

Universitatea “Politehnica” din București
Facultatea de Electronică, Telecomunicații și Tehnologia Informației

Aplicații ale biosemnalelor în controlul unui braț robotic

Proiect de diplomă

prezentat ca cerință parțială pentru obținerea titlului de

Inginer în domeniul Inginerie electronică și telecomunicații

programul de studii de licență *Electronică aplicată*

Conducători științifici

Prof. Corneliu BURILEANU

S.l. dr. ing. Dragoș ȚARĂLUNGĂ


Absolvent

Emanuel RĂDUCANU

2017

Universitatea "Politehnica" din București
Facultatea de Electronică, Telecomunicații și Tehnologia Informației
Departamentul: Electronică Aplicată și Ingineria Informației

Aprobat Director de Departament :


Prof.dr.ing. Sever PASCA

TEMA PROIECTULUI DE DIPLOMĂ
a studentului: Răducanu A. Emanuel 441B

1. Titlul temei: Aplicații ale biosemnalelor în controlul unui braț robotic
2. Contribuția practică, originală a studentului va consta în:

Îmbunătățirea și diversificarea metodelor de prelucrare de semnal pentru implementarea unei aplicații BCI ce are la bază fenomenele neurologice înregistrate în timpul sarcinilor motorii.

Scopul acestui proiect constă în extragerea, selectarea și clasificarea trăsăturilor semnalelor EEG, pentru controlul unui braț robotic.

Pentru atingerea scopului propus vor fi parcurse următoarele etape :

- Înțelegerea modului de funcționare a sistemelor BCI și a fenomenelor neurologice implicate.
- Achiziția de semnale EEG în timpul sarcinilor motorii/imaginării motorii.
- Aplicarea și optimizarea metodelor de extragere, selecție și clasificare a trăsăturilor semnalelor EEG.
- Maparea dintre semnalele procesate și funcțiile responsabile de mișcările pe care le efectuează brațul robotic.

3. Proiectul se bazează pe cunoștințe dobândite în principal la următoarele discipline:

- Rețele neurale și sisteme fuzzy, Electronică și informatică medicală
- Prelucrarea digitală a semnalelor
- Robotică
- Microcontrolere

4. Proprietatea intelectuală asupra proiectului aparține: *UPB, Emanuel Răducanu*

5. Locul de desfășurare a activității: Centrul de cercetări „CAMPUS”, *UPB*

6. Data eliberării temei: 01.10.2016


CONDUCĂTORI LUCRARE:

Prof. Corneliu BURILEANU

S.l. dr. ing. Dragoș ȚARĂLUNGĂ

STUDENT:

Emanuel Răducanu



Declarație de onestitate academică


Prin prezenta declar că lucrarea cu titlul "*Aplicații ale biosemnalelor în controlul unui braț robotic*", prezentată în cadrul Facultății de Electronică, Telecomunicații și Tehnologia Informației a Universității "Politehnica" din București ca cerință parțială pentru obținerea titlului de *Inginer* în domeniul *Inginerie electronică și telecomunicații*, programul de studii de licență *Electronică aplicată* este scrisă de mine și nu a mai fost prezentată niciodată la o facultate sau instituție de învățământ superior din țară sau străinătate.

Declar că toate sursele utilizate, inclusiv cele de pe Internet, sunt indicate în lucrare, ca referințe bibliografice. Fragmentele de text din alte surse, reproduse exact, chiar și în traducere proprie din altă limbă, sunt scrise între ghilimele și fac referință la sursă. Reformularea în cuvinte proprii a textelor scrise de către alți autori face referință la sursă. Înțeleg că plagiatul constituie infracțiune și se sancționează conform legilor în vigoare.

Declar că toate rezultatele simulărilor, experimentelor și măsurărilor pe care le prezint ca fiind făcute de mine, precum și metodele prin care au fost obținute, sunt reale și provin din respectivele simulări, experimente și măsurători. Înțeleg că falsificarea datelor și rezultatelor constituie fraudă și se sancționează conform regulamentelor în vigoare.

București, 28.06.2014

Absolvent Emanuel RĂDUCANU



Cuprins

Introducere	15
• Motivația	15
• Obiective	16
Capitolul 1. Context și stadiul actual al cercetărilor	17
1.1. Structura unei interfețe creier – calculator.....	17
1.1.1. Metode de înregistrare a activității cerebrale	18
1.1.2. Prelucrarea semnalelor EEG	20
1.1.3. Controlul dispozitivelor. Aplicații	24
Capitolul 2. Elemente de fiziologie.....	27
2.1. Noțiuni fundamentale - structura creierului.....	27
2.2. Aspecte practice	30
Capitolul 3. Achiziția semnalelor electroencefalografice	33
3.1. Noțiuni introductive	33
3.1.1. Metode de achiziție	34
3.2. Sistemul de achiziție utilizat	36
3.3. Arie cortex motor și sensorimotor analizată.....	39
3.4. Paradigma utilizată.....	40
Capitolul 4. Brațul robotic JACO	43
4.1. Descriere braț robotic JACO	43
4.1.1. Brațul robotic	44
4.1.2. Efectorul brațului robotic	45
4.1.3. Controller-ul.....	45
Capitolul 5. Metode de extragere a trăsăturilor din semnalele EEG.....	47
5.1. Metode de extragere a trăsăturilor din semnalele EEG.....	47
5.1.1. Metoda Welch	50
5.1.2. Transformata Wavelet (WT).....	53
5.2. Clasificare	59
5.2.1. Rețea neuronală cu funcții de bază radiale (RBF)	59
Capitol 6. Rezultate.....	63
Concluzii și contribuții.....	67
Bibliografie	69

Lista figurilor

Fig. 1 Etape proiect	16
Fig. 1.1 Model funcțional pentru un sistem BCI.....	17
Fig. 1.2 Metode de achiziție de semnal.....	18
Fig. 1.3 Schemă bloc - sistem de achiziție și procesare semnale EEG [19]	19
Fig. 1.4 Metode de extracție de caracteristici din cardul sistemelor BCI bazate pe activitatea senzorimotoare, VEP, SCP, P300, răspuns la sarcini mentale, activitatea neuronilor și multe alte neuromecanisme. [26].....	23
Fig. 1.5 Domeniile de aplicare a sistemelor BCI	24
Fig. 1.6 Utilitatea sistemelor BCI în domeniul medical	25
Fig. 2.1 Cortex motor și somatosenzorial [38].....	28
Fig. 2.2 Potențialul de acțiune generat de un neuron	30
Fig. 2.3 Emisferele cerebrale	31
Fig. 3.1 Amplificatoare diferențiale cu referință comună	34
Fig. 3.2 Neuvo 128 – Amplificator 128 de canale [39]	36
Fig. 3.3 STIM ² [39]	37
Fig. 3.4 Casca electrozi Quik – Cap 128-canale	39
Fig. 3.5 Plasament electrozi.[39]	39
Fig. 3.6 Clasele de mișcări din cadrul paradigmei	41
Fig. 3.7 Structură bază de date	41
Fig. 4.1 Braț robotic JACO [44]	43
Fig. 4.2 Specificații braț robotic – Jaco	44
Fig. 4.3 Controller - Jaco	46
Fig. 5.1 Etapele de prelucrare a semnalelor EEG	47
Fig. 5.2 Canalul C3, Semnalul inițial împărțit în segmente (clasele 1-2), cu durată 8 secunde.	51
Fig. 5.3 Canalul C3, Semnalul inițial împărțit în segmente (clasele 3-4), cu durată 8 secunde.	51
Fig. 5.4 C3, Densitatea spectrală de putere estimată, Clasele 1-2	52
Fig. 5.5 C3, Densitatea spectrală de putere estimată, Clasele 3-4	52
Fig. 5.6 Împărțirea planului timp-frecvență în cazul: a) STFT; b) analizei wavelet[46].....	53
Fig. 5.7 (a) Coif1; (b) db2; (c) Meyer; (d) Sym3; (e) Morlet; (f) Mexican	55
Fig. 5.8 Scalarea funcțiilor mamă Wavelet [47]	55
Fig. 5.9 Efectul translației asupra funcției de bază $\Psi(t)$ [47].....	56
Fig. 5.10 Reprezentarea cu filtre a DWT[47]	56
Fig. 5.11 Descompunere pe trei nivele	57
Fig. 5.12 Descompunerea unui segment în benzile de frecvențe cerebrale	57
Fig. 5.13 Aproximare semnal EEG prin undișoare din familia Daubechies8.....	58
Fig. 5.14 Reprezentarea grafică procentuală a energiilor calculate pentru fiecare coeficient.	58
Fig. 5.15 Arhitectura rețelei neuronale utilizate pentru clasificarea semnalelor EEG.....	60
Fig. 6.1 Activitatea cerebrală înregistrată în zona cortexului motor, în timpul mișcărilor brațelor ..	63
Fig. 6.2 Numerotare actuatori – Jaco 3	65
Fig. 6.3 Comanda gripper-ului, prin intermediul semnalelor EEG.....	66

