

KAUNO TECHNOLOGIJOS UNIVERSITETAS
VYTAUTO DIDŽIOJO UNIVERSITETAS
VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

TOMAS UKTVERIS

**DAUGIAKLASIO EEG SIGNALO KLASIFIKAVIMO IR
ĮRAŠYMO SISTEMA SMEGENŲ-KOMPIUTERIO SAŠAJAI**

Daktaro disertacijos santrauka
Gamtos mokslai, Informatika (N 009)

2019, Kaunas

Disertacija rengta 2014–2019 metais Kauno technologijos universiteto Informatikos fakulteto Programų inžinerijos katedroje.

Mokslinis vadovas:

Prof. dr. Vacius JUSAS (Kauno technologijos universitetas, gamtos mokslai, informatika, N 009).

Redagavo: Gabija Bankauskaitė

Informatikos mokslo krypties disertacijos gynimo taryba:

Prof. habil. dr. Rimantas BARAUSKAS (Kauno technologijos universitetas, gamtos mokslai, informatika, N 009) – **pirmininkas**;

Prof. habil. dr. Gintautas DZEMYDA (Vilniaus universitetas, gamtos mokslai, informatika, N 009);

Prof. dr. Alfonsas MISEVIČIUS (Kauno technologijos universitetas, gamtos mokslai, informatika, N 009);

Prof. dr. Gintaras PALUBECKIS (Kauno technologijos universitetas, gamtos mokslai, informatika, N 009);

Prof. habil. dr. Raimund UBAR (Talino technologijos universitetas, Estija, gamtos mokslai, informatika, N 009).

Disertacija bus ginama viešame Informatikos mokslo krypties disertacijos gynimo tarybos posėdyje 2019 m. rugpjūčio 26 d. 10 val. Kauno technologijos universiteto 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 2019 m. liepos 26 d.

Su disertacija galima susipažinti interneto svetainėje <http://ktu.edu> ir Kauno technologijos universiteto (K. Donelaičio g. 20, 44239 Kaunas), Vytauto Didžiojo universiteto (K. Donelaičio g. 58, 44248 Kaunas) ir Vilniaus Gedimino technikos universiteto (Saulėtekio al. 14, 10223 Vilnius) bibliotekose.

1. ĮVADAS

Smegenų-kompiuterio sąsajos (BCI) sistemos bando užpildyti žmogaus minčių perteikimo į kompiuterį spragą. Tiesioginis taikomųjų kompiuterinių programų valdymas naudojant tik žmogaus mintis ir mąstymo galimybes gali padėti išspręsti daug reabilitacijos, multimedijos ir žaidimų iššūkių. Viena iš svarbiausių BCI sistemos dalių yra tikslūs ir greiti algoritmai, gebantys analizuoti elektroencefalogramos (EEG) signalo potencialus, įrašytus nuo žmogaus galvos skalpo. Tokie signalai turi triukšmo ir kitų nepageidaujamų artefaktų, kliudančių teisingai nustatyti-klasifikuoti įsivaizduojamus motorinius judesius. Nors, norint apeiti šias problemas, buvo sukurta daug algoritmų, tačiau siekiant išanalizuoti uždavinį, vis dar būtinas tolesnis išsamus darbas.

Įsivaizduojamosios motorikos klasifikavimas yra vienas iš daugelio plačiai paplitusių mašininio mokymo uždavinių smegenų-kompiuterio (BCI) sąsajos sistemose. Atsiradus žmogaus mintimis valdomų taikomųjų programų poreikiui, rastas optimalus neintervencinės smegenų aktyvumo analizės sprendimas – EEG įrašymas. Galimybė visiškai suprasti šį smegenų sukurtą elektrinį signalą ženkliai supaprastintų žmonių su negalia gyvenimą ir išspręstų natūralaus bendravimo barjerų problemas pramogų industrijoje.

Šiame darbe dėmesys skiriamas keturių klasių įsivaizduojamosios motorikos uždaviniui, kuriame įrašytas EEG signalas yra klasifikuojamas į keturias skirtingas klases, atspindinčias keturis skirtingus žmogaus subjekto įsivaizduotus motorinius judesius (kairės rankos, dešinės rankos, kojų ir liežuvio judėjimą). Nors paprastesnio dviejų klasių (binarinio) uždavinio sprendimas susijęs su gerais klasifikavimo rezultatais, tačiau sprendžiant keturių klasių uždavinį, panašių rezultatų pasiekama sunkiai, todėl būtini tolesni moksliniai tyrimai.

1.1. Tyrimo tikslas

Šios disertacijos tikslas yra sukurti metodą, skirtą analizuoti keturių klasių įsivaizduojamosios motorikos (ĮM) klasifikavimo uždavinį.

Darbo uždaviniai:

- 1) atlikti egzistuojančių ĮM klasifikavimo technikų ir EEG įrašymo sistemų literatūros apžvalgą ir analizę;
- 2) ištirti ir įvertinti dažniausiai naudojamus klasifikavimo algoritmus su ĮM EEG signalų duomenų baze;
- 3) sukurti efektyvų metodą, leidžiantį analizuoti ĮM klasifikavimo uždavinį;
- 4) suprojektuoti EEG sistemą, gebančią įrašyti ĮM signalus;

5) pagaminti EEG sistemos prototipą ir patikrinti jos tinkamumą.

1.2. Tyrimo objektas

Bruožų išskyrimo metodai ir klasifikavimo Sąsukos neuroninių tinklų (CNN) metodas įsivaizduojamosios motorikos (IM) uždaviniui. Kompaktiškos EEG įrašymo sistemos IM uždaviniui sukūrimas.

1.3. Mokslinis naujumas

Pasiūlytas naujas bruožų išgavimo Kanalų skirtumo metodas, paremtas Juostų galios ir Laplaso filtro metodais, EEG duomenų apdorojimui. Pateiktas metodas leidžia pasiekti artimą tikslumą į gerai žinomą CSP (bendrųjų erdvinių šablonų) algoritmą. Pasiūlytas naujas algoritmas skirtas adaptuoti vienos dimensijos (1D) bruožų vektorių į dvejų dimensijų (2D) bruožų žemėlapius. Šis algoritmas buvo sėkmingai validuotas eksperimentiškai. Sąsukos neuroniniais tinklais (CNN) paremtas metodas buvo adaptuotas keturių klasių IM uždaviniui spręsti. Eksperimentiškai gauti rezultatai artimi pažangiausių algoritmų rezultatams. Taip pat sukurta kompaktiška ir modulinė EEG įrašymo sistema, padėsianti įrašyti antrą keturių klasių IM signalų validavimo rinkinį ir skleisti BCI platesnei auditorijai.

1.4. Praktiniai taikymai

Klasifikavimo metodas buvo validuotas su viešai prieinama realių EEG signalų duomenų baze, įrašyta iš sveikų pacientų. Sukurta EEG įrašymo sistema buvo pagaminta ir validuota realiomis sąlygomis su sveikais pacientais.

1.5. Rezultatų aprobavimas

Disertacijos tema publikuoti penki straipsniai. Du straipsniai išspausdinti žurnaluose, indeksuojamuose ISI Web of Science. Eksperimentiniai disertacijos rezultatai publikuoti ir paviešinti trijose mokslinėse konferencijose Lietuvoje ir užsienyje.


2. SMEGENŲ-KOMPIUTERIO SĄSAJA

2.1. Apžvalga

Smegenų-kompiuterio sąsaja (BCI) yra sistema, kuri transformuoja signalus, sklindančius iš žmogaus smegenų į komandas, kurios gali valdyti kitus įrenginius. Pagrindinis BCI tikslas yra padėti sergantiems ir turintiems fizinę negalią žmonėms komunikuoti nenaudojant raumenų judesių. Pabrėžtina, kad BCI itin domisi pramogų sektorius dėl galimybės pritaikyti naują žmogaus-kompiuterio sąsają. Kiekvienoje BCI yra metodas, skirtas paversti smegenų signalus į kompiuterio valdymo komandas. Šis metodas gali naudoti skirtingą techninę įrangą – fMRI, EEG ar kitokią, ir privalo iš įrašytų smegenų signalų išskirti reikšmingą valdymo informaciją. Minėtinos kitos funkcijos: pradinis signalų apdorojimas, filtravimas, artefaktų pašalinimas. Valdymo algoritmas apmokymo etape turi turėti galimybę adaptuotis prie kiekvieno paciento, kadangi kiekvieno smegenys yra unikalios. Būtina tam tikro tipo užduotis, kurią pacientas galėtų atlikti, taip išreikšdamas savo valią, o sistema tai interpretuotų ir vykdytų. Grįžtamasis ryšys ir pranešimai žmogui turėtų būti atvaizduojami kompiuterio ekrane ar kita forma, pvz., lemputės mirksėjimas. Nemažai funkcionuojančių BCI sistemų jau dirba pagal šiuos principus.

2.2. Įsivaizduojamosios motorikos BCI

Įsivaizduojamoji motorika (IM) yra BCI tipas, kurioje žmogus-subjektas turi įsivaizduoti motorinį veiksmą, pvz., mojuoti dešine ranka, neatlikdamas šio judesio fiziškai (1 pav.). Buvo įrodyta, kad judėjimo įsivaizdavimas aktyvuoja, stimuliuoja smegenų žievėje esančius motorinius regionus. Kitaip nuo įsivaizduojamos galūnės pusės (kairės ar dešinės), atitinkami smegenų hemisferos regionai yra aktyvuojami ir priešingi yra prislopinami. Įsivaizdavirus iš fiksuotos aibės galimų judesių (kairės rankos, dešinės rankos, ir pan.) ir gebant atskirti aktyvacijas, galima kontroliuoti įrenginius ar komunikuoti.




1 pav. Įsivaizduojamosios motorikos BCI eiga

Motorinių veiksmų klasifikavimas iš EEG signalo yra procesas, leidžiantis nustatyti veiksmą, kurį subjektas įsivaizdavo, kai ĮM EEG signalas buvo įrašomas. Klasifikavimo metodai yra skirtingi, tačiau paskutiniu metu mašininio mokymo (ML) algoritmai dažniausiai pasitelkiami dėl savybės gerai atpažinti sudėtingus smegenų signalų bangų sklidimo šablonus. Norint dideliu tikslumu klasifikuoti motorinius judesius, būtina iš EEG signalo išskirti teisingus ir reikšmingus bruožus klasifikatoriaus apmokymui. Įsivaizduojamosios motorikos metu skirtingi smegenų regionai yra aktyvuojami nevienodai – signalų energija mažėja arba didėja pagal tai, kokie motoriniai judesiai yra įsivaizduojami. Energijos sumažėjimo efektas yra vadinamas Su įvykiu susijusia desinchronizacija (ERD), o atvirkščias efektas yra vadinamas Su įvykiu susijusia sinchronizacija (ERS). Kadangi ERD/ERS apibrėžia pereinamąjį smegenų signalų bangų aktyvumą, tai teisingas ir žinomas tokios informacijos šablonas, seka leidžia klasifikuoti ĮM uždavinius. Akcentuotina, kad šablonų išskyrimas nėra tikslus dėl smegenų ypatybių ir nedeterministinės jų veiklos net tam pačiam subjektui. Kai klasifikatorius yra apmokomas panaudojant konkretaus subjekto šablonus, jis gali būti pasitelktas valdyti kitus įrenginius.

3. BRUOŽŲ IŠSKYRIMAS IR KLASIFIKAVIMAS

3.1. Apžvalga

Per gana ilgą laikotarpį buvo pasiūlyta nemažai daugiaklasių BCI sprendimų [1–27], kurie taiko skirtingus bruožų išskyrimo metodus. Bruožų išskyrimo metodas yra viena iš labiausiai kritiškų dalių EEG klasifikavimo uždavinyje ar bet kokios BCI sistemos apdorojimo grandinėje. Kadangi BCI sistemos tikslumas tiesiogiai priklauso nuo išskirtų bruožų vektorių kokybės, tad būtina nuodugniai analizuoti kokybišką jų nustatymą ir apdorojimą. Tipinė EEG signalo apdorojimo etapų grandinė pateikta 2 pav.



2 pav. EEG signalo apdorojimo etapų grandinė

Po pradinio privalomo signalo apdorojimo, kuris turi būti vykdomas visiems signalo kanalams, eina bruožų išskyrimo etapas. Kiekvienam bruožų išskyrimo algoritmui toks etapas gali būti išskaidomas į tris skirtingus apdorojimo blokus, kurie apsprendžia bendrą algoritmo greitaveiką:

1. *Pradinio apdorojimo* [neprivalomas] – papildomas signalų filtravimas (pvz., į skirtingas dažnių sritis).
2. *Bruožų apskaičiavimas* – apdorojami EEG kanalų duomenys (pvz., juostos energijos skaičiavimas).
3. *Vektoriaus sudarymas* – apskaičiuoti galutinius vektoriaus elementus (pvz., kanalų energijos vidurkis).

Kontroliuojant ir keičiant realizaciją blokeliuose, galima gauti daug skirtingų algoritmo variacijų įvertinimui. Ši schema taip pat yra naudinga siekiant analizuoti mažus algoritmų skirtumus.

3.2. Bruožų išskyrimo technikos

Penki dažniausi EEG signalo bruožų išskyrimo metodai, minimi mokslinėje literatūroje [1–27], realizuoti ir analizuoti šiame darbe: Juostų galios bruožai (BP), Laiko srities parametrai (TDP), Teager-Kaiser energijos operatorius (TKEO), Signalų galios bei naujas Kanalų skirtumo. Papildomas signalų apdorojimas atliktas panaudojus Bendrųjų erdviųjų šablonų (CSP) filtrą. Siūlomas Kanalų skirtumo metodas bus apžvelgtas toliau. Platesnis kitų metodų aprašymas pateikiamas pilnoje šio darbo versijoje.

3.2.1. Kanalų skirtumo metodas

Kadangi bruožų išskyrimo metodas yra viena iš kritinių BCI dalių, tai efektyvesnis šio žingsnio sprendimas glaudžiai susijęs su tikslesniu klasifikavimu. Šiame darbe pateiktas naujas bruožų iš EEG signalo išskyrimo metodas – Kanalų skirtumo algoritmas. Jis yra pagrįstas Juostų galios bruožų (BP) algoritmu ir turi papildomą signalo filtravimo žingsnį. Algoritmas (3 pav.)

apskaičiuoja filtruoto signalo bruožus iš EEG kanalų, kurie aplink save turi bent keturis kaimyninius elektrodus. Šis sprendimas leidžia sumažinti naudojamų EEG kanalų skaičių (ir perteklinių duomenų kiekį), iš kurių bus išskiriami bruožai, taip padedant klasifikatoriui efektyviau išmokti naujus šablonus bei išskirti tik unikalų (ne bendrinį) signalą iš kaimyninių EEG kanalų klasifikavimui. Dažniausiai visi kaimyninių kanalų signalai virpa panašiai arba turi bendrą vienodą bazinę dedamąją (triukšmą). Šis bazinis triukšmo signalas yra nepageidaujamas ir turi būti pašalinamas. Jau anksčiau įrodyta, jog Laplaso filtras leidžia efektyviai pagerinti EEG signalo erdvinę raišką [28] ir padeda atskirti EEG signalus nuo aplinkos [29] triukšmo. Dėl šios priežasties Laplaso metodas (4 pav.) buvo pasirinktas kaip papildomas filtravimo žingsnis.

