V2. Abu vartotojai nepatyrę, t.y. naudojo BCI tipo sąsają pirmą kartą. Rezultatai pateikiami 4 lentelėje.

Siekiant palyginti bangelių atomų transformacijos požymių išskyrimo galimybes su standartinėmis metodikomis, papildomai pasirinkta spektro galios požymių išskyrimo metodika. Atlikti bandymai su 4 skirtingais klasifikavimo algoritmais. Eksperimente įvertintas bendras tikslumas bei  $F1$  metrika.

Iš lentelės matyti, kad bangelių atomų transformacija pasiekė geresnius rezultatus su visais klasifikatoriais. Tai parodo, kad ji gali būti sėkmingai naudojama SSVEP paremtų BCI sistemų kūrimui.

**4 lentelė:** Klasifikavimo tikslumo palyginimas

Klasifikatorius	Požymiai	Tikslumas, %,		F1	
		V.1	V.2	V.1	V. 2
LDA	WAT	71.5	78.2	0.64	0.67
	BPS	66.2	73.2	0.56	0.62
sLDA	WAT	70.6	77.4	0.64	0.68
	BP	68.4	73.5	0.59	0.61
SVM, linear kernel	WAT	75.5	79.3	0.64	0.68
	BP	74.3	75.1	0.64	0.66
SVM, RBF kernel	WAT	<b>78.7</b>	<b>82.2</b>	0.68	0.71
	BP	74.0	77.4	0.63	0.67



**4.4 pav.:** Klasifikatoriaus apmokymo duomenų apdorojimo schema

#### 4.10. Išvados

- EEG signalo apdorojimui pasiūlytas klasėms adaptyvus signalų triukšmų šalinimo metodas, pagerinantis klasifikavimo rezultatus. Naudojant šį metodą su standartiniu duomenų rinkiniu pasiektas 94.6% klasifikavimo tikslumas.
- Pasiūlytas bangelių atomų transformacija paremtas požymių išskyrimo algoritmas. Įrodyta, kad algoritmas efektyviai sumažina požymių erdvę, pagreitina klasifikatoriaus apmokymą. Algoritmas išbandytas su įsivaizduojamo judesio paradigmos duomenų rinkiniu, kuriame pasiekė 90% tikslumą, bei dėmesiu valdomų sukeltų potencialų paradigma realioje sistemoje, pasiekiant 82.2% tikslumą trijų klasių problemoje.
- Pasiūlytas signalo triukšmų šalinimo algoritmas, paremtas homogeniniu daugiamačiu polinominiu operatoriumi (HDPO). Šis metodas pasiekė 82.8% tikslumą su standartiniu duomenų rinkiniu.
- Pasiūlytas signalo fazinės erdvės konstravimo naudojant realiųjų skaičių laiko delsos parametrą algoritmas.
- Sukurta 3 klasių BCI sistema, paremta dėmesiu valdomų sukeltų potencialų paradigma bei Emotiv EPOC encefalogramos registravimo įrenginiu. Pritaikius bangelių atomų požymių išskyrimą bei atraminių vektorių klasifikatorių, pasiektas 82.2% tikslumas.

Šie rezultatai parodo, kad BCI sąsaja gali būti panaudota kaip informacijos įvedimo į kompiuterį sąsaja, net naudojant pigius, mažos raiškos EEG registravimo įrenginius. Tai leidžia pritaikyti šią naują sąsają platesniam vartotojų ratui.