Lista tabelelor

Tabel 4.1 Specificații braț robotic – Jaco 3.....	44
Tabel 4.2 Specificații efector – Jaco 3	45
Tabel 4.3 Specificații controller – Jaco 3.....	46
Tabel 5.1 Comparatie între FFT, AR și WT	49
Tabel 5.2 Comparatia performanțelor metodelor de analiză a semnalelor EEG	49
Tabel 6.1 Răspunsurile furnizate de clasificator, folosind DWT(db8)	63
Tabel 6.2 Răspunsurile furnizate de clasificator, folosind DWT(coif5).....	63
Tabel 6.3 Răspunsurile furnizate de clasificator, folosind DWT(sym7)	64
Tabel 6.4 Răspunsurile furnizate de clasificator, folosind DWT(db6).....	64
Tabel 6.5 Răspunsurile furnizate de clasificator după extinderea bazei de date, DWT(db8).....	64

Lista acronimelor

BCI - Brain computer interface (Interfață Creier-Computer)
CAR - Common Average Reference (Referința Medie Comună)
CT-SCAN - Computed Tomography-Scan (Computer Tomograf)
DFT - Discrete Fourier Transform (Transformata Fourier Discretă)
EEG - Electroencefalogramă
EcoG - Electrocorticography (Electrocorticografie)
EP - Evoked Potentials (Potențiale Evocate)
ERP - Event Related Potential (Potențiale corelate procesului cognitiv)
FIR - Finite Impulse Response (Răspuns Finit la Impuls)
FFT - Fast Fourier Transform (Transformata Fourier Rapidă)
FTJ - Filtru Trece Jos
FTS - Filtru Trece Sus
FTB - Filtru Trece Bandă
fMRI -Functional magnetic resonance imaging
fNIRS - Functional near-infrared spectroscopy
HCI - Humman Computer Interface (Interfață Computer-Om)
ICA - Independent component analysis (Analiza componentelor independente)
IIR - Infinite Impulse Response (Răspuns Infinit la Impuls)
K-NN - K-Nearest Neighbors (Cei mai apropiați K vecini)
LDA - Linear Discriminant Analysis (Analiză liniar discriminantă)
LVQ - Learning Vector Quantization
MEG - Magnetoencephalography (Magnetoencefalografie)
MRI - Magnetic resonance imaging (Imagini obținute prin rezonanță magnetică)
PSD - Power Spectral Density (Desitate Spectrală de Putere)
RBF - Radial Basis Function (Funcții de bază radială)
SSVEP - Steady - State Visual Evoked Potential (Potențialul Evocat de Regim Permanent)
STFT - Short-Time Fourier Transform (Transformata Fourier pe termen scurt)
SVM - Support Vector Machines (Mașini cu suport vectorial)

Introducere

- Motivația

De-a lungul timpului, oamenii au fost fascinați de ideea de a crea o interfață care permite mașinilor să “citească” și să interpreteze corect gândurile, pentru execuția automată a unor sarcini. Recentele descoperiri din domeniile neuroștiință și inginerie fac posibilă transpunerea acestei idei, privită în trecut ca un mit, în aplicații care s-au dovedit a fi viabile, dar într-un domeniu restrâns. Deși ideea a persistat cu mult timp în urmă, complexitatea în implementarea acesteia face ca și în zilele noastre, în care tehnologia atinge proporții uriașe evolutive, interfațarea biologicului cu mașinile (roboții/structurile computaționale) să fie o provocare poate mult prea mare. Însă, prin ambiția și perseverența oamenilor de știință, cercetătorilor, acelor oameni avizi de a găsi soluții problemelor care par imposibil de rezolvat, trecerea de la stadiul de prototip la implementarea la scară largă a aplicațiilor de interfațare creier – calculator este doar o noțiune de timp.

Implementarea unei soluții operative de comunicare, venită ca alternativă a utilizării vorbirii, mișcărilor gesticulante ale mâinilor sau a mișcărilor capului, reprezintă un ajutor considerabil în ameliorarea situațiilor persoanelor cu handicap sever, ale căror funcții motorii sunt reduse pe seama unor accidente sau a unor boli ale sistemului locomotor, cum ar fi paraplegia, paralizia sau pierderea unor membre.

Interfețele Computer-Om (HCI) au capacitatea de a pune la dispoziție persoanelor cu traume severe controlul diverselor echipamente computerizate, printr-o cale directă - prin intermediul bioelectricității.

În 1924, Hans Berger a fost primul care a înregistrat activitatea electrică a creierului uman folosind electroencefalografia (EEG). Prin analiza acestor semnale, Berger a fost capabil să identifice activitatea oscilatorie în creier, cum ar fi ritmul alfa (8-12 Hz), de asemenea, cunoscut sub numele de „val Berger”[1].

EEG permite posibilități complet noi de cercetare a activităților creierului uman. Aceasta folosește electrozi plasați direct pe scalp pentru a măsura potențialele electrice generate de activitatea electrică a creierului, ce au o amplitudine mică (5-100 μ V). Din cauza pielii, a țesutului osos (craniu) și a celorlalte țesuturi care separă electrozii de activitatea electrică reală, semnalele tind să fie atenuate și destul de zgomotoase.

Prin urmare, în timp ce măsurătorile EEG au o bună rezoluție temporală cu întârzieri în zeci de milisecunde, rezoluția spațială tinde să fie mică, variind, în cel mai bun caz, la o acuratețe în jur de 2-3 cm, dar de obicei chiar mai puțin. Doi centimetri pe cortexul cerebral poate fi diferența dintre a deduce ca utilizatorul ascultă muzica, când de fapt, acesta își mișcă mâinile. [2]

Așadar, interfața ce are ca punct de pornire potențialele generate de creier (semnalele EEG) are denumirea de “Interfață Creier-Computer”, (BCI – Brain computer interface). Primele aplicații, de interfațare a biologicului cu mașinile, își au originile în cardul domeniului militar. Mediul concurențial a făcut ca aceste aplicații să se dezvolte foarte rapid, iar ideile au fost preluate și implementate ulterior și în alte domenii, cum ar fi medicina sau industria producătoare de jocuri video.

Tehnologia bazată pe BCI reprezintă un instrument puternic de comunicare între sisteme și utilizatori. Un aspect foarte important este acela că în aplicațiile BCI nu este nevoie de intervenția

sistemului muscular. De aceea, unul dintre aspectele principale ale studiilor este acela de a veni în ajutorul persoanelor cu dizabilități, prin implementarea unor soluții care să le îmbunătățească modul de a trăi.

- Obiective

Lucrarea de față urmărește:

- punerea în evidență a importanței semnalelor EEG, achiziționate în cadrul unor experimente cu sarcini motorii
- dezvoltarea unui algoritm de recunoaștere a diferitelor mișcări ale brațelor, urmărind apariția anumitor modele în semnalele EEG înregistrate.
- interfațarea semnalelor EEG achiziționate cu diverse comenzi ale unui braț robotic.

Pașii necesari pentru a îndeplini obiectivele acestei lucrări sunt prezentați în figura de mai jos:




Fig. 1 Etape proiect

Lucrarea este structurată pe șase capitole.

În primul capitol sunt prezentate într-o manieră generală sistemele care au ca element central interfața creier - calculator. Acest capitol pune în evidență fundamentele teoretice și asigură o bibliografie adecvată pentru cei care doresc să aprofundeze noțiunile întâlnite în cadrul acestei lucrări. În cel de-al doilea capitol sunt prezentate pe scurt elementele morfofuncționale ale creierului uman. În capitolul trei este prezentată aparatura utilizată în cadrul achizițiilor de semnale electroencefalografice. Pentru a înțelege mai bine cum funcționează aceasta, este introdus un scurt breviar teoretic în cadrul căruia este descrisă electroencefalografia. În finalul capitolului, este prezentată paradigma experimentală, pe baza căreia au fost achiziționate semnalele EEG. În capitolul patru este descris brațul robotic Jaco. Capitolul cinci, pune în evidență unele dintre metodele de extragere de caracteristici din semnalele EEG. Caracteristicile extrase sunt apoi utilizate în etapa de clasificare, pentru a discrimina sarcinile motorii implicate în experiment. În ultimul capitol sunt prezentate rezultatele obținute în etapa de clasificare și mișcările executate de brațul robotic pentru fiecare clasă în parte.