Įsivaizduojamosios motorikos uždaviniui elektrodai turi būti parinkti simetriški ir padengti abi hemisferas, kad būtų galima užfiksuoti visus energijos pokyčius, sukurtus ERD / ERS procesų [30]. Tokie elektrodų pavyzdžiai galėtų būti (pagal tarptautinę 10-20 sistemą): C3, C4, F3, F4, P3, P4, Cz, Pz, Fz, jeigu jie yra prieinami EEG sistemoje.

Algoritmas: Kanalų skirtumo

Įvestys: $E \leftarrow$ matrica iš visų elektrodų EEG signalų (dydis: $\text{kanalai} \times \text{signalas}$)
 $u \leftarrow n$ pasirinktų elektrodų (tik turintys bent keturis simetriškus kaimynus) ir jų kaimynų elektrodų indeksų matrica (dydis: $n \times 9$)
Išvestys: $v[1..m] \leftarrow$ sukonstruotas bruožų vektorius (ilgis: $m = 3n$)

1. $k = 1$
 2. **for** $i=1$ to n **do**
 3. $Q = \text{laplace}(E, u[i])$ /* Filtruojamas elektrodo EEG signalas naudojant Laplaso filtrą.*/
 4. $Z = \text{bandpower}(Q)$ /* Atliekamas Band Power metodas filtruotam signalui, kad būtų gautas signalas *Mu*, *Alfa* ir *Beta* dažniuose/juostose.*/
 5. **for** $j=1$ to 3 **do**
 6. $v[k] = \text{mean}(Z_j)$ /* Apskaičiuojami bruožų vektoriaus elementai (pvz., vidurkis, dispersija, kt.) iš signalo Z juostos */
 7. $k = k+1$
 8. **end for**
 9. **end for**
-

3 pav. Kanalų skirtumo pseudokodas

Algoritmas: Laplaso filtras

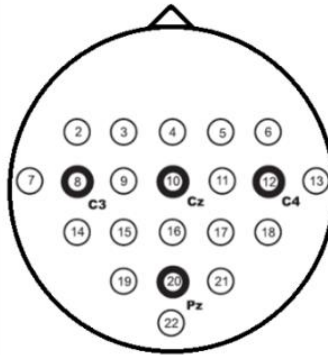
Įvestys: $E \leftarrow$ matrica iš visų elektrodų EEG signalų (kanalai \times signalas)
 $u[1..9] \leftarrow$ elektrodų grupės indeksai (3x3 konfiguracija)

Išvestys: $e \leftarrow$ Filtruotas EEG signalas

```
1.  function laplace(E, u)                                /* Laplaso
2.       $K = [-0.5, -1, -0.5; -1, 6, -1; -0.5, -1, -0.5]$       koeficientai.*/
3.       $e = \{0\}$                                            /* Nulių masyvas */
4.       $k = 0$ 
5.      for  $i=1$  to 3 do
6.          for  $j=1$  to 3 do
7.               $e = e + K[i, j] * E[u[k]]$                 /* Sąsukos operacija su
8.               $k = k + 1$                                 koeficientų matrica.*/
9.          end for
10.     end for
11.     return  $e$ 
11. end
```

4 pav. Laplaso algoritmo pseudokodas

Juostų galios metodas išskaido EEG signalą į keletą dažnių komponentų. Įprasta naudoti dažnius, susijusius su Mu, Alfa ir Beta smegenų bangomis. Signalų energijos skaičiavimas išivaizduojamajai motorikai atrodo intuityvus dėl ERD/ERS procesų, kurie vyksta smegenyse tuo metu, kai atliekamas ĪM eksperimentas. Naudojamų juostų skaičius yra pasirinkimo ir diskusijos klausimas, kadangi smegenų bangų signalai griežtai nepatenka į apibrėžtas dažnių sritis, yra priklausomi nuo subjekto ir dažnai persidengia dėl smegenų elektrinės dinamikos ir nestacionarumo.



5 pav. EEG kanalai, naudoti skaičiavimuose (10–20 sistema)

5 pav. pavaizduota, kaip buvo pasirinkti keturi EEG kanalai, kurie atitinka pirmą anksčiau aprašyto metodo kriterijų (t. y. elektrodai C3, Cz, C4 ir Pz tarptautinėje 10-20 sistemoje). Kiekvieno pasirinkto kanalo signalas buvo filtruojamas naudojant Laplaso filtrą (1), panaudojant kaimyninių kanalų signalus ir standartinę 3x3 Laplaso svorių matricą (branduolį), kaip parodyta (2).

$$Q = \sum_{i=1}^3 \sum_{j=1}^3 K_{ij} E_{ij} \quad (1)$$

$$K = \begin{bmatrix} -0.5 & -1 & -0.5 \\ -1 & 6 & -1 \\ -0.5 & -1 & -0.5 \end{bmatrix}, \quad (2)$$

kur E_{ij} yra kaimyninio EEG kanalo signalas, K_{ij} yra atitinkamas svoris iš branduolio matricos i -osios eilutės ir j -ojo stulpelio. Pavyzdžiui, imant Cz kaip pasirinktą kanalą, K_{11} elementas atitiktų svorį -0.5 trečiam EEG kanalui ir K_{22} atitiktų svorį 6 (šeši) Cz kanalui ir t. t. Neegzistuojantiems kanalams priskiriamas 0 (nulinis) svoris. Didesnio dydžio branduolio matricos nebuvo analizuotos, kadangi dėl to reiktų turėti daugiau kanalų EEG sistemoje ar naudojamose signalų duomenų bazėje.

Po signalo filtravimo buvo apskaičiuota juostų galia dažnių srityse: 8–14Hz, 14–19Hz, 19–24Hz, 24–30Hz kiekvienam iš keturių signalų. Gauta 16-ka naujų signalų, iš kurių kiekvienam buvo apskaičiuotas galios vidurkis ir gautos reikšmės sudėtos į masyvą (bruožų vektorių).

3.3. Klasifikavimo metodai

Iš žinomų EEG signalo klasifikatorių sąrašo, aptikto literatūroje [1–27], buvo pasirinkti dažniausiai naudojami metodai pradinei analizei ir eksperimentams atlikti: Atraminų vektorių mašina (SVM), Tiesinė diskriminantų analizė (LDA), Kvadratinė diskriminantų analizė (QDA) ir k-artimiausių kaimynų (kNN) metodai.

3.4. Duomenų pasirinkimas ir eksperimentas

3.4.1. Vertinimo procedūra

Ankstesniuose skyreliuose paminėti bruožų išskyrimo metodai buvo realizuoti ir palyginti eksperimentiškai. Visi eksperimentai buvo atlikti pasitelkus

MATLAB skaitinio programavimo aplinką, BioSig biblioteką biomedicinių signalų apdorojimui ir libSVM biblioteką SVM klasifikavimo užduotims. Idėjos naudoti skirtingus EEG signalų energijos apdorojimo metodus ir CSP filtravimą (kartu su pradiniu kodu) buvo paimitos iš ankstesnio Piotr Szachewicz darbo [30]. Klasifikatoriai buvo apmokyti ir validuoti naudojant dešimtainę kryžminę validaciją. Numatytosios parametrų reikšmės buvo taikomos LDA ir QDA klasifikatoriams taip, kaip standartiškai nustato MATLAB paketas. Gardelės paieškos metodas buvo pasitelktas optimizuoti SVM RBF (radialinės bazinės funkcijos) gama ir vertės-kainos parametrus [32]. Surastos ir naudotos parametrų reikšmės: $C = 10$, $\gamma = 0.25$.

3.4.2. BCI IV 2a duomenų rinkinys

Klasifikatorių apmokymui ir testavimui buvo panaudota BCI signalų duomenų bazė, rinkinys „2a“ [33] iš BCI IV varžybų, vykusių 2008 metais. Darbo rengimo metu ši duomenų bazė buvo vienintelis žinomas 4 klasių įsivaizduojamosios motorikos duomenų rinkinys, laisvai prieinamas internete ir tinkamas pagal darbo temą.

3.4.3. Tikslumo skaičiavimas

BCI duomenų klasifikavimo rezultatų tikslumas buvo apskaičiuotas naudojant Cohen'o kappa [36] koeficientą.

3.5. Rezultatai

Visi eksperimentų rezultatai yra pateikiami 1 lentelėje ir 2 lentelėje. Pabrėžtina, kad naudojant paprastus EEG bruožus, kappa koeficiento vidurkis LDA metodui visur, išskyrus vieną atvejį, surenka aukščiausią tikslumo įvertį (ir vidurkį). Tai traktuotina kaip ženklas, kad uždavinys yra gerai tiesiškai klasifikuojamas ir (arba) yra geras tiesinis EEG bruožų atskiriamumas (tiesiškai nusakomi duomenys). Tačiau CSP filtravimo ir SVM klasifikavimo kombinacija nežymiai aplenkia LDA vienu atveju. Pasiiektas maksimalus kappa vidurkis 0.495 (t. y. 62 % tikslumas), kuris yra gana toli iki 0.60 kappa (70 % tikslumo), pasiektas kitame darbe [37], kuriame taikyti sudėtingesni metodai. Kadangi Kanalų skirtumo metodas nesuderinamas su CSP filtravimu, tai tie atvejai pažymimi N/A.

1 lentelė. Klasifikavimo rezultatai su CSP filtravimu (kappa reikšmės)

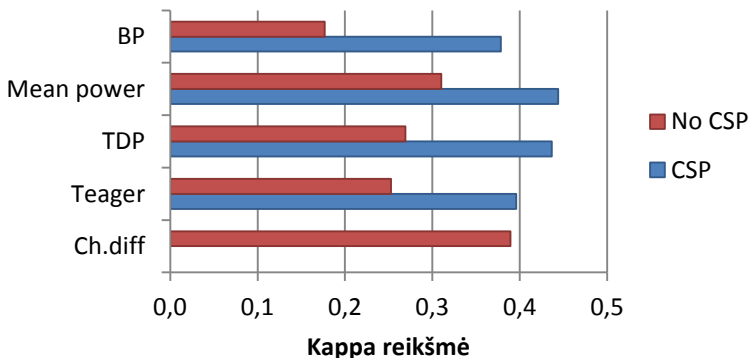
Klasifikatorius	Ch.diff	Teager	TDP	Mean power	BP	Eil. vidurkis
<i>kNN</i>	N/A	0,3890	0,4327	0,4249	0,3393	0,3965
<i>LDA</i>	N/A	0,4437	0,4950	0,4638	0,4154	0,4545
<i>QDA</i>	N/A	0,3868	0,4344	0,4259	0,3515	0,3997
<i>SVM</i>	N/A	0,3645	0,3835	0,4605	0,4075	0,4040
<i>Stulp.vidurkis</i>	N/A	0,3960	0,4364	0,4438	0,3784	

2 lentelė. Klasifikavimo rezultatai be CSP filtravimo (kappa reikšmės)

Klasifikatorius	Ch.diff	Teager	TDP	Mean power	BP	Eil. vidurkis
<i>kNN</i>	0,3678	0,1538	0,2045	0,1867	0,1225	0,2071
<i>LDA</i>	0,4346	0,4147	0,4134	0,4400	0,2487	0,3903
<i>QDA</i>	0,3179	0,2864	0,2790	0,3185	0,1480	0,2700
<i>SVM</i>	0,4372	0,1553	0,1791	0,2950	0,1877	0,2509
<i>Stulp.vidurkis</i>	0,3894	0,2525	0,2690	0,3101	0,1767	

Vidutinis bruožų tikslumas (stulp. vidurkis) indikuoja, kad Vidutinės galios ir TDP bruožai yra geriausi tada, kai naudojamas CSP filtravimas. Tačiau pasiūlytasis Kanalų skirtumo metodas leidžia pasiekti geriausią rezultatą (ir artimą CSP) iš visų metodų, kai CSP nenaudojamas. Pritaikius Juostų galios metodą, testuose gauti prasčiausi rezultatai.

Pabrėžtina, kad kanalų skirtumo metodo rezultatai atkartoja Juostų galios (kartu su CSP metodu) rezultatus, kadangi algoritmas taip pat turi išskirti skirtingas signalo dažnių juostas ir tam naudoja Juostų galios metodą.. Tai matyti 6 pav. Kadangi Kanalų skirtumo metodas negali naudoti CSP filtravimo, tad vienas mėlynas stulpelis paveiksle nėra rodomas.



6 pav. Vidutinis tikslumas pagal bruožų metodą

Visas eksperimentų išėities tekstas, testų duomenys ir detalūs rezultatai yra prieinami kodo saugykloje: <https://github.com/tomazas/icist2015>.

3.6. Išvados

Šiame skyriuje buvo tirti keli signalo energijos bruožų išskyrimo metodai ir jų panaudojimas keturių klasių įsivaizduojamosios motorikos BCI klasifikavimo uždaviniui analizuoti. Atlikus eksperimentinius tyrimus, galima pateikti išvadas:

1. Galios vidurkio ir / ar TDP metodai iš visų eksperimentuose taikytų metodų atskleidė geriausius rezultatus (0,4638 kappa ~ 59 % ir 0,4950 kappa ~ 62 % atitinkamai), kai buvo klasifikuojamas EEG signalas filtravimui naudojant CSP.
2. Teigiamas efektas testų tikslumui (10–15 % didesnis) nustatytas tada, kai buvo naudojamas CSP filtravimas. Tai parodo, kad CSP metodas yra efektyvus ir turėtų būti naudojamas EEG signalų filtravimui.
3. Geriausi klasifikavimo rezultatai iš visų testuotų klasifikatorių buvo pademonstruoti LDA (0,4545 kappa ~ 59 %). Šie rezultatai patvirtina, kad LDA algoritmas gali būti sėkmingai naudojamas EEG signalams klasifikuoti, jeigu bruožai gali būti tiesiškai atskiriami ir / arba EEG duomenys yra gerai apdoroti.
4. Pasiūlytas signalo bruožų išskyrimo Kanalų skirtumo metodas atskleidė geriausią vidutinį klasifikavimo rezultatą (0,3894 kappa ~ 54 %) iš kitų testuotų bruožų išskyrimo metodų, kai CSP filtravimas nebuvo naudojamas (t. y. jis pralenkė kitus metodus 6–16 %). Šio metodo privalumas yra galimybė pasiekti klasifikavimo rezultatus,

- artimus CSP (0,4438 kappa ~ 58 %) taikant paprastesnį filtravimo metodą.
5. Kai kurie subjektai (T5, T6) rodo didelį atsparumą esamiems bruožų išskyrimo metodams, tad, siekiant didesnio klasifikavimo tikslumo, būtinos į subjektą orientuotos (adaptyvios) technikos.
 6. Būsimi darbai susiję su patobulinimo galimybėmis, taip pat geresnių bruožų išskyrimo algoritmų, kurie gali prisitaikyti prie specifinės subjekto EEG informacijos, kūrimu. Siekiant išspręsti įsivaizduojamosios motorikos problemas, gali būti taikomos ir kitos naujos klasifikavimo technikos.

