



UNIVERSITATEA DIN PETROȘANI
DOMENIUL: INGINERIA SISTEMELOR

TEZĂ DE DOCTORAT

Conducător de doctorat:
Prof. univ. dr. habil. ing. **Monica LEBA**

Student doctorand:
ing. **Sebastian – Daniel ROȘCA**

Petroșani, 2024



UNIVERSITATEA DIN PETROȘANI
DOMENIUL: INGINERIA SISTEMELOR

CONTRIBUȚII PRIVIND UTILIZAREA
CĂȘTILOR NEURONALE ÎN CONTROLUL
SISTEMELOR ROBOTICE

Conducător de doctorat:
Prof. univ. dr. habil. ing. **Monica LEBA**

Student doctorand:
ing. **Sebastian – Daniel ROȘCA**

Petroșani, 2024

CUPRINS

Listă de figuri.....	Error! Bookmark not defined.
Listă de tabele.....	Error! Bookmark not defined.
INTRODUCERE.....	Error! Bookmark not defined.
CAPITOLUL 1.....	Error! Bookmark not defined.
INTERFEȚE CREIER – CALCULATOR BCI	Error! Bookmark not defined.
Introducere.....	Error! Bookmark not defined.
1.1 Abordări neuroimagistice în BCI.....	Error! Bookmark not defined.
<i>1.1.1 Electroencefalografia (EEG).....</i>	<i>Error! Bookmark not defined.</i>
1.2 Tipurile de semnale de control utilizate de sistemele BCI	Error! Bookmark not defined.
<i>1.2.1 Potențiale Evocate Vizuale (VEPs).....</i>	<i>Error! Bookmark not defined.</i>
<i>1.2.2 Potențiale Corticale Lente (SCP).....</i>	<i>Error! Bookmark not defined.</i>
<i>1.2.3 Potențiale Evocate P300.....</i>	<i>Error! Bookmark not defined.</i>
<i>1.2.4 Ritmuri senzoriomotorii (ritmurile Mu și Beta) ...</i>	<i>Error! Bookmark not defined.</i>
1.3 Tipuri de BCI.....	Error! Bookmark not defined.
1.4 Caracteristici. Extragere și selecție.....	Error! Bookmark not defined.
<i>1.4.1 Analiza componentelor principale (Principal Component Analysis = PCA)</i>	<i>Error! Bookmark not defined.</i>
<i>1.4.2 Analiza componentelor independente (ICA - Independent Component Analysis)</i>	<i>Error! Bookmark not defined.</i>
<i>1.4.3 Componente autoregresive (AR – Auto Regressive Components).....</i>	<i>Error! Bookmark not defined.</i>
<i>1.4.4 Filtrare corelată (Matched Filtering = MF).....</i>	<i>Error! Bookmark not defined.</i>
<i>1.4.5 Transformata Wavelet (Wavelet Transform = WT)</i>	<i>Error! Bookmark not defined.</i>
<i>1.4.6 Modelul spațial comun (Common Spatial Pattern = CSP)</i>	<i>Error! Bookmark not defined.</i>
<i>1.4.7 Algoritm genetic (Genetic Algorithm = GA).....</i>	<i>Error! Bookmark not defined.</i>
<i>1.4.8 Selecție secvențială.....</i>	<i>Error! Bookmark not defined.</i>
1.5 Artefacte în BCI.....	Error! Bookmark not defined.
Concluzii.....	Error! Bookmark not defined.

CAPITOLUL 2 Error! Bookmark not defined.

ALGORITMI ȘI APLICAȚII ALE BCI..... Error! Bookmark not defined.

Introducere..... **Error! Bookmark not defined.**

2.1 Clasificarea algoritmilor **Error! Bookmark not defined.**

2.1.1 Clasificatorul cei mai apropiați K vecini (*K-Nearest Neighbor Classifier = k-NNC*)..... **Error! Bookmark not defined.**

2.1.2 Analiza discriminanților liniari (*Linear Discriminant Analysis = LDA*).... **Error! Bookmark not defined.**

2.1.3 Mașină cu suport vectorial (*Support Vector Machine = SVM*)**Error! Bookmark not defined.**

2.1.4 Clasificatorul statistic Bayesian..... **Error! Bookmark not defined.**

2.1.5 Rețea neuronală artificială (*Artificial Neural Network = ANN*) **Error! Bookmark not defined.**

2.2 Aplicații BCI..... **Error! Bookmark not defined.**

2.2.1 Comunicare **Error! Bookmark not defined.**

2.2.2 Restabilirea funcției motorii..... **Error! Bookmark not defined.**

2.2.3 Controlul mediului înconjurător **Error! Bookmark not defined.**

2.2.4 Locomoție **Error! Bookmark not defined.**

2.2.6 Alte aplicații BCI..... **Error! Bookmark not defined.**

Concluzii..... **Error! Bookmark not defined.**

CAPITOLUL 3 Error! Bookmark not defined.

ANALIZA UNDELOR CEREBRALE..... Error! Bookmark not defined.

Introducere..... **Error! Bookmark not defined.**

3.1 Metode și implementare a achiziției EEG **Error! Bookmark not defined.**

3.2 Preprocesarea datelor EEG achiziționate **Error! Bookmark not defined.**

3.3 Clasificarea și eliminarea artefactelor aferente componentelor independente ... **Error! Bookmark not defined.**

3.4 Analiza spectrală a activității canalelor EEG **Error! Bookmark not defined.**

Concluzii..... **Error! Bookmark not defined.**

CAPITOLUL 4 Error! Bookmark not defined.

CONDUCEREA UNEI DRONE UTILIZÂND CĂȘTI NEURONALE

..... Error! Bookmark not defined.

Introducere.....	Error! Bookmark not defined.
4.1 Motivația alegerii unei soluții de control bazată pe interfața creier - calculator	Error! Bookmark not defined.
4.2 Controlul unei mini drone de tip quadcopter bazat pe BCI	Error! Bookmark not defined.
4.1.1 Dispozitivele hardware utilizate în realizarea interfeței BCI	Error! Bookmark not defined.
4.1.2 Modelarea, simularea, implementarea și proiectarea interfeței BCI de control al mini dronei.....	Error! Bookmark not defined.
Concluzii.....	Error! Bookmark not defined.
CAPITOLUL 5	Error! Bookmark not defined.
APLICAȚII DE CONTROL BCI.....	Error! Bookmark not defined.
Introducere.....	Error! Bookmark not defined.
5.1 Proiectarea unui joc video 3D controlat prin BCI.....	Error! Bookmark not defined.
5.1.1 Mecanica jocului de biliard.....	Error! Bookmark not defined.
5.1.2 Elementele de interfață utilizator (UI) ale jocului Mental Pool	Error! Bookmark not defined.
5.2 Platformă Lego NXT Mindstorms 2.0 controlată prin semnale considerate artefacte cerebrale.....	Error! Bookmark not defined.
5.2.1 Platforma Lego educațională.....	Error! Bookmark not defined.
5.3. Controlul unui robot păianjen bazat pe interfață BCI SSVEP	Error! Bookmark not defined.
Concluzii.....	Error! Bookmark not defined.
CAPITOLUL 6	Error! Bookmark not defined.
CONCLUZII, CONTRIBUȚII ȘI DIRECȚII DE DEZVOLTARE...	Error! Bookmark not defined.
Bibliografie.....	Error! Bookmark not defined.
Anexe	Error! Bookmark not defined.

INTRODUCERE

O interfață creier-calculator (BCI) este un sistem de comunicare bazat pe hardware și software care permite controlul unui calculator sau a unui dispozitiv extern doar pe baza activității cerebrale. Obiectivul principal al cercetării BCI este acela de a oferi o cale de comunicare persoanelor cu handicap sever, care sunt total paralizate sau „blocate” din cauza afecțiunilor neurologice neuromusculare, cum ar fi: scleroza laterală amiotrofică, accidentul vascular cerebral sau leziunile la nivelul măduvei spinării. Aici, trecem în revistă stadiul actual al sistemelor BCI, analizând diferitele etape care formează un sistem BCI standard: achiziția semnalului, preprocesarea sau prelucrarea semnalului, extragerea caracteristicilor, clasificarea și interfața de control. În continuare se discută avantajele, dezavantajele și ultimele progrese și se analizează numeroase tehnologii raportate la literatura științifică pentru a proiecta fiecare etapă a unei sistem BCI. În primul rând, cercetarea de față examinează modalitățile de neuroimagică utilizate în etapa de achiziție a semnalului, fiecare dintre acestea monitorizând o activitate funcțională diferită a creierului, cum ar fi activitatea electrică, magnetică sau metabolică. În al doilea rând, cercetarea de față analizează diferite semnale de control electrofiziologic care determină intențiile utilizatorilor care pot fi detectate în activitatea creierului. În al treilea rând, cercetarea de față analizează câteva tehnici utilizate în etapa de prelucrare a semnalului pentru a trata artefactele din semnalele de control și pentru a îmbunătăți performanța. În al patrulea rând, se studiază o serie de algoritmi matematici folosiți în etapele de extragere și clasificare a caracteristicilor care traduc informațiile din semnalele de control în comenzi utilizate în operarea unui calculator sau a altui dispozitiv. În final, cercetarea de față urmărește să ofere o imagine de ansamblu asupra diferitelor aplicații ce utilizează un sistem BCI pentru a controla o gamă largă de dispozitive.

În capitolul 1 am realizat o descriere de ansamblu care explorează posibilitățile de utilizare a tehnologiei Interfețelor Creier-Calculator (BCI) și care tratează fundamentele și componentele esențiale necesare pentru proiectarea unui astfel de sistem, explorând implicațiile de la achiziția semnalului și până la interfața de control. Tipurile de activități cerebrale măsurabile sunt tratate în detaliu, inclusiv activitatea electrică, cea magnetică și cea metabolică, accentul fiind pus pe electroencefalografie (EEG), datorită avantajelor funcționale. De asemenea, o analiză detaliată este oferită și principalelor tehnici de procesare și extragere a caracteristicilor, precum și principalelor tipuri de artefacte care contaminatează semnalele cerebrale, o atenție deosebită fiind acordată principalelor abordări de eliminare a acestora.

În capitolul 2 am realizat o descriere detaliată a unor algoritmi eficienți, utilizați pentru clasificarea imaginilor motorii și, în special pentru problema preprocesării semnalelor EEG, care au la bază învățarea automată, folosită pentru a putea interpreta și clasifica eficient semnalele cerebrale din diverse aplicații. În acest sens, a fost descrisă și expansiunea semnificativă a principalelor aplicații BCI, care acoperă domenii de interes, precum reabilitarea prin tratarea dizabilităților severe de comunicare, restaurarea funcției motorii, controlul dispozitivelor și utilizarea în jocurile video. Toate acestea au rolul de a demonstra potențialul acestei tehnologii în îmbunătățirea calității vieții persoanelor cu dizabilități, dar și a deschide noi orizonturi de interacțiune pentru utilizatorii sănătoși.

În capitolul 3 am realizat un studiu de caz menit să analizeze și să determine modelul cerebral rezultat pentru trei subiecți pentru antrenamentul mental a unei condiții de relaxare, a unei comenzi mentale, dependentă de nivelul de atenție al utilizatorului, precum și pentru acționarea intenționată a comenzii învățate. Ca modalitate de achiziție se utilizează electroencefalograma, folosind un dispozitiv de tip cască neuronală prevăzut cu cinci canale EEG. Datele EEG sunt preprocesate și analizate în MATLAB cu instrumentul EEGLAB, aplicând analiza componentelor independente pentru a separa semnalele utile de artefacte și utilizând un algoritm de învățare profundă pentru clasificarea activității cerebrale. Fiecare subiect parcurge un antrenament mental al căror intervale sunt recalculat și afișate printr-un algoritm în patru pași scris în Python, incluzând starea neutră, comanda mentală, acționarea intenționată și etapele de validare.

În capitolul 4 am dezvoltat și implementat un sistem de control al unei mini drone, bazat pe interfața creier-calculator (BCI), combinând două domenii tehnologice conexe și de actualitate într-o singură aplicație cu potențial practic aplicativ, capabilă să folosească ca intrări doar semnalele cerebrale ale utilizatorului, obținând un control intuitiv al dronei. Întregul ecosistem al dronei a fost modelat matematic, simulat și testat în condiții reale de zbor, pentru a valida eficiența sistemului BCI implementat.

În capitolul 5 am realizat și dezvoltat o serie de aplicații care utilizează interfața creier-calculator pentru a controla atât jocuri video, platforme robotizate și principalele cuple care alcătuiesc articulațiile unui robot păianjen, proiectat și imprimat 3D. Am pornit de la un joc video numit Mental Pool Game, controlat prin casca neuronală Emotiv Insight, care folosește paradigma imaginării motorii și am dezvoltat apoi o interfață BCI capabilă să folosească

semnalele de electromiografie detectate prin semnalele de electroencefalogramă, folosind o cască OpenBCI cu 16 canele EEG, reproiectată pentru a controla 2 servomotoare ale platformei robotizate Lego. Folosind o cască NextMind, destinată monitorizării cortexului vizual, am utilizat paradigma potențialelor vizuale în stare de echilibru (SSVEP) pentru a acționa servomotoarele robotului păianjen.

CAPITOLUL 1

INTERFEȚE CREIER – CALCULATOR BCI

Introducere

Interfețele creier-calculator reprezintă tehnologii avansate de comandă și control care prin natura lor creează o punte de legătură între creierul utilizatorului uman și dispozitivul extern ale căror intrări le acționează.

Capitolul curent își propune să abordeze tehnologia care stă la baza interfețelor creier-calculator, explorând fundamentele, descrierea conceptuală și implementarea componentelor esențiale specifice oricărui sistem BCI. Pentru început descriu tipurile de activități cerebrale care pot fi măsurate. De asemenea, descriu tipurile de abordări specifice unui sistem BCI, în ceea ce privește natura lor din punct de vedere funcțional. Pentru fiecare dintre aceste tipuri de activități care pot fi măsurate prezintă principalele tehnici de măsurare. De asemenea, prezintă principalele metode de achiziție a semnalelor cerebrale, accentul fiind pus pe electroencefalografie, împreună cu descrierea avantajelor aferente, dar și pe alte tehnici de neuroimagistică.

Tot în cadrul acestui capitol prezintă tehnicile de procesare și extragere a caracteristicilor prezente în sistemele BCI, dar și principalele tipuri de artefacte ce contaminatează activitatea utilă a creierului.

Obiective

Obiectivele reprezentative ale capitolului sunt:

- Definierea și explicarea conceptului de interfață creier-calculator;
- Analiza și prezentarea principalelor tipuri de semnale cerebrale care sunt utilizate în sistemele BCI;
- Imersiunea în explorarea și descrierea principalelor metode de procesare a semnalelor creierului și extragere a caracteristicilor care sunt utilizate în sistemele BCI;
- Abordarea și eliminarea artefactelor din sistemele BCI.

Interfața creier – calculator (Brain-Computer Interface = BCI) cunoscută de asemenea ca interfață creier – mașină (Brain-Machine Interface = BMI) este un sistem de comunicare bazat pe hardware și software care permite oamenilor să interacționeze cu mediul

înconjurător doar pe baza semnalelor de control generate din activitatea creierului utilizând principiul electroencefalogrammei (EEG).

Ideea de a descifra cu succes gândurile sau intențiile pe baza activității creierului utilizând tehnologia BCI nu a fost exploatată suficient în cercetările științifice anterioare. Studiile în domeniul cercetării creierului s-au limitat, de obicei, la analiza tulburărilor neurologice în clinici sau la explorarea funcțiilor creierului în laborator. Designul BCI a fost considerat mult timp prea complex, datorită rezoluției și a fiabilității informațiilor ce pot fi detectate la nivelul creierului dar și datorită variabilității ridicate.

Domeniul de cercetare BCI este un domeniu multidisciplinar relativ tânăr, care integrează cercetători din zone diferite precum: neurologie, fiziologie, psihologie, inginerie, informatică, reabilitare și alte discipline tehnice și medicale. Drept urmare, în ciuda unor progrese notabile, încă nu a apărut un limbaj comun, iar tehnologiile BCI existente variază, ceea ce face dificilă compararea acestora și armonizarea în vederea standardizării.

Această trecere în revistă a stadiului actual al sistemelor BCI este structurată după cum urmează: subcapitolul 1.1 discută abordările existente legate de neuroimagică ale sistemelor BCI, subcapitolul 1.2 descrie semnalele de control cel mai frecvent întâlnite în cadrul sistemelor BCI, subcapitolul 1.3 explică pe scurt anumite tipuri de sisteme BCI. Subcapitolele 1.4, 1.5 și 1.6 acoperă diferite metode de procesare a semnalului utilizate în extragerea caracteristicilor, reducerea artefactelor și clasificarea caracteristicilor. Subcapitolul 1.7 oferă o imagine de ansamblu asupra aplicațiilor ce utilizează sistemul BCI, iar la sfârșitul capitolului se prezintă principalele concluzii.

Concluzii

Interfețele creier-calculator (BCI) sunt cele care permit crearea unei punți de legătură între activitatea neuronală și dispozitivele externe, fiind principala abordare în neuroimagică. Electroencefalografia rămâne piatra de temelie a acestor interfețe, în special în cazul abordării non-invazive, atât datorită factorilor legați de rezoluția temporală excelentă oferită, dar în special datorită versatilității de captare a activității creierului pentru mediul clinic și în cel de cercetare. Cu toate acestea, pe lângă aceste avantaje, care fac electroencefalografia o soluție accesibilă, BCI-urile care utilizează această metodă de captare a semnalelor se confruntă cu numeroase provocări, care nu exclud raportul semnal zgomot-scăzut, o profundă susceptibilitate la apariția fenomenelor de zgomot intern și extern, precum cazul interferențelor generate de volumul conducției craniului care poate provoca degradarea semnalului EEG. De asemenea, prezența artefactelor biologice ale corpului localizate la nivelul creierului constituie o altă provocare pentru etapa de preprocesare.

Indiferent de tipul de clasificare al BCI-urilor, acestea sunt orientate spre utilizator, pentru a-i oferi acestuia posibilitatea de a controla dispozitive folosind ca mijloc de control semnalele creierului, depinzând doar de voința și atenția utilizatorului, indiferent dacă este vorba de prezența unor alegeri predefinite pentru antrenarea sistemului sau de prezența unor stimuli interni sau externi pentru a produce un răspuns cerebral evocat de aceștia.

CAPITOLUL 2

ALGORITMI ȘI APLICAȚII ALE BCI

Introducere

Domeniul interfețelor BCI a cunoscut numeroase progrese în ultimele două decade, atât raportat la algoritmi utilizați cât și în cazul procesării și clasificării semnalelor, dar și raportat la gama diversificată de aplicații cărora li se aplică. Astfel acestea au permis clasificarea imaginilor motorii care utilizează ca fundament electroencefalograma și potențialele vizuale evocate. Au fost dezvoltate algoritmi pentru vectori de caracteristici de dimensiuni reduse. Luând în calcul instanțele existente și raportându-se la apropierea lor de acestea în spațiul caracteristicilor cu scopul de a clasifica noile instanțe, algoritmul a devenit mai simplu și mai eficient din punct de vedere computațional. Învățarea automată a fost utilizată ca fundament pentru conceperea majorității algoritmilor, fiind adesea folosită de sistemele BCI în interpretarea și clasificarea semnalelor creierului, pentru conceperea algoritmilor de clasificare a stărilor activității creierului, cu scopul de a le traduce în comenzi pentru computer atât în aplicații de tip speller cât și în tratarea modelelor din sistemele multiclass sau pentru detectarea automată a crizelor în domeniul medical; de asemenea, s-a urmărit și tratarea spațiilor de caracteristici de dimensiuni mari, prin identificarea optimului hiperplanului de separare printr-un alt algoritm care să rezolve problema dimensionalității; alt algoritm a devenit util în recunoașterea modelului rezultat din datele de învățare inspirat din modul în care creierul procesează informațiile.

În ceea ce privește aplicațiile BCI, acestea sunt diverse și în continuă expansiune și acoperă: tratarea dizabilităților severe de comunicare, restaurarea funcției motorii pentru pacienți, controlul dispozitivelor casnice, controlul unui mijloc de transport pentru persoanele cu dizabilități și aplicații în jocuri video.

Obiective

Obiectivele acestui capitol sunt:

- Înțelegerea și interpretarea rolului algoritmilor de clasificare în sistemele BCI;
- Prezentarea și interpretarea principalelor tipuri de algoritmi de clasificare;
- Tratarea principalelor aplicații BCI.

BCI este un sistem de comunicare care nu necesită nici o activitate musculară periferică. Într-adevăr, sistemele BCI permit unui subiect să trimită comenzi către un dispozitiv electronic doar prin intermediul activității creierului. Astfel de interfețe pot fi considerate ca fiind singura modalitate de comunicare pentru persoanele afectate de o serie de dizabilități motorii. Pentru a controla un BCI, utilizatorul trebuie să producă diferite modele de activitate cerebrală care vor fi identificate de sistem și traduse în comenzi. În

majoritatea interferențelor BCI existente, această identificare se bazează pe un algoritm de clasificare, adică un algoritm care urmărește estimarea automată a clasei de date, așa cum este reprezentată de un vector caracteristic.