Capitolul 1. Context și stadiul actual al cercetărilor

O interfață creier- calculator este un sistem care permite unei persoane să trimită comenzi unui dispozitiv electronic, doar prin simpla variație voluntară a activității cerebrale (gânduri) [3][4][5][6][7]. Acești termeni fac referire la o interfață care preia semnale generate de creier și le transmite într-o formă interpretabilă unor dispozitive electronice.

Pașii fundamentali pe care îi urmează un sistem BCI sunt:

- măsurarea activității electrice, magnetice sau orice alte forme de manifestări fizice ale activității oscilatorie a creierului;
- interpretarea semnalelor achizitionate;
- transpunerea semnalelor în comenzi viabile pentru un computer sau diverse alte dispozitive (structuri robotice, scaun cu roțile, elemente bionice).

Cu alte cuvinte, interfața creier – calculator traduce intențiile utilizatorilor, care au un impact asupra semnalului encefalografic, în semnale de comandă pentru diverse dispozitive externe computerizate.

Domeniul BCI s-a dezvoltat încă de la începutul anilor '90. Târziu, luând în considerare că această idee a fost frământată cu mult timp în urmă de mințile iluminate ale timpurilor respective. Însă, este de înțeles acest lucru, având în vedere limitările tehnologice întâmpinate. După anii '90 au început să apară din ce în ce mai multe laboratoare în care se fac studii legate de acest domeniu.

În decursul ultimilor ani, diferite echipe de cercetare au dezvoltat diverse aplicații BCI [8] [9][10][11][12]. Cel mai mare avantaj al sistemelor BCI este acela că nu este nevoie de activarea mușchilor sau structurilor nervoase periferice, iar aplicațiile pot varia de la un domeniu la altul: controlul unui scaun cu roțile[13][14][15], navigare pe internet [16], jocuri[17].

În zilele noastre, cercetătorii au început să dezvolte cu totul alte tipuri de sisteme BCI, care deși sunt într-un stadiu teoretic, nu par a fi imposibil de implementat. Aceste sisteme noi reprezintă o latură semnificativă din cadrul dezvoltării inteligenței artificiale. Ideea fundamentală este de a încărca toate funcțiile creierului într-un ansamblu robotic, oferindu-i acestuia capacitatea de fi autonom (de a lua decizii în câmpul spațiului de variabile aleatoare întâlnite).

1.1. Structura unei interfețe creier – calculator

Interfața creier – calculator are nevoie de o buclă de reacție pentru a putea funcționa în mod corect. De fapt, aceasta funcționează prin interacțiunea unor regulatoare adaptive (adaptive controllers): creierul (privit ca un astfel de regulator care produce semnalele) și interfața însăși, cea care traduce semnalele în comenzi. [18]




Fig. 1.1 Model funcțional pentru un sistem BCI

1.1.1. Metode de înregistrare a activității cerebrale




Fig. 1.2 Metode de achiziție de semnal

Achiziția de semnale cerebrale se poate face în două moduri: invaziv sau neinvaziv.

Prima metodă presupune plasarea unor electrozi direct pe creier, în urma unor intervenții chirurgicale. Avantajul constă în calitatea semnalului achiziționat, nefiind perturbat de mediul pe care l-ar străbate, ca în cazul unei achiziții efectuate pe scalp. Metodele invazive sunt aplicate în cazuri restrânse, unde se dorește o mai bună acuratețe a semnalelor achiziționate. Un alt avantaj este acela că se face analiza doar în zona critică, unde rezidă informația de interes. Însă ținând seama de comportamentul organismului viu de a respinge obiectele străine, există posibilitatea ca în timp, calitatea semnalului să scadă. Astfel, metoda invazivă poate determina dezvoltarea unor țesuturi cicatrizante. Bineînțeles, cel mai mare dezavantaj al acestei proceduri îl reprezintă numărul mare de riscuri la care este supus pacientul. În plus, este nevoie și de implicarea unor cadre medicale pentru a se ajunge la zona de analizat. Comparativ cu metoda neinvazivă, pentru care nu este nevoie de cunoștințe, și pregătire medicală pentru a face o achiziție de date.

În cadrul metodei neinvazive, așa cum și denumirea sugerează, electrozii sunt plasați direct pe scalp, nefiind necesară nici o intervenție chirurgicală. Acest tip de achiziție este cel mai des utilizată în zilele noastre, deoarece nu prezintă nici un risc pentru pacient, dar semnalul recepționat este foarte zgomotos și atenuat de către țesuturile de la nivelul capului (piele, craniu, dura mater, arahnoida și pia mater).

Interfața creier-calculator, se referă la sistemele de comunicare destinate culegerii informației activității corticale (intențiile utilizatorului) și transformarea acestor semnale în controlul și comanda unor dispozitive care sunt destinate îmbunătățirii condiției umane, ca de exemplu o neuroproteză, un calculator, sau un cărucior electric. O interfață creier-calculator bazată pe EEG este compusă din patru module principale: sistem de prelevare semnale EEG, sistem de prelucrare informație, sistem de interpretare date și sistem de control și comandă[19].

Pe plan internațional se fac eforturi deosebite pentru conceperea și realizarea unor echipamente pentru înregistrarea și prelucrarea semnalelor EEG, folosite în cadrul sistemelor BCI.

În Fig. 1.3 se prezintă schema bloc a unui sistem modern de achiziție și procesare a semnalelor EEG.




Fig. 1.3 Schemă bloc - sistem de achiziție și procesare semnale EEG [19]

Particularitățile esențiale ale echipamentelor de înregistrare și prelucrare a semnalelor EEG, destinate sistemelor BCI, prin care se diferențiază de sistemele EEG tradiționale, sunt următoarele:

- electrod activ de măsurare de concepție nouă
- condiționarea semnalului analogic completată cu condiționare numerică
- conversie analog numerică de concepție nouă
- transmisie fără fir a semnalelor
- preprocesare numerică la nivel de electrod activ distribuit
- procesarea numerică adaptivă, corelată cu numărul mare de canale EEG (64-256)
- reducerea extremă a consumului de energie și metode speciale (neconvenționale) de alimentare
- rezistență ridicată la perturbații, recunoașterea și eliminarea artefactelor
- miniaturizarea și portabilitatea echipamentului, fără a deranja activitatea normală a persoanei

Pentru realizarea obiectivelor enumerate mai sus, este nevoie de o activitate intensă de cercetare în vederea identificării metodelor și variantelor potrivite, modelarea, experimentarea și verificarea soluțiilor optime.

Astfel, electrodul de prelevare de semnale trebuie să se bazeze pe un nou principiu. Electrozii actuali (cu contact direct) au avantajul prezentării unui contact bun cu rezistența scăzută (datorită gelului conductor folosit), o sensibilitate scăzută la zgomote și tensiuni de polarizare, dar prezintă marele dezavantaj (eliminatoriu în cazul echipamentelor destinate BCI), că scalpul trebuie preparat înaintea aplicării electrozilor, iar efectul preparării nu durează mult, de regulă după 1-2 ore de măsurări trebuie făcute corecții și intervenții.

De asemenea întreg lanțul de condiționare al semnalelor (diferențiere, preamplificare, filtrare analogică, amplificare, conversie analog-numerică, filtrare digitală, preprocesare numerică) trebuie să fie de actualitate, cel puțin din 5 motive principale: parametri semnalelor prelevate (amplitudine, impedanță, fază, etc.) se modifică radical din cauza noilor condiții; cel puțin canalul analogic de condiționare trebuie integrat în electrodul de măsură pentru a satisface noile condiții; canalul digital va trebui să preia o parte a funcțiilor canalului analogic și suplimentar va trebui să conțină unele funcții noi (filtrare adaptivă, amplificare digitală, compresie de date, etc.); întreg lanțul de condiționare trebuie să fie portabil (să fie purtat pe cap o perioadă lungă de timp), de unde rezultă necesitatea folosirii unor tehnologii speciale (miniaturizare extremă, utilizarea unor module și componente electronice puternic integrate, folosirea unor componente cu consum de energie ultra-redus); folosirea tehnicii de comunicare fără fir (wireless) între modulele echipamentului.