4. GILUS MOKYMAS IR NEURONINIAI TINKLAI

4.1. Apžvalga

Mašininio mokymo srityje, gilaus mokymo kryptyje buvo atrastas gana naujas ir perspektyvus EEG duomenų klasifikavimo būdas. Sąsukos neuroniniai tinklai (CNN) – tai naujas metodas, įkvėptas vizualiosios gyvūnų anatomijos, skirtas klasifikuoti paveikslus. Jis nebuvo plačiai naudotas su EEG, taip pat netaikytas įsivaizduojamosios motorikos uždaviniams analizuoti. Šis metodas, pasižymintis galimybėmis apibendrinti-sutelkti ir savaime išmokti tam tikrus bruožus netiesiniais būdais, gali padėti EEG klasifikavimui. Įsivaizduojamosios motorikos EEG uždaviniams stinga tikslų sprendimų, tad CNN galėtų būti naujas perspektyvus būdas, skirtas nuodugniau pažvelgti į tą pačią problemą. Remiantis metodo naujumu ir sėkme kitose srityse, šiame darbe jis buvo pasirinktas kaip pagrindinis įrankis atlikti keturių klasių EEG įsivaizduojamosios motorikos uždavinio analizę.

4.2. Gilus mokymas

Pastaraisiais metais publikuojama itin daug mokslinių straipsnių, naudojančių CNN klasifikavimo uždaviniams analizuoti. Buvo pasiūlyti keli būdai, padedantys spręsti įsivaizduojamosios motorikos ir kitas susijusias problemas. Šio skyrelio likusioje dalyje pateikiama trumpa dažniausiai naudojamų technikų apžvalga.

CNN buvo sėkmingai panaudotas Mirowski ir kt. [38] epileptinių priepuolių numatymui iš EEG. Straipsnio autoriai pasiūlė naudoti keturis EEG bivariacinių statistinių savybių tipus kaip klasifikavimo bruožus. Pasiūlymas argumentuotas tuo, jog dažnai naudojami vienavariaciniai bruožai (t. y. apskaičiuoti iš kiekvieno EEG kanalo atskirai) neturi reikiamos tarpkanalinės sąryšio informacijos. Kryžminė koreliacija, netiesinis susietumas, Lyapunov'o

eksponentės ir bangelių synchronizacijos bruožų informacija buvo įkelta į 2D paveikslus siekiant klasifikuoti. Gautas 70 % klasifikavimo tikslumas. Autoriai Cecotti ir Gräser [39] EEG analizės srityje darbu sprendė SSVEP (statinės būsenos vizualiai iššaukiamų potencialų) signalo klasifikavimo problemą, kai subjektai yra veikiami per vizualinę konkretaus dažnio stimuliaciją. Testuose naudota keturių sluoksnių CNN tinklo topologija su Furje transformacijos filtru antrame sluoksnyje. Pasirinkta architektūra įrodė galinti pasiekti iki 97 % klasifikavimo tikslumą. Nustatyta, kad perėjimas nuo laiko sritys į dažnių sritį teigiamai paveikė klasifikavimo rezultatus. Tačiau įtrauktas pasitikėjimo atmetimo kriterijus kiekvienai klasei galutiniam sprendimui lankstumo nesuteikė, nes sukūrė daug duomenų atmetimų ir algoritmo apibendrinimo galimybes padarė vidutiniškomis. Kitas CNN taikymas SSVEP problemai analizuoti yra pateiktas Bevilacqua ir kt. [40] straipsnyje. Jame autoriai naudojo keturių sluoksnių tinklo architektūrą su paslėptu L2 greitosios Furje transformacijos (FFT) sluoksniu dažniams išgauti. Signalų analizė buvo atlikta dažnių srityje pagal problemos tipą. Per kanalus Pz, PO3, PO4, Oz (10–20 elektrodų sistemoje) 256Hz dažniu buvo įrašyti 2 sekundžių trukmės EEG duomenys. Iš filtruotų EEG duomenų buvo sudaryti 4x512 pikselių dydžio paveikslai, jie panaudoti kaip įvestys CNN klasifikatoriui. Panaudojus 1000 epochų, buvo apmokytas tinklas. Šio metodo pasiektas vidutinis tikslumas – 88 %.

Naujesniame Bai ir kt. [41] straipsnyje apie keturių klasių įsivaizduojamosios motorikos uždavinį pasiūlytas Bangelių-CSP (Bendrųjų erdviųjų šablonų) su ICA (Nepriklausomų komponentių analize) filtru metodas. Pasiiektas 76 % vidutinis šio metodo tikslumas naudojant SVM (Atraminų vektorių mašinos) klasifikatorių.

Vienas iš naujausių CNN darbų keturių klasių įsivaizduojamosios motorikos srityje yra Yang ir kt. [42] straipsnis. Jo autoriai pasiūlė komplementarių dažnių bruožų žemėlapių pasirinkimo (FCMS) metodą. Darbe panaudotas ACSP (Papildytas CSP) bruožų filtravimo metodas. Analizuoti ir kiti du bruožų pasirinkimo metodai: atsitiktinio žemėlapių pasirinkimas (RMS) ir visų bruožų žemėlapių pasirinkimas (SFM). Kaip geriausias metodas vertintinas FCMS, sugebėjęs apriboti ACSP bruožų perteklių skirtinguose dažnių juostose. CNN naudojo 5 (penkių) sluoksnių architektūrą su 5x5 filtrais (branduoliais). Darbas atskleidė, jog CNN gali išmokti išskirtinius, gilios struktūros bruožus EEG klasifikavimui, nepasikliaujant dirbtinai sukurtais bruožais. Buvo pasiektas vidutinis 69 % klasifikavimo tikslumas.

4.3. Sąsukos neuroniniai tinklai (CNN)

Sąsukos neuroniniai tinklai yra biologiškai įkvėptas MLP (daugiasluoksnio perceptrono) variantas. Jis buvo sėkmingai panaudotas raidžių atpažinimui LeCun ir kt. [43] darbe. Šiuo metu juo domisi mokslininkai dėl klasifikavimo galimybių. CNN susideda iš vieno ar kelių sąsukos sluoksnių, kuriuose svoriai yra padalijami bendrai visoms įvestims. Keli tokie sluoksniai suformuoja netiesinę „filtrų“ grandinę. Sąsuka yra pritaikyta naudoti 2D duomenis, kitaip nei kiti neuroniniai tinklai, kurie dirba su 1D vektoriumi. Tokia savybė leidžia geriau ir lengviau pavaizduoti ir suprasti išskirtus bruožus.

4.4. Bruožų išskyrimo metodai


Aibę EEG bruožų išskyrimo metodų tyrinėjo Uktveris ir Jusas [44], kiti autoriai. Metodų išvestis dažniausiai yra vienos dimensijos bruožų vektorius, kurį galima naudoti klasifikavimui. Tačiau galimybė adaptuoti algoritmus dviejų dimensijų CNN iki šiol nebuvo išsamiai analizuota. Itin svarbu žinoti ir tai, ar adaptuotų metodų taikymas gali atskleisti panašius ar geresnius rezultatus, kai jie naudojami 2D erdvėje su CNN. Šiame darbe pasitelkti tokie dažniausiai taikomi bruožų išskyrimo metodai: Vidutinės kanalo energijos (MCE), Kanalo dispersijos (CV), Vidutinės lango energijos (MWE), Principinių komponentų analizės (PCA), Vidutinės juostos galios (BP), Kanalo FFT energijos (CFFT), Kanalo diskrečiosios kosinusų transformacijos (DCT), Laiko srities parametru (TDP), Teger-Kaiser energijos operatoriaus (TKEO), FFT energijos žemėlapiu (FFTEM), Kompleksinės Morlet bangelės transformacijos (CWT), Neapdorotų signalo bruožų (RAW), Signalu energijos žemėlapiu (SEM) realizacijos CNN. Detalus metodų aprašymai pateikiami pilnoje darbo versijoje.

4.4.1. Kanalu dispersija (CV)

Dispersija kiekvienam i -ajam EEG kanalui yra antrasis signalo x_i momentas, paskaičiuotas apie signalo x_i vidurkį \bar{x}_i . Rezultatas yra normalizuojamas naudojant Box-Cox (logaritmo) transformaciją ir gaunamas galutinis bruožų vektorius:

$$y_i = \log \left(\frac{1}{N} \sum_{k=1}^N (x_i[k] - \bar{x}_i)^2 \right), i = \overline{1, n}. \quad (3)$$

Bruožų žemėlapiu pavyzdys, sugeneruotas naudojant šią techniką, pateiktas 7 pav. Duomenys paveikslui sugeneruoti paimti iš duomenų rinkinio, aprašyto 3.4.2 skyrelyje.




7 pav. Bruožų žemėlapis, sugeneruotas taikant CV metodą

4.4.2. FFT energijos žemėlapis (FFTEM)

Šis metodas generuoja 2D bruožų žemėlapi iš EEG, naudojant FFT (Greitąją Furje transformaciją). Kiekvienas i -asis EEG kanalo signalas x_i yra transformuojamas į dažnių sritį ir suformuoja vieną eilutę bruožų žemėlapyje, kaip parodyta (4). Pilno signalo skaičiavimų sritis-langas pasitelktas siekiant gauti globalų energijos paveikslą (būseną), kitaip nei H_u ir kt. [45] darbe, kuriame naudotas trumpas FFT skaičiavimų langas siekiant užfiksuoti energijos kitimo dinamiką. Pilnas langas turi tokį pranašumą, jog įtraukiama visa dažnių sritis neprarandant duomenų, tačiau kartu įdedamas ir papildomas triukšmas, nebūtinai priklausantis įsivaizduojamosios motorikos EEG.

$$H_i = |FFT(x_i)|, \quad i = \overline{1, n} \quad (4)$$

Apskaičiuotas žemėlapis H buvo sumažintas iki reikiamo klasifikavimui CNN bruožų žemėlapio dydžio. 8 pav. pateiktas šio metodo sugeneruotas žemėlapio pavyzdys. Duomenys paveikslui sugeneruoti paimti iš duomenų rinkinio, aprašyto 3.4.2 skyrelyje.




8 pav. FFT energijos žemėlapio pavyzdys

4.4.3. Signalų energijos žemėlapis (SEM)

Dirbant šiuo metodu, bruožų žemėlapis generuojamas iš neapdorotų EEG signalo energijos reikšmių. Apskaičiuojama Box-Cox normalizuota kiekvieno i -ojo EEG signalo x_i kanalo energija, ji tiesiai dedama į bruožų žemėlapio H_i i -ąją eilutę, kaip parodyta (5):

$$H_i = \log x_i^2, \quad i = \overline{1, n}. \quad (5)$$

Jeigu reikia, gautas bruožų žemėlapio mastelis pakeičiamas (padidinamas ar sumažinamas) iki reikiamo CNN paveikslų dydžio. Pavyzdinis žemėlapis, gautas naudojant šį metodą, pateiktas 9 pav. Duomenys paveiksliui sugeneruoti paimti iš duomenų rinkinio, aprašyto 3.4.2 skyrelyje.



9 pav. Bruožų žemėlapis sugeneruotas naudojant SEM

4.5. CNN architektūros pasirinkimas

Siekiant įvertinti geriausią (tikslumo ir spartos prasme) architektūrą sprendžiamam uždaviniui, buvo išbandyta vienuolika skirtingų CNN konfigūracijų – pradedant nuo paprasčiausios ir baigiant kompleksinėmis topologijomis. Visų architektūrų konfigūracijos aprašytos supaprastintu žymėjimu ir pateiktos 3 lentelėje. Naudojama žymėjimo metodika pateikta 4 lentelėje.

Duomenų rinkys, aprašytas 3.4.2 skyrelyje, buvo panaudotas vertinant architektūras. Fiksuoti pradiniai tinklo parametrai: paveikslų dydis – 44x44px, pradinis mokymosis grietis – 0.01, momentas – 0.01, epochos – 500, apmokymo dydis – 128, bruožų algoritmas – MCE.

Architektūrų vertinimo rezultatai pateikti 10 pav. Matyti, kad testavimo tikslumas yra apie ~65 % tarp beveik visų konfigūracijų. Tačiau apmokymo tikslumas rodo dinamiškesnį profilį nuo 50 % iki 80 %. Taigi šiuo atveju kaip


geriausia pasirinktina CNN konfigūracija, kuriai reikia mažiausiai skaičiavimų resursų, t. y. paprasčiausia: 1, 2, 4, ar 10.

3 lentelė. Vertintos CNN architektūros

#	CNN konfigūracija	Pastabos
1	IC(4)RPFSO	4 filtrai
2	IC(4)RP(4)FSO	poslinkis 4
3	IC(8)RPFSO	8 filtrai
4	ICRPFSO	
5	IC(32)RPFSO	32 filtrai
6	IC(64)RPFSO	64 filtrai
7	ICRPCRPFSO	
8	ICRFSO	
9	ICFSO	
10	IC(7x1)RC(1x7)RPFSO	Ne kvadratiniai filtrai
11	IC(1x7)RPC(7x1)RPFSO	Ne kvadratiniai filtrai

4 lentelė. CNN sluoksnių simbolinis žymėjimas

Žymėjimas	Aprašymas (numatytieji parametrai)
I	įvesties sluoksnis (dydis 44x44x1)
C	sąsukos sluoksnis (7x7, 16 filtrų)
R	ReLU sluoksnis
P	sutelkimo-agregavimo sluoksnis (2x2, poslinkis 2)
F	pilnai sujungtas sluoksnis (4 klasės)
S	softmax sluoksnis
O	klasifikavimo (išvesties) sluoksnis




10 pav. CNN architektūrų įvertinimas

4.6. Bruožų žemėlapių generavimas

Daug broožų išgavimo metodų formuoja vienos dimensijos (1D) koeficientų vektorių, vadinamąjį „broožų vektorių“. Iškyla problema, kadangi CNN yra pritaikytas apdoroti tik dviejų dimensijų duomenis (2D paveikslus). Alternatyva yra interpretuoti vienos dimensijos signalą kaip 2D vienos eilutės paveikslą, kurio matmenys $W \times H$ (čia W yra paveikslo plotis ir H yra aukštis), tada $H = 1$. Tokio būdo trūkumas yra tas, kad bus galima naudoti tik vienos eilutės CNN filtrus-branduolius (angl. *kernels*). Nebus įvertinamos sąsajos ar priklausomybės tarp duomenų eilučių. Tad reikia sprendimo, kuris padėtų išvengti šios problemos.