## Literatūra

- [Bayliss, 2001] Bayliss, J. D. (2001). *A Flexible Brain-computer Interface*. PhD thesis, University of Rochester. AAI3023727.
- [Bi et al., 2013] Bi, L., Jie, K., an Fan, X., and Li, Y. (2013). A SSVEP brain-computer interface with the hybrid stimuli of SSVEP and p300. In *Complex Medical Engineering (CME), 2013 ICME International Conference on*, pages 211–214.
- [Buzsaki, 2006] Buzsaki, G. (2006). *Rhythms of the Brain*. Oxford University Press.
- [Cincotti et al., 2008] Cincotti, F., Mattia, D., Aloise, F., Bufalari, S., Schalk, G., Oriolo, G., Cherubini, A., Marciani, M. G., and Babiloni, F. (2008). Non-invasive brain-computer interface system: towards its application as assistive technology. *Brain research bulletin*, 75(6):796–803.
- [Damasevicius and Stuikeys, 2009] Damasevicius, R. and Stuikeys, V. (2009). Specification and generation of learning object sequences for e-learning using sequence feature diagrams and metaprogramming techniques. In *Advanced Learning Technologies, 2009. ICALT 2009. Ninth IEEE International Conference on*, pages 572–576.
- [Demanet and Ying, 2007] Demanet, L. and Ying, L. (2007). Wave atoms and sparsity of oscillatory patterns. *Applied and Computational Harmonic Analysis*, 23(3):368 – 387.
- [Donoho, 1995] Donoho, D. L. (1995). De-noising by soft-thresholding. *IEEE Trans. Inf. Theor.*, 41(3):613–627.
- [Falk et al., 2011] Falk, T., Guirgis, M., Power, S., and Chau, T. (2011). Taking nirs-BCIs outside the lab: Towards achieving robustness against environment noise. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 19(2):136–146.
- [Farwell and Donchin, 1988] Farwell, L. and Donchin, E. (1988). Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials. *Electroencephalography and Clinical Neurophysiology*, 70(6):510–523.
- [Guger et al., 2015] Guger, C., Müller-Putz, G., and Allison, B. (2015). *Brain-Computer Interface Research: A State-of-the-Art Summary 4*.

SpringerBriefs in Electrical and Computer Engineering. Springer International Publishing.

- [Hjorth, 1970] Hjorth, B. (1970). {EEG} analysis based on time domain properties. *Electroencephalography and Clinical Neurophysiology*, 29(3):306 – 310.
- [Holz et al., 2013] Holz, A. M., Botrel, L., and Kubler, A. (2013). Bridging gaps: Long-term independent BCI home- use by a locked-in end-user. *Proceedings of TOBI Workshop IV*.
- [Jacko, 2012] Jacko, J. A. (2012). *Human Computer Interaction Handbook: Fundamentals, Evolving Technologies, and Emerging Applications*. CRC press.
- [Jasper, 1958] Jasper, H. H. (1958). Report of the committee on methods of clinical examination in electroencephalography. *Electroencephalography and Clinical Neurophysiology*, 10(2):370–375.
- [Kennedy et al., 2000] Kennedy, P., Bakay, R., Moore, M., Adams, K., and Goldwithe, J. (2000). Direct control of a computer from the human central nervous system. *Rehabilitation Engineering, IEEE Transactions on*, 8(2):198–202.
- [Krusienski et al., 2011] Krusienski, D. J., Grosse-Wentrup, M., Galán, F., Coyle, D., Miller, K. J., Forney, E., and Anderson, C. W. (2011). Critical issues in state-of-the-art brain-computer interface signal processing. *Journal of neural engineering*, 8(2):025002.
- [Kübler et al., 2001] Kübler, A., Kotchoubey, B., Kaiser, J., Wolpaw, J. R., and Birbaumer, N. (2001). Brain-computer communication: Unlocking the locked in. *Psychological bulletin*, 127(3):358.
- [Kubler et al., 2006] Kubler, A., Mushahwar, V., Hochberg, L., and Donoghue, J. (2006). BCI meeting 2005-workshop on clinical issues and applications. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 14(2):131–134.
- [Lal et al., 2005] Lal, T. N., Hinterberger, T., Widman, G., Schröder, M., Hill, J., Rosenstiel, W., Elger, C. E., Schölkopf, B., and Birbaumer, N. (2005). Methods towards invasive human brain computer interfaces. In *IN ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS 17*, pages 737–744. MIT Press.