Scopul etapei de clasificare într-un sistem BCI este recunoașterea intențiilor utilizatorului pe baza unui vector caracteristic care caracterizează activitatea creierului oferită de etapa caracteristică. Fie algoritmul de regresie fie cel de clasificare poate fi utilizat pentru a atinge acest obiectiv, dar algoritmi de clasificare sunt în prezent cea mai populară abordare în sistemele BCI. Acești algoritmi sunt utilizați pentru a recunoaște modelele EEG ale utilizatorilor pe baza caracteristicilor EEG. De-a lungul anilor, o mare diversitate de tipuri de clasificatoare au fost explorate pentru a proiecta BCI-uri, inclusiv clasificatoare liniare, rețele neuronale, clasificatoare bayesiene neliniare, clasificatoare de tipul cel mai apropiat vecin (Nearest Neighbour Classifier) și combinații de clasificatoare (Lotte, și alții, 2018).

Algoritmii de clasificare au fost în mod tradițional calibrați de utilizatori prin învățarea supravegheată folosind un set de date etichetate.

Pentru clasificarea semnalelor non-staționare învățarea supravegheată nu este optimă, însă pentru a obține o precizie acceptabilă sunt de obicei necesare seturi mari de date și sesiuni inițiale lungi de calibrare. Învățarea semi-supravegheată (semi-supervised learning – SSL) este utilă pentru a reduce timpul de pregătire și pentru a actualiza clasificatorul în sesiunea online în mod continuu.

Într-un scenariu BCI în care semnalul asociat cu intențiile subiectului este necunoscut și etichetele nu sunt disponibile, învățarea nesupravegheată și învățarea consolidată (Reinforcement Learning – RL) pot fi aplicate pentru adaptarea BCI. Utilizarea tehnicilor de învățare automată a permis utilizatorilor, care nu au putut obține feedback de succes, să obțină un control semnificativ asupra sistemului BCI (Abu-Rmileh, Zakkay, Shmuelof, & Shriki, 2019).

Clasificatorii trebuie să înfrunte două probleme principale legate de activitatea de recunoaștere a modelului: blestemul dimensionalității (the curse of dimensionality) și compromisul bias-variance.

Proiectarea etapei de clasificare implică alegerea din mai multe alternative a unuia sau mai multor algoritmi de clasificare. Au fost propuși mai mulți algoritmi de clasificare, cum ar fi printre alții: clasificatorul k-nearest neighbor classifier (k-NNC), clasificatorii liniari, mașini cu suport vectorial (Support Vector Machine – SVM) și rețelele neuronale (ANN).

În prezent, pacienții cu LIS și cei susceptibili de a dezvolta CLIS sunt principalii candidați la BCI. În ciuda ratelor scăzute de transfer de informații furnizate de BCI, gradul ridicat de dizabilitate în rândul pacienților cu LIS îi forțează să folosească un BCI mai degrabă decât interfețe convenționale mai fiabile, cum ar fi sisteme bazate pe activitatea musculară sau pe privire.

În zilele noastre, există un număr mare de aplicații BCI foarte diferite, cum ar fi procesoarele de text, browser-ele web adaptate, controlul unui scaun cu roțile sau a neuroprotezei cu ajutorul creierului și bineînțeles jocurile.

Ca un instrument care execută o funcție specifică, specificațiile particulare ale BCI corespund modului în care îndeplinește funcția respectivă. Următoarele subsecțiuni descriu pe scurt aplicațiile BCI, clasificate în cinci domenii principale: comunicare, restaurare motorie, controlul mediului înconjurător, locomoție și divertisment.

Concluzii

Acest capitol a trecut în revistă stadiul tehnicii sistemelor BCI discutând aspectele fundamentale ale proiectării sistemului BCI. Au fost prezentate unele dintre cele mai semnificative obiective care au determinat cercetarea BCI-urilor în ultimii 25 de ani. S-a remarcat că au fost realizate multe progrese în cercetarea acestora. Diferite abordări neuroimagistice au fost aplicate cu succes în BCI: (i) EEG, care oferă semnale de calitate acceptabilă, cu o portabilitate ridicată fiind de departe cea mai uzuală modalitate în BCI; (ii) fMRI și MEG, care sunt metode atestate și eficiente pentru localizarea regiunilor active din interiorul creierului; (iii) NIRS care este o metodă de neuroimagică foarte promițătoare în BCI și (iv) modalități invazive, care au fost prezentate ca metode valoroase pentru a furniza semnale de înaltă calitate necesare în unele aplicații de control multidimensional, ca de exemplu controlul neuroprotezelor.

În proiectarea BCI au fost testate o mare varietate de caracteristici ale semnalului și algoritmi de clasificare. Deși cercetarea BCI este relativ tânără, au fost obținute multe progrese în mai puțin de două decenii, deoarece multe dintre aceste metode se bazează pe cercetarea anterioară a procesării semnalului și a recunoașterii modelului. Multe studii au demonstrat acuratețea BCI-urilor și au furnizat o viteză de transfer a informațiilor acceptabilă, în ciuda dificultăților majore inerente în procesarea semnalului cerebral. În consecință, timpul de pregătire a utilizatorilor a fost redus semnificativ, ceea ce a dus la aplicații BCI mai răspândite în viața de zi cu zi a persoanelor cu dizabilități, cum ar fi printre altele procesarea textelor, browserele, emailul, controlul scaunului cu roțile, controlul mediului înconjurător sau neuroprotezele.

În ciuda progreselor recente din domeniul BCI unele probleme încă trebuie rezolvate. În primul rând, avantajele și dezavantajele relative ale diferitelor metode de achiziție a semnalului sunt încă neclare. Clarificarea acestora va necesita studii ulterioare la om și animale. În al doilea rând, metodele invazive au nevoie de investigații suplimentare pentru a face față deteriorării țesuturilor, riscului de infecție și problemelor de stabilitate pe termen lung. Au fost deja propuși electrozii care conțin medii neurotrope care promovează evoluția neuronală și transmiterea wireless a semnalelor neuronale înregistrate. În al treilea rând, semnalele electrofiziologice și metabolice care sunt cele mai în măsură să codifice intenția utilizatorului ar trebui identificate și caracterizate mai bine. Majoritatea studiilor BCI au tratat independent timpul, frecvența și dimensiunile spațiale ale semnalelor cerebrale. Aceste interdependențe ale dimensiunii semnalului pot duce la îmbunătățirea semnificativă a performanței BCI. În al patrulea rând, viteza de transfer a informațiilor furnizată de BCI-urile actuale este scăzută pentru asigurarea unei interacțiuni eficiente om-mașină în unele aplicații. BCI bazat pe semnale exogene poate oferi un randament mult mai mare. În al

cincilea rând, adaptarea nesupravegheată este o provocare cheie pentru implementarea BCI-urilor în afara laboratorului. Au fost deja propuși cu succes moderat unii algoritmi de clasificare adaptativă. Pe lângă vitezele reduse de transfer a informațiilor și fiabilitatea variabilă, majoritatea sistemelor BCI actuale sunt incomode, deoarece electrozii trebuie umeziți, software-ul poate necesita o instruire, iar contactele electrozilor au nevoie de o corecție continuă. S-a propus deja un BCI bazat pe P300 ușor de utilizat cu monitorizare la distanță folosind o conexiune la internet de mare viteză pentru a reduce dependența de experți tehnici.

Ultimele progrese ale cercetării BCI sugerează că în viitorul apropiat pot apărea evoluții inovatoare. Aceste realizări și potențialul pentru noi aplicații BCI au dat în mod evident un impuls semnificativ cercetării BCI la care au participat oameni de știință din domenii multidisciplinare, printre alții de exemplu, neurologi, ingineri, matematicieni și specialiști în recuperare clinică. Se preconizează că interesul pentru domeniul BCI va crește iar proiectarea și dezvoltarea BCI vor continua să aducă avantaje în viața de zi cu zi a persoanelor cu dizabilități. Mai mult, interesul comercial recent din cadrul anumitor companii sugerează că sistemele BCI pot găsi aplicații utile populației în general și nu doar pentru persoanele cu dizabilități severe. În viitorul apropiat, sistemele BCI prin urmare pot deveni un nou mod de interacțiune om-mașină cu utilizări zilnice, similare cu alte interfețe actuale.

CAPITOLUL 3

ANALIZA UNDELOR CEREBRALE

Introducere

În acest capitol, în contextul analizării și determinării modelului cerebral rezultat din antrenamentul mental pentru relaxare, urmat de antrenamentul unei comenzi mentale, dar și a acționării intenționate a acesteia din urmă, se prezintă un studiu de caz care implică un scenariu aplicat unui număr de trei subiecți. Semnalele EEG au fost achiziționate folosind o casă neuronală comercială, prevăzută cu cinci canale EEG. Datele EEG, în prealabil înregistrate, au fost stocate în format medical și analizate cu setul de instrumente EEGLAB, în mediul de dezvoltare MATLAB, pentru a elimina zgomotul printr-un algoritm de preprocesare în șase pași. Algoritmul a aplicat analiza componentelor independente pentru a separa semnalele utile de artefacte. Datele EEG au fost apoi procesate cu ajutorul unui clasificator, bazat pe învățare profundă pentru a clasifica activitatea cerebrală separată de sursele de zgomot.

Pentru fiecare subiect, antrenamentul a fost recalculat și afișat folosind un algoritm în patru pași scris în limbajul de programare Python. Fiecare segment de timp a fost împărțit pentru antrenarea stării neutre și a comenzii mentale, a acționării intenționate și a etapelor de validare. Densitatea de putere spectrală a fost analizată pentru a identifica undele alfa și beta pe fiecare canal EEG, folosind un algoritm implementat în limbajul de programare C,

rulat în mediul de dezvoltare MATLAB. Rezultatele au fost reprezentate grafic pentru a determina amplitudinea și puterea maximală a semnalelor EEG, precum și distribuția lor pe regiuni cerebrale.

Obiective

Obiectivele acestui capitol sunt:

Implementarea unui algoritm de preprocesare offline a datelor EEG de tip raw înregistrate, aferente unui studiu de caz cu 3 subiecți;

Evaluarea impactului artefactelor asupra semnalelor EEG;

Determinarea distribuției undelor cerebrale dominante;

Analiza comparativă a sesiunilor de antrenare mentală.

Un număr de 3 subiecți voluntari au fost aleși să participe la experiment, având vârste cuprinse între 32 și 55 de ani. Toți subiecții au fost aleși din categoria persoanelor cu o bună stare de sănătate, provenind din același mediu demografic și urmând un ciclu de pregătire în învățământul superior. Măsurătorile au fost realizate prin preluarea semnalului EEG de la subiecți, în decursul mai multor zile, în același interval al zilei, și anume după amiaza, folosind același echipament și același kit de dezvoltare, Emotiv Insight, atât pentru achiziția cât și pentru procesarea semnalelor EEG. De asemenea, toate măsurătorile au fost realizate în condiții de laborator, fără surse de zgomot extern, iar subiecții au fost instruiți ca pe toată perioada antrenării și imaginării consecinței unei comenzi mentale să nu vorbească și, de asemenea, să nu se miște pentru a nu afecta validitatea experimentului. Voluntarii au fost pregătiți în prealabil, pentru a se familiariza cu interfața BCI, pentru fiecare persoană fiind alocat un timp de pregătire de 20 de minute.

Scopul principal al experimentului a fost de a determina distribuția undelor cerebrale dominante ale tuturor subiecților, urmărind în același timp același tipar și același proces de antrenare pentru condiția neutră și o singură comandă mentală, cea de ridicare (Lift). În acest sens, se urmărește analiza datelor de electroencefalogramă preprocesate, provenite din datele crude (raw), atât pe perioada antrenării acesteia cât și post-antrenare în momentul imaginării comenzii antrenate.

Astfel, tuturor participanților li s-a cerut să parcurgă individual câte două sesiuni de antrenare, prima în care să antreneze doar condiția neutră pentru a putea analiza distribuția spațială a undelor cerebrale pentru perioada de relaxare, iar în cea de-a doua să reia procesul acesteia pentru a putea antrena și comanda mentală de ridicare, ambele sesiuni urmând să fie înregistrate simultan.

Pentru a face acest lucru am utilizat aplicația Emotiv Xavier TestBench, care este furnizată de compania Emotiv Inc. în pachetul de aplicații standard odată cu achiziția căștii neuronale Emotiv Insight.

Prin intermediul înregistrării stării neutre și a sarcinii mentale de ridicare pentru fiecare subiect în parte s-a putut realiza o analiză comparativă a sesiunilor de antrenare folosind facilitatea de redare offline oferită de aplicația Emotiv Xavier TestBench. Astfel au fost

identificate pe baza funcției de afișare sub formă grafică, oferită de panoul de afișare EEG, modificările semnalelor de electroencefalogramă pentru fiecare din cele 5 canale EEG analizate, atât pe perioada inducerii stării de relaxare cât și pe perioada antrenării și imaginării consecinței comenzii mentale imaginate, la o rată de eșantionare implicită de 128 de eșantioane per secundă, aplicând asupra semnalelor implicit un filtru trece-sus de ordinul întâi pentru eliminarea offset-ului (decalajului) generat de curentul continuu produs de sistemul electronic al căștii Emotiv Insight, care nu poate fi dezactivat decât dacă se alege analiza EEG a unui singur canal.

În etapa de preprocesare a datelor EEG achiziționate am ales să utilizez setul de instrumente de tip open-source EEGLAB care poate fi integrat în mediul de dezvoltare MATLAB pentru procesarea continuă a semnalelor electroencefalografice (EEG), magnetoencefalografice (MEG) și a altor semnale electrofiziologice.

EEGLAB a fost ales, de asemenea, întrucât este dezvoltat în jurul unei interfețe grafice cu utilizatorul, simplă dar intuitivă, ce oferă o tranziție ușoară de la programarea în linia de comandă din MATLAB, pentru o analiză personalizată, la graficele de bază generate prin intermediul MATLAB.

Datele EEG sunt apoi pregătite pentru o analiză ulterioară cu scopul de a le discrimina în funcție de componentele de frecvență și de a le curăța de sursele de zgomot în vederea eliminării artefactelor.

Antrenarea ICA a fost realizată la o rată de învățare setată inițial la valoarea de 0,001 (Kittilstved, și alții, 2018). Cu toate acestea, pe parcursul antrenării această rată se ajustează în baza unui prag, care se raportează la un unghi Delta care reprezintă unghiul dintre direcția vectorului în spațiul ponderii care descrie pasul curent de învățare și direcția care descrie pasul anterior. În cazul în care unghiul Delta este mai mare sau egal cu 60° , rata de învățare este înmulțită automat cu 0,9, având scopul de a asigura stabilitatea procesului de învățare. Prin apelarea funcției `pop_runica()` setul de instrumente EEGLAB generează pe lângă matricea de ponderi ICA și o matrice de sferizare a datelor, care realizează o distribuție uniformă ce este utilizată pentru preprocesarea ICA.

În general, recunoașterea și respingerea IC-urilor obținute în urma descompunerii prin aplicarea ICA în preprocesarea sesiunilor EEG reprezintă un pas dificil, deoarece constituie un proces ce necesită timp și experiență pentru a înțelege și evalua corect prin inspecție manuală proprietățile acestora. Acest lucru se datorează complexității IC, acestea neavând o interpretare clar definită și nici o ordine specifică (Asogbon, și alții, 2023).

Astfel, pentru acest pas, am optat pentru un clasificator ICLabel, care implementează un model de învățare profundă (deep learning) pentru recunoașterea și eliminarea automată a componentelor independente din înregistrările EEG.

Ca prim rezultat al aplicării clasificării automate a componentelor independente s-a observat faptul că aplicarea descompunerii ICA produce o separare eficientă a surselor ce compun potențialele electrice ale creierului în cazul analizei seturilor de date EEG aferente tuturor subiecților implicați în studiu.

Astfel cinci hărți topografice, fiecare dintre acestea fiind asociate cu un rezultat obținut prin clasificarea ICLabel, indicând fie tipul de artefact, fie sursa de semnal pe care o reprezintă, împreună cu eticheta aferentă procentului de încredere ce determină precizia clasificării.

Concluzii

Primul obiectiv are ca rezultat obținerea unor seturi de date EEG curate, cu cât mai multe artefacte eliminate în urma aplicării algoritmului de preprocesare, care să permită o analiză precisă a activității cerebrale individuale pentru diferite acțiuni mentale, în condiții experimentale aferente fiecăruia din cei trei subiecți studiați.

Al doilea obiectiv are ca rezultat asigurarea calității și integrității datelor EEG din fiecare set de date analizat, în sensul menținerii unei amplitudini reduse a artefactelor reziduale post procesare, pentru a obține rezultate optime ulterioare.

Al treilea obiectiv imprimă un mod de identificare și comparare a distribuției undelor cerebrale dominante pe perioada stării de relaxare, alternată cu instalarea atenției și concentrării din timpul antrenării comenzii mentale alese, care este utilizată ca bază pentru acționarea intenționată a acesteia.

Al patrulea obiectiv are ca rezultat identificarea și înțelegerea modelelor mentale per studiu, a punctelor comune între antrenare și acționare intenționată și de înțelegere a diferențelor care le caracterizează prin răspunsurile EEG între subiecți, care să ofere informații despre variabilitatea individuală în procesul de proiectare a oricărui scenariu de antrenare mentală care este utilizat ca fundament pentru controlul oricărei aplicații BCI.

CAPITOLUL 4

CONDUCEREA UNEI DRONE UTILIZÂND CĂȘTI NEURONALE

Introducere

În acest capitol se prezintă modul prin care două elemente tot mai prezente în zilele noastre pot fi interconectate pentru a realiza un sistem capabil să fie condus de o categorie largă de persoane. Pe de o parte, dronele prezente și integrate în domenii de activitate variate, atât civile cât și militare, extinse spre abordarea axată pe divertisment cât și spre livrarea de produse și mai nou spre domeniul viitorului, acela al transportului de pasageri pe cale aeriană fără pilot. Pe de altă parte, interfețele om-mașină fiind considerate mai neconvenționale pot fi considerate un domeniu de nișă ce oferă subiecte generoase ce merită a fi exploatate atât în prezent cât și în viitor. Datorită acestor considerente am ales să utilizez și să dezvolt o interfață creier - calculator (BCI) deoarece oferă avantajul unui control ce nu implică elemente în mișcare. Pentru a îndeplini acest obiectiv am dezvoltat prin modelare

matematică și simulare numerică atât modelul unei mini drone cât și al interfeței BCI utilizate ca metodă de control.

Obiective

Obiectivele reprezentative capitolului sunt:

- Dezvoltarea și implementarea interfeței creier-calculator;
- Modelarea matematică și simularea dinamicii dronei;
- Antrenarea și validarea comenzilor mentale pentru controlul dronei.

Am ales să utilizez tehnologia BCI pentru că permite controlul dispozitivelor electromecanice sau al calculatoarelor folosind ca mijloc de acționare doar semnalele creierului. Un astfel de sistem BCI este capabil să identifice tipare de activitate neuronală care în urma procesării pot fi asociate cu comenzi mașină. Printre sistemele BCI, de altfel, predominant se folosește tehnica electroencefalogrammei (EEG) analizată prin metoda neinvazivă pentru a transforma gândurile conștiente ale utilizatorului în acțiuni de comandă și control.

Motivația principală pentru dezvoltarea BCI-urilor este îmbunătățirea calității vieții pentru persoanele care suferă de dizabilități generate de boli neuromusculare, accident vascular cerebral, scleroză laterală amiotrofică (ALS) sau polineuropatie severă (Moufassih, Tarahi, Hamou, Agounad, & Azami, 2022).

În realizarea acestui experiment obiectivul urmărit s-a bazat pe controlul unei mini drone realizat prin implementarea unei interfețe creier – calculator ce folosește paradigma imaginării motorii prin care utilizatorul să fie capabil să controleze, doar folosind o serie de comenzi mentale antrenate, poziția și orientarea unei mini drone în spațiu, pe baza implementării în mediul de dezvoltare Matlab - Simulink a rezultatelor obținute în urma modelării matematice și simulării numerice.

Casca neuronală utilizată, Emotiv Insight reprezintă un dispozitiv de urmărire a activității creierului conceput în anul 2015 de o antreprenoare australiană, Tan Le, cofondatoare a companiei Emotiv Inc., cu sediul în San Francisco, California. Emotiv Insight este un dispozitiv wireless, multicanal, o cască neuronală concepută pentru aplicații BCI.