În sfârșit, prelucrarea numerică a semnalelor, la nivel de echipament trebuie să se adapteze radical noilor condiții. O parte din procesele matematice de conversie și analiză a datelor extrasă din semnalele achiziționate, trebuie executate la nivel de microcontrolere, distribuite în lanțul de achiziție, pentru a face față cerințelor de interpretare a datelor în timp real și a permite următoarelor module din lanțul de echipamente BCI de a interveni și a controla elementele de acționare din cadrul sistemului.[19]

1.1.2. Prelucrarea semnalelor EEG

Majoritatea semnalelor regăsite în practică au caracter nestaționar. Astfel, informația vizată se poate extrage din parametri statistici, spațiali, temporali și nu în ultimul rând din domeniul frecvență. Semnalele video și semnalele vocale sunt unele din cele mai reprezentative din categoria celor nestaționare. De-a lungul timpului, acestea au primit cea mai mare atenție în domeniul telecomunicațiilor și pe baza lor s-au dezvoltat numeroase tehnici de prelucrare, de la aplicarea diverselor filtre, până la implementarea mai multor transformări ce fac trecerea din timp în frecvență și invers. În cazul analizei Fourier, parametrii semnalului sunt analizați într-o manieră globală, lucru determinat de domeniul de integrare de la minus infinit la plus infinit, din expresia transformatei Fourier directe și inverse. Astfel, noțiuni importante legate de localizarea spațială și temporală a semnalelor dispar. În cadrul aplicațiilor unde analiza este făcută în timp real, iar semnalul este tratat pe baza sosirii datelor nu se poate calcula transformata Fourier, deoarece aceasta se aplică pe întreg semnalul. Un alt dezavantaj este acela că spectrul semnalului este afectat de existența unei porțiuni alterate, apărute în cadrul semnalului. Se poate concluziona foarte ușor că transformata Fourier clasică nu poate fi utilizată în aplicațiile care implică analiza semnalelor nestaționare sau proceselor de timp real. O modalitate de a evita această problemă este de a analiza semnalul pe mai multe subintervale.

Câteva soluții alternative pentru analiza semnalelor în timp real sunt: transformata wavelet, transformata Wigner – Ville, transformata Gabor, transformata Fourier pe termen scurt. În cadrul acestor transformări reprezentarea este de tipul timp – frecvență. Un dezavantaj al transformării Fourier pe termen scurt este acela că rezoluția timp - frecvență rămâne neschimbată pe întreg semnalul. Însă, transformarea wavelet permite obținerea de mai multe rezoluții timp - frecvență prin folosirea de ferestre temporale variabile.

Majoritatea semnalelor biomedicale sunt definite de anumite ritmuri, periodicități și forme de undă. În cazul semnalelor generate de creier, este mai ușor să le analizăm și percepem în termeni de frecvență și nu în unități temporale. Pentru semnalele EEG este mult mai ușor să exprimăm ritmul beta ca fiind 20,5 Hz, decât echivalentul său în timp 0.048 s. Caracteristicile semnalelor pot fi mai bine puse în evidență prin aplicarea transformatei Fourier - obținerii distribuției energiei și puterii semnalului în domeniul frecvență.

Cum semnalele EEG sunt semnale nestăționare, analiza lor spectrală devine problematică. Astfel, se încearcă identificarea unor metode noi de analizare a acestora. La aplicarea unui stimul, creierul are un răspuns întotdeauna. Acest răspuns poate fi definit prin apariția unei componente spectrale. Este de mare interes a se cunoaște momentul în care intervine componenta spectrală.

Un sistem BCI înregistrează și procesează semnalele cerebrale (EEG) în mod continuu (și în timp real) urmărind intențiile utilizatorilor. Prelucrarea semnalelor însumează trei etape: preprocesarea, extragerea de trăsături și clasificarea.

Preprocesarea

Așa cum au fost enumerate, sunt puse în ordinea cronologică a execuției lor. Se aplică mai întâi preprocesarea pentru a mări raportul semnal zgomot al semnalului. După achiziție, zgomotul apărut în semnal trebuie înlăturat. Semnalul achiziționat este foarte zgomotos din cauza activității de fond a creierului, care nu are nici o legătură cu experimentul efectuat. În plus, în semnal se regăsesc numeroase artefacte, generate de musculatura facială sau clipitul. Faptul că semnalul corespunzător artefactelor are o amplitudine mai ridicată, face dificilă extragerea informației utile din acesta. Alfel spus, înlăturarea artefactelor poate duce la deteriorarea semnalului. Etapa de preprocesare presupune reducerea numărului de caracteristici și selecția doar anumitor canale, pentru a reduce volumul de date și zgomotele ce pot apărea.

Există numeroase tehnici de preprocesare a semnalelor în domeniul BCI. Cele mai uzuale sunt filtrele spațiale și filtrele temporale. Cele temporale cuprind: filtrele trece-jos (FTJ), filtrele trece-sus (FTS), filtrele trece-bandă. Scopul utilizării acestor filtre este de a reduce domeniul de frecvență în care se face analiza. În cele mai multe situații este cunoscut domeniul de frecvență în care semnalele neurofiziologice sunt localizate. Spre exemplu, sistemele BCI bazate pe ritmurile senzomotorii folosesc un filtru trece-bandă între 8 și 30 de Hz. Studiile anterioare au demonstrat că în intervalul 8-30 Hz sunt localizate ritmurile cerebrale alfa (8-12 Hz) și beta (13-30 Hz).

Această metodă de filtrare este de asemenea utilă pentru a elimina variațiile slabe ale semnalelor EEG și interferența cu linia de alimentare. Scopul utilizării filtrelor temporale este de a reduce influența frecvențelor din afara domeniului de interes. Acest tip de filtrare este îndeplinit prin aplicarea Transformatei Fourier Discrete (DFT), sau utilizarea filtrelor cu Răspuns Finit la Impuls (FIR)/ Răspuns Infinit la Impuls (IIR).

Filtrele spațiale sunt similare cu cele temporale și sunt utilizate pentru a izola informații spațiale relevante, în situațiile în care se dorește concentrarea doar asupra unei anumite zone a creierului, depinzând de sarcina mentală executată. Această metodă presupune selecția anumitor canale sau definirea unor proporții, în contribuția anumitor electrozi. După cum știm, atunci când ne concentrăm asupra mișcărilor mâinilor, zona de interes este aria cortexului motor sau senzomotor.

Astfel, se vor face analize pe canalele C3 și C4 împreună cu cele adiacente lor, definind un filtru spațial. De asemenea, electrozii folosiți în cadrul experimentelor SSVEP sunt O1 și O2, localizați în zona occipitală a capului, responsabilă de procesarea vizuală.

Exemple de filtre spațiale utilizate: filtru Laplace, Referința Medie Comună (CAR)

Metoda "Common spatial patterns" este bazată pe descompunerea semnalelor EEG în modele spațiale[20][21][22]. Numărul de modele spațiale sunt alese în sensul de a maximiza diferențele dintre clasele implicate. Determinarea acestor modele este realizată prin diagonalizarea matricei de covariație a semnalelor EEG a fiecărei clase implicate[23].

Metoda "soluției inverse" este relevantă dar cel mai puțin utilizată în cadrul sistemelor BCI.

Această metodă încearcă să reconstruiască activitatea cerebrală utilizând doar măsuratori efectuate pe scalp și un model al capului[23][24][25].

Așa cum s-a arătat mai sus, partea de preprocesare a semnalelor este foarte diversificată, dar alegerea celei mai bune metode sau combinații între acestea, încă nu a fost identificată.

Partea de preprocesare are ca intrare semnale EEG și ca ieșire tot semnale, caracterizate de faptul că informația utilă se află în proporții mai mari comparativ cu zgomotul, diferit de semnalul de intrare al cărui raport semnal zgomot este mic. Acest lucru are un caracter mai mult teoretic, deoarece în practică este o misiune grea să separi artefactele și zgomotul de fond de semnalul util, în cadrul aplicațiilor.

Cu toate acestea, cea mai apreciată și utilizată metodă de preprocesare este reprezentată de filtrarea spațială. S-a arătat că aceasta reduce drastic zgomotul, astfel, îmbunătățind performanțele sistemului, dacă se lucrează cu un număr suficient de electrozi.

Extragerea de trăsături

În această secțiune vom discuta despre câteva metode de extracție care au captat mai multă atenție în cadrul sistemelor BCI.