- [Lin et al., 2010] Lin, C.-T., Ko, L.-W., Chang, M.-H., Duann, J.-R., Chen, J.-Y., Su, T.-P., and Jung, T.-P. (2010). Review of wireless and wearable electroencephalogram systems and brain-computer interfaces – a mini-review. *Gerontology*, 56(1):112–119.
- [Mason and Birch, 2003] Mason, S. and Birch, G. (2003). A general framework for brain-computer interface design. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 11(1):70–85.
- [McFarland et al., 2006] McFarland, D., Anderson, C., Muller, K.-R., Schlogl, A., and Krusienski, D. (2006). BCI meeting 2005-workshop on BCI signal processing: feature extraction and translation. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 14(2):135–138.
- [Menon et al., 2013] Menon, S., Brantner, G., Aholt, C., Kay, K., and Khatib, O. (2013). Haptic fmri: Combining functional neuroimaging with haptics for studying the brain’s motor control representation. In *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE*, pages 4137–4142.
- [Rance et al., 1995] Rance, G., Rickards, F. W., Cohen, L. T., De Vidi, S., and Clark, G. M. (1995). The automated prediction of hearing thresholds in sleeping subjects using auditory steady-state evoked potentials. *Ear and hearing*, 16(5):499–507.
- [Raudonis et al., 2008] Raudonis, V., Narvydas, G., and Simutis, R. (2008). A classification of flash evoked potentials based on artificial neural network. *ELECTRONICS AND ELECTRICAL ENGINEERING*, 81(1):31–36.
- [Resalat et al., 2012] Resalat, S., Saba, V., Afdideh, F., and Heidarnesjad, A. (2012). High-speed SSVEP-based BCI: Study of various frequency pairs and inter-sources distances. In *Biomedical and Health Informatics (BHI), 2012 IEEE-EMBS International Conference on*, pages 220–223.
- [Shyu et al., 2013] Shyu, K.-K., Chiu, Y.-J., Lee, P.-L., Liang, J.-M., and Peng, S.-H. (2013). Adaptive SSVEP-based BCI system with frequency and pulse duty-cycle stimuli tuning design. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 21(5):697–703.

- [Verikas and Gelžinis, 2008] Verikas, A. and Gelžinis, A. (2008). *Neuroniniai tinklai ir neuroniniai skaičiavimai : mokomoji knyga*. Technologija.
- [Vidal, 1973] Vidal, J. J. (1973). Toward direct brain-computer communication. *Annual Review of Biophysics and Bioengineering*, 2(1):157–180.
- [Wang et al., 2010] Wang, J., Xu, G., Wang, L., and Zhang, H. (2010). Feature extraction of brain-computer interface based on improved multivariate adaptive autoregressive models. In *Biomedical Engineering and Informatics (BMEI), 2010 3rd International Conference on*, volume 2, pages 895–898.
- [Wolpaw et al., 2002] Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., and Vaughan, T. M. (2002). Brain-computer interfaces for communication and control. *Clinical neurophysiology*, 113(6):767–791.

## AUTORIAUS PUBLIKACIJŲ SĄRAŠAS

### Tarptautinėse duomenų bazėse esančiuose mokslo leidiniuose paskelbti straipsniai

#### Mokslinės informacijos instituto duomenų bazės „ISI Web of Science“ leidiniuose, turinčiuose citavimo indeksą

1. Martišius, Ignas; Damaševičius, Robertas; Jusas, Vacius; Birvinskas, Darius. Using higher order nonlinear operators for SVM classification of EEG data // Elektronika ir elektrotechnika = Electronics and Electrical Engineering. Kaunas: KTU. ISSN 1392-1215. 2012, nr. 3(119), p. 99-102. [Science Citation Index Expanded (Web of Science); INSPEC; Computers & Applied Sciences Complete; Central & Eastern European Academic Source]. [0,250]. [IF (E): 0,411 (2012)]
  2. Birvinskas, Darius; Jusas, Vacius; Martišius, Ignas; Damaševičius, Robertas. Data compression of EEG signals for artificial neural network classification // Informacinės technologijos ir valdymas = Information technology and control / Kauno technologijos universitetas. Kaunas: KTU. ISSN 1392-124X. 2013, T. 42, nr. 3, p. 238-241. [Science Citation Index Expanded (Web of Science); INSPEC]. [0,354]. [IF (E): 0,813 (2013)]
  3. Damaševičius, Robertas; Martišius, Ignas; Jusas, Vacius; Birvinskas, Darius. Fractional delay time embedding of EEG signals into high dimensional phase space // Elektronika ir elektrotechnika = Electronics and electrical engineering. Kaunas: KTU. ISSN 1392-1215. 2014, Vol. 20, no. 8, p. 55-58. [Science Citation Index Expanded (Web of Science); Inspec; Computers & Applied Sciences Complete; Central & Eastern European Academic Source; Scopus]. [0,250]. [IF (E): 0,561 (2014)]
  4. Birvinskas, Darius; Jusas, Vacius; Martišius, Ignas; Damaševičius, Robertas. Fast DCT algorithms for EEG data compression in embedded systems // Computer science and information systems. Novi Sad: University of Novi Sad. ISSN 1820-0214. 2015, Vol. 12, Iss. 1, p. 49-62. [Science Citation Index Expanded (Web of Science)]. [0,250]. [IF (E): 0,477 (2014)]
- [Indėlis grupėje: 1,589]