Pe de altă parte instrumentul ales de tip mini dronă cu patru rotoare utilizat în cadrul experimentului BCI poate fi privit ca un cadru de testare și evaluare a unor idei din domenii pluridisciplinare, cum ar fi: informatica, ingineria electrică și mecanică, pentru a rezolva probleme cum ar fi: teoria controlului zborului în timp real, robotică și navigație. Principalul avantaj al acestui tip de dispozitiv este reprezentat de faptul că reprezintă o platformă de testare versatilă, ce implică un design mecanic relativ simplist care oferă atât un cost de achiziție cât și întreținere redus.

Mini drona este prevăzută cu modul bluetooth cu consum redus de energie (BLE) care îi oferă o rază de operare de 20 de metri față de operator.

Pentru proiectarea interfeței creier-calculator am folosit ca intrare antrenarea cu succes a condiției neutre, ca stare mentală de bază a utilizatorului. În acest scop folosind kitul de

dezvoltare Emotiv Xavier ControlPanel, am antrenat patru clase de sarcini mentale folosind ca declanșator propria imaginație asupra mișcării kinestezice a brațului drept, plecând de la supoziția că experimentând același sentiment cu mișcarea reală a brațului ce se bazează pe execuția motorie și combinând cu observarea unei acțiuni, poate să inducă un răspuns cerebral mai puternic (Miladinović, și alții, 2020). De asemenea, am beneficiat de feedback vizual oferit printr-o serie de animații prestabilite ce proiectează mișcarea unui obiect țintă virtual reprezentat în 3D, format din șase cuburi îmbinate, fiecare mișcare a sa fiind presetată în mod automat în funcția de sarcina mentală ce urmează a fi antrenată. Am ales sarcinile mentale astfel încât să fie intuitive și să corespundă în mare măsură cu deplasarea pe axe a mini dronei după cum urmează:

- Sarcină mentală de ridicare (Lift), utilizată pentru a transmite comanda de decolare a mini dronei Parrot Rolling Spider la o altitudine prestabilită de 1,1 m și ascensiunea cu un pas de 0,2 m/s;
- Sarcină mentală de coborâre (Drop), care controlează reducerea altitudinii cu un pas de 0,2 m/s;
- Sarcină mentală deplasare la dreapta (Right), care controlează girația spre dreapta cu un pas de 0,05 grade;
- Sarcină mentală deplasare la stânga (Left), care controlează girația spre stânga cu un pas de 0,05 grade.

Pe baza imaginării consecințelor comenzii mentale timp de 8 secunde tiparele mentale sunt apoi asociate cu comanda.

În urma procesării secvențelor antrenate prin intermediul Interfeței Emotiv Xavier ControlPanel, acestea fiind memorate în cod binar, este nevoie să fie convertite în secvențe de apăsări de taste care să servească ca intrări pentru controlul mini dronei în timp real.

Doar pentru comanda de resetare a fost aleasă o expresie facială și anume clipitul (blink) pentru care a fost setată condiția de declanșare „la apariție (occur)” care va gestiona apăsarea tastei „R” la fiecare detectare a activității ținând cont de întârzierea stabilită cu scopul de a avea un dublu mecanism de control, având atât funcția de anulare a comenzilor anterioare cât și cea de siguranță în cazul în care utilizatorul își pierde concentrarea.

Prin implementarea unei soluții bazată pe BCI integrată în controlul unei mini drone se pot simplifica pașii care implică interacțiunea dintre om și mașină, aceasta se adresează unui număr mare de persoane, fie sănătoase, fie cu probleme neurologice sau care suferă de amputări, conform prezentării din secțiunea în care a fost descrisă motivația alegerii temei.

Concluzii

Primul obiectiv urmărit a abordat crearea unei interfețe-creier calculator care utilizează ca fundament paradigma imaginării motorii, prin intermediul căruia utilizatorul să poată controla poziția și orientarea unei mini drone de tip quadcopter, doar utilizând intrările creierului bazate pe comenzi mentale antrenate. Acest obiectiv a implicat utilizarea aceleiași căști neuronale Emotiv Insight, care a fost folosită înainte în studiul de caz, pentru

înțelegerea fundamentelor modelelor cerebrale, care au stat la baza conceperii scenariului de antrenare a patru clase de comenzi mentale.

Al doilea obiectiv a avut ca scop realizarea modelării matematice și simulării numerice a dinamicii mini dronei Parrot Rolling Spider, fiind implementată pentru a optimiza și valida controlul acesteia prin intermediul interfeței BCI. Acest lucru a implicat testarea validității modelului atât în condiții reale de zbor, cât și prin simularea comportamentului mini dronei implementată în Simulink 3D Animation.

Al treilea obiectiv a concis cu antrenarea utilizatorului cu scopul de a învăța comenzi mentale specifice care au fost validate ca răspuns în controlul direcției și orientării dronei pentru validarea eficienței sistemului BCI.

CAPITOLUL 5

APLICAȚII DE CONTROL BCI

Introducere

Interfața creier calculator (BCI) permite, pe lângă controlul dispozitivelor fizice și a unor instrumente virtuale, recunoașterea și transpunerea în timp real a intențiilor utilizatorului, folosind ca intrări modele cerebrale recunoscute în urma cartografierii creierului acestuia. Progresul continuu al tehnologiei interfeței BCI a făcut posibilă dezvoltarea unor jocuri care implică utilizarea în mod direct a intrărilor provenite de la creier în detrimentul metodelor de control tradiționale, consacrate. Astfel, utilizând același dispozitiv de interfațare BCI, reprezentat de casca neuronală Emotiv Insight, am proiectat și dezvoltat un joc, intitulat Mental Pool Game, bazat pe atenția și concentrarea utilizatorului în controlul puterii și a vitezei pe care o poate imprima unui obiect virtual, în cazul de față unei bile albe, specifice jocului de biliard. Jocul a fost dezvoltat în întregime în cadrul motorului de jocuri de tip multiplatformă Unity3D.

În continuare este tratată o altă aplicație care prezintă controlul unei platforme robotizate Lego, care utilizează semnalele EEG și EMG captate folosind o cască OpenBCI reproiectată. O altă metodă de control, bazată pe artefacte musculare, este utilizată pentru controlul direcției platformei robotice Lego Mindstorms în baza a patru expresii faciale impuse. Secțiunea detaliază, de asemenea, hardware-ul utilizat, împreună cu implementarea software și interfața de control.

Ultima aplicație este cea care demonstrează potențialul interfețelor creier-calculator, prin faptul că oferă noi modalități de interacțiune atât în jocuri, dar mai ales în robotică, utilizând ca fundament potențialele vizuale în stare de echilibru, pentru a controla și acționa cuplele unui robot păianjen imprimat 3D. La fel ca și în cazul primei aplicații prezentate, motorul de jocuri Unity 3D a fost utilizat pentru realizarea și integrarea interfeței BCI.

Obiective

Obiectivele reprezentative ultimului capitolului sunt:

- Integrarea și implementarea interfeței creier-calculator într-un joc video 3D;
- Dezvoltarea unui sistem de control al unei platforme robotizate prin semnale EEG și EMG;
- Controlul unui robot păianjen folosind paradigma SSVEP.

Proiectarea unui joc video 3D controlat prin BCI

În realizarea acestui joc am ales să implementez și să mă folosesc de o singură intrare neuronală, fundamentată de rezultatele oferite din studiul de caz al celor trei subiecți în ceea ce privește comanda mentală de ridicare. Astfel, în baza aceluiași paradigmă de imaginare motorie, bazată tot pe relaxare și niveluri de concentrare, am implementat o altă mișcare imaginată a brațului uman. Aceasta implică același grad de conștientizare kinestezică, precum cel produs în cazul mișcării de flexie, generată de complexul articular al umărului, cu articulația cotului și a încheieturii fixate, utilizate anterior ca idee generală de antrenare mentală a comenzii de ridicare. În acest scop a fost aleasă comanda mentală „împinge” (push) ca indicator al puterii de concentrare a utilizatorului pentru a controla deplasarea spațială intenționată, doar prin control mental, fără a implica alte grupe de mușchi.

În conceperea jocului am ales Unity, dezvoltat de Unity Technologies, deoarece este un motor de jocuri de tip open-source, de tip multiplatformă.

Acest joc a plecat de la ideea de a acoperi mai multe grupuri țintă, atât pentru persoane sănătoase, cât și pentru persoane cu dizabilități. Mai ales în cazul celor din urmă, utilizarea dispozitivelor de intrare periferice pentru PC, din categoria tastaturii, mouse-ului sau joystick-ului ar putea să reprezinte o provocare. Astfel, metoda propusă, care nu implică aceste comenzi clasice, ci doar analiza și interpretarea comenzilor provenite de la creier pentru a controla viteza de deplasare a bilei albe cu scopul de a lovi oricare din cele 15 bile de pe masa de biliard, este o soluție care își propune să ofere rezultate mai bune pentru toți acești participanți.

Pentru a putea juca jocul de biliard, utilizatorul trebuie să parcurgă 2 etape de antrenare mentală, similare din punct de vedere al activităților premergătoare cu modalitatea prin care s-a antrenat starea mentală neutră și cea de ridicare, prin interfața Emotiv Xavier ControlPanel în cazul quadcopterului. Astfel, utilizatorul își induce inițial o stare de relaxare în aceleași condiții de menținere a unei priviri defocalizate/nefocusate și menține capul în aceeași poziție timp de zece secunde. În ceea ce privește modelul de antrenare pentru comanda mentală „împinge”, utilizatorul trebuie să își imagineze timp de 9 secunde complexul kinestezic de mișcări mai sus amintit, dar față de antrenarea comenzii mentale de ridicare, utilizată pentru navigarea după axa „z” a quadcopterului. Astfel, puterea cognitivă pe care o alocă utilizatorul sarcinii mentale este cea care determină viteza variabilă de deplasare a bilei albe pe axa de mișcare y.

Platformă Lego NXT Mindstorms 2.0 controlată prin semnale considerate artefacte cerebrale

Am realizat un dispozitiv de captare a semnalelor EEG pentru controlul acționării unei platforme robotizate tip Lego, care să ofere robustețe și un cost redus. În acest sens, soluția aleasă oferă avantajul utilizării nelimitate a electrozilor de captare EEG, fără să necesite aplicarea unei soluții de rehidratare sau înlocuirea periodică a acestora, cum este cazul celor fabricați din polimeri semiconductori utilizați de casca neuronală Emotiv Insight în aplicațiile prezentate anterior. Primul pas în dezvoltarea interfeței BCI a fost alegerea unei platforme educaționale, care permite programarea într-un limbaj de programare de nivel înalt, cum este limbajul C#, dar și integrarea unui protocol de comunicație fără fir prin bluetooth. Din acest punct de vedere hardware-ul a fost de asemenea ales să corespundă unei soluții software de tip open-source, capabilă să discrimineze între activitatea generată de semnalele de electroencefalogramă (EEG) și activitatea electrică generată de semnalele de electromiografie (EMG). Acestea din urmă, deși sunt considerate artefacte care contaminatează semnalul EEG, pot fi folosite ca metodă directă de control al creierului la fel ca și în cazul primelor, fiind și obiectivul urmărit pentru a realiza un control BCI al platformei Lego, bazat pe detectarea impulsurilor generate de mușchii faciali.

Pentru a realiza un control direct bazat pe impulsuri neuronale, am utilizat o cască OpenBCI a cărei structură a fost reproiectată tridimensional în baza unei licențe de tip open-source. Principalul obiectiv a fost de a oferi o bună acoperire a locațiilor EEG selectate și un grad de confort ridicat, împreună cu o potrivire rapidă a electrozilor EEG la contactul cu scalpul și care să ofere un mod rapid de reconfigurare. Casca OpenBCI astfel proiectată plasează o matrice de 16 electrozi de electroencefalogramă, fiecare de tip uscat, care sunt fabricați din clorură de argint (AgCl), fiind reutilizabili.

Pentru conducerea experimentului de achiziție a semnalelor EEG am utilizat o placă de dezvoltare și OpenBCI Cython și una de expansiune OpenBCI Daisy, integrate prin intermediul unui PCB prevăzut cu conectori mamă auriți de siguranță la 90°, realizat în software-ul de proiectare a circuitelor Proteus.

Pentru a controla platforma Lego am gândit și implementat patru expresii faciale, obținute ca aport combinat al semnalelor de electromiografie și electroencefalogramă, cu avantajul oferit de faptul că nu necesită timp alocat pentru a implementa un antrenament, care folosește ca intrări comenzi mentale cum este cazul anterior, ceea ce a implicat paradigma imaginării motorii bazată pe relaxare și nivelurile de concentrare anterior implementată, atât în cazul controlului quadcopterului cât și al jocului de biliard.

Astfel cele patru expresii faciale urmărite care produc semnale musculare (EMG) sunt: ridicarea sprâncenei drepte prin mușchii aferenți acesteia, mișcarea generată de mandibulă prin mișcarea intenționată a mușchilor aferenți acesteia în partea dreaptă, precum și mișcarea celeilalte sprâncene și a mandibulei în sens invers. Interfața OpenBCI a fost utilizată pentru a procesa și interpreta semnalele musculare.

Datele de semnal odată interpretate sunt convertite în binar de interfața OpenBCI și sunt transmise prin intermediul sistemului Lab Streaming Layer (LSL), sub formă de serii de timp către o aplicație implementată cu cod scris în limbajul Python, denumită PyCommand.py. Această aplicație, are rolul de a clasifica fiecare semnal obținut și de a-l mapa unor secvențe de apăsări de taste.

Pentru a recepționa aceste secvențe de taste am dezvoltat și implementat o interfață în C#, care să creeze o punte între dispozitivul bluetooth al calculatorului și cel al platformei Lego.

Controlul unui robot păianjen bazat pe interfață BCI SSVEP

În această secțiune propun un sistem BCI care utilizează paradigma potențialelor vizuale evocate în stare de echilibru (SSVEP) pentru a controla vectorii de mișcare a unui robot păianjen, proiectat și printat 3D.

Potențialul vizual evocat în stare de echilibru (SSVEP), din punct de vedere al modului prin care poate fi folosit ca intrare într-un sistem BCI, reprezintă actul intenționat al voinței unei persoane. Potențialul SSVEP astfel constituit concentrează energia spectrală într-o bandă îngustă și depinde de atenție pentru a modula această energie în mod voluntar, fapt ce îl face potrivit pentru a fi utilizat în sistemele BCI.

Aplicația de control este bazată exclusiv pe paradigma SSVEP ca mod de tratare a interfeței BCI, în timp ce este aplicată pentru a controla deplasarea sau acțiunea capabilă să exprime interacțiunea cu utilizatorul a unui robot păianjen proiectat 3D.

Din punct de vedere al hardware-ului ales am utilizat o placă de dezvoltare Arduino Nano V3 ce integrează un MCU ATmega 328P. Pentru a nu necesita proiectarea și realizarea unei plăci PCB dedicate, am utilizat un modul de expansiune conceput special pentru această placă de dezvoltare care să permită un control PWM. Pentru a putea recepționa comenzi de la distanță am folosit pe post de minicomputer o altă placă de dezvoltare Raspberry Pi Zero W, deoarece beneficiază de modul integrat WiFi, făcând ușoară implementarea unui protocol de comunicație User Datagram Protocol (UDP) atât pentru client cât și pentru server.

Casca BCI NextMind utilizată a fost dezvoltată de NextMind SAS din Paris, Franța, și a fost aleasă deoarece oferă un număr de 9 electrozi brevetati de tip uscat cu preamplificare, plasați după același standard Internațional 10 - 20, a căror locații au fost adaptate pentru a identifica și măsura activitatea creierului produsă în cortexul vizual. Folosind ca bază SDK-ul NextMind dezvoltat pentru Unity3D, am implementat managerul de calibrare care măsoară atenția utilizatorului ca nivel raportat la răspunsul stimulilor vizuali ca referință folosită în implementarea unui control activ.

Acestea îndeplinesc mișcările: înainte, înapoi, întoarcere la stânga și respectiv dreapta, așezare și respectiv ridicare.

Interfața GUI integrată în Unity este augmentată cu șase obiecte (primitive) de tip sferă pentru a putea reprezenta intrări care generează stimuli vizuali folosiți ca declanșatori pentru sistemul SSVEP-BCI. În fiecare sferă, mai apoi este integrată o componentă NeuroTag pusă la dispoziție de NextMind și care conferă obiectului un aspect al unei suprapunerii grafice cu

transparență. Pentru ca utilizatorul să poată valida acțiunea am implementat un prefabricat denumit TrainagleFeedback care este integrat la nivelul fiecărei sfere.

Ca pas următor, printr-un script implementat în limbajul de programare C#, se realizează citirea activărilor declanșatorului NeuroTag, care are rolul de a acționa în mod similar cu un buton care trimite prin interfața serială valoarea șirului de caractere atribuit comenzii predefinite.

Mișcările predefinite ale robotului și anume poziția: ridicare, coborâre, pași înainte, pași înapoi, rotire la dreapta, rotire la stânga, strângere de mână și respectiv bate palma.

Pentru a valida acuratețea sistemului BCI-SSVEP și a verifica nivelul de atenție necesar pentru a conduce robotul, dar și pentru a determina timpul mediu petrecut de un utilizator pentru familiarizarea cu mecanica aplicației, au fost selectați trei subiecți pentru care au fost întreprinse acțiuni de mentorat timp de 15 minute fiecare. Fiecare sesiune de instruire a fost realizată în aceleași condiții de laborator similare cu cele aduse în cazul antrenării comenzii mentale de ridicare prin paradigma bazată pe imaginarea motorie. Astfel rezultatele obținute de fiecare participant pe tot parcursul antrenamentului și sesiunii libere de acționare voluntară a acțiunii au fost memorate într-un fișier CSV individual. Acesta are rolul de a stoca nivelul de încredere al fiecărui utilizator manifestat prin nivelul de atenție individual generat ca răspuns la prezența stimulilor vizuali. Pentru fiecare set de date stocat s-a calculat apoi o valoare medie a încrederii cumulative normalizate cu scopul de a raporta procentul de atenție obținut ca urmare a aplicării unui cod scris în Python a cărui implementare să ofere o reprezentare grafică.

Ca prim rezultat timpul măsurat al primului subiect **S1** a fost de 157 de secunde, în care a obținut un grad de atenție exprimat în procent de 91 %.

Și în cazul subiectului **S2**, un timp măsurat de 185 de secunde a fost înregistrat și un nivel crescut al atenției de 98%.

În cazul ultimului subiect **S3**, timpul măsurat a atins 197 de secunde și un nivel al atenției raportat la 74 %.

Concluzii

Primul obiectiv expus al capitolului demonstrează sustenabilitatea și eficiența utilizării interfeței BCI în controlul unui joc video 3D, care simulează comportamentul real al unui joc de biliard. De asemenea, implică utilizarea unui motor grafic realist, care oferă toate facilitățile necesare pentru a crea o interfață grafică cu utilizatorul optimizată, pentru a reduce timpul necesar acomodării acestuia. De asemenea, faptul că este implementată o interfață creier-calculator, care folosește o cască EEG pentru manipularea și controlul elementelor jocului folosind ca intrări comenzi mentale, face ca aplicația să fie disponibilă atât în scopuri de recreere pentru persoanele sănătoase, cât și în scopuri de reabilitare pentru persoanele cu deficiențe motorii.

Al doilea obiectiv se concentrează pe crearea unei soluții software care să integreze o legătură între o soluție hardware care a fost proiectată să detecteze atât semnalele EEG cât și conținutul lor de natura artefactelor musculare (EMG), pentru a le folosi pe cele din urmă

pentru controlul mișcării robotului. Astfel mișcările mușchilor faciali în sistemele BCI bazate doar pe EEG ar trebui eliminate pentru a nu introduce surse de zgomot care alterează calitatea semnalelor, în aplicația curentă sunt folosite pe post de semnale de control.

Ultimul obiectiv integrează capacitățile de navigare ale unui robot, cu cost redus, echipat cu servomotoare și controlat printr-o placă de dezvoltare Arduino, cu posibilitatea unui control neuronal bazat doar pe focalizarea pe stimuli vizuali specifici.

CAPITOLUL 6

CONCLUZII, CONTRIBUȚII ȘI DIRECȚII DE DEZVOLTARE

CONCLUZII

În capitolul 1 am tratat interfețele creier-calculator (BCI) ca pe o principală punte de legătură între dispozitivele externe și activitatea neuronală captată prin măsurarea potențialelor electrice ale utilizatorului. Astfel electroencefalografia (EEG) este principala metodă, cea mai des folosită, pentru captarea semnalelor cerebrale, datorită rezoluției temporale excelente. Cu toate acestea, majoritatea sistemelor BCI care se bazează exclusiv pe EEG prezintă provocări semnificative care trebuie depășite, fiind susceptibile la interferențe, perturbații și discontinuitate, în special în cazul sistemelor ce utilizează metode de captare non-invazive. Prezența artefactelor biologice reprezintă de asemenea surse de contaminare ce pot degrada semnalul EEG. Indiferent de tipul de interfață BCI ales, toate au în comun orientarea către utilizator pentru controlul dispozitivelor, folosind interpretarea activității cerebrale, raportată la intenția, atenția și voința acestuia.