Darbe apžvelgiamos ir siūlomos kelios transformavimo technikos ir adaptavimo metodai, leidžiantys transformuoti 1D broožų vektorius duomenis į 2D duomenis, tinkamus naudoti su sąsukos neuroniniais tinklais (CNN). Kaip adaptavimo žingsnis bendroje EEG klasifikavimo grandinėje įsiterpia, pateikta 11 pav.



11 pav. Adaptavimas EEG klasifikavimo grandinėje

Kadangi CNN klasifikavimui dažniausiai priima santykinai mažo dydžio ($N \times N$) kvadratinį-stačiakampį paveikslą (pvz., 7×7 px, 22×22 px, 44×44 px ir pan.), tai gali būti trys skirtingi atvejai, kai dydis N yra lyginamas su broožų vektorius ilgiu L .

Apibrėžkime palyginimo santykį kaip FVLIR (angl. *feature vector length and image ratio*). Šis santykis aprašomas, kaip pateikta (6) lygtyje, o galimi atvejai nagrinėjami 5 lentelėje.

$$FVLIR = L/N, \quad (6)$$

čia N yra broožų žemėlapi (paveikslo) dydis, L yra broožų vektorius ilgis.

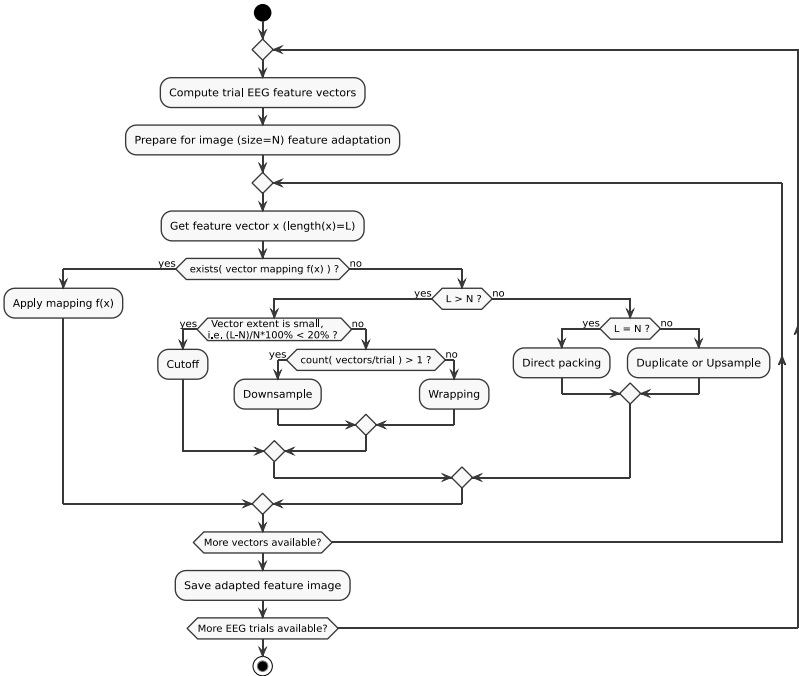
5 lentelė. Bruožų vektorių transformavimo technikos

FVLIR	Technika	Savybės
< 1 (trumpas)	1. Duplication	Horizontalus / vertikalus daugiklis
	2. Upsampling (interpolation/expansion)	
	3. 2D mapping	transformavimo funkcija
1 (tinka)	1. Direct packing	Horizontalus / vertikalus transformavimo funkcija
	2. 2D mapping	
> 1 (ilgas)	1. Cutoff	ilgis
	2. Wrapping	horizontalus / vertikalus
	3. Downsampling (reduction)	žingsnis
	4. 2D mapping	transformavimo funkcija

Pagal FVLIR reikšmę (t. y. L ir N palyginimo rezultatą) galima parinkti transformavimo techniką. Siūlomos technikos plačiau aprašytos pilnoje šio darbo versijoje.

4.6.1. Adaptavimo algoritmas

Žinant bruožų vektorių ilgį L ir bruožų žemėlapių-paveikslo dydį N , pagal adaptavimo algoritmą (12 pav.) galima nustatyti rekomenduojamą transformavimo techniką EEG bruožų vektoriui. Technika yra parenkama taip, kad išsaugotų kuo daugiau įvedimo duomenų ir pašalintų kuo mažesnę bruožų kiekį atliekant 2D transformaciją.



12 pav. Bruožų vektoriaus adaptavimo algoritmas

Pagal minėto algoritmo logiką parinktos bruožų transformavimo technikos eksperimentuose naudotiems algoritmams yra pateiktos 6 lentelėje. Jeigu bruožų metodus generuoja 2D bruožų žemėlapij arba vektorių, kurio ilgis toks pats, kaip paveikslas dydis N , naudojamas tiesioginis pakavimas (angl. *direct packing*). Kitu, 2D duomenų atveju, yra atliekamas padidinimas (angl. *upsample*) arba sumažinimas (angl. *downsample*), o kartojimas (angl. *duplication*) papildomai taikomas ir 1D duomenų atveju. Standartinis vektoriaus ilgis ir paveikslas dydis parinktas taip, kad sutaptų su 22 EEG kanalais tam, kad būtų įmanoma lengviau pagaminti kvadratinio dydžio apmokymo paveikslus CNN klasifikatoriui.

6 lentelė. Adaptavimo algoritmo parinktos transformavimo technikos

Metodas	Bruožų dimensija (ilgis L)	Parinkta 2D transformacija		
		N > 22	N < 22	N = 22
MCE	1D (1x22)	duplication	cutoff/downsampling	direct packing
CV	1D (1x22)	duplication	cutoff/downsampling	direct packing
MWE	2D (22x22)	upsample	downsampling	direct packing
PCA	1D (1x22)	duplication	cutoff/downsampling	direct packing
BP	1D (1x22)	duplication	cutoff/downsampling	direct packing
CFFT	1D (1x22)	duplication	cutoff/downsampling	direct packing
DCT	2D (22x22)	upsample	downsampling	direct packing
TDP	1D (1x22)	duplication	cutoff/downsampling	direct packing
TKEO	1D (1x22)	duplication	cutoff/downsampling	direct packing
FFTEM	2D (22x22)	upsample	downsampling	direct packing
CWT	2D (22x22)	upsample	downsampling	direct packing
RAW	1D (1xSamples)	downsampling	downsampling	downsampling
SEM	1D (1xSamples)	downsampling	downsampling	downsampling

4.7. Eksperimentai

Pagrindinis eksperimentų tikslas buvo ištirti CNN galimybes keturių klasių įsivaizduojamosios motorikos klasifikavimo problemai spręsti. Taip pat siekta išanalizuoti galimas CNN architektūras, broožų žemėlapius, filtrų dydžius ir kitus parametrus klasifikavimo tikslumui. Eksperimentai buvo vykdomi analizės etape (taip pat derinami CNN parametrai) ir pagrindiniame įsivaizduojamosios motorikos klasifikavimo etape (kiekvienam subjektui).

Eksperimentų rezultatai buvo gauti ir vertinami naudojant normalizuotą tikslumą [0; 1]. CNN parametrai buvo suderinti ir validuoti prieš galutinį klasifikavimo etapą. Testai buvo atliekami naudojant dešimtainę kryžminę validaciją. CNN galimybė mokytis iš broožų duomenų buvo patikrinta peržiūrint išmokus svorių-filtrų paveikslus.

4.7.1. Duomenų rinkinys

Šio darbo 3.4.2 skyriuje klasifikatoriaus apmokymui ir testavimui buvo panaudotas minėtas BCI signalų duomenų rinkinys „2a“ (paskelbtas Brunner ir kt. [33]) iš 2008 metais surengtų BCI IV varžybų.

4.8. Rezultatai

Galutiniai klasifikavimo rezultatai buvo gauti atlikus pradinę analizę ir CNN parametrų derinimo etapą. Siekiant galutinio įvertinimo su kiekvieno subjekto duomenimis, buvo apmokytas ir testuotas CNN su pradiniu 0.1 mokymosi greičiu, 0.1 momentu, 128 paveikslų paketų dydžiu mokymui, 200 epochų ir architektūra I(22x22)C(4x4,16)RPFSO. Rezultatai verifikuoti taikant dešimtainės kryžminės validacijos schemą. Gauti tikslumo rezultatai kartu su standartinio nuokrypio reikšmėmis yra pateikti 7 lentelėje. Iš rezultatų matyti, kad optimaliausias vertes (70 % apmokymas ir 68 % testavimas) demonstruoja FFT energijos žemėlapiu metodas. Toliau rikiuojasi Kanalo dispersijos (68 % ir 61 %) bei Signalo energijos žemėlapiu (67 % ir 61 %) broožų metodai. Mažiausią tikslumą (41 % ir 43 %) pasiekė TDP broožų metodas.

7 lentelė. Klasifikavimo rezultatai skirtingiems broožų metodams

Metodas	Apmokymas	Testavimas
MCE	0.66 ± 0.19	0.58 ± 0.20
CV	0.68 ± 0.18	0.61 ± 0.22
MWP	0.66 ± 0.19	0.58 ± 0.20
PCA	0.61 ± 0.16	0.55 ± 0.20
BP	0.52 ± 0.18	0.39 ± 0.11
CFFT	0.66 ± 0.19	0.58 ± 0.20
DCT	0.54 ± 0.17	0.42 ± 0.11
TDP	0.41 ± 0.11	0.31 ± 0.07
TKEO	0.43 ± 0.12	0.34 ± 0.05
FFTEM	0.70 ± 0.18	0.68 ± 0.20
CWT	0.46 ± 0.10	0.43 ± 0.13
RAW	0.48 ± 0.14	0.37 ± 0.11
SEM	0.67 ± 0.18	0.61 ± 0.20

Geriausio FFTEM metodo tikslumas buvo palygintas su kitais žinomais metodais (8 lentelė), aptiktais mokslinėje literatūroje, taip pat su BCI IV konkurso finalistais. Gautas tikslumas yra panašus į BCI IV konkurso laimėtojo rezultatus ir artimas pažangiausiems metodams.

8 lentelė. Tikslumo palyginimas su kitais metodais

Autorius	Broožai	Klasifikatorius	Kappa	Klasifikavimo tikslumas
Song ir kt. [34] (BCI IV 3-ia vieta)	CSP	Sudėtinis daugiaklasis	0.31	48 %

Xygonakis ir kt. [22]	CSP	Sudėtinis modelis	0.46	59 %
Guangquan ir kt. [34] (BCI IV 2-a vieta)	Log variance	LDA ir Bajeso	0.52	64 %
She ir kt. [23]	CSP	Netiesinės Ekstremumų Mokymo mašinos	0.52	64 %
Yang ir kt. [42] (BCI IV 1-a vieta)	FBCSP	Naivaus Bajeso Parzeno Lango	0.57	68 %
Pasiūlytas metodas	FFTEM	CNN	0.57	68 %
She ir kt. [9]	CSP	PPTSVM	0.63	72 %
Ang ir kt. [35]	FBCSP	Naivaus Bajeso Parzeno Lango	0.66	75 %

Visas eksperimentų išeities tekstas, testų duomenys ir detalūs rezultatai yra prieinami kodo saugykloje: <https://github.com/tomazas/itc2017>.

4.9. Išvados

Šiame skyriuje buvo analizuojamas Sąsukos neuroninių tinklų (CNN) metodas ir jo panaudojimas keturių klasių įsivaizduojamosios motorikos uždaviniui spręsti. Atlikus išsamią CNN analizę ir parametrų derinimą, gauti geri rezultatai. Įvertinus eksperimentų rezultatus, galima daryti tokias išvadas:

1. FFT energijos žemėlapių metodas pademonstravo geriausią bruožų išskyrimą ir pasiekė 68% vidutinį klasifikavimo testavimo tikslumą tarp visų BCI IV varžybų „2a“ duomenų rinkinio subjektų. Gauta tikslumo reikšmė yra šiek tiek geresnė nei Tabar ir Halici [46] pasiūlytose naujose technikoje ir panaši į sudėtingų naujausių EEG metodų tikslumą Yang ir kt. [42] darbe.
2. Pasiūlytas bruožų vektorių adaptavimo metodas leido panaudoti bruožų išgavimo metodus, duodančius 1D bruožų vektorius, ir pritaikyti juos 2D bruožų žemėlapių CNN klasifikavimui. Realizuota technika buvo sėkmingai validuota eksperimentiškai.
3. Paprastesnių bruožų išskyrimo metodų (FFT energijos žemėlapių) panaudojimas parodo aukštą CNN metodo potencialą įsivaizduojamosios motorikos uždavinių analizei ir galimybę atpažinti kompleksinius smegenų signalų virpėjimo šablonus.
4. Norint pasiekti geriausius tikslumo rezultatus, sumažinti skaičiavimo resursų panaudojimą ir sutrumpinti apdorojimo laiką, naudotinos mažiau sudėtingos CNN architektūros (kaip ICRPFSO).
5. Norint pasiekti aukštą klasifikavimo tikslumą ir efektyvų skaičiavimo resursų panaudojimą, būtina derinti CNN parametrus. Parametrų parinkimas naudojant diapazono paiešką yra pakankamas, siekiant neviršyti laiko ir skaičiavimo resursų ribų.

6. Geriausias CNN filtro dydis duotam įsivaizduojamosios motorikos uždaviniui yra 7×7 , kadangi šiuo atveju galima efektyviai išmolti bruožų detales. Surastas geriausias bruožų žemėlapiio dydis 24×24 pikseliai (arba bent dvigubai didesnis negu naudojamo filtro dydis). Didesni dydžiai padidina skaičiavimo resursų poreikį, o mažesni sukuria pernelyg mažai svorių.
7. CNN vertintinas kaip geras pasirinkimas, pasiteisinęs sprendžiant EEG įsivaizduojamosios motorikos uždavinį. Darbas gali būti tęsiamas siekiant sukurti specialiai pritaikytus CNN efektyvesnius bruožų išskyrimo metodus, kurie būtų ne tik tikslūs, bet ir greiti.