Având de a face cu semnale EEG se vor genera cantități mari de date. Cercetătorii lucrează cu un număr de electrozi variind de la 1 la 265 și cu o frecvență de eșantionare de la 100 până la 1000 Hz. Din cauza volumului mare de date achiziționate este necesară etapa extragerii de trăsături, care selectează doar informația utilă din setul de date.

Este esențial să se extragă doar datele necesare pentru sistem, altfel algoritmul de clasificare va întâmpina probleme sau chiar îi va fi imposibil să ia decizii. Este important ca numărul de caracteristici extrase din datele de intrare să fie mic și în același timp datele să fie relevante pentru algoritmul de clasificare.

În cadrul cercetărilor BCI, metodele de extracție de parametri au fost divizate în patru mari categorii:

- Modelare parametrică
- Metode de reprezentare în timp
- Metode de reprezentare în frecvență
- Metode de reprezentare timp-frecvență

Deasemenea, există și alte metode care nu sunt încadrate în aceste categorii, precum dinamica neliniară, LDA și multe altele.

Metode de reprezentare în timp

Aceste metode folosesc drept caracteristici, variațiile temporale ale semnalului analizat. Sunt adaptate perfect pentru procesele specifice de timp, precum P300 sau ERD/ERS, mai notabile fiind cele în care se folosește imaginarea motorie[23].

Metode de reprezentare în frecvență

Caracteristicile extrase din domeniul frecvență sunt utilizate des în cadrul procesării semnalelor datorită ușurinței lor de aplicare, vitezei de calcul și interpretării directe a rezultatelor. Mai specific, aproape o treime din sistemele BCI au fost dezvoltate pe baza caracteristicilor extrase din spectrul de putere al semnalelor. Ținând seama de caracterul nestăionar al semnalelor EEG, aceste caracteristici nu dau nici o informație despre domeniul timp.

Metode de reprezentare timp-frecvență

Metodele de extragere de caracteristici ce utilizează reprezentarea timp-frecvență au demonstrat că pot îmbunătăți performanțele sistemelor. Acestea mapează un semnal unidimensional în funcții bidimensionale de timp și frecvență, și sunt utilizate pentru a analiza variația în timp a conținutului spectral al semnalului.

Modelare parametrică

Modelare parametrică presupune că intervalele de timp, extrase din semnal, supuse analizei, să fie ieșirea unui model matematic dat. Metoda necesită o alegere a priori a structurii semnalelor și ordinii în care sunt generate acestea.




Fig. 1.4 Metode de extracție de caracteristici din cardul sistemelor BCI bazate pe activitatea senzomotorie, VEP, SCP, P300, răspuns la sarcini mentale, activitatea neuronilor și multe alte neuromecanisme. [26]

Alegerea metodei potrivite de extragere a caracteristicilor este un pas primordial în proiectarea de sisteme BCI, dar domeniul BCI a demonstrat că nu există o metodă perfectă, aplicabilă în toate cazurile, ci există doar subiecți specifici metodei alese. Bineînțeles, aceasta înseamnă că metodele de extragere de parametri pot fi adaptate pe subiecți (ajustarea în banda de frecvențe ale utilizatorului), în vederea obținerii unor rezultate mai bune.

Clasificarea

Al treilea pas în crearea unui sistem BCI îl reprezintă etapa de clasificare. Acest pas este esențial deoarece în cadrul lui caracteristicile sunt convertite în comenzi.

În etapa de clasificare se construiește un model pe baza unor date de învățare, care apoi este aplicat pe alte seturi de date, fie ele de test sau tot de antrenare.

Principial, clasificarea constă în identificarea clasei corespunzătoare unui vector de intrare x , folosind o funcție f de mapare, unde f este învățată dintr-un set de antrenare T . Clasa reprezintă starea mentală a utilizatorului. Scopul etapei de antrenare este de a asigura algoritmului date preclasificate și marcate corespunzător, din care algoritmul construiește maparea în sensul prezicerii, pentru noi date de intrare, a marker-ilor corespunzători [27].

Clasificatorii sunt împărțiți în cinci categorii:

1. Clasificatori liniari

- folosesc funcții liniare pentru a distinge clasele
- cele mai utilizate: Support Vector Machines (SVM) și Linear Discriminant Analysis (LDA)
- sunt cei mai populari în domeniul BCI

2. Rețelele neuronale

- sunt structuri de neuroni artificiali care iau decizii și definesc granițele dintre clase (nu mereu granițele sunt definite doar de un plan de separație, ci de structuri neliniare)
- împreună cu clasificatorii liniari sunt cele mai utilizate în sistemele BCI
- cea mai utilizată rețea neuronală este MultiLayerPerceptron (MLP)
- alte rețele importante utilizate sunt Radial Basis Function (RBF) și Learning Vector

Quantization (LVQ)

3. Clasificatori neliniari Bayes

- sunt mai preciși decât cei liniari, dar nu sunt atât de simpli și eficienți
- cei mai utilizați sunt cuadratura Bayes și Hidden Markov Model (HMM)

4. Clasificatori din categoria “cei mai apropiați vecini”

- principiul este de a atribui unui vector de caracteristici o clasă ținând seama de cei mai apropiați vecini ai acestuia
- cele mai utilizate tehnici sunt “Cei mai apropiați K vecini” (K-NN) și distanța Mahalanobis

5. Clasificatori combinați

- de regulă se folosește o singură tehnică de clasificare în cadrul unei interfețe, însă au apărut modele care folosesc tehnici agregate
- există diferite strategii de combinare a tipurilor de clasificatori: Boosting, Voting, Stacking, etc.

1.1.3. Controlul dispozitivelor. Aplicații

În decursul anilor, sistemele BCI au fost integrate în numeroase aplicații, cu diferite grade de complexitate. De asemenea, domeniile în care pot fi întâlnite aplicațiile BCI variază foarte mult, de la medicină, prevenție, diagnoză, securitate, la industria producătoare de jocuri și divertisment.




Fig. 1.5 Domeniile de aplicare a sistemelor BCI

Domeniul medical are o varietate de aplicații care scot în evidență avantajele semnalelor generate de creier, asociate unor stări mentale sau unui comportament nedorit, în cazul unor boli neurologice. Aceste semnale pot da informații utile în cazul prevenției, detecției și diagnozei, reabilitării și restaurării condiției umane.



Fig. 1.6 Utilitatea sistemelor BCI în domeniul medical

Prevenția

Cercetătorii din domeniu au dezvoltat numeroase sisteme de determinare a nivelului de conștiință, analizând activitatea cerebrală. S-a încercat scoaterea la lumină a influenței pe care o au fumatul și alcoolul asupra undelor cerebrale [28][29][30]. Aceste studii au o importanță destul de mare în prevenirea posibilelor disfuncționalități ale creierului, sau descreșteri nivelului de alertă rezultat din consumul de alcool sau fumat. În cadrul acestor studii cercetătorii au trecut prin mai multe etape, pentru a ajunge la un rezultat concret. Inițial, nu exista nici certitudinea locației activității cele mai evidente și edificatoare din creier, care sunt în strânsă legătură cu fumatul sau consumul de alcool. Astfel, au fost necesare studii preliminare de detecție a acestor zone, urmărind întreaga activitate cerebrală.

Accidentele rutiere sunt considerate ca fiind una din cele mai mari cauze a decesurilor sau a leziunilor severe. Modalitățile de prevenție a acestora a fost și este preocuparea multor cercetători din diverse domenii. Cele mai studiate probleme sunt cele legate de mișcările involuntare ale sistemului locomotor (cauză a multor accidente). Mișcările involuntare apar atunci când sunt transmise către creier informații senzoriale eronate generate de corp, ochi sau urechi. Aceste disfuncționalități nu pot fi permise în mediul transportului, unde persoanele ar trebui să fie capabile să mențină controlul asupra propriilor mișcări. Fiind foarte dificil să menții atenția și controlul tot timpul este necesar un sistem de monitorizare și de alertă. O soluție ar fi monitorizarea activității cerebrale prin intermediul unor sisteme de analiză și control. În cadrul unui studiu bazat pe disfuncționalitățile motorii, s-a creat o platformă virtuală utilizând un sistem EEG de achiziție cu 32 de canale și un joystick, care monitorizează în timp real mișcările involuntare.

Detecția și diagnoza

Monitorizarea activității cerebrale prin intermediul sistemelor BCI contribuie enorm la detecția anumitor probleme legate de structura sau activitatea creierului, cum ar fi tumorile cerebrale, epilepsia, narcolepsia, encefalita s.a.m.d.. Tumorile, care sunt rezultatul divizării necontrolate a celulelor pot fi descoperite folosind electroencefalograma, ca o alternativă mai ieftină pentru MRI și CT-SCAN. În cadrul studiului [31], s-a dezvoltat un sistem de recunoaștere al anomaliilor, din semnalele EEG asociate cu tumorile cerebrale și gradul de severitate al epilepsiei.