În cel de-al doilea capitol am trecut în revistă stadiul actual al tehnicilor utilizate de sistemele BCI, în care am căutat să punctez progresele semnificative care au fost aduse în ultimele decenii. Am studiat diverse metode de neuroimagică, precum EEG, fMRI, MEG și NIRS, care au fost aplicate cu succes în crearea interfeței BCI. Comparativ cu metodele non-invazive, metodele invazive au demonstrat că furnizează semnale de înaltă calitate care sunt indispensabile pentru aplicații complexe, cum este cazul controlului neuroprotezelor. Cu toate acestea, în domeniul BCI rămân de depășit numeroase provocări, inclusiv clarificarea diferitelor metode de achiziție a semnalului în ceea ce privește avantajele și dezavantajele, investigarea problemelor legate de metodele non-invazive și îmbunătățirea vitezei de transfer a informațiilor. Progresele recente înregistrate în acest domeniu au arătat faptul că BCI-urile vor continua să aducă beneficii semnificative în domeniul reabilitării pentru persoanele cu dizabilități, dar se vor găsi și aplicații utile de uz general.

În cel de-al treilea capitol am descris și implementat etapele necesare pentru obținerea unor seturi de date EEG curățate de artefacte, pentru care principalul obiectiv a fost asigurarea calității și integrității acestora. Pe lângă eliminarea artefactelor, alt obiectiv urmărit a fost menținerea unei amplitudini reduse în cazul artefactelor reziduale, dar și

compararea distribuției undelor cerebrale pentru diverse stări mentale. Acest capitol scoate în evidență importanța înțelegerii variabilității individuale utilizată în procesul de proiectare a scenariilor de antrenare mentală ca modalitate de control al aplicațiilor BCI.

În capitolul 4 am descris modul de creare a unei interfețe BCI bazată pe paradigma imaginării motorii, care creează o punte de legătură între utilizator și secvențele de tip apăsare de taste, utilizate pentru controlul unei mini drone de tip quadcopter. Pentru a îndeplini acest obiectiv am integrat tehnologia interfeței BCI reprezentată prin casca neuronală Emotiv Insight cu modelarea matematică și simularea numerică a dinamicii dronei. De asemenea, accentul a fost pus pe antrenarea utilizatorului pentru a învăța comenzi mentale specifice, cu scopul de a valida eficiența sistemului BCI.

În capitolul 5 am utilizat interfața BCI în controlul unui joc video 3D de biliard, demonstrând potențialul aplicării acestei tehnologii în mediul virtual pentru a recrea dinamica reală bazată pe legile fizicii folosind un motor grafic capabil să reproducă fidel acest lucru. De asemenea, am propus și integrat o soluție bazată pe EEG și EMG pentru a controla prin artefacte musculare direcția de deplasare a unei platforme robotizate, demonstrând faptul că și artefactele fiziologice reprezintă potențial pentru a fi utilizate ca intrări de comandă și control pentru dispozitive externe. De asemenea, am demonstrat faptul că integrând o interfață BCI creată într-un motor grafic de jocuri, cu o cască neuronală care monitorizează cortexul vizual, se poate utiliza un control neuronal bazat pe focalizarea pe stimuli vizuali specifici ce necesită o scurtă perioadă de acomodare a utilizatorului pentru controlul mișcării unui robot.

CONTRIBUȚII

În cadrul tezei de doctorat au fost aduse o serie de contribuții, dintre care le-aș menționa inițial pe cele legate de stadiul actual al temei abordate, care reies din cercetarea bibliografică.

- Am realizat o prezentare comprehensivă a stadiului actual a interfețelor creier-calculator (BCI), prin care am acoperit toate etapele de proiectare: de la stadiul de achiziție a semnalelor creierului la metodele de preprocesare, de extragere a caracteristicilor, dar și de clasificare și implementare a interfeței de control. Întregul flux de lucru legat de proiectarea BCI a fost abordat într-o manieră holistică, prin care am urmărit să creez o imagine de ansamblu asupra problematicei actuale a integrării intenției utilizatorului uman ca factor de decizie în controlul dispozitivelor externe;
- Am realizat o examinare aprofundată a principalelor modalități utilizate în neuroimagistică, pentru a identifica principalele tipuri de semnale de control care pot fi folosite ca intrări ale BCI-urilor, scoțând în evidență atât avantajele, dar și dezavantajele fiecărei tehnici;
- Am realizat și implementat un studiu de caz pe mai mulți subiecți pentru a înțelege modelele cerebrale pentru mai multe stări mentale și condiții de antrenare, pentru

a le folosi ca fundament în conceperea unor scenarii cât mai eficiente de proiectare BCI, pentru a reduce complexitatea și timpul învățării și acomodării utilizatorului cu mediul astfel creat.

CONTRIBUȚIILE DETALIATE PE CAPITOLE

Capitolul 1:

1. Am realizat un studiu al principalelor tipuri de activități ale creierului, care constituie abordări existente legate de neuroimagnostică în sistemele BCI, și anume cele electrofiziologice, care utilizează ca metode de captare: electroencefalografia, electrocorticografia, magnetoencefalografia și achiziția semnalului electric în neuronii singuri și cele hemodinamice reprezentate prin metodele de captare: rezonanța magnetică funcțională și spectroscopia NIR.
2. Am definit conceptul de electroencefalografie ca modalitate de neuroimagnostică, prezentând avantajele și dezavantajele sale, în special în tehnicile non-invazive de captare a semnalelor creierului.
3. Am analizat și descris modalitățile invazive de captare a semnalelor cerebrale, descriind principalele metode specifice în cercetarea BCI și am descris principalele probleme care apar în urma implantării microelectrodului.
4. Am analizat și descris tipurile de semnale de control utilizate de sistemele BCI, printre care: potențialele evocate vizuale, potențialele corticale lente, potențialele evocate P300 și ritmurile senzoriomotorii.
5. Am analizat și descris tipurile de interfețe BCI, clasificate ca: exogene sau endogene și, respectiv sincrone sau asincrone, care sunt modulate pentru a transmite informații, precum și avantajele și dezavantajele lor.
6. Am descris și analizat principalele metode de selecție și de extragere a caracteristicilor din semnalele creierului, utilizate pentru reducere dimensională, metode de analiză în timp / frecvență și modelare parametrică.
7. Am descris și tratat principalele artefacte fiziologice și tehnice prezente în sistemele BCI, precum și principalele abordări de eliminare.

Capitolul 2:

8. Am analizat și descris principalii algoritmi de clasificare pentru estimarea automată a clasei de date, de modelare generativă, liniară și neliniară, utilizați pentru a putea controla un sistem BCI. Aceștia sunt esențiali pentru recunoașterea modelelor de activitate cerebrală care odată identificate de sistem sunt traduse în comenzi.
9. Am identificat și analizat principalele aplicații BCI actuale utilizate în principal pentru domeniul medical, pentru reabilitare, dar și pentru sectorul civil, cum este domeniul divertismentului și neuromarketing-ului.

Capitolul 3:

10. Am proiectat și realizat un studiu de caz prin care am instruit trei subiecți să utilizeze o cască neuronală cu cinci canale de EEG, pentru a antrena o condiție de relaxare, utilizată ca fundament pentru antrenarea unei comenzi mentale impuse și acționarea intenționată a acesteia.
11. Am creat un scenariu prin care participanții parcurg două sesiuni de antrenare mentală, prima în care să antreneze doar condiția neutră pentru a putea analiza distribuția spațială a undelor cerebrale pentru perioada de relaxare, iar în cea de-a doua să reia procesul acesteia pentru a putea antrena și comanda mentală de ridicare, ambele sesiuni fiind înregistrate simultan.
12. Am propus și implementat un algoritm în șase pași, de preprocesare offline a datelor EEG, implementat în mediul de dezvoltare Matlab, folosind setul de instrumente EEGLAB, rezultate din fiecare înregistrare pentru fiecare dintre cele două sesiuni de antrenare mentală, cu scopul de a obține componente independente statistic care să realizeze o separare a datelor EEG, utile studiului, de artefactele care le contaminatează.
13. Am implementat un clasificator bazat pe învățare profundă, utilizat pentru recunoașterea și eliminarea automată a componentelor independente din înregistrările EEG. Am ales acest clasificator pentru capacitatea de predicție a surselor de semnal ale creierului și a procentului celor de natura artefactelor.
14. Am realizat și implementat un algoritm reprezentat în patru pași, scris în limbajul de programare Python, care să gestioneze datele EEG înregistrate în urma preprocesării și să le reprezinte grafic, raportat la intervalele de antrenare a stării neutre, de antrenare a comenzii mentale de ridicare și de acționare intenționată, precum și a intervalelor de validare inter-acțiuni.
15. Am dezvoltat și implementat un algoritm complex de analiză a densității de putere spectrală (PSD), scris în limbajul de programare C, pentru a evalua distribuția spațială a activității cerebrale în spectrul de frecvențe al undelor alfa și beta pentru scenariul de antrenare impus.

Capitolul 4:

16. Am realizat o descriere amănunțită a dispozitivului BCI de tip cască neuronală Emotiv Insight, conform studierii brevetului de invenție, inclusiv specificațiile tehnice, senzorii EEG utilizați, avantajele oferite și locațiile corticale acoperite.
17. Am realizat o prezentare a mini dronei Parrot Rolling Spider utilizată, prin care am prezentat caracteristicile sale tehnice și componentele hardware încorporate.
18. Am dezvoltat modelul matematic al dronei, care conține ecuațiile de mișcare de la sol la un pol și am determinat modelul dinamic al dronei pentru a determina forța de tracțiune verticală, efectul de rotație, momentul de derivă, efectul de ruluu, forța de tracțiune și intervalele de inerție raportate la axe. Acestea au fost implementate într-o simulare în mediul de dezvoltare Matlab-Simulink pe baza căreia să se

- realizeze un algoritm de conducere, estimare și control în timp real a dinamicii mini dronei.
19. Am realizat procesul de implementare al interfeței BCI folosind ca fundament procesul de achiziție și procesare a semnalelor EEG bazate pe kiturile de dezvoltare Emotiv.
 20. Am implementat procesul de antrenare și clasificare a comenzilor mentale, folosind ca bază kitul Emotiv, pentru patru clase de sarcini mentale (ridicare, coborâre, deplasare stânga/dreapta) folosind imaginația motorie. Printr-o altă interfață Emotiv, rezultatul antrenării comenzilor mentale a fost mapat acțiunilor dronei.
 21. Am propus extinderea funcționalității dronei pentru monitorizarea zonelor de hazard, prin integrarea unui kit CC2650 SensorTag care conține 10 senzori MEMS care pot fi utilizați pentru achiziția parametrilor de mediu.

Capitolul 5:

22. Am realizat și proiectat un joc de biliard numit Mental Pool Game, utilizând motorul de jocuri Unity3D. Pentru achiziția semnalelor EEG am utilizat aceeași cască neuronală folosită și pentru controlul quadcopter-ului și în conceperea studiului de caz. Acest joc a fost dezvoltat pentru a fi accesibil atât persoanelor cu o bună stare de sănătate cât și a celor cu dizabilități. De asemenea, prin interfața BCI se oferă o alternativă la dispozitivele de intrare periferice tradiționale, cum ar fi tastatura, mouse-ul sau joystick-ul.
23. Am proiectat jocul de biliard în motorul de jocuri Unity3D, folosind componente de tip plasă (mesh), componente care implică elemente de interacțiune fizică, componente de randare, toate fiind folosite în cadrul jocului pentru a descrie interacțiunile dintre obiectele virtuale.
24. Pentru integrarea interfeței BCI am implementat un script în limbajul de programare C#, prin care s-a antrenat starea mentală neutră și comanda mentală „Împinge” timp de nouă secunde. A fost implementat un scenariu prin care utilizatorul își imaginează mișcarea unui complex kinestezic efectuată de articulația umărului și a cotului. Prin această acțiune imaginată utilizatorul poate crește viteza de deplasare a bilei albe cu scopul de a lovi oricare din cele 15 bile de pe masa de biliard.
25. Am integrat citirea valorilor coordonatelor x și y provenite de la giroscopul cu 3 axe al căștii neuronale printr-un script realizat în limbajul de programare C#, pentru a controla rotirea camerei folosind kitul de dezvoltare Emotiv integrat în Unity. Astfel utilizatorul poate să controleze direcția de deplasare a bilei albe în jurul mesei.
26. Am implementat mecanica jocului de biliard, importând elementele 3D, masa și bilele de biliard în baza unei licențe open-source, apoi am adăugat componentele

- de coliziune, împreună cu materialele fizice pentru a putea simula interacțiunile realiste legate între obiectele de joc.
27. Pentru a putea configura sistemul BCI am creat o interfață utilizator folosind elemente UI din Unity, pentru a putea gestiona profilul utilizatorului, butoanele de antrenare a comenzilor mentale și afișarea mesajelor de status, toate fiind incluse într-un panou principal de meniu.
 28. Am realizat o aplicație de comandă și control BCI a unei platforme educaționale Lego NXT Mindstorms 2.0, care a fost programată folosind interfețe create în limbajul de programare C#.
 29. Pentru a realiza interfața BCI am utilizat o cască neuronală OpenBCI, bazată pe o placă de dezvoltare Cython și un modul de extensie Daisy, a cărui structură a fost reproiectată și imprimată 3D pentru a se potrivi pe forma anatomică a capului oricărui utilizator.
 30. Am realizat un control neuronal în baza a 16 canale EEG, folosind interfața OpenBCI, pentru a oferi feedback legat de semnalele EMG detectate în urma recunoașterii a patru expresii faciale neantrenate generate de musculatura feței și care controlează înaintarea, mersul înapoi, întoarcerea la stânga și la dreapta a platformei robotizate.
 31. Pentru a controla platforma Lego, am dezvoltat o interfață în C#, care facilitează comunicația Bluetooth între calculator și platforma Lego. Interfața permite utilizatorului să configureze tastele pentru controlul servomotoarelor, să verifice starea bateriei și să afișeze versiunea de firmware a platformei.
 32. Am realizat un sistem BCI care utilizează paradigma potențialelor vizuale evocate în stare finită (SSVEP) pentru a controla vectorii de mișcare a unui robot păianjen, proiectat și printat 3D. Am utilizat casca neuronală NextMind prevăzută cu 9 electrozi uscați care permite măsurarea activității cortexului vizual.
 33. Am dezvoltat o arhitectură hardware și software a sistemului controlat, folosind o placă de dezvoltare Arduino Nano V3, conectată printr-un modul de expansiune conceput special pentru această placă de dezvoltare, care să permită un control PWM. De asemenea, am integrat o placă Raspberry Pi Zero W utilizată ca minicomputer pentru comunicația wireless și am implementat un protocol de comunicație UDP pentru transmiterea comenzilor.
 34. Am dezvoltat un cadru de fundal în software-ul asistat de calculator SolidWorks, cu scopul de a îmbunătăți aspectul interfeței BCI. Acesta a fost integrat în motorul de jocuri Unity3D, fiind augmentat cu șase obiecte (primitive) de tip sferă, pentru a putea reprezenta intrări care generează stimuli vizuali folosiți ca declanșatori pentru sistemul SSVEP-BCI.
 35. Am realizat implementarea interfeței BCI pentru controlul robotului în motorul de jocuri Unity3D în baza unui script implementat în limbajul de programare C#, care realizează citirea activărilor declanșatorului NeuroTag integrat în fiecare primitivă,

- care are rolul de a acționa în mod similar cu un buton care trimite prin interfața serială valoarea șirului de caractere atribuit comenzii predefinite.
36. Pentru a îmbunătăți aspectul interfeței BCI a fost creat un cadru de fundal în software-ul asistat de calculator (CAD) SolidWorks. Interfața GUI astfel rezultată va fi augmentată cu șase obiecte (primitive) de tip sferă, pentru a putea reprezenta intrări care generează stimuli vizuali folosiți ca declanșatori pentru sistemul SSVEP-BCI.
 37. Pentru acomodarea utilizatorului cu interfața și măsurarea atenției utilizatorului la răspunsul evocat prin stimuli vizuali am implementat un manager de calibrare în Unity3D integrat prin intermediul kitului de dezvoltare oferit de NextMind.
 38. Am implementat un proces de testare a rezultatelor obținute de fiecare din cei trei participanți pe tot parcursul antrenamentului și sesiunii libere de acționare voluntară, acestea fiind memorate într-un fișier CSV individual. Pentru fiecare dintre aceștia a fost măsurat timpul de familiarizare și nivelul de atenție obținut, fiind reprezentat sub formă grafică pe baza unui cod scris în limbajul de programare Python.

DIRECȚII DE DEZVOLTARE

În ceea ce privește direcțiile de dezvoltare viitoare pot defini câteva propuneri principale:

- Am în vedere extinderea studiului de caz prin utilizarea căștii neuronale OpenBCI, prevăzută cu 16 canale EEG, pentru a analiza distribuția undelor cerebrale în locațiile care nu sunt acoperite de casca neuronală Emotiv Insight. Acest lucru implică adăugarea unor electrozi EEG în locațiile cortexului motor primar (M1), și anume în locațiile C3 și C4 care sunt legiferate prin intermediul standardului internațional 10-20 ce prevede modul de plasare a electrozilor de electroencefalogramă. În acest fel pot fi validate rezultatele obținute prin scenariul propus de antrenare a comenzii mentale de ridicare pe baza imaginării mișcării kinestezice a brațului, și anume pe baza implementării propriu-zise a paradigmei kinesthetic motor imagery.
- Ca o a doua propunere îmi doresc să extind aplicațiile BCI deja propuse spre un domeniu de reabilitare, care să implice controlul unei neuroproteze proiectate și imprimate 3D, folosind o metodă de achiziție a semnalelor EEG non-invazivă. O astfel de soluție poate să ofere o alternativă la soluțiile scumpe ale protezelor existente pe piață, care adesea sunt incomode și prezintă o funcționalitate redusă datorită caracteristicilor tehnice limitate.
- În final, am în vedere și extinderea aplicației de control a dronei pentru navigare în exterior, folosind o altă soluție hardware, care să beneficieze de o rețea mai vastă de senzori, chiar bazată pe integrarea kitului pentru monitorizarea parametrilor de mediu deja propus pentru gestionarea situațiilor de hazard, folosind o soluție BCI. De asemenea, disponibilitatea unei drone care să conțină și un modul de navigare

autonomă bazat pe tehnologie GPS este un alt obiectiv, împreună cu găsirea unei soluții de comunicare la distanță între casca neuronală și dronă, folosind o soluție bazată pe rețele mobile prin integrarea unui modul GSM. Astfel, se poate extinde distanța acoperită de dronă și posibilitatea revenirii ei în punctul de decolare, în cazul în care se pierde conexiunea între dispozitive.