5. EEG ĮRAŠYMO SISTEMOS KŪRIMAS

5.1. Įžanga

Didėjant sąmoningumui apie smegenų-kompiuterio sąsajas (BCI), galinčias analizuoti smegenų signalus, kilo naujas susidomėjimas elektroencefalogramos (EEG) įrašymo prietaisų kūrimu. Įvairios reabilitacijos [47], pramogų ir net saugumo [48] taikomosios programos gali būti realizuotos apdorojant [49,50,51] tokius elektrinius signalus, įrašytus nuo žmogaus galvos skalpo. Tačiau dėl triukšmingo ir kintamo EEG signalo pobūdžio sukurti BCI yra sudėtinga. Šios srities pažangai trukdo validavimo, dizaino žinių ir tokių sistemų analizės stoka. Net jei būtų buvę tinkamų bandymų naudoti mobiliuosius įrenginius tokiai problemai spręsti [52], nestacionarių smegenų signalų įrašymui mikrovoltų lygyje reikėtų profesionalių aukštos kokybės ir didelės skiriamosios gebos analoginių keitiklių. Tokios užduotys lengviau įgyvendinamos atsiradus specialiams mažo triukšmo programuojamiems analoginiams-skaitmeniniams keitikliams kaip (ADC) ADS1298. Profesionalias ir aukštos kokybės EEG įrašymo sistemas siūlo keli tiekėjai, pvz., „G.Tec“ ir „TMSi“ ir t. t. Šie įrenginiai yra brangūs, kainuoja daugiau nei keturi tūkstančiai JAV dolerių, todėl nėra skirti bendram viešajam naudojimui ar pradinio lygio kūrėjams, dėl to sudėtingas platesnis BCI įsisavinimo procesas ir jo tyrimai. Be to, nėra pakankamai žinių apie architektūrą ar veikimo informaciją, ar tai, kaip šie prietaisai yra iš tikrųjų patvirtinti ir pasiekia nurodytas specifikacijas. Be to, nėra kompaktiškų EEG sistemų, leidžiančių keisti aparatūrą pagal problemos reikalavimus (iki 64 ar daugiau kanalų). Tai padėtų valdyti ir supaprastinti procesą, taip pat sumažinti sąnaudas.

Remiantis anksčiau paminėtomis problemomis, šiame darbe pristatoma nauja nebrangi modulinė ir vertikaliai sudedama plokštė, kuri gali būti naudojama pradinio lygio EEG signalų įrašymui. Be to, siūloma konstrukcija leidžia sistemą lengvai keisti ir pritaikyti įvairioms EEG užduotims, taip

sutaupyti išlaidų. Darbe pateikiami paprasti, bet veiksmingi sistemos validavimo metodai, skirti įrašymui ir bendram projekto įvertinimui.

5.2. Apžvalga

Egzistuoja daugiau nei keletas straipsnių, apibūdinančių parengtus EEG įrašymo sistemų prototipus. F. Pinho ir kt. [53] pateikė skaičiuojamąją galia galingą, nešiojamą sistemą su 32 aktyviais sausais elektrodais (paremtą TLC272 preciziniu operaciniu stiprintuvu) ilgalaikiam paciento epilepsijos stebėjimui. Akumulatoriaus konstrukcija pasižymėjo 24 bitų skiriamosios gebos analoginiu-skaitmeniniu keitikliu ADS1299, galinčiu įrašyti iki 1 kps (1k reikšmių/s). EEG duomenys gali būti apdorojami realiu laiku tam skirtame 1 GHz ARM procesoriuje arba siunčiami į pagrindinį kompiuterį per „Wi-Fi 802.11 b/g“ ryšį analizei ir antriniam apdorojimui. Nors darbo tikslas buvo sukurti savarankišką sistemą su aukštesnio našumo procesoriumi, sistemai veikiant visu pajėgumu, pagrindinis trūkumas buvo ilgiausias 25 val. akumulatoriaus veikimo laikas. Kadangi prietaisas nebuvo optimizuotas pagal dydį, tai reikėjo naudoti ilgesnius laidus ir aktyvius elektrodus.

Panašų metodą taikė S. Feng [54], projektuodamas savo EEG įrašymo sistemą pastovios būsenos vizualiai sukeltų potencialų (SSVEP) problemai spręsti. Papildomas 16 kanalų praplėtimas („Beagle Bone Black“ vystymo plokštei, turinčiai AM3358 ARM Cortex-A8 1 GHz CPU) sukurtas su dviem ADS1299 keitikliais, galinčiais įrašyti signalą 1 kps greičiu. Autorių teigimu, jų sistema buvo pranašesnė dėl įterptinės duomenų apdorojimo galios ir gebėjimo dirbti iki 12 valandų su dviem ličio baterijomis. Nepaisant to, kad pagamintas gaubtas sunaudojo tik 5 % (101,2 mW) visos reikiamos galios esant maksimaliai apkrovai, tokios sistemos naudojimas nešiojamoje baterijomis maitinamoje techninėje įrangoje šiuo metu vis dar yra didelis iššūkis.

B. Senevirathna ir kt. [55] suprojektavo nebrangų septynių kanalų, mažo dydžio ir baterijomis maitinamą EEG sprendimą, skirtą ilgalaikiam šizofrenija sergančių pacientų stebėjimui. Plokštė naudojo vieną ADS1299 keitiklį, kuris buvo valdomas SAM G55 mikrovaldikliu. Autorių teigimu, jų sistema fiksuoja analoginius duomenis 250Hz dažniu ir siunčia juos per „Bluetooth“ 230,4 kbps greičiu. Pažymėtinas sistemos 69 mA energijos suvartojimas dirbant visiems kanalams. T. T. Vo ir kt. [56] pateikė panašų atvejį – mažai kainuojantį aštuonių kanalų EEG įrašymo įrenginį, skirtą BCI taikymams. Įrenginys, turėdamas STM32F4 mikrovaldiklį, vieną ADS1299 ir sugebantis siųsti duomenis per „Bluetooth“, buvo skirtas naudoti kaip nedidelių matmenų ir mažos galios prietaisas. EEG įrašymas buvo vykdomas 250Hz greičiu naudojant šlapius auksu padengtus elektrodus. Nepaisant sėkmingų realizacijų, abiems anksčiau

minėtiems prietaisams trūksta erdvinės EEG skiriamosios gebos, o galimybė išplėsti įrenginius nebuvo svarstoma.

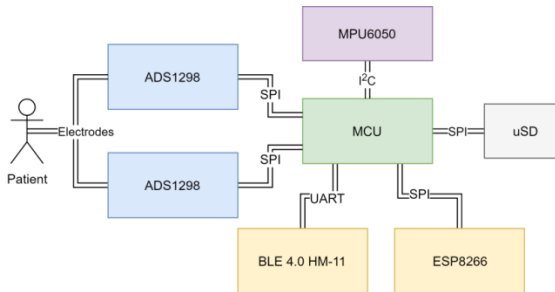
Naują EKG (elektrokardiogramos) įrašymo sistemos, kurioje yra 24 bitų ADS1298 keitiklis, projektą atliko D. Campillo [57]. Straipsnio autorius prijungė aštuonių kanalų analoginį-skaitmeninį keitiklį prie MSP430F5529 mikrovaldiklio, veikiančio 12 MHz dažniu. Sistemos plokštė buvo pajėgi įrašyti signalą 500 Hz greičiu, vidinis kanalo triukšmas (ICN) buvo 9 μV , o bendros modos atmetimo santykis (CMRR) buvo 94 dB. Plokštė buvo bandyta ilgiau nei 12 val. Pagrindinis sistemos apribojimas EEG panaudojimui buvo kanalų trūkumas gerai erdvinei skiriamajai gebai užtikrinti.

5.3. Sistemos architektūra

5.3.1. Skaitmeninis analoginis keitiklis

Suprojektuoti patikimą, didelio tikslumo, precizinę analoginę keitiklio dalį (AFE) nėra paprasta užduotis [58], todėl pirmiausia derėtų apsvarstyti komercinius, paruoštus sprendimus. Rinkoje yra keli AFE įrenginiai, galintys diskretizuoti analoginį EEG signalą. Kadangi pagrindinės smegenų EEG svyravimų bangos sklinda žemo dažnio diapazone nuo 0 iki 40 Hz, aukšto dažnio diskretizavimo AFE nebūtinai. Taigi pagrindinis dėmesys turėtų būti skiriamas tokiems AFE, kurie turi maksimalų palaikomų kanalų skaičių, triukšmo mažinimo galimybes ir aukštą įrašymo skiriamąją gebą. ADS1299 (ir alternatyva ADS1298) keitiklis buvo pasirinktas kaip sistemos AFE, nes pasižymi plačiu savybių spektru, yra plačiai naudojamas pramonėje ir daugelyje taikomųjų programų. Šiam projektui iš „Texas Instruments“ buvo gauti nemokami ADS1298 pavyzdžiai. ADS1298 / 9 yra prietaisas [59], skirtas biopotencialiniams matavimams (elektrokardiograma (EKG), elektromiograma (EMG) ir EEG). Jis yra su aštuoniais mažo triukšmo, programuojamo stiprinimo stiprintuvais (PGA) ir aštuoniais aukštos 24-bitų skiriamosios gebos, Delta-Sigma ADC keitikliais. Prietaisas turi savikontrolės, temperatūros ir nuimtų elektrodų aptikimo mechanizmus.

5.3.2. Mikrovaldiklis




13 pav. EEG plokštės komponentų integracija

Pradinei sistemos versijai (13 pav.) buvo pasirinktas Atmega2560 mikrovaldiklis (MCU), veikiantis 16 MHz dažniu. Realizuota pertraukimais paremta serijinė periferinė sąsaja (SPI), skirta ADC įrašymui ir duomenų perdavimui per belaidį ryšį. Du ADS1298 AFE buvo glaudžiai supakuoti (viršuje ir apačioje) vienoje keturių sluoksnių spausdintinėje plokštėje (PCB) (14 pav. a), sudarant 16 kanalų EEG sistemą. Papildomos bendrosios paskirties įvestys-išvestys (GPIO) buvo išskaidytos dviem išvadais. Belaidžio ryšio atveju buvo naudojamos dvi papildomos plokštės – Bluetooth 4.0 Low Energy „HM-11“ (viršuje) ir populiarus ESP8266 Wi-Fi modulis (apačioje). Be to, į sistemą buvo įtrauktas akselerometro ir giroskopo MPU 6050 modulis, valdomas per I2C magistralę. Vietinė duomenų saugykla buvo realizuota naudojant „micro SD“ kortelės lizdą. Baigtos pradinės sistemos plokštės versijos vaizdas pateikiamas 14 pav. b) paveiksle. Kredito kortelės dydžio plokštės matmenys yra 10×5 cm.



(a)



(b)

14 pav. Sukurta PCB: (a) plokštės viršus ir apačia; (b) pradinė pabaigtos sistemos plokštės versija

Norint pasiekti išplečiamą ir modulinę architektūrą, SPI išvadai buvo išvesti ant PCB, kad būtų galima prijungti iki trijų papildomų plokščių ir pasiekti

bendrą 64 EEG kanalų skaičių. Visi ADS1298 įrenginiai buvo prijungti naudojant pakopinį konfigūracijos režimą. Kitas palaikomas „Daisy-Chain“ konfigūracijos tipas nebuvo priimtinas dėl apribojimo – nesugebėjimo skaityti ir rašyti kiekvieno (atskirai) ADS registrų, todėl šiame darbe nebuvo naudojamas.

5.3.3. Belaidė komunikacija

Siūlomoje EEG sistemoje buvo panaudoti „Wi-Fi 802.11“ ir „Bluetooth“ technologiniai metodai. „Bluetooth“ komponentas buvo įdiegtas naudojant mini HM-11 BLE 4.0 modulį, kuris yra apribotas maksimaliu 230,400 kbps siuntimo greičiu. „Wi-Fi“ komponentas buvo realizuotas ESP8266-12E moduliu, naudojant universalią asinchroninę imtuvo-siūstuvo (UART) ir SPI sąsajas, kurios yra apribotos atitinkamai maksimaliu 921,600 kbps ir mikrovaldiklio greičiu.

5.3.4. Elektrodo sistema ir galvos kepurė


Akrilonitrilo butadieno stireno (ABS) plastiko galvos kepurės prototipas (15 pav. a), paremtas populiariu atviro kodo „Ultracortex“ OpenBCI modeliu, buvo atspausdintas 3D spausdintuvu ir panaudotas bandymuose. Elektrodo išdėstymas galvos kepurėje atitinka tarptautinę 10–20 elektrodo sistemą.



(a)



(b)



(c)

15 pav. Galvos kepurės komponentai (a) atspausdinta 3D spausdintuvu plastikinė galvos kepurė; (b) elektrodo kepurėlė; (c) plastikinė elektrodo laikymo sistema su spyruokle

Kadangi gelio pagrindu pagaminti elektrodai reikalauja naudoti laidžią pastą ir yra linkę išdžiūti per ilgą naudojimo laiką, tai tyrimams buvo pasitelkti sausi daugkartinio naudojimo EEG elektrodai (15 pav. b) iš Floridos mokslo instituto, JAV. Sausieji elektrodai turi turėti tinkamą kontaktą su oda, kad būtų apribota varža iki 10 k Ω ar mažiau [60]. Prispaudus elektrodą ant odos paviršiaus, pagerėja sąlytis su oda. Siekiant išvengti odos ir elektrodo sąlyčio degradavimo (ir dėl to didėjančio impedanso), kiekvienam elektrodui buvo

panaudota spyruoklinė įtempimo sistema (15 pav. c), o dalys atspausdintos 3D spausdintuvu [61]. Sistema sudaryta iš prisukamų lizdo tipo laikiklių, kad elektrodas būtų laikomas vienoje vietoje.

5.3.5. Akselerometras

Akselerometro ir giroskopo įtraukimas į įrašymo sistemą leido nustatyti EEG signalo artefaktus [62], kurie buvo iššaukti pacientui judant. Ne visada įmanoma, kad subjektas liktų ramus ilgą laiką. Dėl didelės komponentų integracijos buvo optimalu panaudoti egzistuojantį MPU-6050 modulį pradinei sistemos PCB versijai.