Dislexia, poate fi diagnosticată măsurând activitatea creierului. Această boală influențează capacitatea de a citi și de a învăța, iar detecția ei într-un stadiu incipient poate ajuta persoanele să nu-și piardă încrederea în sine și să-și dezvolte propriile aptitudini și cunoștințe. Dereglările somnului pot fi detectate prin sisteme BCI, așa cum este susținut și în studiul [32].

Reabilitarea și restaurarea

Reabilitarea mobilității este o formă fizică de reabilitare care ajută persoanele cu deficiențe motorii să-și recapete abilitatea de a se mișca[33]. Persoanele care și-au pierdut anumite funcții motorii în urma unor accidente, pot prin intermediul sistemelor BCI să se recupereze complet. În urma obstrucției curgerii sângelui, celule sunt private de oxigen, iar structuri importante din creier pot fi deteriorate. Aceste condiții pot apărea prin atacuri cerebrale sau lovituri severe la cap. Pacienții își pot pierde abilitatea de a vorbi, pot avea probleme cu memoria, sau o anumită parte a corpului poate paraliza.

Roboții mobili pot fi utilizați pentru a îndeplini sarcini zilnice în folosul persoanelor complet imobilizate. Pacienții care nu-și pot recăpăta mobilitatea anumitor membre, pot beneficia de implanturi intracerebrale și un braț mobil care să fie controlat de creier.

Semnalele corelate cu imaginarea motorie reprezintă de asemenea o latură importantă în dezvoltarea sistemelor BCI cu buclă de reacție, utilizate în cadrul terapiei de recăpătare a funcțiilor motorii. Rezultate semnificative de clasificare și de comparare a diverselor sarcini de imaginare motorie au fost obținute în studiul [34].

Așa cum s-a menționat mai sus, aplicațiile BCI nu sunt exclusive pentru domeniul medical. Interfețele creier-calculator pot fi exploatate pentru a oferi avantaje oamenilor din multe puncte de vedere: confort, transport, control fiziologic, siguranță și securitate.

Oamenii din zona industriei producătoare de jocuri video au un interes deosebit în a implementa asemenea interfețe, care să apropie tot mai mult lumea virtuală de spațiul realității. Diferite jocuri au fost concepute pe baza principiilor de funcționare a sistemelor BCI, în care obiectele din spațiul virtual sunt comandate direct prin capabilitățile creierului. Câteva exemple de astfel de jocuri sunt: BrianArena (utilizează imaginarea mișcărilor brațelor), Brainball (monitorizează nivelul stresului).

Capitolul 2. Elemente de fiziologie

O structură biologică poate fi văzută ca generator de semnal electric sau electromagnetic, generator electric indirect, prin culegere de semnale cu ajutorul unor traductoare.

Oamenii de știință au două direcții în studiul modalității de funcționare a creierului. Una din metode este studierea funcțiilor creierului după ce o parte a creierului a fost distrusă. Funcțiile care dispar, sau care nu mai sunt normale după alterarea anumitor regiuni ale creierului pot fi deseori asociate cu regiunile lezate. Cea de-a doua direcție este studierea răspunsului creierului la stimulare directă sau stimularea anumitor organe de simț.

Neuronii sunt împărțiți după funcții în grupuri de celule numite nuclee. Aceste nuclee sunt conectate la senzori motori și alte sisteme. Neuronii pot fi clasificați și în funcție de direcția în care transmit informația:

- neuroni senzitivi (aferenți) -> trimit informația de la receptorii senzitivi (situați în ochi, urechi, nas, limbă, piele) către sistemul nervos central.

- neuronii motorii (eferenți) -> trimit informația de la sistemul nervos central către mușchi sau glande

- interneuronii -> trimit informația între neuronii motori și cei senzitivi. Aceștia se află în mare parte localizați în sistemul nervos central.

Oamenii de știință pot studia funcțiile somatosenzorilor (durerea și atingerea), motoare, olfactive, vizuale, auditive, cât și a altor sisteme care măsoară schimbările fiziologice (fizice și chimice) care apar în creier atunci când aceste simțuri sunt activate.

De exemplu, electroencefalograma (EEG) măsoară activitatea electrică a unor anumitor grupuri de neuroni, prin electrozi atașați suprafeței creierului. Electrozii inserați direct în creier pot analiza activitatea unui număr restrâns de neuroni. Schimbările în debitul sanguin, glucoza, consumul de oxigen în grupul unor celule active pot fi de asemenea observate. [35]

2.1. Noțiuni fundamentale - structura creierului

„Creierul este un țesut alcătuit din aproape 14 miliarde de celule nervoase care prezintă un anumit grad de interconectare. Creierul este alcătuit din două emisfere cerebrale, fiecare prezentând scizuri care separă patru lobi cerebrali:

- frontal (responsabil de controlul aparatului locomotor și al organelor interne)
- parietal (cu rol de analizor senzitiv)
- occipital (responsabil de analiza optică)
- temporal (responsabil de funcțiile limbajului, analizor acustic, arie de protecție vestibulară)

Creierul funcționează cu ajutorul unor circuite neuronale, sau celule nervoase. Comunicarea între neuroni este atât electrică cât și chimică și călătorește întotdeauna de la dendritele unui neuron, prin soma, prin axon, către dendritele unui alt neuron. Dendritele unui neuron primesc semnale de la axonii altor neuroni prin structuri chimice, numite neurotransmițători. Neurotransmițătorii produc o încărcare electrochimică în soma. Soma integrează informația, care este apoi transmisă electrochimic mai departe de axon.

Neuronul este unitatea morfofuncțională a sistemului nervos.

Acesta îndeplinește următoarele funcții:

- captează informații de la alți neuroni;

- execută o însumare temporală și spațială a potențialelor de stimulare excitatorie sau inhibatorie;
- conduce potențialele de acțiune de-a lungul uneia din prelungirile corpului celular (axonului);
- transmite informația altor neuroni sau celule efectoare.

Transmisia informației prin neuroni se face prin eliberarea din neuronul presinaptic a unei substanțe cu rol de mediator chimic, care depolarizează membrana celulei post sinaptice.

Amplitudinea potențialului de acțiune al unei celule nervoase este constantă, rezultând că transportul de informație prin fibrele nervoase se face prin modulația în frecvență a impulsului de depolarizare. Transmisia și prelucrarea informației se face prin secvențe de impulsuri care constituie cuvinte de cod.[35]

Ritmurile cerebrale sunt împărțite în cinci categorii, având criteriu de clasificare, benzile de frecvență caracteristice:

- ritmul delta (cu frecvențe sub 4 Hz)
- ritmul teta (cu frecvențe cuprinse între 4 și 7 Hz)
- ritmul alfa (cu frecvențe cuprinse între 8 și 12 Hz)
- ritmul beta (cu frecvențe cuprinse între 13 și 30 Hz)
- ritmul gama (cu frecvențe ce depășesc 30 Hz)

Ritmul alfa întâlnit în zona sensorimotorie poartă numele de ritm mu. O descreștere în activitatea oscilatorie într-o bandă de frecvențe poartă numele de desincronizare (ERD) [36]. Fenomenul invers și anume creșterea activității oscilatorii într-o anumită bandă de frecvențe poartă denumirea de sincronizare (ERS). Benzile de frecvențe analizate din semnalele EEG achiziționate, în cadrul acestei lucrări sunt cele corespunzătoare ritmurilor alfa și beta.

Zona analizată în cadrul acestei lucrări cuprinde aria cortexului motor și sensorimotor.




Fig. 2.1 Cortex motor și somatosenzorial [38]

Pentru a înțelege ce se întâmplă în creierul nostru atunci când acesta procesează senzația stării actuale a fizicului (conștientizarea orientării exacte a mâinilor, a ochilor, a capului) trebuie să înțelegem cum funcționează acesta. Nu trebuie să cădem în iluzia faptului că o senzație precum orientarea corpului nostru este un proces prea ordinar pentru a nu se mai menționa despre el. Realitatea este că acest proces minimal solicită o putere mare computațională a creierului, iar acesta

este un motiv suficient de bun pentru ca oamenii de știință entuziaști să exploreze pe acesta temă. Pentru a înțelege cum funcționează creierul trebuie să ținem seama și de felul în care acesta interacționează cu restul corpului și cu mediul înconjurător. Dar pentru a relaționa cu mediul înconjurător creierul are nevoie de senzori. Mentea construiește un sens al spațiului în care ne aflăm prin combinarea mai multor simțuri care includ vederea, auzul, simțul tactil, poziția corpului, balansul și mișcările. Acesta este un proces extrem de complex care angajează coerent toate simțurile corpului pentru a oferi o informație clară despre starea prezentă a corpului și a mediului înconjurător. Acest proces de conștientizare include o monitorizare continuă a senzorilor corpului.