Bibliografie

- Abdulaal, M., Casson, A., & Gaydecki, P. (2021). Critical Analysis of Cross-Validation Methods and Their Impact on Neural Networks Performance Inflation in Electroencephalography Analysis. *IEEE Canadian Journal of Electrical and Computer Engineering*, 44(1), 75-82. doi:10.1109/ICJECE.2020.3024876
- Abu-Rmileh, A., Zakkay, E., Shmuelof, L., & Shriki, O. (2019). Co-adaptive Training Improves Efficacy of a Multi-Day EEG-Based Motor Imagery BCI Training. *Frontiers in human neuroscience*, 13, 362. doi:10.3389/fnhum.2019.00362
- Acharya, J. N., Hani, A., Cheek, J., Thirumala, P., & Tsuchida, T. N. (2016). American Clinical Neurophysiology Society Guideline 2: Guidelines for Standard Electrode Position Nomenclature. *Journal of clinical neurophysiology : official publication of the American Electroencephalographic Society*, 33(4), 308-311. doi:10.1097/WNP.0000000000000316
- Addison, P., Walker, J., & Guido, R. (2009). Time--frequency analysis of biosignals. *IEEE Engineering in Medicine and Biology Magazine*, 28(5), 14-29. doi:0.1109/MEMB.2009.934244
- Aggarwal, S., & Chugh, N. (2022). Review of Machine Learning Techniques for EEG Based Brain Computer Interface. *Archives of Computational Methods in Engineering*, 29, 3001-3020. doi:10.1007/s11831-021-09684-6
- Ahi, S. T., Kambara, H., & Koike, Y. (2011). A dictionary-driven P300 speller with a modified interface. *IEEE transactions on neural systems and rehabilitation engineering*, 19(1), 6-14. doi:10.1109/TNSRE.2010.2049373
- Akinci, B., & Gencer, N. (2009). Classification of 4-class motor imagery EEG data with Common Sparse Spectral Spatial Pattern method. *2009 14th National Biomedical Engineering Meeting*, (pg. 1-4). doi:10.1109/BIYOMUT.2009.5130261
- Akram, F., Alwakeel, A., Alwakeel, M., Hijji, M., & Masud, U. (2022). A Symbols Based BCI Paradigm for Intelligent Home Control Using P300 Event-Related Potentials. *Sensors*, 22(24), 10000. doi:10.3390/s222410000
- Akujuobi, C. (2022). *Wavelets*. Springer. doi:10.1007/978-3-030-87528-2_2
- Alakuş, T. B., & Türkoğlu, İ. (2019). Feature Selection with Sequential Forward Selection Algorithm from Emotion Estimation based on EEG Signals. *Sakarya University Journal of Science*, 23(6), 1096-1105. doi:10.16984/saufenbilder.501799

- Alhudhaif, A. (2021). An effective classification framework for brain-computer interface system design based on combining of fNIRS and EEG signals. *PeerJ Comput Sci*(e537), 7. doi:10.7717/peerj-cs.537
- Alimardani, M., Nishio, S., & Ishiguro, H. (2018). Brain-Computer Interface and Motor Imagery Training: The Role of Visual Feedback and Embodiment. În D. Larrivee, *Evolving BCI Therapy*. doi:10.5772/intechopen.78695
- Alotaiby, T., Alshebeili, S., F.M., A., & Alrshoud, S. (2017). Epileptic Seizure Prediction Using CSP and LDA for Scalp EEG Signals. *Computational Intelligence and Neuroscience*, 1(11). doi:10.1155/2017/1240323
- Anders, P., Müller, H., Skjæret-Maroni, N., Vereijken, B., & Baumeister, J. (2020). The influence of motor tasks and cut-off parameter selection on artifact subspace reconstruction in EEG recordings. *Medical & Biological Engineering & Computing*, 85, 2673-2683. doi:https://doi.org/10.1007/s11517-020-02252-3
- Angulo-Ruiz, B. Y., Muñoz, V., Rodríguez-Martínez, E. I., & Gómez, C. M. (2021). Absolute and relative variability changes of the resting state brain rhythms from childhood and adolescence to young adulthood. *Neuroscience Letters*, 749, 135747. doi:10.1016/j.neulet.2021.135747
- Appakaya, S. B., & Sankar, R. (2020). Parkinson's Disease Classification using Pitch Synchronous Speech Segments and Fine Gaussian Kernels based SVM. *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, (pg. 236-239). doi:10.1109/EMBC44109.2020.9176193
- Ariely, D., & Berns, G. S. (2010). Neuromarketing: the hope and hype of neuroimaging in business. *Nature reviews. Neuroscience*, 11(4), 284-292. doi:10.1038/nrn2795
- Arif, S., Arif, M., Munawar, S., Ayaz, Y., Khan, M., & Naseer, N. (2021). EEG Spectral Comparison Between Occipital and Prefrontal Cortices for Early Detection of Driver Drowsiness. *2021 International Conference on Artificial Intelligence and Mechatronics Systems (AIMS)*, 1-6. doi:10.1109/AIMS52415.2021.9466007.
- Arvaneh, M., Robertson, I. H., & Ward, T. E. (2019). A P300-Based Brain-Computer Interface for Improving Attention. *Frontiers in human neuroscience*, 12, 524. doi:10.3389/fnhum.2018.00524
- Asogbon, M. G., Huai, Y., Samuel, O. W., Jing, Z., Ma, Y., Liu, J., . . . Li, Y. (2023). Analysis of Artifactual Components Rejection Threshold towards Enhanced Characterization of Neural Activity in Post-Stroke Survivor. *2023 45th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, (pg. 1-5). doi:10.1109/EMBC40787.2023.10340688
- Assche, K., Zhang, Y., Ourak, M., Verschooten, E., Joris, P., & Poorten, E. (2023). Physiological Motion Compensation in Patch Clamping using Electrical Bio-impedance Sensing. *2023 International Symposium on Medical Robotics (ISMR)*, 1-7. doi:10.1109/ISMR57123.2023.10130269
- Aydemir, O., Öztürk, M., & Kayıkçıoğlu, T. (2011). Performance evaluation of five classification algorithms in low-dimensional feature vectors extracted from EEG

- signals. *34th International Conference on Telecommunications and Signal Processing (TSP)*, (pg. 403-407). doi:10.1109/TSP.2011.6043701
- Baltag, D. (1999). Modalități de stimulare în studiul potențialelor evocate vizuale [Stimulation modalities in the study of visual evoked potentials]. *Revista medico-chirurgicală a Societății de Medici și Naturaliști din Iași*(103), 29-32.
- Barry, R., Blasio, F., & Cave, A. (2014). Eyes-closed vs. eyes-open EEG in young and older adults. *International Journal of Psychophysiology*, 94(2), 236. doi:10.1016/j.ijpsycho.2014.08.915
- Bekiryazici, S., Demir, A., & Yilmaz, G. (2020). Feature Selection and Analysis EEG Signals with Sequential Forward Selection Algorithm and Different Classifiers. *2020 28th Signal Processing and Communications Applications Conference (SIU)*, (pg. 1-4). doi:10.1109/siu49456.2020.9302482
- Beniczky, S., & Schomer, D. L. (2020). Electroencephalography: basic biophysical and technological aspects important for clinical applications. *Epileptic Disorders*, 22(6), 697-715. doi:10.1684/epd.2020.1217
- Bensch, M., Karim, A. A., Mellinger, J., Hinterberger, T., Tangermann, M., Bogdan, M., . . . Birbaumer, N. (2007). Nessi: an EEG-controlled web browser for severely paralyzed patients. *Computational intelligence and neuroscience*, 017863. doi:10.1155/2007/71863
- Bianchi, L., Liti, C., & Piccialli, V. (2020). A New Early Stopping Method for P300 Spellers. *IEEE transactions on neural systems and rehabilitation engineering*, 27(8), 1635-1643. doi:10.1109/TNSRE.2019.2924080
- Birbaumer, N., Ghanayim, N., Hinterberger, T., Iversen, I., Kotchoubey, B., Kübler, A., . . . Flor, H. (1999). A spelling device for the paralysed. *Nature*, 398(6725), 297-298. doi:10.1038/18581
- Blankertz, B., Lemm, S., Treder, M., Haufe, S., & Müller, K. R. (2011). Single-trial analysis and classification of ERP components--a tutorial. *NeuroImage*, 56(2), 814-825. doi:10.1016/j.neuroimage.2010.06.048
- Blankertz, B., Müller, K. R., Krusienski, D. J., Schalk, G., Wolpaw, J. R., Schlögl, A., . . . Birbaumer, N. (2006). The BCI competition. III: Validating alternative approaches to actual BCI problems. *IEEE Engineering in Medicine and Biology Society*, 153-159.
- Bleichner, M., & Debener, S. (2019). Independent component decomposition of around ear EEG data to detect artifacts. *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, (pg. 3631-3634). doi:10.1109/SMC.2019.8914292
- Borra, D., Fantozzi, S., Bisi, M. C., & Magosso, E. (2023). Modulations of Cortical Power and Connectivity in Alpha and Beta Bands during the Preparation of Reaching Movements. *Sensors*, 23(7), 3530. doi:10.3390/s23073530
- Bostanov, V. (2004). BCI Competition 2003--Data sets Ib and Iib: feature extraction from event-related brain potentials with the continuous wavelet transform and the t-value scalogram. *IEEE Transactions on Biomedical engineering*, 51(6), 1057-1061. doi:10.1109/TBME.2004.826702

- Brienza, M., Davassi, C., & Mecarelli, O. (2019). Artifacts. În *Clinical Electroencephalography* (pg. 109-130). doi:10.1007/978-3-030-04573-9_8
- Browarska, N., & Stach, T. (2018). System to Communicate Disabled People with Environment Using Brain-Computer Interfaces. *Biomedical Engineering and Neuroscience. BCI 2018. Advances in Intelligent Systems and Computing*, 720, pg. 150-157. doi:10.1007/978-3-319-75025-5_14
- Bruni, V., Cardinali, M., & Vitulano, D. (2022). A Short Review on Minimum Description Length: An Application to Dimension Reduction in PCA. *Entropy*, 24(2), 269. doi:10.3390/e24020269
- Buch, E., Weber, C., Cohen, L. G., Braun, C., Dimyan, M. A., Ard, T., . . . Birbaumer, N. (2008). Think to move: a neuromagnetic brain-computer interface (BCI) system for chronic stroke. *Stroke*, 39(3), 910-917. doi:10.1161/STROKEAHA.107.505313
- Bu-Omer, H. M., Gofuku, A., Sato, K., & Miyakoshi, M. (2021). Parieto-Occipital Alpha and Low-Beta EEG Power Reflect Sense of Agency. *11(6)*, 743. doi:10.3390/brainsci11060743
- Buzsáki, G., Anastassiou, C., & Koch, C. (2012). The origin of extracellular fields and currents — EEG, ECoG, LFP and spikes. *Nature reviews. Neuroscience*, 13(6). doi:10.1038/nrn3241
- Camós-Vidal, R., & Rosell-Ferrer, J. (2023). Ultra-High Input Impedance Buffer for Dry or Capacitive Electrodes: Design and Characterization for Industry. *IEEE Access*, 11, 68316-68323. doi:10.1109/ACCESS.2023.3292304
- Cantillo-Negrete, J., Carino-Escobar, R., Leyva-Martinez, I., Barrera-Ortiz, A., Rodriguez-Barragan, M., Mendoza-Montoya, O., & Antelis, J. (2023). Upper Limb Recovery in Cervical Spinal Cord Injury After a Brain-Computer Interface Controlled Functional Electrical Stimulation Intervention. *Journal of Medical and Biological Engineering*, 43, 522-531. doi:10.1007/s40846-023-00824-w
- Castellini, C. (2022). Peripheral Nervous System Interfaces: Invasive or Non-invasive? *Frontiers in Neurorobotics*, 16, 846866. doi:10.3389/fnbot.2022.846866
- Chambayil, B., Singla, R., & Jha, R. (2010). Virtual keyboard BCI using Eye blinks in EEG. *2010 IEEE 6th International Conference on Wireless and Mobile Computing, Networking and Communications*, (pg. 466-470). doi:10.1109/WIMOB.2010.5645025
- Chan, A. T., Quiroz, J. C., Dascalu, S., & Harris, F. C. (2015). An overview of brain computer interfaces. *Proceedings of the 30th International Conference on Computers and Their Applications, CATA 2015*, (p. 22).
- Chang, C. W., Lo, Y. C., Lin, S. H., Yang, S. H., Lin, H. C., Lin, T. C., . . . Chen, Y. Y. (2019). Modulation of Theta-Band Local Field Potential Oscillations Across Brain Networks With Central Thalamic Deep Brain Stimulation to Enhance Spatial Working Memory. *Frontiers in neuroscience*, 13, 1269. doi:10.3389/fnins.2019.01269
- Chang, C. Y., Hsu, S. H., Pion-Tonachini, L., & Jung, T. P. (2020). Evaluation of Artifact Subspace Reconstruction for Automatic Artifact Components Removal in Multi-

- Channel EEG Recordings. *IEEE Transactions on Biomedical Engineering*, 67(4), 1114-1121. doi:10.1109/TBME.2019.2930186
- Chee, L., Valle, G., Preatoni, G., Basla, C., Marazzi, M., & Raspopovic, S. (2022). Cognitive benefits of using non-invasive compared to implantable neural feedback. *12*, 16696. doi:10.1038/s41598-022-21057-y
- Chen, R., Xu, G., Zheng, Y., Yao, P., Zhang, S., Yan, L., & Zhang, K. (2021). Waveform feature extraction and signal recovery in single-channel TVEP based on Fitzhugh-Nagumo stochastic resonance. *Journal of neural engineering*, 18(5). doi:10.1088/1741-2552/ac2459
- Chen, Y. H., & Wang, S. P. (2020). Low-Cost Implementation of Independent Component Analysis for Biomedical Signal Separation Using Very-Large-Scale Integration. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 67(12), 3437-3441. doi:10.1109/TCSII.2020.2999573
- Chen, Z., Wang, Y., & Song, Z. (2021). Classification of Motor Imagery Electroencephalography Signals Based on Image Processing Method. *Sensors*, 21(14), 4646. doi:10.3390/s21144646
- Chholak, P., Niso, G., Maksimenko, V., Kurkin, S., Frolov, N., Pitsik, E., . . . Pisarchik, A. (2019). Visual and kinesthetic modes affect motor imagery classification in untrained subjects. *Scientific Reports*, 9, 9838. doi:10.1038/s41598-019-46310-9
- Choi, J., Kim, K., Lee, J., Lee, S., & Kim, H. (2020). Robust Semi-synchronous BCI Controller for Brain-Actuated Exoskeleton System. *2020 8th International Winter Conference on Brain-Computer Interface (BCI)*, (pg. 1-3). doi:10.1109/BCI48061.2020.9061658
- Cincotti, F., Mattia, D., Aloise, F., Bufalari, S., Schalk, G., Oriolo, G., . . . Babiloni, F. (2008). Non-invasive brain-computer interface system: towards its application as assistive technology. *Brain research bulletin*, 75(6), 796-803. doi:10.1016/j.brainresbull.2008.01.007
- Cipresso, P., Carelli, L., Solca, F., Meazzi, D., Meriggi, P., Poletti, B., . . . Riva, G. (2012). The use of P300-based BCIs in amyotrophic lateral sclerosis: from augmentative and alternative communication to cognitive assessment. *Brain and behavior*, 2(4), 479-498. doi:10.1002/brb3.57
- Coelli, S., Calcagno, A., Cassani, C. M., Temporiti, F., Reali, P., Gatti, R., & Bianchi, A. M. (2024). Selecting methods for a modular EEG pre-processing pipeline: An objective comparison. *Biomedical Signal Processing and Control*, 90, 105830. doi:10.1016/j.bspc.2023.105830
- Connelly, A., Li, P., Rangpong, P., Wilairasitporn, T., & Yagi, T. (2023). Effects of Trial-Adjusted Neurofeedback Training on Motor-Imagery Based Brain-Computer Interface Performance. *2023 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, (pg. 1-5). doi:10.1109/MeMeA57477.2023.10171918

- Constantinescu, M., Orîndaru, A., Pachițanu, A., Rosca, L., Căescu, Ș., & Orzan, M. (2019). Attitude Evaluation on Using the Neuromarketing Approach in Social Media: Matching Company's Purposes and Consumer's Benefits for Sustainable Business Growth. *Sustainability*, *11*(24), 7094. doi:10.3390/su11247094
- Cook, I. A., Warren, C., Pajot, S. K., Schairer, D., & Leuchter, A. F. (2011). Regional brain activation with advertising images. *Journal of Neuroscience, Psychology, and Economics*, *4*(3), 147-160. doi:10.1037/a0024809
- Courchaine, C., Tabassum, T., Wade, C., & Sethi, R. (2023). Explainable e-Discovery (XeD) Using an Interpretable Fuzzy ARTMAP Neural Network for Technology-Assisted Review. *2023 IEEE International Conference on Big Data (BigData)*, (pg. 2761-2766). doi:10.1109/BigData59044.2023.10386391
- Cover, T. (1965). Geometrical and Statistical Properties of Systems of Linear Inequalities with Applications in Pattern Recognition. *IEEE Transactions on Electronic Computers*, *EC-14*(3), 326-334. doi:10.1109/PGEC.1965.264137
- Dash, D., Ferrari, P., & Wang, J. (2020). Decoding Speech Evoked Jaw Motion from Non-invasive Neuromagnetic Oscillations. *2020 International Joint Conference on Neural Networks (IJCNN)*, 1-8. doi:10.1109/IJCNN48605.2020.9207448
- Dash, D., Ferrari, P., Heitzman, D., & Wang, J. (2019). Decoding Speech from Single Trial MEG Signals Using Convolutional Neural Networks and Transfer Learning. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, (pg. 5531-5535). doi:10.1109/EMBC.2019.8857874
- Dash, S., Verma, S., Kavita, Bevinakoppa, S., Wozniak, M., Shafi, J., & Ijaz, M. (2022). Guidance Image-Based Enhanced Matched Filter with Modified Thresholding for Blood Vessel Extraction. *Symmetry*, *14*(2), 194. doi:10.3390/sym14020194
- Daud, S., & Sudirman, R. (2022). Wavelet Based Filters for Artifact Elimination in Electroencephalography Signal: A Review. *Ann Biomed Eng*, *50*, 1271-1291. doi:10.1007/s10439-022-03053-5
- De Wit, B., Badcock, N. A., Grootswagers, T., Hardwick, K., Teichmann, L., Wehrman, J., . . . Kaplan, D. M. (2017). Neurogaming Technology Meets Neuroscience Education: A Cost-Effective, Scalable, and Highly Portable Undergraduate Teaching Laboratory for Neuroscience. *Journal of Undergraduate Neuroscience Education*, *15*(2), A104-A109.
- Delorme, A., Truong, D., Martinez-Cancino, R., Pernet, C., Sivagnanam, S., Yoshimoto, K., . . . Makeig, S. (2021). Tools for Importing and Evaluating BIDS-EEG Formatted Data. *2021 10th International IEEE/EMBS Conference on Neural Engineering (NER)*, (pg. 210-213). doi:10.1109/NER49283.2021.9441399.
- Denoeux, T. (1995). A k-nearest neighbor classification rule based on Dempster-Shafer theory. *IEEE Transactions on Systems, Man, and Cybernetics*, *25*(5), 804-813. doi:10.1109/21.376493

- Dimigen, O., & Ehinger, B. V. (2021). Regression-based analysis of combined EEG and eye-tracking data: Theory and applications. *Journal of vision*, 21(1), 3-3. doi:10.1167/jov.21.1.3
- Do, H., Hoang, H., Nguyen, N., An, A., Chau, H., Khuu, Q., . . . Ha, H. (2023). Intermediate effects of mindfulness practice on the brain activity of college students: An EEG study. *IBRO Neuroscience Reports*, 14, 308-319. doi:10.1016/j.ibneur.2023.03.003
- Dora, C., & Biswal, P. K. (2019). Efficient detection and correction of variable strength ECG artifact from single channel EEG. *Biomedical Signal Processing and Control*, 50, 168-177. doi:10.1016/j.bspc.2019.01.023
- Dudani, S. (1976). The Distance-Weighted k-Nearest-Neighbor Rule. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-6(4), 325-327. doi:10.1109/TSMC.1976.5408784
- Emotiv. (2022). Preluat de pe Everything you need to know about reference sensors of EMOTIV hardware: <https://www.emotiv.com/knowledge-base/everything-you-need-to-know-about-reference-sensors-of-emotiv-hardware/>
- Emotiv. (2023). Preluat pe 09 10, 2023, de pe <http://www.emotiv.com>
- Eva, O., & Lazar, A. (2018). An Amplitude Modulation of Cerebral Rhythms based Method in a Motor Task BCI Paradigm. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 9(9), 26-31. doi:10.14569/IJACSA.2018.090904
- Farabbi, A., Figueiredo, P., Ghiringhelli, F., Mainardi, L., Sanches, J. M., Moreno, P., . . . Vourvopoulos, A. (2023). Investigating the impact of visual perspective in a motor imagery-based brain-robot interaction: A pilot study with healthy participants. *Frontiers in Neuroergonomics*, 1080794. doi:10.3389/fnrgo.2023.1080794
- Farwell, L. A., & 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. doi:10.1016/0013-4694(88)90149-6
- Fazel-Rezai, R., & Abhari, K. (2009). A region-based P300 speller for brain-computer interface. *Canadian Journal of Electrical and Computer Engineering*, 34(3), 81-85. doi:10.1109/CJECE.2009.5443854
- Fedosov, N., Levadny, I., Dmitriev, A., & Nikolaev, A. (2020). Independent Component Analysis for Different Movements Detection in BCI Application Based on Sensorimotor Rhythms. *2020 Ural Symposium on Biomedical Engineering, Radioelectronics and Information Technology (USBREIT)*, (pg. 69-72). doi:10.1109/USBREIT48449.2020.9117785
- Felzer, T., & Freisleben, B. (2003). Analyzing EEG signals using the probability estimating guarded neural classifier. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(4), 361-371. doi:10.1109/TNSRE.2003.819785
- Finke, A., Lenhardt, A., & Ritter, H. (2009). The MindGame: a P300-based brain-computer interface game. *Neural networks*, 22(9), 1329-1333. doi:10.1016/j.neunet.2009.07.003