#### Mokslinės informacijos instituto duomenų bazės „ISI Web of Science“ leidiniuose, neturinčiuose citavimo indekso

#### Kitų tarptautinių duomenų bazių leidiniuose

1. Martišius, Ignas; Vasiljevas, Mindaugas; Šidlauskas, Kęstutis; Turčinas, Rūtenis; Plauska, Ignas; Damaševičius, Robertas. Design of a neural interface based system for control of robotic devices // Information and software technologies : 18th international conference, ICIST 2012, Kaunas, Lithuania, September 13-14, 2012 : proceedings / [Edited by] Tomas Skersys, Rimantas Butleris, Rita Butkienė. Berlin: Springer, 2012. (Communications in computer and information science, Vol. 319, ISSN 1865-0929), ISBN 9783642333071. p. 297-311. [Conference Proceedings Citation Index]. [0,167]
2. Martišius, Ignas; Damaševičius, Robertas. Class-adaptive denoising for EEG data classification // Artificial intelligence and soft computing : proceedings of the 11th international conference, ICAISC 2012, April 29 - May 3, 2012, Zakopane, Poland, Part 2. Berlin: Springer-Verlag, 2012.

(Lecture Notes in Computer Science, Vol. 7268, ISSN 0302-9743), ISBN 978642293498. p. 302-309. [Conference Proceedings Citation Index; SpringerLINK]. [0,500]

3. Birvinskas, Darius; Jusas, Vacius; Martišius, Ignas; Damaševičius, Robertas. EEG dataset reduction and feature extraction using discrete cosine transform // UKSim-AMSS EMS 2012 : 6th European Modelling Symposium on Mathematical Modeling and Computer Simulation 2012, 14-16 November, 2012, Malta : proceedings. Los Alamitos, Washington, Tokyo: IEEE Computer Society, 2012, ISBN 9780769549262. p. 199-204. [IEEE]. [0,250]
  4. Martišius, Ignas; Birvinskas, Darius; Damaševičius, Robertas; Jusas, Vacius. EEG dataset reduction and classification using wave atom transform // Artificial neural networks and machine learning - ICANN 2013 : 23rd international conference on artificial neural networks, Sofia, Bulgaria, September 10-13, 2013 : proceedings / [edited by] Valeri Mladenov, Petia Koprinkova-Hristova, Guenther Palm. New York: Springer, 2013. (Lecture notes in computer science, Vol. 8131, ISSN 0302-9743), ISBN 9783642407277. p. 208-215. [Conference Proceedings Citation Index; SpringerLINK]. [0,250]
  5. Martišius, Ignas; Šidlauskas, Kęstutis; Damaševičius, Robertas; Damaševičius, Robertas. Real-time training of voted perceptron for classification of EEG data // International Journal of Artificial Intelligence. Kaunas: KTU. ISSN 0974-0635. 2013, Vol. 10, iss. S13, p. 41-50. [INSPEC; SCOPUS; Zentralblatt MATH; IndexCopernicus]. [0,250]
- [Indėlis grupėje: 1,417]