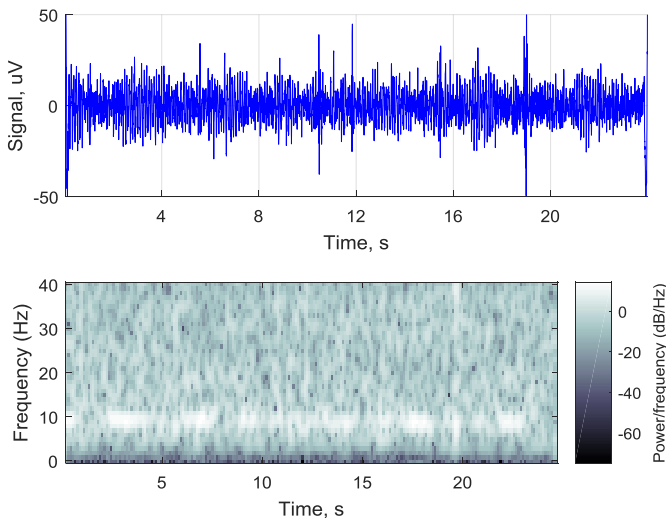
5.4. Vertinimas

Šiame skyriuje pateikiami EEG įrašymo sistemos plokštės vertinimo metodai ir eksperimentai, atliekami siekiant patvirtinti jos operacinį teisingumą. Nors yra būdų, kaip patikrinti sistemą, naudojant brangią trečiosios šalies bandymo įrangą [63], tačiau egzistuoja ir paprastesnės sistemos validavimo technikos. Siūlomi metodai išsamiai aprašyti tolesniuose skyriuose. Sudėta keturių plokščių sistema buvo validuota su 64 elektrodais. Patikrinimo bandymai buvo atlikti naudojant didelės skiriamosios gebos (HR) režimą, kai PGA reikšmė buvo lygi 1 (vienam), diskretizavimo dažnis 500Hz, o Wi-Fi pralaidumo vertinimui buvo naudojamas 1 kHz diskretizavimo dažnis.

5.4.1. Alfa bangos

Paprastas EEG įrašymo sistemos patikrinimo metodas yra alfa bangų analizė [64]. Šios bangos gali būti įrašytos žmogaus subjekto atsipalaidavimo metu, kai subjekto akys yra užmerktos.


Alfa bangų aptikimas ir registravimas bandytas prijungus elektrodus (O1, Oz, O2 (10–20 elektrodų išdėstymo sistemoje) prie subjekto galvos skalpo ir paprašius tiriamojo atsipalaiduoti, atverti akis 30 sekundžių ir tada būti atsipalaidavus su užmerktomis akimis vieną minutę. Užmerktų akių metu padidėjęs EEG signalo aktyvumas 7,5–12,5 Hz dažnių srityje parodė tipinę smegenų okcipitalinės srities srities alfa bangos signalą (16 pav.). Gauti rezultatai atskleidė, kad sistema sugebėjo sėkmingai užregistruoti tokio reiškinio EEG signalą.



16 pav. Alfa bangų nustatymas iš įrašyto EEG signalo

5.4.2. EKG signalo įrašymas

Vienas iš paprastesnių testų, kuriuos galima atlikti siekiant patvirtinti bet kokią instrumentinį keitiklį (ADC), susijęs su širdies veiklos įrašu (elektrokardiograma arba EKG). Panaudojus tris laidus-elektrodus, buvo užregistruotas sveiko paciento EKG. EKG 78 dūžių/min diagramos pavyzdys pateiktas 17 pav. Tipiniai periodiniai QRS kompleksai matomi 2mV amplitudės signale, tai reiškia tinkamą signalų įrašymo dalies veikimą.



17 pav. EKG signalo įrašas atliktas naudojant sukurtą sistemą

5.4.3. Įvesties triukšmas

Įvesties triukšmas yra kiekvieno kanalo charakteristika, rodanti triukšmą, kurį sukelia vidinės ADS1298 lusto grandinės ir ADC. Kiekvieno kanalo

triukšmo lygis buvo patikrintas užtrumpinus visus kanalų įėjimus per ADS1298 registrą CHnSET = 1 (kur n = 1–8) ir įrašant 10s triukšmo lygį į mikro SD kortelę, naudojant skirtingus PGA ir diskretizacijos dažnio nustatymus. Kiekvieno kanalo triukšmo įtampos vidurkiai V_{PP} (nuo piko iki piko) pateikti 9 lentelėje.

9 lentelė. Vidutinis kanalo įvesties triukšmas μV_{PP}

Dažnis Fs, Hz	PGA						
	1	2	3	4	6	8	12
32000	2876	1883	937	753	617	357	283
16000	710	285	152	152	101	66	48,83
8000	118	43.90	33.62	33.09	21.65	15.66	11.54
4000	47.49	27.70	15.41	11.49	11.08	10.72	8.94
2000	31.70	13.88	10.25	10.25	6.32	5.70	5.74
1000	16.56	8.67	7.82	6.04	4.55	5.23	3.38
500	14.85	5.92	4.92	4.77	3.94	3.13	2.87

Matyti, kad triukšmas veiksmingai sumažėja, kai mažėja diskretizavimo dažnis (dėl ADS automatiškai daromo vidurkinimo). Maksimalus triukšmo sumažėjimas maždaug $1883 / 5,92 = 318$ kartų buvo pastebėtas PGA = 2 atveju. EEG taikymams nebūtinai didelis diskretizavimo dažnis, todėl iki 1 kHz dažniai yra daugiau nei pakankami, kad užtikrintų 7–30 Hz smegenų bangų svyravimų fiksavimą. Be to, didesnė stiprinimo reikšmė leidžia sumažinti įvesties triukšmą. Maksimalus triukšmo sumažėjimas maždaug $710 / 48,83 = 14,5$ karto buvo stebimas Fs = 16 kHz eksperimente.


5.4.4. SNR ir ADC tikslumas

Signalų ir triukšmo santykis (SNR) rodo sistemos gebėjimą nustatyti efektyvius signalus iš foninio triukšmo. Dirbant su EEG signalais, reikia kuo didesnio SNR, nes vertingas signalas yra toje pačioje mikro-voltų zonoje, kaip ir triukšmas. SNR decibelų skalėje yra apibrėžiamas taip, kaip parodyta (7) lygtyje:

$$SNR = 20 \log_{10} \left(\frac{A_{signal}}{A_{noise}} \right), \quad (7)$$


kur A_{signal} ir A_{noise} yra atitinkamai signalo ir triukšmo vidutinės kvadratinės (RMS) amplitudės. Siekiant įvertinti suprojektuotos sistemos SNR, buvo atliktas EEG įrašymo eksperimentas. Pirmiausia, 1 min. trukmės triukšmo signalas buvo registruojamas visuose ADS1298 kanaluose naudojant 250 Hz įrašymo greitį, vidutinė triukšmo RMS amplitudė buvo apskaičiuota iš visų duomenų. Po to kiekvienam kanalui buvo paduodamas žinomos amplitudės efektyvus 10Hz sinusinis signalas ir buvo atlikti tokio paties ilgio įrašai. Šie gauti signalai buvo

naudojami apskaičiuoti vidutinę RMS amplitudę ir, galiausiai, SNR reikšmę. Įvesties sinusinio signalo amplitudė buvo mažinama nuo 0 dB (100 % VCC) iki -100 dB (0,001 % VCC), kad visiškai užfiksuotų labai didelių ir labai mažų signalų sistemos elgesį. Tas pats metodas buvo pakartotas 500 Hz įrašymo dažniui. Eksperimento rezultatai pateikti 18 pav. Galima pastebėti, kad įvesties signalams, kurių amplitudė yra didesnė nei -12 dB (> 25 % VCC), pasiekiami daugiau kaip 100 dB SNR. Tipiniams 10–100 μ V (-100 dB iki -80 dB) EEG signalams SNR vertė svyruoja nuo 12 dB iki 35 dB. Mažesnis įrašymo dažnis suteikia didesnę SNR dėl didesnio ADS1298 signalo vidurkinimo ir perteklinio diskretizavimo (triukšmo panaikinimo).



18 pav. Signalu-triukšmo santykio (SNR) vertinimo rezultatai

ADC tikslumo vertinimas naudojo tuos pačius anksčiau įrašytus duomenis. Kiekviena iš įrašyto signalo reikšmių buvo palyginta su pradinėmis sinuso įvesties signalo reikšmėmis, kad būtų rasta diskretizavimo paklaida. Šio eksperimento rezultatai pateikiami 19 pav. Vidutinė gauta paklaida buvo 0,07 % su 0,22 % standartiniu nuokrypiu. Gauti rezultatai atskleidžia gerą atitiktį su oficialioje TI ADS1298 specifikacijoje pateikiamais rezultatais ir leidžia kvalifikuoti sistemą kaip tinkamai veikiančią įrenginį.



19 pav. Signalo tikslumas 60s įrašė ($F_s = 250$ Hz, $PGA = 6$)

5.4.5. Bendrosios modos atmetimo santykis (CMRR)

Galimybė atmesti bendrosios modos signalą yra labai svarbi EEG įrašymo sistemoms. Aukštesnis bendrosios modos atmetimo koeficientas (CMRR) užtikrina, kad matavimuose atsirastų mažiau bendrosios modos signalo. CMRR yra diferencinio stiprintuvo savybė [65]. Tokio stiprintuvo išėjimas gali būti modeliuojamas kaip diferencialinių ir bendrosios modos komponentų suma, kaip parodyta (8) lygtyje:

$$V_{out} = A_d V_{in} + A_{cm} V_{cm} \quad (8)$$

kur A_d yra diferencialinis ir A_{cm} yra bendrosios modos stiprinimas išreikštas atitinkamai (9) ir (10) lygtyje:

$$A_d \approx V_{out} / V_{in} \quad (9)$$

$$A_{cm} \approx V_{out} / V_{cm} \quad (10)$$

kur


$$V_{in} = (V_p - V_n), \quad (11)$$

$$V_{cm} = (V_p + V_n) / 2 \quad (12)$$

kur V_p yra įtampa teigiamoje įvestyje ir V_n yra įtampa neigiamoje įvestyje. Idealiems stiprintuvams $A_{cm} = 0$ ir $A_d \rightarrow \infty$. Tikrose programose $A_{cm} \neq 0$ ir $A_{cm} \ll A_d$. (10) lygties lygybė taikoma tik tada, kai tas pats bendrosios modos signalas paduodamas į abu stiprintuvo įėjimus, nes diferencialinio stiprinimo komponentas pašalinamas dėl $V_{in} \rightarrow 0$. CMRR gali būti apskaičiuojamas įvertinant (13) lygtį:

$$CMRR = 20 \log \left(\frac{A_d}{A_{cm}} \right). \quad (13)$$

Bandymas buvo atliktas sujungus kiekvieno kanalo diferencialines įvestis IN_xP , IN_xN ($x = \overline{1,8}$) ir generuojant išorinį fiksuoto dažnio sinuso įvesties bendrosios modos signalą. Išmatuotos įtampas ir vidutinis CMRR apskaičiuotas naudojant (13) lygtį. Bandymas buvo atliktas skirtingoms stiprinimo reikšmėms 1, 2, 4, 12 ir dažniams nuo 1 Hz iki 1 kHz. CMRR vertinimo rezultatai pateikiami 20 pav.



20 pav. Bendrosios modos atmetimo santykio matavimo rezultatai

Bandymų rezultatai rodo, kad stiprinimo padidėjimas nuo 1 iki 12 leidžia pasiekti ~15 dB geresnį atmetimo santykį 1–10 Hz signalams, nepaisant greitesnio mažėjimo nuo 15 Hz iki 1 kHz. Pažymėtina, kad mažiausia stiprinimo vertė, lygi 1 (vienetui), suteikia stabilų CMRR ~97 dB signalams iki ~70 Hz. Norint pasiekti aukščiausią stabilų CMRR EEG signalams 7–30 Hz dažnių diapazone, reikia naudoti 4 (keturių) stiprinimo vertę.

5.5. Išvados

Šiame skyriuje pristatytas modulinis biopotencialų įrašymo sistemos projektas, galintis įrašyti iki 64 EEG kanalų naudojant naują sudedamą konfigūraciją. Atlikus eksperimentus, formuluotinos tokios išvados:

1. Visi plokštės testai ir rezultatai parodė, kad kiekvienas sistemos komponentas veikia tinkamai. Atlikti eksperimentai leido patvirtinti, kad sistemos architektūros ir ADC lusto EEG įrašymui pasirinkimas buvo teisingas siekiant sukurti kompaktišką ir modernią sistemą.

2. Siūdomi paprasti vertinimo metodai leido patikrinti sistemos gebėjimą teisingai ir veiksmingai įrašyti EEG signalą, taip pat suteikė reikiamą grįžtamąjį ryšį tolesniam plokštės vystymui.
3. Atlikti vidiniai ADC bandymai buvo pradinis įrenginio teisingumo patikrinimo žingsnis. Kituose atliktuose bandymuose gauta vidutinė $6.59 \mu\text{Vpp}$ įvesties triukšmo ir vidutinė bendrosios modos atmetimo reikšmė -97 dB $0\text{--}70 \text{ Hz}$ dažnių juostoje atitinka oficialias „Texas Instruments“ ADS1298 specifikacijas.
4. Gebėjimas tinkamai užfiksuoti EEG alfa bangų reiškinį arba EKG atskleidė, kad sistema veikia taip, kaip tikėtasi. Bandymų metu išmatuotas $12\text{--}35 \text{ dB}$ SNR $10\text{--}100 \mu\text{V}$ amplitudės EEG signalams ir daugiau kaip 100 dB SNR signalams, kurių amplitudė didesnė nei $25 \% \text{ VCC}$.
5. Nustatyta, kad SNR ir tikslumas atitinka paskelbtas prietaiso charakteristikas, kaip nurodyta oficialioje „Texas Instruments“ specifikacijoje.
6. Siūloma sistema gali būti EEG arba EKG įrašymui ir stebėjimui skirtas nešiojamas prietaisas, pasižymintis maksimalia $\sim 250 \text{ mAh}$ suvartojama galia, esant pilnai apkrovai, ir daugiau nei 10 kartų mažesne gamybos kaina (palyginti su komerciniais prietaisais).
7. Sistemų palyginimas su kitomis literatūroje analizuotomis plokštėmis atskleidė panašius arba geresnius rezultatus. Tačiau, palyginti su komercinės klasės aparatūra, sistemoje trūksta geresnio triukšmo slopinimo priemonių, tad ją būtina toliau tobulinti.
8. Kadangi tokiems didelės skiriamosios gebos AFE reikia gero triukšmo slopinimo, tolesnis tyrimas ir plėtra gali būti sietini su aktyvių elektrodų panaudojimu ir sistemos ekranavimu.