- Flanagan, K., & Saikia, M. J. (2023). Consumer-Grade Electroencephalogram and Functional Near-Infrared Spectroscopy Neurofeedback Technologies for Mental Health and Wellbeing. *Sensors*, 23(20), 8432. doi:10.3390/s23208482
- Floreani, E. D., Rowley, D., Kelly, D., Kinney-Lang, E., & Kirton, A. (2022). On the feasibility of simple brain-computer interface systems for enabling children with severe physical disabilities to explore independent movement. *Frontiers in human neuroscience*, 16, 1007199. doi:10.3389/fnhum.2022.1007199
- FUGA - Fun of Gaming. (2006). Preluat de pe Fun of gaming: Measuring the human experience of media enjoyment. Available online:: <http://fuga.aalto.fi/>
- Galán, F., Nuttin, M., Lew, E., Ferrez, P. W., Vanacker, G., Philips, J., & Millán, J. (2008). A brain-actuated wheelchair: asynchronous and non-invasive Brain-computer interfaces for continuous control of robots. *Clinical neurophysiology*, 119(9), 2159-2169. doi:10.1016/j.clinph.2008.06.001
- Gamage, T. A., Kalansooriya, L. P., & Sandamali, E. R. (2022). An Emotion Classification Model for Driver Emotion Recognition Using Electroencephalography (EEG). *2022 International Research Conference on Smart Computing and Systems Engineering (SCSE)*, 5, pg. 76-82. doi:10.1109/SCSE56529.2022.9905108
- Georgiadis, K., Laskaris, N., Nikolopoulos, S., & Kompatsiaris, I. (2020). BCIs using motor imagery and sensorimotor rhythms. În S. Nikolopoulos, C. Kumar, & I. Kompatsiaris, *Signal Processing to Drive Human-Computer Interaction: EEG and eye-controlled interfaces* (pg. 185-210). doi:10.1049/pbce129e_ch9
- Ghaheri, A., Shoar, S., Naderan, M., & Hoseini, S. (2015). The Applications of Genetic Algorithms in Medicine. *Oman Medical Journal*, 30(6), 406-416. doi:10.5001/omj.2015.82
- Ghumman, M. K., Singh, S., Singh, N., & Jindal, B. (2021). Optimization of parameters for improving the performance of EEG-based BCI system. *Journal of Reliable Intelligent Environments*, 7, 145-156. doi:10.1007/s40860-020-00117-y
- Gil Ávila, C., Bott F., S., Tiemann L, H. V., M., N. M., Zebhauser P. T., G. J., & M., P. (2023). DISCOVER-EEG: an open, fully automated EEG pipeline for biomarker discovery in clinical neuroscience. *Scientific Data*. doi:10.1038/s41597-023-02525-0
- Giudice, M., Varone, G., Ieracitano, C., Mammone, N., Bruna, A., Tomaselli, V., & Morabito, F. (2020). 1D Convolutional Neural Network approach to classify voluntary eye blinks in EEG signals for BCI applications. *2020 International Joint Conference on Neural Networks (IJCNN)*, (pg. 1-7). doi:10.1109/IJCNN48605.2020.9207195
- Grassini, S., Revonsuo, A., Castellotti, S., Petrizzo, I., Benedetti, V., & Koivisto, M. (2019). Processing of natural scenery is associated with lower attentional and cognitive load compared with urban ones. *Journal of environmental psychology*, 62, 1-11. doi:10.1016/j.jenvp.2019.01.007

- Grobbelaar, M., Phadikar, S., Ghaderpour, E., Struck, A., Sinha, N., Ghosh, R., & Ahmed, M. (2022). A Survey on Denoising Techniques of Electroencephalogram Signals Using Wavelet Transform. *Signals*, 3(3), 577-586. doi:10.3390/signals3030035
- Guerrero, M., Parada, J., & Espitia, H. (2021). EEG signal analysis using classification techniques: Logistic regression, artificial neural networks, support vector machines, and convolutional neural networks. *Heliyon*, 7(6). doi:10.1016/j.heliyon.2021.e07258
- Guharoy, R., Jana, N., & Biswas, S. (2023). Detection of Epilepsy Seizure using Different Dimensionality Reduction Techniques and Machine Learning on Transform Domain. *ArXiv, abs/2302.12012*. doi:10.48550/arXiv.2302.12012
- Gulino, M., Kim, D., Pané, S., Santos, S. D., & Pêgo, A. P. (2019). Tissue Response to Neural Implants: The Use of Model Systems Toward New Design Solutions of Implantable Microelectrodes. *Frontiers in neuroscience*, 13, 689. doi:10.3389/fnins.2019.00689
- Gupta, A., Vardalakis, N., & Wagner, F. B. (2023). Neuroprosthetics: from sensorimotor to cognitive disorders. *Communications biology*, 6(1), 14. doi:10.1038/s42003-022-04390-w
- Haddad, N., Derkach, M., Dmitriev, A., Sergeev, I., & Shchukin, S. (2021). Selection of P300 signal features based on machine learning and the Morlet wavelet use for BCI applications. *Biomedical Radioelectronics*, 5. doi:10.18127/j15604136-202105-03
- Han, C., Kim, Y., Kim, D., Kim, S., Nenadic, Z., & Im, C. (2019). Electroencephalography-based endogenous brain-computer interface for online communication with a completely locked-in patient. *J Neuroeng Rehabil*, 16(1), 18. doi:10.1186/s12984-019-0493-0
- Han, C., Shapley, R., & Xing, D. (2022). Gamma rhythms in the visual cortex: functions and mechanisms. *Cognitive neurodynamics*, 16(4), 745-756. doi:10.1007/s11571-021-09767-x
- Haq, A., Li, J., Memon, M., Hunain Memon, M., Khan, J., & Marium, S. (2019). Heart Disease Prediction System Using Model Of Machine Learning and Sequential Backward Selection Algorithm for Features Selection. *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)*, (pg. 1-4). doi:10.1109/I2CT45611.2019.9033683
- Harding, C. D., Guillaumin, M. C., Krone, L. B., Kahn, M. C., Blanco-Duque, C., Mikutta, C., & Vyazovskiy, V. V. (2023). Detection of neuronal OFF periods as low amplitude neural activity segments. *BMC neuroscience*, 24(1), 13. doi:10.1186/s12868-023-00780-w
- Hasslinger, J., Meregalli, M., & Bölte, S. (2022). How standardized are "standard protocols"? Variations in protocol and performance evaluation for slow cortical potential neurofeedback: A systematic review. *Frontiers in human neuroscience*, 16, 887504. doi:10.3389/fnhum.2022.887504

- Herrero, M. A., Gallego, R., Ramos, M., Lopez, J. M., de Arcas, G., & Gonzalez-Nieto, D. (2021). Sleep–Wake Cycle and EEG–Based Biomarkers during Late Neonate to Adult Transition. *Brain sciences*, *11*(3), 298. doi:10.3390/brainsci11030298
- Heunis, C. (2016). Export and analysis of emotiv insight EEG. doi:10.13140/RG.2.1.3081.4326
- Hinterberger, T., Schmidt, S., Kamei, T., & Walach, H. (2014). Decreased electrophysiological activity represents the conscious state of emptiness in meditation. *Frontiers in psychology*, *5*, 99. doi:10.3389/fpsyg.2014.00099
- Hinterberger, T., Walter, N., Doliwa, C., & Loew, T. (2019). The brain's resonance with breathing-decelerated breathing synchronizes heart rate and slow cortical potentials. *Journal of breath research*, *13*(4), 046003. doi:10.1088/1752-7163/ab20b2
- Hochberg, L. R., Serruya, M. D., Friehs, G. M., Mukand, J. A., Saleh, M., Caplan, A. H., . . . Donoghue, J. P. (2006). Neuronal ensemble control of prosthetic devices by a human with tetraplegia. *Nature*, *442*, 164-171. doi:10.1038/nature04970
- Holtze, B., Rosenkranz, M., Jaeger, M., Debener, S., & Mirkovic, B. (2022). Ear-EEG measures of auditory attention to continuous speech. *Frontiers in Neuroscience*, *15*-28. doi:10.3389/fnins.2022.869426
- Hou, H., Sun, B., & Meng, Q. (2019). Slow cortical potential signal classification using concave-convex feature. *Journal of neuroscience methods*, *324*, 108303. doi:10.1016/j.jneumeth.2019.05.012
- Hu, X. L., Tong, K. Y., Li, R., Chen, M., Xue, J. J., Ho, S. K., & Chen, P. N. (2011). Post-stroke wrist rehabilitation assisted with an intention-driven functional electrical stimulation (FES)-robot system. *2011 IEEE International Conference on Rehabilitation Robotics*, (pg. 1-6). doi: 10.1109/ICORR.2011.5975424
- Hurst, A. J., & Boe, S. G. (2022). Imagining the way forward: A review of contemporary motor imagery theory. *Frontiers in human neuroscience*, *16*, 1033493. doi:10.3389/fnhum.2022.1033493
- Iturrate, I., Antelis, J., Kübler, A., & Minguez, J. (2009). A Noninvasive Brain-Actuated Wheelchair Based on a P300 Neurophysiological Protocol and Automated Navigation. *IEEE Transactions on Robotics*, *25*(3), 614-627. doi:10.1109/TRO.2009.2020347
- Jiang, X., Bian, G. B., & Tian, Z. (2019). Removal of Artifacts from EEG Signals: A Review. *Sensors*, *19*(5), 987. doi:10.3390/s19050987
- Jones, R. (2005). Mind control. *Nat Rev Neurosci*, *6*(90). doi:10.1038/nrn1610
- Jósko, A. (2016). Electrocardiographic signals Wavelet Transform – identification and classification properties. *Przegląd Elektrotechniczny*, *1*, 53-56. doi:10.15199/48.2016.11.13
- Kabir, E., Shahid, M., & Rokibul, M. (2017). Developing Diabetes Disease Classification Model using Sequential Forward Selection Algorithm. *International Journal of Computer Applications*, *180*, 1-6. doi:10.5120/IJCA2017916018

- Kaeseler, R. L., Johansson, T. W., Struijk, L. N., & Jochumsen, M. (2022). Feature and Classification Analysis for Detection and Classification of Tongue Movements From Single-Trial Pre-Movement EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30, 678-687. doi:10.1109/TNSRE.2022.3157959
- Kaiser, J., Kübler, A., Hinterberger, T., Neumann, N., & Birbaumer, N. (2002). A non-invasive communication device for the paralyzed. *Minimally invasive neurosurgery : MIN*, 45(1), 19-23. doi:10.1055/s-2002-23578
- Kaneko, N., Yokoyama, H., Masugi, Y., Watanabe, K., & Nakazawa, K. (2021). Phase dependent modulation of cortical activity during action observation and motor imagery of walking: An EEG study. *NeuroImage*, 117486. doi:10.1016/j.neuroimage.2020.117486
- Kanoga, S., Hoshino, T., & Asoh, H. (2020). Independent Low-Rank Matrix Analysis-Based Automatic Artifact Reduction Technique Applied to Three BCI Paradigms. *Frontiers in human neuroscience*, 14, 173. doi:10.3389/fnhum.2020.00173
- Karim, A. A., Hinterberger, T., Richter, J., Mellinger, J., Neumann, N., Flor, H., . . . Birbaumer, N. (2006). Neural internet: Web surfing with brain potentials for the completely paralyzed. *Neurorehabilitation and neural repair*, 20(4), 508-515. doi:10.1177/1545968306290661
- Katoch, S., Chauhan, S., & Kumar, V. (2021). A review on genetic algorithm: past, present, and future. *Multimedia Tools and Applications*, 80, 8091-8126. doi:10.1007/s11042-020-10139-6
- Kibriya, H., Amin, R., Alshehri, A. H., Masood, M., Alshamrani, S. S., & Alshehri, A. (2022). A Novel and Effective Brain Tumor Classification Model Using Deep Feature Fusion and Famous Machine Learning Classifiers. *Computational intelligence and neuroscience*, 7897669. doi:10.1155/2022/7897669
- Kim, H., Kim, E., Choi, C., & Yeo, W. H. (2022). Advances in Soft and Dry Electrodes for Wearable Health Monitoring Devices. *Micromachines*, 13(4)(629). doi:10.3390/mi13040629
- Kim, H., Luo, J., Chu, S., Cannard, C., Hoffmann, S., & Miyakoshi, M. (2023). ICA's bug: How ghost ICs emerge from effective rank deficiency caused by EEG electrode interpolation and incorrect re-referencing. *Frontiers in Signal Processing*, 3, 1064138. doi:10.3389/frsip.2023.1064138
- Kirasirova, L., Bulanov, V., Ossadtchi, A., Kolsanov, A., Pyatin, V., & Lebedev, M. (2020). A P300 Brain-Computer Interface With a Reduced Visual Field. *Frontiers in neuroscience*, 14, 604629. doi:10.3389/fnins.2020.604629
- Kittilstved, T., Reilly, K. J., Harkrider, A. W., Casenhiser, D., Thornton, D., Jenson, D. E., . . . Saltuklaroglu, T. (2018). The Effects of Fluency Enhancing Conditions on Sensorimotor Control of Speech in Typically Fluent Speakers: An EEG Mu Rhythm Study. *Frontiers in human neuroscience*, 12, 126. doi:10.3389/fnhum.2018.00126
- Kostyalik, D., Kelemen, K., Lendvai, B., Hernádi, I., Román, V., & Lévy, G. (2022). Response-related sensorimotor rhythms under scopolamine and MK-801 exposures

- in the touchscreen visual discrimination test in rats. *Scientific reports*, 12(1), 8168. doi:10.1038/s41598-022-12146-z
- Kothe, C. A. (2016). *US, California Brevet nr. US20160113587A1*.
- Koyun, A. H., Stock, A. K., & Beste, C. (2023). Neurophysiological mechanisms underlying the differential effect of reward prospect on response selection and inhibition. *Scientific Reports*. doi:10.1038/s41598-023-37524-z
- Krusienski, D., Schalk, G., McFarland, D., & Wolpaw, J. (2007). A μ -Rhythm Matched Filter for Continuous Control of a Brain-Computer Interface. *IEEE Transactions on Biomedical Engineering*, 54(2), 273-280. doi:10.1109/TBME.2006.886661
- Kübler, A., & Birbaumer, N. (2008). Brain-computer interfaces and communication in paralysis: extinction of goal directed thinking in completely paralysed patients? *Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology*, 119(11), 2658-2666. doi:10.1016/j.clinph.2008.06.019
- Kübler, A., Furdea, A., Halder, S., Hammer, E. M., Nijboer, F., & Kotchoubey, B. (2009). A brain-computer interface controlled auditory event-related potential (p300) spelling system for locked-in patients. *Annals of the New York Academy of Sciences*, 1157, 90-100. doi:10.1111/j.1749-6632.2008.04122.x
- Kumar, A., Kannur, A., Akash, C. K., PS, V. K., Kushal, S., & Anwar, C. S. (2022). Learning Brain Computer Interface model for Amyotrophic Lateral Sclerosis (ALS) people using Random Forest – Linear Discriminant Analysis (RF-LDA) Algorithm. *2022 IEEE 19th India Council International Conference (INDICON)*, (pg. 1-10). doi:10.1109/INDICON56171.2022.10039916
- Kužilek, J. (2013). *Independent Component Analysis: Applications in ECG signal processing*. Ph.D. thesis, Czech Technical University.
- Kwon, M., Cho, H., Won, K., Ahn, M., & Jun, S. (2018). Event-Related Desynchronization (ERD) May Not be Correlated with Motor Imagery BCI Performance. *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, (pg. 1133-1137). doi:10.1109/SMC.2018.00200
- Kwon, S., Kim, J., & Kim, T. (2023). Neuropsychological activations and networks while performing visual and kinesthetic motor imagery. *Brain Sciences*, 983. doi:10.3390/brainsci13070983
- Kyriaki, K., Koukopoulos, D., & Fidas, C. A. (2024). A Comprehensive Survey of EEG Preprocessing Methods for Cognitive Load Assessment. *IEEE Access*, 12, pg. 23466-23489. doi:10.1109/ACCESS.2024.3360328
- Ladouce, S., Darnet, L., Torre Tresols, J., Velut, S., Ferraro, G., & Dehais, F. (2022). Improving user experience of SSVEP BCI through low amplitude depth and high frequency stimuli design. *Scientific reports*, 12(1), 8865. doi:10.1038/s41598-022-12733-0
- Lai, C., Ibrahim, H., Abdullah, M., Abdullah, J., Suandi, S., & Azman, A. (2019). Current Practical Applications of Electroencephalography (EEG). *Journal of Computational and Theoretical Nanoscience*, 16, 4943-4953. doi:10.1166/jctn.2019.8546

- Lalor, E. C., Kelly, S. P., Finucane, C., Burke, R., Smith, R., Reilly, R. B., & Mcdarby, G. (2005). Steady-State VEP-Based Brain-Computer Interface Control in an Immersive 3D Gaming Environment. *EURASIP Journal on Advances in Signal Processing*, 1-9. doi:10.1155/ASP.2005.3156
- Lazarou, I., Nikolopoulos, S., Petrantonakis, P., Kompatsiaris, I., & Tsolaki, M. (2018). EEG-Based Brain-Computer Interfaces for Communication and Rehabilitation of People with Motor Impairment: A Novel Approach of the 21 st Century. *Frontiers in Human Neuroscience*, 12(14). doi:10.3389/fnhum.2018.00014
- Lee, C., Chuang, C., Yeng, C., Chen, Y., & Lin, B. (2017). Noise Suppression by Minima Controlled Recursive Averaging for SSVEP-Based BCIs With Single Channel. *IEEE Signal Processing Letters*, 24(12), 1783-1787. doi:10.1109/LSP.2017.2761193
- Lee, D., Ahn, H., Jeong, J., & Lee, S. (2021). Design of an EEG-based Drone Swarm Control System using Endogenous BCI Paradigms. *2021 9th International Winter Conference on Brain-Computer Interface (BCI)*, (pg. 1-5). doi:10.1109/BCI51272.2021.9385356
- Lee, M., Akshay, P., Yuchen, K., Hairston, W., & Cauwenberghs, G. (2022). Characterization of Ag/AgCl Dry Electrodes for Wearable Electrophysiological Sensing. *Frontiers in Electronics*, 2. doi:10.3389/felec.2021.700363
- Li, B., Liu, J., & Cao, J. (2023). Robotic Motion Control via P300-based Brain-Computer Interface System. *INTERNATIONAL JOURNAL OF COMPUTERS & TECHNOLOGY*. doi:10.24297/ijct.v23i.9538
- Li, F., Chen, B., Li, H., Zhang, T., Wang, F., Jiang, Y., . . . Xu, P. (2016). The Time-Varying Networks in P300: A Task-Evoked EEG Study. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 24(7), 725-733. doi:10.1109/TNSRE.2016.2523678
- Li, M., Liao, S., Pun, S., & Chen, F. (2023). Effects of EEG Analysis Window Location on Classifying Spoken Mandarin Monosyllables. *2023 11th International IEEE/EMBS Conference on Neural Engineering (NER)*, (pg. 1-4). doi:10.1109/NER52421.2023.10123748
- Lim, S., Yeo, M., & Yoon, G. (2019). Comparison between Concentration and Immersion Based on EEG Analysis. *Sensors*, 19(7), 1669. doi:10.3390/s19071669
- Lin, M. H., Liran, O., Bauer, N., & Baker, T. E. (2022). Scalp recorded theta activity is modulated by reward, direction, and speed during virtual navigation in freely moving humans. *Scientific reports*, 12(1)(2041). doi:10.1038/s41598-022-05955-9
- Littmann, L. (2021). Electrocardiographic artifact. *Journal of Electrocardiology*, 64, 23-29. doi:10.1016/j.jelectrocard.2020.11.006
- Liu, G., Huang, G., Meng, J., Zhang, D., & Zhu, X. (2010). Improved GMM with parameter initialization for unsupervised adaptation of Brain-Computer interface. *International Journal for Numerical Methods in Biomedical Engineering*, 26, 681-691. doi:10.1002/cnm.1362

- Liu, H., Jiang, H., & Zheng, R. (2016). The Hybrid Feature Selection Algorithm Based on Maximum Minimum Backward Selection Search Strategy for Liver Tissue Pathological Image Classification. *Computational and Mathematical Methods in Medicine*, 1-9. doi:10.1155/2016/7369137
- Liu, J., Shen, H., Wang, D., Kang, Y., & Tian, Q. (2021). Unsupervised Domain Adaptation with Dynamics-Aware Rewards in Reinforcement Learning. *Neural Information Processing Systems*, 34, 28784-28797. doi:10.48550/arXiv.2110.12997
- Liu, M., Kuo, C. C., & Chiu, A. W. (2011). tatistical threshold for nonlinear Granger Causality in motor intention analysis. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 5036-5039. doi:10.1109/IEMBS.2011.6091247
- Long, J., Li, Y., Wang, H., Yu, T., Pan, J., & Li, F. (2012). A hybrid brain computer interface to control the direction and speed of a simulated or real wheelchair. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 20, pg. 720-729. doi:10.1109/TNSRE.2012.2197221
- Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., & Yger, F. (2018). A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *Journal of neural engineering*, 15(3), 031005. doi:10.1088/1741-2552/aab2f2
- Loukas, A. (2017). How Close Are the Eigenvectors of the Sample and Actual Covariance Matrices? *Proceedings of the 34th International Conference on Machine Learning*, 70, pg. 2228-2237.
- Ma, D., Yuan, S., Shang, J., Liu, J., Dai, L., Kong, X., & Xu, F. (2021). The Automatic Detection of Seizure Based on Tensor Distance And Bayesian Linear Discriminant Analysis. *International journal of neural systems*, 31(5), 2150006. doi:10.1142/S0129065721500064
- Ma, T., Li, Y., Huggins, J. E., Zhu, J., & Kang, J. (2022). Bayesian Inferences on Neural Activity in EEG-Based Brain-Computer Interface. *Journal of the American Statistical Association*, 117, 1122-1133. doi:10.1080/01621459.2022.2041422
- Maddirala, A. K., & Veluvolu, K. C. (2022). SSA with CWT and k-Means for Eye-Blink Artifact Removal from Single-Channel EEG Signals. *Sensors*, 22(3), 931. doi:10.3390/s22030931
- Mahmood, D., Nisar, H., & Voon, Y. (2021). Removal of Physiological Artifacts from Electroencephalogram Signals: A Review and Case Study. *021 IEEE 9th Conference on Systems, Process and Control (ICSPC 2021)*, (pg. 141-146). doi:10.1109/ICSPC53359.2021.9689094
- Maiseli, B., Abdalla, A., Massawe, L., Mbise, M., Mkocha, K., Nassor, A., . . . Kimambo, S. (2023). Brain-computer interface: trend, challenges, and threats. *Brain Informatics*, 10(1)(20). doi:10.1186/s40708-023-00199-3