#### **Kituose recenzuojamuose mokslo leidiniuose paskelbti straipsniai**

##### **Konferencijų pranešimų medžiagoje paskelbti straipsniai**

1. Birvinskas, Darius; Martišius, Ignas. Aparatinė dvimatės DCT ir IDCT realizacija, naudojant Bindct algoritmą // Informacinės technologijos : 16-oji tarpuniversitetinė magistrantų ir doktorantų konferencija : konferencijos pranešimų medžiaga / Kauno technologijos universitetas, Vytauto Didžiojo universitetas, Vilniaus universiteto Kauno humanitarinis fakultetas. Kaunas: Technologija. ISSN 2029-249X. 2011, p. 129-132. [0,500]
2. Šidlauskas, Kęstutis; Martišius, Ignas. EEG duomenų klasifikavimas naudojant balsavimo ir daugiasluoksnius perceptronus // Informacinės technologijos : 17-oji tarpuniversitetinė magistrantų ir doktorantų konferencija : konferencijos pranešimų medžiaga / Vilniaus universiteto Kauno humanitarinis fakultetas, Kauno technologijos universitetas, Vytauto Didžiojo universitetas. Vilnius: Vilniaus universitetas. ISSN 2029-249X. 2012, p. 39-42. [0,500]
3. Vasiljevas, Mindaugas; Turčinai, Rūtenis; Martišius, Ignas. Netiesinių operatorių taikymas EEG duomenų apdorojimui // Informacinės technologijos : 17-oji tarpuniversitetinė magistrantų ir doktorantų konferencija : konferencijos pranešimų medžiaga / Vilniaus universiteto Kauno humanitarinis fakultetas, Kauno technologijos universitetas, Vytauto Didžiojo universitetas. Vilnius: Vilniaus universitetas. ISSN 2029-249X. 2012, p. 23-26. [0,333]
4. Martišius, Ignas. EEG signal processing methods for BCI applications // XV International PhD Workshop OWD 2013 : under the auspices of deans of electrical, electronic and computer science faculties of engineering, IEE - The Institution of Engineering and Technology, IEEE - Institute of Electrical and Electronics Engineers - Polish Section, 19-22 October 2013, Wisła, Poland. Gliwice: Organizing Committee of the Symposium PPEE & Seminar BSE, 2013. (Archiwum konferencji PTETiS = Conference archives PTETiS, Vol. 33), ISBN 9788393542727. p. 84-89. [1,000]
5. Vasiljevas, Mindaugas; Martišius, Ignas; Šumskas, Tomas. Evaluation of user fatigue in neural computer interface system // Informacinės technologijos : 19-oji tarpuniversitetinės magistrantų ir doktorantų konferencija "Informacinė visuomenė ir universitetinės studijos" (IVUS 2014) : konferencijos pranešimų medžiaga / Kauno technologijos universitetas, Vytauto Didžiojo

universitetas, Vilniaus universiteto Kauno humanitarinis fakultetas. Kaunas: Technologija. ISSN 2029-249X. 2014, p. 193-196. [0,333]

6. Vasiljevas, Mindaugas; Martišius, Ignas; Šumskas, Tomas. Evaluation of user fatigue in neural computer interface system // Informacinės technologijos : 19-oji tarpuniversitetinė magistrantų ir doktorantų konferencija "Informacinė visuomenė ir universitetinės studijos" (IVUS 2014) : konferencijos pranešimų medžiaga / Kauno technologijos universitetas, Vytauto Didžiojo universitetas, Vilniaus universiteto Kauno humanitarinis fakultetas. Kaunas: Technologija. ISSN 2029-4832. 2014, p. 193-196. [0,333]

[Indėlis grupėje: 3,000]

Sąrašo sudarymo data: 2016-02-12



# Ignas Martisius

## Curriculum Vitae

### Professional summary

A PhD student at Kaunas University of Technology, working in the field of signal processing and direct Brain-Computer interfaces. Extensive experience in teaching, digital logic, signal processing and System on Chip design.

### Work experience

- 2014–present **Lecturer**, *Kaunas University of Technology. Department of Computer Sciences.*  
Lecturing in digital logic design and computer architecture.
- 2012–2014 **Assistant**, *Kaunas University of Technology. Department of Computer Sciences.*  
Lecturing in digital logic design and computer architecture.
- 2011–2012 **Consulting Engineer**, *Pacific Microchip Corp*, Kaunas.  
Design of digital systems-on-chip. Digital and analog layout and simulation.
- 2006–2008 **Electronics engineer**, *Mikrovisata, inc*, Kaunas.  
Installation and service of security and fire suppression systems.