În continuare, ne vom concentra asupra tematicii legate de conștientizarea poziției corpului (și a mișcărilor efectuate) și procesele cerebrale implicate. Sunt două tipuri de senzori implicați în monitorizarea poziției corpului, sau mai specific a pozițiilor mușchilor și anume: GTO (Golgi Tendon Organs) și MSR (Muscle Spindle Receptors). Semnalele combinate provenite de la acestea permit creierului să perceapă configurația corpului cu o acuratețe crescută. Sensorii GTO măsoară tensiunea din mușchi și sunt localizați la joncțiunea dintre mușchi și tendoane, în timp ce senzorii MSR sunt localizați în interiorul mușchilor și măsoară lungimea acestora. Făcând abstracție de acești termeni și raportându-ne doar la procesul în sine, este impresionant cum creierul uman poate procesa un asemenea volum de informații la fiecare milisecundă a existenței noastre și făcând asta doar pentru a conștientiza configurația prezentă a corpului. Acest proces are loc chiar și atunci când nu ne mișcăm deloc. Ținând seama de faptul că pe lângă acest proces, creierul mai are numeroase informații senzoriale de prelucrat, precum cele provenite de la ochi sau urechi, volumul de date este enorm, iar puterea computațională a creierului este impresionantă. S-a recurs la următorul experiment - "Vibratory Myesthetic Illusion". Această demonstrație arată că apare iluzia că ne mișcăm atunci când se aplică vibrații mușchilor. De exemplu, când o vibrație este aplicată bicepsilor, se creează iluzia că mâna se mișcă. Vibrația simulează contracția mușchilor, contracție care apare când mușchii se mișcă, de fapt. Experimentul presupune acoperirea ochilor, deoarece vederea are abilitatea de a întrece simțul poziționării corpului, iar abilitatea de conștientizare a stării prezente nu mai poate fi inhibată.

Secțiunea anterioară acoperă doar partea de simțuri. Devine mult mai interesant de înțeles cum acești stimuli fizici sunt convertiți în semnale electrice și transmiși către creier. Generarea unui semnal electric dintr-o forță mecanică, într-un neuron, implică procesul numit mecanotransducție. Mecanotransducția este procesul prin care celulele convertesc stimulii mecanici în activitate chimică, care mai departe crează un potențial de acțiune, numindu-se și potențial de activare a neuronului. Acest potențial este rezultatul mai multor procese chimice ce se desfășoară în cascadă, generate de un stimul fizic inițial. Nu se cunoaște exact cum GTO și MSR activează aceste procese. Poate că forța mecanică deschide direct canale ionice sau modifică forma unei proteine pentru a seta un lanț biochimic ce provoacă generarea de semnale.

Celulele vii îndeplinesc funcții diverse. Receptorii, fibra musculară, fibra nervoasă și neuronii răspund la stimulare printr-un potențial de acțiune. Celula este definită de următoarele elemente constitutive: nucleu, citoplasma, membrana (componentă esențială în ceea ce privește activitatea electrică a celulei). În organism celulele pot fi asociate în grupuri, formând țesuturi, sau pot fi libere într-un mediu lichid. Fiecare celulă trece prin trei etape de-a lungul existenței sale: faza inițială nediferențiată, faza de diferențiere urmată de faza de îmbătrânire.

Activitatea unei celule poate fi urmărită la nivelul membranei celulare prin concentrațiile de ioni din interiorul și exteriorul celulei sau prin schimburile de ioni care au loc între celulă și exteriorul ei. Concentrația diferită de ioni determină ca potențialul în interiorul celulei să fie de aproximativ -90 mV față de lichidul interstițial. Membrana celulară "pompează" ioni în ambele direcții, dinspre și către celulă, asigurând un echilibru dinamic. Aceasta are un caracter selectiv și prezența ei face ca potențialul din interiorul celulei să fie diferit de cel din exterior. Potențialul electric se poate calcula cu formula lui Nerst:

$$V = 61,6 \lg \frac{C_{int}}{C_{ext}} \quad [mV]$$

O concentrație de ioni de K^+ mai mare de 30 de ori în exterior față de cea din interior caracterizează celula ca fiind în starea polarizată. În această situație potențialul din interiorul celulei poartă numele de potențial de repaus celular. În starea de echilibru curentul total prin membrană este nul, iar potențialul de repaus calculat este de -90 mV.

Atunci când se acționează din exterior cu stimuli mecanici, electrici, termici și chimici, caracteristicile membranei celulare se schimbă. Membrana celulară va deschide porți pentru ca ionii de Na^+ să pătrundă în celulă, astfel mărind potențialul electric din exterior. Pentru un stimul suficient de puternic, potențialul din interior atinge o valoare de prag de la care celula, printr-un fenomen de avalanșă, intră într-o stare de depolarizare. Această stare nu durează, iar celula revine în starea polarizată într-un timp scurt.

Potențialul de acțiune al celulei poate fi monitorizat prin plasarea unor electrozi în interiorul și exteriorul acesteia. În acest fel, se pot determina formele de undă și intervalele de valori ale tensiunii, pentru diferite celule.

Potențialul neuronilor aflați în starea de repaus este de -70 mV. Printr-un proces cascada, potențialul de acțiune sau de activare a neuronului atinge valori până la +40 mV. Diagrama de mai jos ilustrează clar producerea unui potențial de acțiune.




Fig. 2.2 Potențialul de acțiune generat de un neuron

Procesul începe prin deschiderea de canale de sodiu, pentru ca ionii pozitivi ai acestuia să pătrundă în interiorul celulei, creând un potențial electric pozitiv. Ionii de sodiu pătrund în interiorul celulei până se atinge valoarea +40 mV, moment în care începe procesul de depolarizare.

Foarte important de menționat este faptul că informația vizată nu se regăsește în forma de undă sau valorile potențialului de acțiune ale neuronului. Altfel spus neuronii nu stransmit informație bazată pe nivelurile de tensiune sau forma de undă a potențialelor de acțiune, ci mai degrabă bazată pe frecvența cu care aceștia sunt activați. Se poate spune că potențialele de acțiune sunt identice, iar informația semnificativă se regăsește în frecvența de apariție a acestora.

Simțurile corpului sunt mapate cu regiuni specifice ale creierului, iar toate aceste asocieri se regăsesc pe harta somatotopică (Fig. 2.1).

2.2. Aspecte practice

Achiziția de semnale cerebrale reprezintă un pas esențial în comunicarea dintre creier și calculator. Un ansamblu BCI are datoria de a reduce volumul de date înregistrate, de a extrage caracteristicile esențiale din setul de date, și de a clasifica trăsăturile specifice diferitelor sarcini mentale sau activități.

Artefactul este deosebit de important în analiza EEG, deoarece chiar și experții din domeniu îl pot confunda cu zgomotul. Artefacte comune includ semnale care au depășit dinamica gamă de amplificare (tensiune prea mare din cauza setărilor de amplificare necorespunzătoare sau mișcarea electrozilor pe piele). Un alt tip comun de artefact este cauzat de prezența unui semnal suplimentar aflat în afara intervalului de frecvență EEG. Acest tip de semnal ar putea proveni de la activitatea electrică a mușchilor sau de la liniile de alimentare.

În cazul în care frecvența de eșantionare este suficient de mare, acest tip de artefacte pot fi filtrate, păstrându-se doar semnalul EEG util.

Alte tipuri de artefacte: activitatea electrică a inimii (se comporta ca o pompă de artefacte) - apar în gama de frecvențe de interes a EEG și pot fi de obicei recunoscute ușor.

Fiecare interacțiune între neuroni generează o descarcare electrică, foarte mică. Este imposibil de măsurat din afara craniului acest fenomen. Însă o stare mentală poate produce concomitent sute de mii de descărcări electrice, care însumate pot genera un curent electric măsurabil.