- Mangia, A. L., Ursino, M., Lannocca, M., & Cappello, A. (2017). Transcallosal Inhibition during Motor Imagery: Analysis of a Neural Mass Model. *Frontiers in computational neuroscience*, *11*, 57. doi:10.3389/fncom.2017.00057
- Martínez-Cancino, R., Delorme, A., Truong, D., Artoni, F., Kreutz-Delgado, K., Sivagnanam, S., . . . Makeig, S. (2021). The open EEGLAB portal Interface: High-Performance computing with EEGLAB. *NeuroImage*, *224*, 116778. doi:10.1016/j.neuroimage.2020.116778
- Mason, S., & Birch, G. (2003). A general framework for brain-computer interface design. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, *11*(1), 70-85. doi:10.1109/TNSRE.2003.810426
- Matsuda, Y., & Yamaguchi, K. (2022). Unique estimation in EEG analysis by the ordering ICA. *PloS one*, *17*(10), e0276680. doi:10.1371/journal.pone.0276680
- McFarland, D. J., & Wolpaw, J. R. (2005). Sensorimotor rhythm-based brain-computer interface (BCI): feature selection by regression improves performance. *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, *13*(3), 372-379. doi:10.1109/TNSRE.2005.848627
- Middendorf, M., McMillan, G., Calhoun, G., & Jones, K. (2000). Brain-computer interfaces based on the steady-state visual-evoked response. *IEEE Transactions on Rehabilitation Engineering*, *8*(2), 211-214. doi:10.1109/86.847819
- Milanés-Hermosilla, D., Trujillo-Codorniú, R., Lamar-Carbonell, S., Sagaró-Zamora, R., Tamayo-Pacheco, J. J., Villarejo-Mayor, J. J., & Delisle-Rodríguez, D. (2023). Robust Motor Imagery Tasks Classification Approach Using Bayesian Neural Network. *Sensors*, *23*(2), 703. doi:10.3390/s23020703
- Millán, J., & Mouriño, J. (2003). Asynchronous BCI and local neural classifiers: an overview of the Adaptive Brain Interface project. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, *11*(2), 159-161. doi:10.1109/TNSRE.2003.814435
- Millán, J., Renkens, F., Mouriño, J., & Gerstner, W. (2004). Noninvasive brain-actuated control of a mobile robot by human EEG. *IEEE Transactions on Biomedical Engineering*, *51*(6), 1026-1033. doi:10.1109/TBME.2004.827086
- Milosevic, M., Marquez-Chin, C., Masani, K., Hirata, M., Nomura, T., Popovic, M. R., & Nakazawa, K. (2020). Why brain-controlled neuroprosthetics matter: mechanisms underlying electrical stimulation of muscles and nerves in rehabilitation. *Biomedical engineering online*, *19*(1). doi:10.1186/s12938-020-00824-w
- Milsap, G., & Peranich, P. (2021). Technical Note: A Low-Cost Research Platform for Brain-Computer-Interface Applications in Mixed Reality. *2021 10th International IEEE/EMBS Conference on Neural Engineering (NER)*, (pg. 515-518). doi:10.1109/NER49283.2021.9441260
- Mina, F., Attina, V., Duroc, Y., Veuillet, E., Truy, E., & Thai-Van, H. (2017). Auditory steady state responses and cochlear implants: Modeling the artifact-response mixture in the

- perspective of denoising. *PloS one*, 12(3), e0174462. doi:10.1371/journal.pone.0174462
- Mishra, A., & Bhusnur, S. (2022). A New Adaptive Modeling and Denoising of Real ECG signal. *2022 IEEE 3rd Global Conference for Advancement in Technology (GCAT)*, (pg. 1-6). doi:10.1109/GCAT55367.2022.9971940
- Miyakoshi, M. (2023). Artifact subspace reconstruction: a candidate for a dream solution for EEG studies, sleep or awake. *Sleep*, 46(12), zsad241. doi:10.1093/sleep/zsad241
- Miyakoshi, M., Kim, H., Nakanishi, M., Palmer, J., & Kanayama, N. (2024). One out of ten independent components shows flipped polarity with poorer data quality: EEG database study. *Human brain mapping*, 45(1), e26540. doi:10.1002/HBM.26540
- Moein Esfahani, M., & Sadati, H. (2022). Application of NSGA-II in Channel Selection of Motor Imagery EEG Signals with Common Spatio-Spectral Patterns in BCI Systems. *2022 8th International Conference on Control, Instrumentation and Automation (ICCIA)*, (pg. 1-6). doi:10.1109/ICCIA54998.2022.9737199
- Moore, M. (2003). Real-world applications for brain-computer interface technology. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(2), 162-165. doi:10.1109/TNSRE.2003.814433
- Mountaj, N., Hamzaoui, E. M., Himmi, M. M., & Besson, M. R. (2019). Development of Wavelet Based Tools for Event related potentials' N400 detection: Application to visual and auditory vowelling and semantic priming in Arabic language. *Advances in Science, Technology and Engineering Systems Journal*, 4(4), 414-420. doi:10.25046/aj040450
- Mousavi, E., Maller, J., Fitzgerald, P., & Lithgow, B. (2011). Wavelet Common Spatial Pattern in asynchronous offline brain computer interfaces. *Biomedical Signal Processing and Control*, 6(2), 121-128. doi:10.1016/j.bspc.2010.08.003
- Mu, J., Grayden, D. B., Tan, Y., & Oetomo, D. (2020). Comparison of Steady-State Visual Evoked Potential (SSVEP) with LCD vs. LED Stimulation. *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, (pg. 2946-2949). doi:1109/EMBC44109.2020.9175838
- Mudgal, S., Sharma, S., Chaturvedi, J., & Sharma, A. (2020). Brain computer interface advancement in neurosciences: Applications and issues. *Interdisciplinary Neurosurgery*, 20, 100694. doi:10.1016/j.inat.2020.100694
- Mugler, E., Ruf, C., Halder, S., Bensch, M., & Kubler, A. (2010). Design and Implementation of a P300-Based Brain-Computer Interface for Controlling an Internet Browser. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 18(6), 599-609. doi:10.1109/TNSRE.2010.2068059
- Müller-Putz, G. R., & Pfurtscheller, G. (2008). Control of an electrical prosthesis with an SSVEP-based BCI. *55(1)*, 361-364. doi:10.1109/TBME.2007.897815
- Müller-Putz, G. R., Scherer, R., Pfurtscheller, G., & Rupp, R. (2005). EEG-based neuroprosthesis control: a step towards clinical practice. *Neuroscience letters*, 382(1-2), 169-174. doi: 10.1016/j.neulet.2005.03.021

- Müller-Putz, G., Ofner, P., Pereira, J., Pinegger, A., Schwarz, A., Zube, M., . . . Rupp, R. (2019). Applying intuitive EEG-controlled grasp neuroprostheses in individuals with spinal cord injury: Preliminary results from the MoreGrasp clinical feasibility study. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, (pg. 5949-5955). doi:10.1109/EMBC.2019.8856491
- Mussabayeva, A., Jamwal, P. K., & Tahir Akhtar, M. (2021). Ensemble Learning Approach for Subject-Independent P300 Speller. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society*.
- Mussi, M. G., & Adams, K. D. (2022). EEG hybrid brain-computer interfaces: A scoping review applying an existing hybrid-BCI taxonomy and considerations for pediatric applications. *Frontiers in human neuroscience*, *16*, 1007136. doi:10.3389/fnhum.2022.1007136
- Nann, M., Cordella, F., Trigili, E., Lauretti, C., Bravi, M., Miccinilli, S., . . . Soekadar, S. (2020). Restoring Activities of Daily Living Using an EEG/EOG-Controlled Semiautonomous and Mobile Whole-Arm Exoskeleton in Chronic Stroke. *IEEE Systems Journal*, *15*(2), 2314-2321. doi:10.1109/JSYST.2020.3021485
- NeuroSky. (2023). Preluat pe 09 10, 2023, de pe <http://www.neurosky.com>
- Nicolas-Alonso, L. F., & Gomez-Gil, J. (2012). Brain computer interfaces, a review. *Sensors*, *12*(2), 1211-1279. doi:10.3390/s120201211
- Norcia, A. M., Appelbaum, L. G., Ales, J. M., Cottreau, B. R., & Rossion, B. (2015). The steady-state visual evoked potential in vision research: A review. *Journal of vision*, *15*(6), 4. doi:10.1167/15.6.4
- Obermaier, B., Müller, G. R., & Pfurtscheller, G. (2003). "Virtual keyboard" controlled by spontaneous EEG activity. *IEEE transactions on neural systems and rehabilitation engineering*, *11*(4), 422-426. doi:10.1109/TNSRE.2003.816866
- Onishi, A., & Nakagawa, S. (2019). Comparison of Classifiers for the Transfer Learning of Affective Auditory P300-Based BCIs. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, (pg. 6766-6769). doi:10.1109/EMBC.2019.8856320
- Orban, M., Elsamanty, M., Guo, K., Zhang, S., & Yang, H. (2022). A Review of Brain Activity and EEG-Based Brain-Computer Interfaces for Rehabilitation Application. *Bioengineering*, *9* (12)(768). doi:10.3390/bioengineering9120768
- Otte, A. (2020). Invasive versus Non-Invasive Neuroprosthetics of the Upper Limb: Which Way to Go? *Prosthesis*, *2*(3), 237-239. doi:10.3390/prosthesis2030020
- Paek, A., & Prashad, S. (2023). Repetitive execution of a reach-and-lift task causes longitudinal attenuation in movement-related EEG features. *bioRxiv*. doi:10.1101/2023.02.09.527923
- Pan, J., Chen, X., Ban, N., He, J., Chen, J., & Huang, H. (2022). Advances in P300 brain-computer interface spellers: toward paradigm design and performance evaluation. *Frontiers in human neuroscience*, *16*, 1077717. doi:10.3389/fnhum.2022.1077717

- Pan, J., Wang, L., Huang, H., Xiao, J., Wang, F., Liang, Q., . . . Xie, Q. (2023). A Hybrid Brain–Computer Interface Combining P300 Potentials and Emotion Patterns for Detecting Awareness in Patients With Disorders of Consciousness. *IEEE Transactions on Cognitive and Developmental Systems*, 15(3), 1386-1395. doi:10.1109/TCDS.2022.3213194
- Pareniuk, A., Pareniuk, D., Drozdenko, K., & Nayda, S. (2021). Study of the Combined Effect of Stress Factor and Musical Signal on the Psychophysical State of Human. *Microsystems, Electronics and Acoustics*, 26. doi:10.20535/2523-4455.me.228179
- Paszkiel, S., & Szpulak, P. (2018). Methods of acquisition, archiving and biomedical data analysis of brain functioning. *3rd International Scientific Conference on Brain-Computer Interfaces, BCI 2018*, 720, pg. 158-171. doi:10.1007/978-3-319-75025-5_15
- Pawar, D., & Dhage, S. (2020). Feature Extraction Methods for Electroencephalography based Brain-Computer Interface: A Review. *IAENG International Journal of Computer Science*, 47(3).
- Peksa, J., & Mamchur, D. (2023). State-of-the-Art on Brain-Computer Interface Technology . *Sensors*, 23(13), 6001. doi:10.3390/s23136001
- Pfurtscheller, G., & Neuper, C. (2001). Motor Imagery and Direct Brain-Computer Communication. *Proceedings of the IEEE*, 89(7), 1123-1134. doi:10.1109/5.939829
- Pfurtscheller, G., Guger, C., Müller, G., Krausz, G., & Neuper, C. (2000). Brain oscillations control hand orthosis in a tetraplegic. *Neuroscience letters*, 292(3), 211-214. doi:10.1016/s0304-3940(00)01471-3
- Pfurtscheller, G., Müller, G. R., Pfurtscheller, J., Gerner, H. J., & Rupp, R. (2003). 'Thought'-control of functional electrical stimulation to restore hand grasp in a patient with tetraplegia. *Neuroscience letters*, 351(1), 33-36. doi:10.1016/s0304-3940(03)00947-9
- Philips, J., Millán, J., Vanacker, G., Lew, E., Galán, F., Ferrez, P., . . . Nuttin, M. (2007). Adaptive Shared Control of a Brain-Actuated Simulated Wheelchair. *2007 IEEE 10th International Conference on Rehabilitation Robotics*, (pg. 408-414). doi:10.1109/ICORR.2007.4428457
- Pion-Tonachini, L., Kreutz-Delgado, K., & Makeig, S. (2019). ICLabel: An automated electroencephalographic independent component classifier, dataset, and website. *NeuroImage*, 198, 181-197. doi:10.1016/j.neuroimage.2019.05.026
- Plechawska-Wójcik, M., Augustynowicz, P., Kaczorowska, M., Zabielska-Mendyk, E., & Zapała, D. (2023). The Influence Assessment of Artifact Subspace Reconstruction on the EEG Signal Characteristics. *Applied Sciences*, 13(3), 1605. doi:10.3390/app13031605
- Plechawska-Wojcik, M., Kaczorowska, M., & Zapala, D. (2018). The Artifact Subspace Reconstruction (ASR) for EEG Signal Correction. A Comparative Study. *In Information systems architecture and technology: proceedings of 39th international*

- conference on information systems architecture and technology–ISAT 2018: part II, 853, pg. 125-135. doi:10.1007/978-3-319-99996-8_12
- Ponnam, H., & Shaik, J. (2020). Circulant Matrix-Based Continuous Wavelet Transform for Achieving Low Complexity Electrocardiogram Feature Extraction in Health Monitoring Applications. *Journal of Computational and Theoretical Nanoscience*, 17, 254-259. doi:10.1166/jctn.2020.8659
- Quiles, V., Ferrero, L., Iáñez, E., Ortíz, M., Cano, J., & Azorín, J. (2022). Detecting the Speed Change Intention from EEG Signals: From the Offline and Pseudo-Online Analysis to an Online Closed-Loop Validation. *Applied Sciences*, 12(1), 415. doi:10.3390/app12010415
- Racz, F., Fakhreddine, R., Kumar, S., & Millán, J. (2023). Riemannian geometry-based detection of slow cortical potentials during movement preparation. *2023 11th International IEEE/EMBS Conference on Neural Engineering (NER)*, (pg. 1-5). doi:10.1109/NER52421.2023.10123857
- Ramírez-Arias, F., García-Guerrero, E., Tlelo-Cuautle, E., Colores-Vargas, J., García-Canseco, E., López-Bonilla, O., . . . Inzunza-González, E. (2022). Evaluation of Machine Learning Algorithms for Classification of EEG Signals. *Technologies*, 10(4), 79. doi:10.3390/technologies10040079
- Rashid, M., Sulaiman, N., P P Abdul Majeed, A., Musa, R. M., Ab Nasir, A. F., Bari, B. S., & Khatun, S. (2020). Current Status, Challenges, and Possible Solutions of EEG-Based Brain-Computer Interface: A Comprehensive Review . *Frontiers in neurorobotics*, 14, 25. doi:10.3389/fnbot.2020.00025
- Rayson, H., Debnath, R., Alavizadeh, S., Fox, N., Ferrari, P. F., & Bonaiuto, J. J. (2022). Detection and analysis of cortical beta bursts in developmental EEG data. *Developmental cognitive neuroscience*, 54, 101069. doi:10.1016/j.dcn.2022.101069
- Raza, H., Cecotti, H., Li, Y., & Prasad, G. (2015). Learning with covariate shift-detection and adaptation in non-stationary environments: Application to brain-computer interface. *2015 International Joint Conference on Neural Networks (IJCNN)*, (pg. 1-8). doi:10.1109/IJCNN.2015.7280742
- Rebsamen, B., Burdet, E., Cuntai, G., Chee Leong, T., Qiang, Z., Ang, M., & Laugier, C. (2007). Controlling a wheelchair using a BCI with low information transfer rate. *2007 IEEE 10th International Conference on Rehabilitation Robotics*, (pg. 1003-1008). doi: 10.1109/ICORR.2007.4428546
- Rebsamen, B., Cuntai, G., Haihong, Z., Chuanchu, W., Cheeleong, T., Ang, M., & Burdet, E. (2010). A Brain Controlled Wheelchair to Navigate in Familiar Environments. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 18(6), 590-598. doi:10.1109/TNSRE.2010.2049862
- Reza, F., & Begum, T. (2019). Mild cognitive impairment in mild brain injury (MBI) patients: An event related potential (ERP) and neuropsychology study. *Bangladesh Journal of Medical Science*, 18(3), 557-566. doi:10.3329/bjms.v18i3.41626

- Rezazadeh Sereshkeh, A., Trott, R., Bricout, A., & Chau, T. (2017). EEG Classification of Covert Speech Using Regularized Neural Networks. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 25(12), 2292-2300. doi:10.1109/TASLP.2017.2758164
- Ricci, S., Tatti, E., Mehraram, R., Panday, P., & Ghilardi, M. F. (2019). Beta band frequency differences between motor and frontal cortices in reaching movements. *2019 IEEE 16th International Conference on Rehabilitation Robotics (ICORR)*, (pg. 1254-1259). doi:10.1109/ICORR.2019.8779373
- Rimbert, S., & Lotte, F. (2022). ERD modulations during motor imageries relate to users' traits and BCI performances. *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, (pg. 203-207). doi:10.1109/EMBC48229.2022.9871411
- Riyadi, M., Prakoso, T., Whaillan, F., Wahono, M. D., & Hidayatno, A. (2019). Classification of EEG-based Brain Waves for Motor Imagery using Support Vector Machine. *2019 International Conference on Electrical Engineering and Computer Science (ICECOS)*, (pg. 422-425). doi:10.1109/ICECOS47637.2019.8984565
- Robbins, K. A., Touryan, J., Mullen, T., Kothe, C., & Bigdely-Shamlo, N. (2020). How Sensitive are EEG Results to Preprocessing Methods: A Benchmarking Study. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 1081-1090. doi:10.1109/TNSRE.2020.2980223
- Rodríguez-Martínez, E. I., Angulo-Ruiz, B. Y., Arjona-Valladares, A., Rufo, M., Gómez-González, J., & Gómez, C. M. (2020). Frequency coupling of low and high frequencies in the EEG of ADHD children and adolescents in closed and open eyes conditions. *Research in developmental disabilities*(96), 103520. doi:10.1016/j.ridd.2019.103520
- Rosca, S. D., & Leba, M. (2019). Design of a brain-controlled video game based on a BCI system. *MATEC Web of Conferences*, (p. 01019). doi:10.1051/mateconf/201929001019
- Rosca, S. D., Leba, M., & Sibisanu, R. C. (2022). SSVEP Based BCI Control of a Robot Swarm., (pg. 296-305). doi:10.1007/978-3-031-04826-5_29
- Rosca, S. D., Leba, M., Sibisanu, R. C., & Muntean, E. (2022). Gesture Control of a Robotic Head using Kinect. *2022 7th International Conference on Mathematics and Computers in Sciences and Industry (MCSI)*, (pg. 101-108). doi:10.1109/MCSI55933.2022.00023
- Rosca, S., Leba, M., Ionica, A., & Gamulescu, O. (2018). Quadcopter control using a BCI. *IOP Conference Series: Materials Science and Engineering*, 294, p. 012048. doi:10.1088/1757-899X/294/1/012048
- Rosca, S., Leba, M., Sibisanu, R., & Panaite, F. A. (2021). Brain Controlled Lego NXT Mindstorms 2.0 Platform. *2021 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, (pg. 325-330). doi:10.1109/ISITIA52817.2021.9502229