### Education and training

- 2011–present **PhD student. Informatics engineering**, *Kaunas University of Technology. Software Engineering Department.*  
Thesis – Data Acquisition and Signal Processing Methods for Brain – Computer Interfaces
- 2009–2011 **Master. Informatics engineering**, *Kaunas University of Technology. Software Engineering Department*, System on-chip design.
- 2005–2009 **Bachelor. Informatics engineering**, *Kaunas University of Technology. Department of Computer Sciences.*

*Pasilių 8-oji g. 9, Pasiliai, Jonavos raj.*

☎ +370 (625) 42465 • ✉ [ignas.martisius@ktu.lt](mailto:ignas.martisius@ktu.lt)  
🌐 [www.personalas.ktu.lt/~ignmart](http://www.personalas.ktu.lt/~ignmart)

## Language skills

Lithuanian **Mother tongue**

English **Fluent**

C2

German **Proficient**

C2 - C1. Deutsches Sprachdiplom Stufe II

Russian **Proficient**

B2

## Skills summary

Fields of expertise	Brain-Computer Interface systems, machine learning algorithms, VLSI design, FPGA prototyping,
Programing languages	VHDL, Verilog, SystemC, C, C++, MATLAB, ARM and 8086 assembler
SOC design software	Cadence IUS, Encounter, Virtuoso, Synopsys Design analyzer, Xilinx ISE, Lattice Diamond
OS	Debian, CentOS Linux, Windows

## Other skills

- o Effective communication skills.
- o Good Planning/management/organisation/skills acquired through work practice

## Projects

Project researcher VP1-3.1-ŠMM-08-K-01-018 „Research and development of Internet technologies and their infrastructure for smart environments of things and services“ (2012- 2015), funded by the European Social Fund (ESF).

Pasilių 8-oji g. 9, Pasiliai, Jonavos raj.

☎ +370 (625) 42465 • ✉ ignas.martisius@ktu.lt

🌐 www.personalas.ktu.lt/~ignmart

## RÉSUMÉ

### Relevance of the work

Human-computer interaction has been an important research concept since the invention of the computer. Methods of computer interfacing have progressed from perforated cards, keyboards and mice to touchscreen and speech recognition. HCI devices allow humans to interface with computers for the purposes of data entry, control or communication. Most of the efforts over the years have been dedicated to the design of user-friendly, efficient and ergonomic systems to produce a faster and more comfortable means of communication. Interfaces based on voice recognition, gesture recognition, physical movement and other technologies have received enormous research attention over the years and successful examples of these technologies are being produced commercially.

Direct brain-computer communication requires high computational capacity to analyze brain signals in detail and in real-time, and until recently the requisite technology either did not exist or was extremely expensive.

The continuing development of computer hardware and software now supports highly sophisticated online analysis of many signal channels at high speed. Also, greatly increased social recognition of the needs and potential contributions of people with severe neuromuscular disorders such as spinal cord injury has generated clinical, scientific, and commercial interest in better communication and control technology.

An interdisciplinary field of research has been created to offer direct HCI via signals, generated by the brain itself. Brain-Computer Interface (BCI) technology, as it is known, is a communication channel that enables users to control devices and applications without the use of muscles. The development of cognitive neuroscience field has been instigated by recent advances in brain imaging technologies such as electroencephalography, magnetoencephalography and functional magnetic resonance imaging.

The growing field of BCI research is relatively new. The first BCI prototype was created by Dr. Vidal in 1973 [Vidal, 1973]. This system was intended to be used as a promising communication channel for persons with severe disabilities, such as paralysis, amyotrophic lateral sclerosis (ALS), brain stroke or cerebral paralysis [Kübler et al., 2001].

It is estimated that about one million people worldwide suffer from the so-called locked-in syndrome, but despite their paralysis, retain full

brain function, which could be employed for communication.

BCI research has been successfully used not only for helping the disabled, but also as being an additional data input channel for healthy people. It can be exploited as an extra channel in game control, augmented reality applications, household device control, fatigue and stress monitoring and other applications.

BCI design represents a new frontier in science and technology that requires multidisciplinary skills from fields such as neuroscience, engineering, computer science, psychology and clinical rehabilitation. Despite recent developments, there are numerous obstacles to building a usable and effective BCI system. The biggest challenges are related to accuracy, speed, price and usability. Current BCI systems are inaccurate and have a low information transfer rate. This means that the user needs a long period of time in order to send commands to the device that is being controlled.

Another problem is the high cost of EEG equipment, such as an EEG cap and amplifiers [Holz et al., 2013]. Systems with a high sensor count take a long time to prepare for use and are uncomfortable. Due to these limitations, no BCI system has become commercially successful to this date. If a disabled person can move their eyes or even one muscle in a controlled way, the interfaces based on eye-gaze or muscle movement (electromyogram - EMG) switch technology are more efficient than any of the BCIs that exist today.