6. DARBO IŠVADOS

1. Išnagrinėjus mokslinius darbus apie keturių klasių įsivaizduojamosios motorikos (IM) klasifikaciją, nustatyta, kad gilaus mokymo klasifikavimo metodai, skirti spręsti šią problemą, nebuvo plačiai analizuoti ir taikyti.
2. Po eksperimentinio, dažniausiai naudojamų, keturių klasių IM problemos bruožų išskyrimo ir klasifikavimo algoritmų įvertinimo nustatyta, kad būtini nauji savybių išskyrimo ir klasifikavimo metodai.
3. Buvo pasiūlyti ir eksperimentiškai patvirtinti IM problemos sprendimai:
 - a) Pristatytas naujas filtravimo-bruožų išgavimo Kanalų skirtumo metodas. Eksperimentiškai įrodyta, kad Kanalų skirtumo metodas (54 % tikslumas) savo rezultatais panašus į CSP metodą (58 % tikslumas) ir 6–16 % lenkia kitus išbandytus funkcijų išskyrimo metodus, kai nenaudojamas CSP filtravimas.
 - b) Sąsukos neuroniniai tinklai (CNN) adaptuoti IM uždaviniui spręsti. Eksperimentiškai įrodyta, kad CNN metodas yra veiksmingas, naudojant FFT energijos žemėlapių metodą bruožų išgavimui, pasiekia 68 % tikslumą ir gali būti lyginamas su kitais literatūroje aptartais pažangiais klasifikavimo metodais (69 % tikslumas).
 - c) Pasiūlyta nauja bruožų vektorių adaptavimo technika leido sėkmingai panaudoti bruožų išgavimo metodus, kurie duoda 1D bruožų vektorius, 2D bruožų žemėlapių CNN klasifikavimui. Metodas buvo validuotas eksperimentiškai ir pasiekta gerų rezultatų.
4. Dėl keturių klasių IM bandymų duomenų rinkinių stygiaus, nebrangių mokslinių EEG signalų įrašymo įrenginių ir jų kūrimo informacijos literatūroje trūkumo, sėkmingai suprojektuota ir pagaminta nauja EEG sistema, galinti įrašyti iki 64 kanalų IM EEG signalą.
5. Pagaminta EEG sistema buvo patvirtinta eksperimentiškai naudojant siūlomus paprastus, bet veiksmingus metodus. Palyginimas su esamais įrenginiais parodė panašius arba geresnius rezultatus:
 - a) unikalus modulinis-sudedamas dizainas su diskretizavimo greičiu iki 1 kHz;
 - b) išmatuotas aukštas -97dB CMRR 0–70 Hz dažnių srityje;
 - c) tipinis 12–35dB SNR 10–100 μV amplitudės signalams;
 - d) mažas energijos suvartojimas $< 250\text{mAh}$.

LITERATURA

1. YI, W., S., QIU, H., QI, L., ZHANG, B., WAN, D., MING. EEG feature comparison and classification of simple and compound limb motor imagery. *Journal of NeuroEngineering and Rehabilitation*, 2013, Vol. 10, No. 1, <https://doi.org/10.1186/1743-0003-10-106>
2. YI, W., S., QIU, K., WANG, H., QI, F., HE, P., ZHOU, L., ZHANG, D., MING. EEG oscillatory patterns and classification of sequential compound limb motor imagery. *Journal of NeuroEngineering and Rehabilitation*, 2016, Vol. 13, No. 1, <https://doi.org/10.1186/s12984-016-0119-8>
3. ÚBEDA, A., J. M., AZORÍN, R., CHAVARRIAGA. Classification of upper limb center-out reaching tasks by means of EEG-based continuous decoding techniques, *Journal of NeuroEngineering and Rehabilitation*, 2017, Vol. 14, No. 1, <https://doi.org/10.1186/s12984-017-0219-0>
4. ANGULO-SHERMAN, I. N., M., RODRÍGUEZ-UGARTE, N., SCIACCA, E., IÁÑEZ. Effect of tDCS stimulation of motor cortex and cerebellum on EEG classification of motor imagery and sensorimotor band power, *Journal of NeuroEngineering and Rehabilitation*, 2017, Vol. 14, No. 1, <https://doi.org/10.1186/s12984-017-0242-1>
5. ANDRADE, J., J., CECÍLIO, M., SIMÕES, F., SALES and M., CASTELO-BRANCO. Separability of motor imagery of the self from interpretation of motor intentions of others at the single trial level: an EEG study, *Journal of NeuroEngineering and Rehabilitation*, 2017, Vol. 14, No. 1, <https://doi.org/10.1186/s12984-017-0276-4>
6. WANG, K., Z., WANG, Y., GUO, F., HE, H., QI, M., XU and D., MING. A brain-computer interface driven by imagining different force loads on a single hand: an online feasibility study, *Journal of NeuroEngineering and Rehabilitation*, 2017, Vol. 14, No. 1, <https://doi.org/10.1186/s12984-017-0307-1>
7. GEORGIADIS, K., N., LASKARIS, S., NIKOLOPOULOS and I., KOMPATSIARIS. Exploiting the heightened phase synchrony in patients with neuromuscular disease for the establishment of efficient motor imagery BCIs, *Journal of NeuroEngineering and Rehabilitation*, 2018, Vol. 15, No. 1, <https://doi.org/10.1186/s12984-018-0431-6>
8. PFURTSCHELLER, G., P., LINORTNER, R., WINKLER, G., KORISEK, and G., MÜLLER-PUTZ. Discrimination of Motor Imagery-Induced EEG Patterns in Patients with Complete Spinal Cord Injury, *Computational Intelligence and Neuroscience*, Vol. 2009, Article ID 104180, 6 pages, 2009, <https://doi.org/10.1155/2009/104180>
9. SHE, Q., Y., MA, M., MENG, and Z., LUO. Multiclass Posterior Probability Twin SVM for Motor Imagery EEG Classification, *Computational Intelligence and Neuroscience*, Vol. 2015, Article ID 251945, 9 pages, 2015, <https://doi.org/10.1155/2015/251945>

10. XU, B., Y., FU, G., SHI, X., YIN, Z., WANG, H., LI, and C., JIANG. Enhanced Performance by Time-Frequency-Phase Feature for EEG-Based BCI Systems, *The Scientific World Journal*, Vol. 2014, Article ID 420561, 10 pages, 2014, <https://doi.org/10.1155/2014/420561>
11. HIGASHI, H. and T., TANAKA. Common Spatio-Time-Frequency Patterns for Motor Imagery-Based Brain Machine Interfaces, *Computational Intelligence and Neuroscience*, Vol. 2013, Article ID 537218, 12 pages, 2013, <https://doi.org/10.1155/2013/537218>
12. ZHANG, R., P., XU, T., LIU, Y., ZHANG, L., GUO, P., LI, and D., YAO. Local Temporal Correlation Common Spatial Patterns for Single Trial EEG Classification during Motor Imagery, *Computational and Mathematical Methods in Medicine*, Vol. 2013, Article ID 591216, 7 pages, 2013, <https://doi.org/10.1155/2013/591216>
13. ASTIGARRAGA, A., A., ARRUTI, J., MUGUERZA, R., SANTANA, J. I., MARTIN, AND B., SIERRA. User Adapted Motor-Imaginary Brain-Computer Interface by means of EEG Channel Selection Based on Estimation of Distributed Algorithms, *Mathematical Problems in Engineering*, Vol. 2016, Article ID 1435321, 12 pages, 2016, <https://doi.org/10.1155/2016/1435321>
14. BATULA, A. M., Y. E., KIM, and H., AYAZ. Virtual and Actual Humanoid Robot Control with Four-Class Motor-Imagery-Based Optical Brain-Computer Interface, *BioMed Research International*, Vol. 2017, Article ID 1463512, 13 pages, 2017, <https://doi.org/10.1155/2017/1463512>
15. KIM, Y., J., RYU, K. K., KIM, C. C., TOOK, D. P., MANDIC, and C., PARK. Motor Imagery Classification Using Mu and Beta Rhythms of EEG with Strong Uncorrelating Transform Based Complex Common Spatial Patterns, *Computational Intelligence and Neuroscience*, Vol. 2016, Article ID 1489692, 13 pages, 2016, <https://doi.org/10.1155/2016/1489692>
16. LIU, R., Z., ZHANG, F., DUAN, X., ZHOU, and Z., MENG. Identification of Anisomeric Motor Imagery EEG Signals Based on Complex Algorithms, *Computational Intelligence and Neuroscience*, Vol. 2017, Article ID 2727856, 12 pages, 2017, <https://doi.org/10.1155/2017/2727856>
17. MONDINI, V., A. L., MANGIA, and A., CAPPELLO. EEG-Based BCI System Using Adaptive Features Extraction and Classification Procedures, *Computational Intelligence and Neuroscience*, Vol. 2016, Article ID 4562601, 14 pages, 2016, <https://doi.org/10.1155/2016/4562601>
18. GUAN, S., K., ZHAO, and S., YANG. Motor Imagery EEG Classification Based on Decision Tree Framework and Riemannian Geometry, *Computational Intelligence and Neuroscience*, Vol. 2019, Article ID 5627156, 13 pages, 2019, <https://doi.org/10.1155/2019/5627156>
19. JI, H., J., LI, R., LU, R., GU, L., CAO, and X., GONG. EEG Classification for Hybrid Brain-Computer Interface Using a Tensor Based Multiclass Multimodal Analysis Scheme, *Computational Intelligence and Neuroscience*, Vol. 2016, Article ID 1732836, 15 pages, 2016, <https://doi.org/10.1155/2016/1732836>

20. KO, L. W., S. S. K., RANGA, O., KOMAROV, and C. C., CHEN. Development of Single-Channel Hybrid BCI System Using Motor Imagery and SSVEP, *Journal of Healthcare Engineering*, Vol. 2017, Article ID 3789386, 7 pages, 2017, <https://doi.org/10.1155/2017/3789386>
21. MARTIŠIUS, I. AND R., DAMAŠEVIČIUS. A Prototype SSVEP Based Real Time BCI Gaming System, *Computational Intelligence and Neuroscience*, Vol. 2016, Article ID 3861425, 15 pages, 2016, <https://doi.org/10.1155/2016/3861425>
22. XYGONAKIS, I., A., ATHANASIOU, N., PANDRIA, D., KUGIUMTZIS, and P. D., BAMIDIS. Decoding Motor Imagery through Common Spatial Pattern Filters at the EEG Source Space, *Computational Intelligence and Neuroscience*, Vol. 2018, Article ID 7957408, 10 pages, 2018, <https://doi.org/10.1155/2018/7957408>
23. SHE, Q., K., CHEN, Y., MA, T., NGUYEN, and Y., ZHANG. Sparse Representation-Based Extreme Learning Machine for Motor Imagery EEG Classification, *Computational Intelligence and Neuroscience*, Vol. 2018, Article ID 9593682, 9 pages, 2018, <https://doi.org/10.1155/2018/9593682>
24. DAI, M., D., ZHENG, S., LIU, and P., ZHANG. Transfer Kernel Common Spatial Patterns for Motor Imagery Brain-Computer Interface Classification, *Computational and Mathematical Methods in Medicine*, Vol. 2018, Article ID 9871603, 9 pages, 2018, <https://doi.org/10.1155/2018/9871603>
25. OZMEN, N. G., L., GUMUSEL, AND Y., YANG. A Biologically Inspired Approach to Frequency Domain Feature Extraction for EEG Classification, *Computational and Mathematical Methods in Medicine*, Vol. 2018, Article ID 9890132, 10 pages, 2018, <https://doi.org/10.1155/2018/9890132>
26. LI, M., X., LUO, J., YANG, AND Y., SUN. Applying a Locally Linear Embedding Algorithm for Feature Extraction and Visualization of MI-EEG, *Journal of Sensors*, Vol. 2016, Article ID 7481946, 9 pages, 2016, <https://doi.org/10.1155/2016/7481946>
27. BATRES-MENDOZA, P., M. A., IBARRA-MANZANO, E. I., GUERRA-HERNANDEZ, D. L., ALMANZA-OJEDA, C. R., MONTORO-SANJOSE, R. J., ROMERO-TRONCOSO, and H., ROSTRO-GONZALEZ. Improving EEG-Based Motor Imagery Classification for Real-Time Applications Using the QSA Method, *Computational Intelligence and Neuroscience*, Vol. 2017, Article ID 9817305, 16 pages, 2017, <https://doi.org/10.1155/2017/9817305>
28. TANDONNET, C., B. BURLE, T., HASBROUCQ, F., VIDAL. Spatial enhancement of EEG traces by surface Laplacian estimation: comparison between local and global methods. *Clinical Neurophysiology*, 116, 18–24 (2005)
29. QIN, L., B. HE. A wavelet-based time-frequency analysis approach for classification of motor imagery for brain-computer interface applications. *Journal of Neural Engineering*, Vol. 2, 65–72 (2005)
30. DOLEZAL, J., V., CERNY, J., STASTNY. *Online motor-imagery based BCI*, *Applied Electronics (AE)*, International Conference, 65, 68, 5–7 (2012)
31. SZACHEWICZ, P. *Classification of Motor Imagery for Brain-Computer Interfaces*, Master's thesis, Poznan University of Technology, Poznan (2013)

32. HSU, C., et al. *A Practical Guide to Support Vector Classification*, National Taiwan University, Taiwan (2010)
33. BRUNNER, C., et al. *BCI Competition 2008 – Graz data set A*. Available online: https://www.bbci.de/competition/iv/desc_2a.pdf (2008)
34. BCI IV competition final results. Available online: <http://bbci.de/competition/iv/results/> (accessed on 8 June 2019)
35. ANG, K. K., Z. Y., CHIN, C., WANG, C., GUAN, and H., ZHANG. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b, *Frontiers in Neuroscience*, 2012, Vol. 6. <https://dx.doi.org/10.3389%2Ffnins.2012.00039>
36. SCHLOGL, A. et al. Evaluation criteria in BCI research. In: G. Dornhege, J. del R. Millan, T. Hinterberger, D. J. McFarland, K.-R. Muller (Eds.). *Toward brain-computer interfacing*, MIT Press, 327–342 (2007)
37. ANG, K. K., et al. *Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface*, Neural Networks, 2008. IJCNN 2008. IEEE World Congress on Computational Intelligence, 2390, 2397, 1–8 June (2008)
38. MIROWSKI, P., Y., LECUN, D., MADHAVAN, R., KUZNIECKY. Comparing SVM and convolutional networks for epileptic seizure prediction from intracranial EEG, *IEEE Workshop Machine Learning Signal Processing*, 2008, <https://doi.org/10.1109/MLSP.2008.4685487>
39. CECOTTI, H., A., GRÄSER. Convolutional neural network with embedded fourier transform for EEG classification, *Proceedings of the 19th International Conference on Pattern Recognition (ICPR '08)*, 2008, 1–4, <https://doi.org/10.1109/ICPR.2008.4761638>
40. BEVILACQUA, V. et al. A novel BCI-SSVEP based approach for control of walking in Virtual Environment using a Convolutional Neural Network, *International Joint Conference on Neural Networks (IJCNN)*, 2014, 4121–4128, <https://doi.org/10.1109/IJCNN.2014.6889955>
41. BAI, X., X., WANG, S., ZHENG, M., YU. The offline feature extraction of four-class motor imagery EEG based on ICA and Wavelet-CSP, *Control Conference (CCC)*, 2014, 7189–7194, <https://doi.org/10.1109/ChiCC.2014.6896188>
42. YANG, H., S., SAKHAVI, K. K., ANG, C., GUAN. On the use of convolutional neural networks and augmented CSP features for multi-class motor imagery of EEG signals classification, *37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2015, 2620–2623, <https://doi.org/10.1109/EMBC.2015.7318929>
43. LECUN, Y., L., BOTTOU, Y., BENGIO, P., HAFFNER. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324, <https://doi.org/10.1109/5.726791>
44. UKTVERIS, T., V., JUSAS. Comparison of Feature Extraction Methods for EEG BCI Classification, *Information and Software Technologies: 21st International Conference*, 2015, 81-92, https://doi.org/10.1007/978-3-319-24770-0_8