- Rosca, S., Risteiu, M., Leba, M., Negru, N., & Ridzi, M. (2020). Artificial arm for manipulations in toxic atmospheres based on EEG-EMG signals. *MATEC Web of Conferences 9th International Symposium on Occupational Health and Safety (SESAM 2019)*, 305, p. 00007. doi:10.1051/mateconf/202030500007
- Ruiting, Y., Gray, D., Ng, B., & Mingyi, H. (2009). Comparative analysis of signal processing in brain computer interface. *2009 4th IEEE Conference on Industrial Electronics and Applications*, (pg. 580-585). doi:10.1109/ICIEA.2009.5138215
- Rusnac, A., & Grigore, O. (2021). EEG Preprocessing Methods for BCI Imagined Speech Signals. *2021 International Conference on e-Health and Bioengineering (EHB)*, (pg. 1-4). doi:10.1109/EHB52898.2021.9657563
- Saha, P., Rahman, M., Alam, M., Ferdowsi, A., & Mollah, M. (2021). Common Spatial Pattern in Frequency Domain for Feature Extraction and Classification of Multichannel EEG Signals. *SN Computer Science*, 2, 149. doi:10.1007/s42979-021-00586-9
- Salahuddin, U., & Gao, P.-X. (2021). Signal Generation, Acquisition, and Processing in Brain Machine Interfaces: A Unified Review. *Frontiers in Neuroscience*, 15, 1174. doi:10.3389/fnins.2021.728178
- Salankar, N., Nemade, S., & Gaikwad, V. (2020). Classification of seizure and seizure free EEG signals using optimal mother wavelet and relative power. *Indonesian Journal of Electrical Engineering and Computer Science*, 20(1), 197. doi:10.11591/IJEECS.V20.I1.PP197-205
- Salyers, J. B., Y. D., & Gai, Y. (2019). Continuous Wavelet Transform for Decoding Finger Movements From Single-Channel EEG. *IEEE transactions on bio-medical engineering*, 66(6), 1588-1597. doi:0.1109/TBME.2018.2876068
- Schembri, P., Pelc, M., & Ma, J. (2019). Comparison between a Passive and Active response task and their effect on the Amplitude and Latency of the P300 component for Visual Stimuli while using Low Fidelity Equipment. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, (pg. 4566-4571). doi:10.1109/EMBC.2019.8857093
- Schlögl, A., Lee, F., Bischof, H., & Pfurtscheller, G. (2005). Characterization of four-class motor imagery EEG data for the BCI-competition. *Journal of Neural Engineering*, 2, L14-22. doi:10.1088/1741-2560/2/4/L02
- Sellers, E. W., Vaughan, T. M., & Wolpaw, J. R. (2010). A brain-computer interface for long-term independent home use. *Amyotrophic lateral sclerosis : official publication of the World Federation of Neurology Research Group on Motor Neuron Diseases*, 11(5), 449-455. doi:10.3109/17482961003777470
- Senneff, S., McManus, L., & Lowery, M. M. (2019). Investigating the Effect of Persistent Inward Currents on Motor Unit Firing Rates and Beta-Band Coherence in a Model of the First Dorsal Interosseous Muscle. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, (pg. 2293-2296). doi:10.1109/EMBC.2019.8857534

- Serruya, M. D., Hatsopoulos, N. G., Paninski, L., Fellows, M. R., & Donoghue, J. P. (2002). Instant neural control of a movement signal. *Nature*, *416*, 141-142. doi:10.1038/416141a
- Shahzad, F., Alhabeb, M., Hatter, C. B., Anasori, B., Man Hong, S., Koo, C. M., & Gogotsi, Y. (2016). Electromagnetic interference shielding with 2D transition metal carbides (MXenes). *Science*, *353*(6304), 1137-1140. doi:10.1126/science.aag2421
- Sharma, M., Rafiuddin, N., Sarfaraz, M., & Uzzaman Khan, Y. (2022). Brain-Computer Interface Based Control for Disabled. *2022 5th International Conference on Multimedia, Signal Processing and Communication Technologies (IMPACT)*, (pg. 1-5). doi:10.1109/IMPACT55510.2022.10029243
- She, Q., Zou, J., Luo, Z., Nguyen, T., Li, R., & Zhang, Y. (2020). Multi-class motor imagery EEG classification using collaborative representation-based semi-supervised extreme learning machine. *Medical & biological engineering & computing*, *58*(9), 2119-2130. doi:10.1007/s11517-020-02227-4
- Shenoy, P., Krauledat, M., Blankertz, B., Rao, R., & Müller, K. (2006). Towards adaptive classification for BCI. *3*(1), R13-R23. doi:10.1088/1741-2560/3/1/R02
- Shi, Q., Li, Z., Zhang, I., Jiang, H., Tian, F., Zhao, Q., & Hu, B. (2021). High-speed ocular artifacts removal of multichannel EEG based on improved moment matching. *J Neural Eng.*, *18*(5), 056038. doi:10.1088/1741-2552/ac1d5a
- Shiman, F., Irastorza-Landa, N., Sarasola-Sanz, A., Spuler, M., Birbaumer, N., & Ramos-Murguialday, A. (2017). Towards decoding of functional movements from the same limb using EEG. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, (pg. 1922-1925). doi:10.1109/EMBC.2015.7318759
- Shin, H., Byun, J., Roh, D., Choi, N., Shin, H. S., & Cho, I. J. (2022). Interference-free, lightweight wireless neural probe system for investigating brain activity during natural competition. *Biosensors and Bioelectronics*, *195*(113665). doi:10.1016/j.bios.2021.113665
- Shinde, A., Achrekar, V., Ambekar, A., & Dabke, D. (2015). Real Time EEG Signal Analysis. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Energy*, *4*, 4340-4345. doi:10.15662/IJAREEIE.2015.0405108
- Shirzhiyan, Z., Keihani, A., Farahi, M., Shamsi, E., GolMohammadi, M., Mahnam, A., . . . Jafari, A. H. (2020). Toward New Modalities in VEP-Based BCI Applications Using Dynamical Stimuli: Introducing Quasi-Periodic and Chaotic VEP-Based BCI. *Frontiers in neuroscience*, *14*, 534619. doi:10.3389/fnins.2020.534619
- Simfukwe, C., Youn, Y. C., Kim, M. J., Paik, J., & Han, S. H. (2023). CNN for a Regression Machine Learning Algorithm for Predicting Cognitive Impairment Using qEEG. *Neuropsychiatric Disease and Treatment*, *19*, 851-863. doi:10.2147/NDT.S404528
- Singh, A., & Krishnan, S. (2023). Trends in EEG signal feature extraction applications. *Frontiers in Artificial Intelligence*(5), 1072801. doi:10.3389/frai.2022.1072801

- Singh, N., Saini, M., Kumar, N., Srivastava, M. V., Kumaran, S. S., & Mehndiratta, A. (2021). A Case Report: Effect of Robotic Exoskeleton Based Therapy on Neurological and Functional Recovery of a Patient With Chronic Stroke. *Frontiers in neurology*, *12*, 680733. doi:10.3389/fneur.2021.680733
- Soroka, G., & Idiart, M. (2021). Theta, alpha and gamma traveling waves in a multi-item working memory model. Preluat de pe <https://arxiv.org/abs/2103.15266>
- Sosnik, R., & Ben Zur, O. (2020). Reconstruction of hand, elbow and shoulder actual and imagined trajectories in 3D space using EEG slow cortical potentials. *Journal of neural engineering*, *17*(1), 016065. doi:10.1088/1741-2552/ab59a7
- Stawicki, P., Gembler, F., Rezeika, A., & Volosyak, I. (2017). A Novel Hybrid Mental Spelling Application Based on Eye Tracking and SSVEP-Based BCI. *Brain sciences*, *7*(4), 35. doi:10.3390/brainsci7040035
- Stieger, J., Engel, S., & He, B. (2021). Continuous sensorimotor rhythm based brain computer interface learning in a large population. *Sci Data*, *8*(1), 98. doi:10.1038/s41597-021-00883-1
- Sudibyo, U., Rustad, S., Nurtantio Andono, P., Zainul Fanani, A., Purwanto, P., & Muljono, M. (2020). A Novel Approach on Linear Discriminant Analysis (LDA)., (pg. 131-136). doi:10.1109/iSemantic50169.2020.9234274
- Sun, J., Wen, S., Wen, Y., Liu, J., Wu, Q., Han, L., & Wang, F. (2023). An Asynchronous SSVEP-BCI for Intelligent Rehabilitation Exoskeleton Based on Alpha Rhythm-Detected CCA. *2023 IEEE 13th International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)*, (pg. 1349-1354). doi:10.1109/CYBER59472.2023.10256645
- Sun, W., Chang, C., & Long, Q. (2021). Graph-guided Bayesian SVM with Adaptive Structured Shrinkage Prior for High-dimensional Data. *IEEE International Conference on Big Data (Big Data)*, (pg. 4472-4479). doi:10.1109/BigData52589.2021.9671712
- Świec, J. (2021). Brain-Computer Interface in Lie Detection. *Control, Computer Engineering and Neuroscience. ICBCI 2021. Advances in Intelligent Systems and Computing*, *1362*, pg. 166-175. doi:10.1007/978-3-030-72254-8_17
- Takase, R., Boasen, J., & Yokosawa, K. (2019). Different roles for theta- and alpha-band brain rhythms during sequential memory. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, (pg. 1713-1716). doi:10.1109/EMBC.2019.8856816
- Tan, X., Chen, M., & Gan, J. (2015). A co-training algorithm based on modified Fisher's linear discriminant analysis. *Intelligent Data Analysis*, *19*(2), 279-292. doi:10.3233/IDA-150717
- Tanaka, K., Matsunaga, K., & Wang, H. (2005). Electroencephalogram-based control of an electric wheelchair. *IEEE Transactions on Robotics*, *21*(4), 762-766. doi:10.1109/TRO.2004.842350

- Tangemann, M., Krauledat, M., Grzeska, K., Sagebaum, M., Blankertz, B., Vidaurre, C., & Müller, K. (2008). Playing Pinball with non-invasive BC., (pg. 1641-1648).
- Teng, C. L., Zhang, Y. Y., Wang, W., Luo, Y. Y., Wang, G., & Xu, J. (2021). A novel method based on combination of independent component analysis and ensemble empirical mode decomposition for removing electrooculogram artifacts from multichannel electroencephalogram signals. *Frontiers in neuroscience*, *15*, 729403. doi:10.3389/fnins.2021.729403
- Teng, F., Chen, Y., Choong, A. M., Gustafson, S., Reichley, C., Lawhead, P., & Waddell, D. (2011). Square or sine: finding a waveform with high success rate of eliciting SSVEP. *Computational intelligence and neuroscience*, *2011*, 364385. doi:10.1155/2011/364385
- Teo, J., Ahmad, N., & Goh, P. (2022). Visual Stimuli-Based Dynamic Commands With Intelligent Control for Reactive BCI Applications. *EEE Sensors Journal*, *22*(2), 1435-1448. doi:10.1109/JSEN.2021.3130626
- Thakur, R. (2023). Improved Artifact Mitigation From ECG Signal For Effective Ischemia Detection and Classification. *2023 1st International Conference on Innovations in High Speed Communication and Signal Processing (IHCSPP)*, (pg. 224-227). doi:10.1109/IHCSPP56702.2023.10127218
- Townsend, G., LaPallo, B. K., Boulay, C. B., Krusienski, D. J., Frye, G. E., Hauser, C. K., . . . Sellers, E. W. (2010). A novel P300-based brain-computer interface stimulus presentation paradigm: moving beyond rows and columns. *Clinical neurophysiology*, *121*(7), 1109-1120. doi:10.1016/j.clinph.2010.01.030
- Treder, M. S., Schmidt, N. M., & Blankertz, B. (2011). Gaze-independent brain-computer interfaces based on covert attention and feature attention. *Journal of neural engineering*, *8*(6), 066003. doi:10.1088/1741-2560/8/6/066003
- Tsoneva, T., Garcia-Molina, G., & Desain, P. (2021). SSVEP phase synchronies and propagation during repetitive visual stimulation at high frequencies. *Scientific Reports*, *11*, 4975. doi:10.1038/s41598-021-83795-9
- Turi, F., G. N., Clerc, M., Turi, F., ayraud, N., & Clerc, M. (2020). Auto-calibration of c-VEP BCI by word prediction. *hal-02844024* .
- Ueno, K., Ishii, R., Ueda, M., Yuri, T., Shiroma, C., Hata, M., & Naito, Y. (2023). Frontal midline theta rhythm and gamma activity measured by sheet-type wearable EEG device. *Frontiers in human neuroscience*, *17*(1145282). doi:10.3389/fnhum.2023.1145282
- Usakli, A. (2010). Improvement of EEG signal acquisition: an electrical aspect for state of the art of front end. *Computational intelligence and neuroscience*(630649). doi:10.1155/2010/630649
- Utzerath, C., Schmits, I. C., Kok, P., Buitelaar, J., & de Lange, F. P. (2019). No evidence for altered up- and downregulation of brain activity in visual cortex during illusory shape perception in autism. *Cortex; a journal devoted to the study of the nervous system and behavior*, *117*, 247-256. doi:10.1016/j.cortex.2019.03.011

- Valentim, C. A., Inacio Jr, C. M., & David, S. A. (2021). Fractal Methods and Power Spectral Density as Means to Explore EEG Patterns in Patients Undertaking Mental Tasks. *MDPI*, 5, 225. doi:10.3390/fractalfract5040225
- Vanacker, G., del R Millán, J., Lew, E., Ferrez, P. W., Moles, F. G., Philips, J., . . . Nuttin, M. (2007). Context-based filtering for assisted brain-actuated wheelchair driving. *Computational intelligence and neuroscience*, 25130. doi:10.1155/2007/25130
- Vastano, R., & Perez, M. A. (2020). Changes in motoneuron excitability during voluntary muscle activity in humans with spinal cord injury. *Journal of neurophysiology*, 123(2), 454-461. doi:10.1152/jn.00367.2019
- Vecchiato, G., De Vico Fallani, F., Astolfi, L., Toppi, J., Cincotti, F., Mattia, D., . . . Babiloni, F. (2010). The issue of multiple univariate comparisons in the context of neuroelectric brain mapping: an application in a neuromarketing experiment. *Journal of neuroscience methods*, 191(2), 283-289. doi:10.1016/j.jneumeth.2010.07.009
- Vidaurre, C., Krämer, N., Blankertz, B., & Schlögl, A. (2009). Time Domain Parameters as a feature for EEG-based Brain-Computer Interfaces. *Neural networks : the official journal of the International Neural Network Society*, 22(9), 1313-1319. doi:10.1016/j.neunet.2009.07.020
- Wang, G., Teng, C., Li, K., Zhang, Z., & Yan, X. (2016). The Removal of EOG Artifacts From EEG Signals Using Independent Component Analysis and Multivariate Empirical Mode Decomposition. *IEEE Journal of Biomedical and Health Informatics*, 20(5), 1301-1308. doi:10.1109/JBHI.2015.2450196
- Wang, J., Xu, G., Wang, L., & Zhang, H. (2010). Feature extraction of brain-computer interface based on improved multivariate adaptive autoregressive models. *2010 3rd International Conference on Biomedical Engineering and Informatics*, 895-898. doi:10.1109/BMEI.2010.5639885
- Wang, W. E., Ho, R. L., Gatto, B., Van Der Veen, S. M., Underation, M. K., Thomas, J. S., . . . A., C. S. (2020). A Novel Method to Understand Neural Oscillations During Full-Body Reaching: A Combined EEG and 3D Virtual Reality Study. *IEEE transactions on neural systems and rehabilitation engineering*, 28(12), 3074-3082. doi:10.1109/TNSRE.2020.3039829
- Wang, Z., Wong, C., Nan, W., Tang, Q., Rosa, A., Xu, P., & Wan, F. (2022). Learning Curve of a Short-Time Neurofeedback Training: Reflection of Brain Network Dynamics Based on Phase-Locking Value. *IEEE Transactions on Cognitive and Developmental Systems*, 14(3), 1282-1295. doi:10.1109/TCDS.2021.3125948
- Wendiggensen, P., Ghin, F., Koyun, A. H., Stock, A. K., & Beste, C. (2022). Pretrial Theta Band Activity Affects Context-dependent Modulation of Response Inhibition. *Journal of cognitive neuroscience*, 34(4), 605-617. doi:10.1162/jocn_a_01816
- Wolpaw, J. R. (2007). Brain-computer interfaces as new brain output pathways. *The Journal of physiology*, 579(Pt.3), 613-617. doi:10.1113/jphysiol.2006.125948
- Wolpaw, J. R. (2013). Chapter 6 - Brain-computer interfaces. În *Handbook of Clinical Neurology* (Vol. 110, pg. 67-74). doi:10.1016/B978-0-444-52901-5.00006-X

- Wolpaw, J. R., Birbaumer, N., Heetderks, W., McFarland, D., Peckham, P., Schalk, G., . . . Vaughan, T. (2000). Brain-computer interface technology: a review of the first international meeting. *IEEE Transactions on Rehabilitation Engineering*, 82(2), 164-173. doi:doi:10.1109/tre.2000.847807
- Wolpaw, J., & McFarland, D. (2004). Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proceedings of the National Academy of Sciences of the United States of America*, 101(51), 17849-17854. doi:10.1073/pnas.0403504101
- Yadav, D., Yadav, S., & Veer, K. (2020). A comprehensive assessment of Brain Computer Interfaces: Recent trends and challenges. *Journal of Neuroscience Methods*, 346, 108918. doi:10.1016/j.jneumeth.2020.108918
- Yang, Y., & Li, M. (2023). Motor Imagery Recognition Based on an Optimized Probabilistic Neural Network with the Particle Swarm Optimization. *2023 35th Chinese Control and Decision Conference (CCDC)*, (pg. 4743-4748). doi:10.1109/CCDC58219.2023.10326560
- Yin, J., Jiang, D., & Hu, J. (2009). Design and application of brain-computer interface web browser based on VEP,. *009 International Conference on Future BioMedical Information Engineering (FBIE)*, (pg. 77-80). doi:10.1109/FBIE.2009.5405788
- Ying, J., Wei, Q., & Zhou, X. (2022). Riemannian geometry-based transfer learning for reducing training time in c-VEP BCIs. *Scientific reports*, 12(1), 9818. doi:10.1038/s41598-022-14026-y
- Younis, M., Sleiman, S., Khadra, S., Zaylaa, A., Daher, A., & Ayache, M. (2023). Building a Brain Computer Interface (BCI) Using Electroencephalogram (EEG) Signals' Classification. *2023 Seventh International Conference on Advances in Biomedical Engineering (ICABME)*, (pg. 130-136). doi:10.1109/ICABME59496.2023.10293031
- Yu, M. (2021). Removal methods of EMG Artifacts from EEG Signals. În J. o. Series (Ed.), *2021 2nd International Conference on Electrical, Electronic Information and Communication Engineering (EEICE 2021)*, 1920, p. 012076. doi:10.1088/1742-6596/1920/1/012076
- Zabcikova, M., Koudelkova, Z., Jasek, R., & Lorenzo Navarro, J. J. (2022). Recent advances and current trends in brain-computer interface research and their applications. *International Journal of Developmental Neuroscience*, 82(2), 107-123.
- Zammit, N., & Muscat, R. (2023). Alpha/beta-gamma decoupling in methylphenidate medicated ADHD patients. *Frontiers in neuroscience*, 17, 1267901. doi:10.3389/fnins.2023.1267901
- Zavala, S., Chicaiza, K., López, J., Sulca, J., & Yoo, S. (2020). BCI Based Home Automation using User Controlled Blinks. *Journal of Engineering and Applied Sciences*, 15(6), 1377-1384. doi:10.36478/jeasci.2020.1377.1384

- Zawiślak, T. (2017). Sposoby generowania stymulacji wywołujących SSVEP z zastosowaniem monitorów LCD. *Zeszyty Naukowe Wydziału Elektroniki i Informatyki Politechniki Koszalińskiej*, 11, 123-131.
- Zeng, H., & Song, A. (2014). Removal of EOG artifacts from EEG recordings using stationary subspace analysis. *ScientificWorldJournal*, 259121. doi:10.1155/2014/259121
- Zhang, J., Gao, S., Zhou, K., Cheng, Y., & Mao, S. (2023). An online hybrid BCI combining SSVEP and EOG-based eye movements. *Frontiers in human neuroscience*, 17, 1103935. doi:10.3389/fnhum.2023.1103935
- Zhang, L., He, W., He, C., & Wang, P. (2010). Improving mental task classification by adding high frequency band information. *Journal of medical systems*, 34(1), 51-60. doi:10.1007/s10916-008-9215-z
- Zhang, X., Qiu, S., Geng, M., & He, H. (2021). Enhancing Detection of SSVEPs for High-Speed Brain-Computer Interface with a Siamese Architecture. *2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, (pg. 1623-1627). doi:10.1109/BIBM52615.2021.9669482