A sound knowledge of the data acquisition process, EEG waveform characteristics, signal processing methodologies for feature extraction and classification is a prerequisite before attempting to design and implement a functional BCI system. These research points have been highlighted by the BCI development community as being both important and necessary, for further BCI development [Guger et al., 2015, McFarland et al., 2006, Kubler et al., 2006, Krusienski et al., 2011].

## **Object of the work**

The object of this research is to study EEG signal processing and classification techniques in order to design a Brain-Computer Interface system architecture with a EEG signal as the input modality.

## **Aim of the work**

This thesis focuses on BCI data acquisition, signal processing and classification techniques for BCI. The aim of this work is to develop new signal denoising and feature extraction algorithms, as well as integrating these algorithms into a BCI system design, based on the Emotiv EPOC

neuroheadset device. The system is to be both end-user friendly, cost effective, wearable, wireless and provide reasonable usability and quality of control for a domestic BCI. It is envisioned to design and implement a non-invasive, affordable and simple to use solution.

### **Tasks of the work**

The main task of this study is to investigate and design feature extraction and classification algorithms and architectures. The main tasks of this work are:

1. Investigate advances in the field of neurotechnology, and the state-of-the-art BCI system structure;
2. Proposing a classification scheme for BCI systems;
3. Designing a signal denoising technique for EEG;
4. Proposing feature extraction algorithms for BCI;
5. Producing a practical implementation of the proposed algorithms by developing a BCI system architecture.

### **Scientific novelty**

The work achieved these novel results:

1. A novel Class-adaptive signal denoising scheme has been proposed for use with EEG data.
2. In order to improve feature extraction, the Wave Atom transform has been applied in EEG data processing. By testing this method with standard datasets and comparing results, we have shown that this method can be successfully used for feature extraction and dataset feature reduction in BCI systems.
3. A novel non-linear operator, named Homogeneous Multivariate Polynomial Operator (HMPO) was proposed for signal feature extraction . This operator can be used for developing new EEG processing algorithms.
4. Since BCI systems are subject-dependent, a time-bound voted perceptron artificial neural network training algorithm, bound by real-time constraints has been developed. This algorithm is suited for real time BCI systems, which require constant classifier retraining.

5. We propose a method for fractional time-delay embedding, by selection of positive and negative trajectories from the phase space, distance adaptive sampling and reconstruction of the high-dimensional phase space of the EEG signal.

## **Practical value**

Systems used today are bulky, wired and laboratory-oriented. They are uncomfortable and inconvenient for users, impeding their daily tasks. Most signal processing is performed off-line, hindering real-life applications.

BCI systems require correct classification of signals interpreted from the brain for useful operation. The developed algorithms allow for an improvement in classification accuracy, thereby making them useful in the development of BCI systems.

Such a system would be extremely useful for disabled patients, provided it was portable, wearable and capable of monitoring signals remotely via a wireless transmission protocol. First a wireless system would reduce installation complexity, provide the user with more freedom of movement, so they could perform routine tasks in real-world environments. This would allow for a much wider application of BCI systems [Lin et al., 2010].

This thesis presents the fundamental knowledge in EEG based BCI development, signal processing and machine learning-based classification. It also presents a state-of-the-art review of BCI research and then describes a system implemented by the author.

## **Thesis statements**

1. Since the EEG signal is non-linear and non-stationary it requires complex feature extraction methods. The Wave Atom transform was used to reduce EEG feature complexity, thereby achieving good classification results.
2. Nonlinear operators were considered for EEG signal processing. A novel Homogenous Multivariate Polynomial Operator (HMPO) was proposed, achieving classification accuracy of 94% with a standard dataset.
3. Since BCI classifiers require constant retraining, a time-bound Voted Perceptron Artificial Neural Network training algorithm was proposed, achieving good classification results with 3 different datasets, with improved training time, suitable for real-time BCI systems.

4. An analysis of the BCI domain reveals that although consumer-grade devices are incapable of quality signal acquisition, they can be implemented in a BCI architecture. A 3-class self-paced BCI system, based on SSVEP and the Emotiv EPOC headset achieved good accuracy and usability results.