45. HU, J., Z., MU, D., XIAO. Application of Energy Entropy in Motor Imagery EEG Classification. *JDCTA*, 2009, Vol. 3, 83–90, <http://dblp.dagstuhl.de/rec/bib/journals/jdcta/HuXM09>
46. TABAR, Y. R., U., HALICI. A novel deep learning approach for classification of EEG motor imagery signals, *Journal of Neural Engineering*, 2016, Vol. 14, No. 1, <https://doi.org/10.1088/1741-2560/14/1/016003>
47. RASHID, N., J., IQBAL, A., JAVED, M. I., TIWANA, U. S., KHAN. Design of Embedded System for Multivariate Classification of Finger and Thumb Movements Using EEG Signals for Control of Upper Limb Prosthesis, *BioMed Research International*, Vol. 2018, Article ID 2695106, 11 pages, 2018, doi: 10.1155/2018/2695106
48. DAMAŠEVIČIUS, R., R., MASKELIŪNAS, E., KAZANAVIČIUS, M., WOŽNIAK. Combining Cryptography with EEG Biometrics, *Computational Intelligence and Neuroscience*, Vol. 2018, Article ID 1867548, 11 pages, 2018, doi: 10.1155/2018/1867548
49. LIU, A., K., CHEN, Q., LIU, Q., AI, Y., XIE, A., CHEN. Feature Selection for Motor Imagery EEG Classification Based on Firefly Algorithm and Learning Automata. *Sensors* 2017, 17, 2576. doi: 10.3390/s17112576
50. PLANELLES, D., E., HORTAL, Á., COSTA, A., ÚBEDA, E., IÁEZ, J. M., AZORÍN. Evaluating Classifiers to Detect Arm Movement Intention from EEG Signals. *Sensors* 2014, 14, 18172–18186. doi: 10.3390/s141018172
51. TANG, Z., S., SUN, S., ZHANG, Y., CHEN, C., LI, S., CHEN. A Brain-Machine Interface Based on ERD/ERS for an Upper-Limb Exoskeleton Control. *Sensors* 2016, 16, 2050. doi: 10.3390/s16122050
52. BLUM, S., S., DEBENER, R., EMKES, N., VOLKENING, S., FUDICKAR, M. G., BLEICHNER. EEG Recording and Online Signal Processing on Android: A Multiapp Framework for Brain-Computer Interfaces on Smartphone, *BioMed Research International*, Vol. 2017, Article ID 3072870, 12 pages, 2017, doi: 10.1155/2017/3072870
53. PINHO, F., J. H., CORREIA, N. J., SOUSA, J. J., CERQUEIRA, N. S., DIAS. Wireless and wearable eeg acquisition platform for ambulatory monitoring. *IEEE 3rd International Conference on Serious Games and Applications for Health (SeGAH)*, Rio de Janeiro, 2014, 1–7, doi: 10.1109/SeGAH.2014.7067078
54. FENG, S., M., TANG, F., QUIVIRA, T., DYSON, F., CUCKOV, G., SCHIRNER. EEGu2: an embedded device for brain/body signal acquisition and processing. *International Symposium on Rapid System Prototyping (RSP)*, Pittsburgh, PA, 2016, 1–7. doi: 10.1145/2990299.2990304
55. SENEVIRATHNA, B., L., BERMAN, N., BERTONI, F., PARESCHI, M., MANGIA, R., ROVATTI, G., SETTI, J., SIMON, P., ABSHIRE. Low cost mobile EEG for characterization of cortical auditory responses. *2016 IEEE International Symposium on Circuits and Systems (ISCAS)*, Montreal, QC, 2016, 1102–1105, doi: 10.1109/ISCAS.2016.7527437

56. VO, T. T., N. P., NGUYEN, T., VO VAN. WEEGEE: Wireless 8-Channel EEG Recording Device. *6th International Conference on the Development of Biomedical Engineering in Vietnam (BME6)*. BME 2017. IFMBE Proceedings, Singapore, 2017, Vol. 63, 621–625, doi: 10.1007/978-981-10-4361-1_106
57. CAMPILLO, D., R., GUARDARRAMA, R., GONZÁLEZ, J., RODRÍGUEZ, D., JIMÉNEZ. A real time ECG preprocessing system based on ADS1298. *Computing in Cardiology*, Zaragoza, 2013, 947–950.
58. CONSUL-PACAREU, S., R., MAHAJAN, M. J., ABU-SAUDE, B. I., MORSHED. NeuroMonitor: a low-power, wireless, wearable EEG device with DRL-less AFE. *IET Circuits, Devices & Systems*, Vol. 11, No. 5, 471–477, 9 2017, doi: 10.1049/iet-cds.2016.0256
59. TEXAS INSTRUMENTS. ADS129x Low-Power, 8-Channel, 24-Bit Analog Front-End for Biopotential Measurements. Accessed 2018-05-11, <http://www.ti.com/lit/ds/symlink/ads1298.pdf>
60. LOPEZ-GORDO, M. A., D., SANCHEZ-MORILLO, F. P., VALLE. Dry EEG Electrodes. *Sensors* 2014, 14, 12847–12870, doi: 10.3390/s140712847
61. KRACHUNOV, S., A. J., CASSON. 3D Printed Dry EEG Electrodes. *Sensors* 2016, 16, 1635, doi:10.3390/s16101635
62. MASSAI, S., S., ROUTHU, D., WRIGHT, K. S., MOON, Y., OZTURK, S. Q., LEE. A Wireless Visual Attention Brain Signal Monitoring System. *MATEC Web of Conferences*, Vol. 32, 04005, 2015, doi: 10.1051/mateconf/20153204005
63. TORESANO, L. O. H. Z., S. K., WIJAYA, PRAWITO, A., SUDARMAJI, C., BADRI. Data acquisition system of 16-channel EEG based on ATSAM3X8E ARM Cortex-M3 32-bit microcontroller and ADS1299. *AIP Conference Proceedings*, Vol. 1862, 030149, 2017, doi: 10.1063/1.4991253
64. CHEN, J., X., LI, X., MI, X. S., PAN. A high precision EEG acquisition system based on the CompactPCI platform. *7th International Conference on Biomedical Engineering and Informatics*, Dalian, 2014, 511–516, doi: 10.1109/BMEI.2014.7002828
65. ANALOG DEVICES. Op Amp Common-Mode Rejection Ratio. Accessed 2018-05-11, <http://www.analog.com/media/en/training-seminars/tutorials/MT-042.pdf>

PUBLIKACIJŲ SĄRAŠAS

Straipsniai *Web of Science* duomenų bazėje, turintys citavimo indeksą:

1. Uktveris, T., Jusas, V. Application of Convolutional Neural Networks to Four-Class Motor Imagery Classification Problem. *Information Technology and Control*. 2017, 46 (2), pp. 260–273.
2. Uktveris, T., Jusas, V. Development of a Modular Board for EEG Signal Acquisition. *Sensors*. 2018, 18, 2140.

Straipsniai *Web of Science* duomenų bazėje be citavimo indekso:

1. Uktveris, T., Jusas, V. Comparison of Feature Extraction Methods for EEG BCI Classification. *Information and Software Technologies: 21st International Conference, ICIST 2015*, 2015, pp. 81–92.
2. Uktveris T., Jusas, V. Convolutional Neural Networks for Four-Class Motor Imagery Data Classification. *Intelligent Distributed Computing XI. IDC 2017*, 737, 2018, pp. 185–197.
3. Uktveris, T., Jusas, V. Development of a Modular Board for EEG Signal Acquisition. *Fifth International Conference on Mathematics and Computers in Sciences and in Industry (MCSI)*, 2018.

INFORMACIJA APIE AUTORIŲ

Vardas, pavardė: Tomas Uktveris
Tautybė: Lietuvis
Gimimo data: 1989-02-05
Gimimo vieta: Klaipėda
Išsilavinimas:
2008–2012 Informatikos bakalauras, Kauno technologijos universitetas
2012–2014 Informatikos magistras, Kauno technologijos universitetas
2014–2018 Doktorantūros studijos Kauno technologijos universitete

Kontaktai: El. paštas: tomas.uktveris@gmail.com

RESUME

Background and motivation

Brain-computer interface (BCI) systems try to narrow the gap between human and computer interaction. The direct control of computer applications by using only human mind and mental abilities can help to solve many rehabilitation, multimedia and gaming challenges. One of the key parts of a BCI system is accurate and fast algorithms that are capable of analysing electroencephalogram (EEG) signal potentials that are recorded along the human scalp. Such signals contain noise and other unwanted artifacts, which prevent from correctly determining-classifying imagined motoric actions (imagery). Though many algorithms were developed to overcome such issues, the problem still requires extensive work.

The motor imagery classification is one of many widespread machine-learning problems of BCI systems. With the need for human mind controlled applications, the recording of EEG has emerged as an optimal solution for non-interventional brain activity analysis. The ability to understand this brain induced electrical signal fully would greatly simplify the life of people with disabilities or break the barrier of natural interaction in the entertainment industry.

This work focuses on four-class motor imagery problem where the recorded EEG signal is classified into four different classes that correspond to four different human subject imagined motoric actions (left hand, right hand, feet and tongue movement). Even if a simpler two-class (binary) problem achieves good classification performance, the four-class still struggles to reach the same results and requires more scientific investigation.

Aim of the dissertation

The aim of this dissertation is to create a method for solving four-class motor imagery (MI) classification problem.

Objectives of the dissertation

1. Perform review and analysis of existing MI classification techniques and EEG recording systems in literature,
2. Evaluate common classification algorithms by using MI EEG signal database,
3. Develop an effective method for solving MI classification task,
4. Design the EEG system capable of recording MI signals,
5. Manufacture and validate correctness of the EEG recording system.

Scientific novelty

A new feature extraction channel difference method has been proposed for the EEG data processing based on Bandpower and Laplace filtering approaches. The proposed algorithm gives a similar filtering performance to a well-known CSP (common spatial patterns) algorithm. A new method for a single dimension (1D) feature vector adaptation to two-dimensional (2D) feature maps has been proposed. The algorithm has been successfully validated during the experiments. The CNN based classification method has been adapted to solve four-class MI problem, and the experimentally acquired results were close to the other state-of-the-art methods. Moreover, a stackable and modular EEG acquisition system for MI has been developed to help record second four-class validation EEG dataset and spread BCI among the wider audience.

Practical applications

The classification, proposed feature extraction and feature adaptation methods have been validated on publicly available real EEG signal database that was gathered from healthy subjects. The created EEG acquisition system has been constructed and validated in real-life usage scenarios of healthy subjects.

Methods

The dissertation is based on experimental analysis methods. Multiple feature extraction and classification methods have been investigated experimentally using computational software. The designed EEG acquisition system has been validated with proposed validation techniques and according to official technical characteristics.

Structure of the dissertation

This dissertation is divided into five main chapters. The first chapter introduces reader with the main topic of brain-computer interfaces. The second chapter analyses existing literature and tackles the problem of motor imagery (MI) task classification by using traditional machine learning approaches. The third chapter introduces deep learning methods for the same EEG data classification task. A methodology is given to successfully apply Convolutional Neural Networks (CNN) to the four-class MI problem. The fourth chapter introduces a practical approach of designing an EEG signal acquisition system for MI. A developed printed circuit board (PCB) design is presented and detailed along with the effective system validation techniques. The last section summarizes the whole work and gives the main conclusions of this dissertation and recommendations for further research.

Conclusions

1. After the analysis of scientific papers on the topic of four-class motor-imagery (MI) classification, it has been determined that deep learning classification methods have not been widely analysed and used for the specified problem.
2. After the experimental evaluation of common feature extraction and classification algorithms for four-class motor imagery problem, it has been determined that new feature extraction and classification methods are necessary.
3. Solutions to the MI problem have been proposed and validated experimentally:
 - a) new filtering/feature extraction Channel difference method has been introduced. It has been shown that the Channel difference method (54% accuracy) compares similarly to the CSP method (58% accuracy) and outperforms other tested feature extraction methods by 6–16% when not using CSP filtering.
 - b) Convolutional Neural Networks (CNN) were adapted for the MI task. It has been shown that CNN method is effective, achieves 68% accuracy when using FFT energy maps for feature extraction and compares similarly (69% accuracy) to the other state-of-the-art classification methods found in the literature.
 - c) proposed new feature vector adaptation technique allowed using feature extraction methods that produce 1D feature vectors for 2D feature map CNN classification successfully. The technique has been validated during the experiments, and promising classification results were achieved.
4. Due to the lack of four-class MI test datasets, low-cost solutions for scientific EEG signal recording devices and lack of design information in literature, a new EEG system capable of recording 64 channels of EEG MI signals has been successfully designed and manufactured.
5. The produced EEG system has been validated experimentally by using proposed simple but effective methods. The comparison with existing devices showcased similar or better performance:
 - a) unique modular/stackable design with sampling speed up to 1 kHz;
 - b) high CMRR of -97dB in 0-70 Hz has been measured;
 - c) typical 12–35dB SNR for 10–100 μ V signals;
 - d) low power consumption < 250mAh.

UDK 004.5+616.831-073] (043.3)

SL344. 2019-07-02, 3,25 leidyb. apsk. I. Tiražas 50 egz.

Išleido Kauno technologijos universitetas, K. Donelaičio g. 73, 44249 Kaunas
Spausdino leidyklos „Technologija“ spaustuvė, Studentų g. 54, 51424 Kaunas

50