## **Scientific approval**

All of the results presented in the thesis are original and correspond to a total of 15 publications. 4 internationally referred "ISI Web of Science" scientific journal publications with a citing index, 5 publications in "ISI Web of Science" journals without a citing index and 6 conference proceedings publications in the fields of informatics, electronics and machine learning journals. The remaining are experimental setups, small unpublished observations or well known facts.

The experimental results were presented in and discussed in 4 international conferences:

1. 11th International conference on Artificial intelligence and soft computing, ICAISC 2012;
2. 18th International conference on information and software technologies, ICIST 2012;
3. 18th International conference Electronics 2014, Palanga;
4. 15th International PhD Workshop OWD 2013, Wisla.

## **Thesis organization**

The thesis consists of 5 chapters: Chapter 1 is an introduction, providing a short summary of the works novelty, aims and objectives.

Chapter 2 performs a thorough review of electroencephalography (EEG), a brain imaging technology based on the electrophysiological activity within the brain. The chapter describes in detail the origin, functional behavior, acquisition, characterization, taxonomy and applications of EEG signals. The purpose of this chapter is to familiarize the reader with terminology and EEG characteristics that will be exploited and referred to in later chapters.

Chapter 3 begins by introducing the idea and purpose of a BCI. The essential components of a BCI framework are described and some of the signal-processing methodologies behind them are reviewed in detail. A large portion of this chapter is a review of BCI technology and a description of the various approaches by different BCI research groups

worldwide. Different performance metrics are reviewed. The chapter concludes by reviewing necessary standardized performance metrics and discusses the challenges for future progression of this technology.

Chapter 4 describes the offline datasets used for direct result comparison with other authors. It introduces proposed novel methods for BCI applications, including signal filtering and classification algorithms. It also presents an architecture of the cost effective BCI system, based on Emotiv EPOC hardware and novel algorithms. The chapter describes the brain activity associated with visual stimulation and the methodologies that are exploited in this study to offer control, presents a real-time BCI controlled video application. The real-time deployment of this system and the associated performance results are reviewed. Finally, a discussion reviews the success and future work of this type of BCI implementation.

Chapter 5 provides a conclusion on the issues addressed by this research and on the future of BCI technology.

## Conclusions

1. Concerning signal preprocessing, we have proposed a Class-Adaptive signal denoising approach, improving classification results. 94.6% accuracy was achieved on a standard dataset. Because of complexity and the need for a lot of training data, this method was shown to be suited only for offline data analysis.
2. We have also proposed a Wave Atom transform algorithm for EEG feature extraction. The algorithm is shown to be effective in reducing the number of features, classifier training and testing time. This algorithm was tested on motor imagery (MI) data and also selected for a Steady-State Visually Evoked Potential (SSVEP) paradigm based system development. It was able to achieve an accuracy of 90% with a standard motor imagery (MI) dataset and showed good results (82.2% accuracy) with SSVEP data.
3. We have proposed a signal denoising method based on a Homogeneous Multivariate Polynomial Operator (HMPO). This method improved classification accuracy when used together with state-of-the-art classifiers, such as Support Vector Machines (SVM), to 82.8% on a standard dataset.
4. A algorithm for EEG signal fractional delay time embedding into a high dimensional phase space (see Chapter 4) has also been studied. The algorithm proposes a novel fractional time embedding scheme.

5. Finally, we have developed a 3 class BCI system, based on SSVEP and the Emotiv EPOC headset. An online target shooting game, implemented in the OpenViBE environment, has been used for feedback. The system utilizes Wave Atom transform for feature extraction. The system achieved an accuracy of 80.5% while using a Support Vector Machine classifier with a radial basis kernel.

Taken together, these results show that BCI can actually be used as an interaction technique for complex applications, providing real time operation and feedback.

These results also highlight that BCI can be feasible even when using a low resolution EEG acquisition devices. This allows for reduced system cost, mobility, subject preparation time and, consequently, allows for the subject to be prepared by a non-expert supervisor;

UDK 004.5+616.8-009.1] (043.3)

SL344. 2016-03-03, 2.75 leidyb. apsk. 1. Tiražas 50 egz. Užsakymas 102.

Išleido Kauno technologijos universitetas, K. Donelaičio g. 73, 44249 Kaunas

Spausdino leidyklos „Technologija“ spaustuvė, Studentų g. 54, 51424 Kaunas