Potențialele undelor alfa (8-13 Hz), au valori cuprinse între 10 și 120 μV , în starea de relaxare. Potențialele undelor beta (14-30 Hz), au valori cuprinse între 5 și 30 μV , în starea de activitate mentală.

Mișcarea mâinii drepte este asociată sincronizării din partea stângă a creierului. Astfel, putem afirma că dacă mișcăm mâna dreaptă, activitatea mai intensă va fi înregistrată pe partea stângă a creierului [37]. Fiecare emisferă cerebrală controlează jumătatea contralaterală a corpului.




Fig. 2.3 Emisferele cerebrale

Capitolul 3. Achiziția semnalelor electroencefalografice

3.1. Noțiuni introductive

Primul pas în cadrul cercetărilor îl reprezintă achiziția de semnale EEG. EEG este o soluție sigură, rapidă, neinvazivă și economică. În plus, nu necesită o pregătire laborioasă a subiecților.

Avantajele electroencefalogramelor

În ciuda sensibilității spațiale slabe, EEG posedă multiple avantaje față de celelalte tehnici de analiză a creierului uman (fMRI, MEG, etc.):

- costurile de implementare hardware sunt reduse semnificativ.
- gradul de disponibilitate al acestei tehnologii este mult peste cel al celorlalte tehnici, putând fi implementată în orice spital.
- senzorii EEG pot fi folosiți în mai multe locații decât cei ai tehnicilor fMRI, SPECT, PET, MRS sau MEG, tehnici care necesită echipamente voluminoase și imobile. Spre exemplu, tehnica MEG utilizează detectoare ale variațiilor de magnetism (SQUID), fiind foarte sensibile la perturbațiile magnetice (lucrând în heliu lichid, aproape de zero absolut și în camere ecranate magnetic).
- are rezoluții temporale foarte ridicate, de ordinul milisecundelor. De regulă achiziția semnalelor EEG se face cu o frecvență de eșantionare cuprinsă între 250 și 2000 Hz, însă există aparatură capabilă să achiziționeze și cu o frecvență de eșantionare de 20 kHz.
- tolerează anumite mișcări ale subiectului, comparativ cu celelalte metode în care subiecții sunt imobilizați. Există chiar și metode de minimizare sau eliminare a artefactelor introduse de mișcări.
- este o metodă silențioasă, putând astfel analiza mai bine răspunsurile cerebrale la prezența unor stimuli auditivi.
- nu implică supunerea subiecților la câmpuri magnetice de intensitate mare (> 1 Tesla), precum se face în tehnica MRI sau MRS.
- este o tehnică neinvazivă, spre deosebire de Electrocorticografia, care necesită plasarea de electrozi direct pe suprafața creierului.
- poate detecta procese cerebrale ascunse.
- unele potențiale evocate pot fi detectate chiar dacă subiecții nu sunt supuși stimulilor.
- EEG oferă posibilitatea de a urmări schimbările apărute în activitatea cerebrală pe parcursul diferitelor faze ale vieții.

Dezavantajele electroencefalogramelor

- EEG prezintă rezoluție spațială slabă comparativ cu fMRI, care afișează direct regiunile creierului active. În cazul EEG este nevoie de o interpretare a cărei regiune este activă, urmărind răspunsurile punctuale de pe scalp.
- activitatea cerebrală este foarte slab resimțită la nivelul scalpului.
- spre deosebire de PET sau MRS, nu se poate specifica locația exactă din creier unde pot fi întâlnite diferite forme de neurotransmițători nedorțiți, precum drogurile.
- adesea durează foarte mult timp pentru a conecta subiectul la aparatura EEG. Aceasta necesită plasarea precisă a zeci de electrozi, pe toată suprafața capului, folosirea diferitelor tipuri de geluri conductoare, soluții saline și păstrarea electrozilor în aceeași poziție. Pentru a diminua această problemă se pot utiliza căști de electrozi.
- raportul semnal zgomot este mic, astfel este nevoie de o analiză sofisticată a datelor înregistrate. Este nevoie de un număr mare de subiecți pentru a putea extrage informații utile din EEG.

Activitate electrică a creierului este susținută de milioane de neuroni. Aceștia schimbă constant ioni cu mediul extracelular, pentru a menține potențialul de repaus sau de a propaga un potențial de acțiune. Acțiunea simultană a mai multor neuroni de atracție sau respingere a ionilor determină apariția unor unde. Acest proces poartă numele de “conducție prin medii separatoare”, deoarece potențialele electrice sunt înregistrate la o distanță față de sursa care le produce. Când undele de ioni ating electrozii de pe scalp, electronii din metal sunt atrași și respinși printr-un proces alternant. Electrozii fiind compuși dintr-un metal bun conductor (de regulă argint – Ag), răspund foarte bine la câmpul electric prezent, înregistrându-se variații de potențial la nivelul acestora. Aceste variații pot fi puse în evidență utilizând un volmetru. Înregistrarea în timp a acestor tensiuni reprezintă, de fapt, encefalograma.

Potențialul electric generat de un singur neuron este foarte mic pentru a putea fi resimțit la nivelul scalpului. Prin urmare, EEG reflectă întotdeauna sumarea activităților sincrone a mai multor neuroni care au orientări spațiale similare. Dacă celulele nu au o orientare spațială similară, ionii lor nu se aliniază în așa manieră de a crea unde detectabile. Neuroni piramidali corticali produc cele mai multe semnale EEG, pentru ca sunt bine aliniați și se activează împreună.

Activitatea cerebrală înregistrată la nivelul scalpului prezintă oscilații, cu o mare varietate de frecvențe. Câteva dintre aceste oscilații sunt caracterizate de anumite benzi de frecvență, distribuții spațiale și sunt asociate diferitelor stări funcționale ale creierului.

3.1.1. Metode de achiziție

În sistemele convenționale înregistrarea semnalelor EEG se face prin plasarea mai multor electrozi pe scalp, utilizându-se și un gel conductor pentru a reduce impedanța de contact. Multe din acestea folosesc electrozi atașați unui singur cablu. În aplicațiile în care densitatea punctelor analizate de pe scalp este mare, se folosesc căști în care sunt deja încorporați electrozii. Localizarea și denumirea electrozilor este specificată de sistemul internațional 10-20, pentru majoritatea aplicațiilor (exceptându-le pe cele cu densitate mare de puncte analizate).

Fiecare electrod este conectat la una din intrările amplificatorului diferențial (un amplificator pentru fiecare pereche de electrozi), iar referința comună la toate celelalte intrări rămase ale amplificatoarelor. Aceste amplificatoare amplifică diferența de potențial dintre electrodul activ și electrodul de referință (amplificare cuprinsă între valorile 1000-100000). Majoritatea sistemelor EEG din zilele noastre sunt digitale, iar semnalul analogic amplificat este digitalizat printr-un convertor analogic digital, dar asta după ce semnalul este trecut printr-un filtru trece jos (de anti-aliere).




Fig. 3.1 Amplificatoare diferențiale cu referință comună

Semnalul digital EEG poate fi stocat electronic și poate fi filtrat pentru afișare. Setările tipice pentru filtrul trece sus și filtrul trece jos sunt 0.5 – 1 Hz și 35 – 70 Hz respectiv. Filtrul trece sus elimină artefactele de frecvențe joase, precum semnalele electrogalvanice sau artefactele introduse de mișcări, iar filtrul trece jos elimină artefactele de frecvențe înalte, precum semnalele electromiografice. De regulă, se mai folosește și un filtru adițional Notch pentru a rejecta artefactele introduse de linia de alimentare (50 Hz).

Un semnal EEG, tipic unui adult, măsurat la nivelul scalpului are amplitudini cuprinse între 10 μ V și 100 μ V. Dacă electrozii sunt plasați sub Dura mater, potențialele înregistrate au valori cuprinse între 10 și 20 mV.

Cât timp semnalele EEG reprezintă diferența de potențial dintre doi electrozi, citirea lor se poate face în mai multe feluri.

Reprezentarea canalelor referită de diferite montaje:

- Montajul secvențial

Fiecare canal (forma de undă) reprezintă diferența dintre doi electrozi adiacenți. Întregul montaj este alcătuit din o serie de astfel de canale. De exemplu, canalul “Fp1-F3” reprezintă diferența în tensiune dintre electrodul Fp1 și electrodul F3. Următorul canal din montaj, “F3-C3”, reprezintă diferența de tensiune dintre F3 și C3, și așa mai departe până se acopera toată matricea de electrozi.

- Montajul referențial

Fiecare canal reprezintă diferența dintre un electrod specific și un electrod de referință setat. Nu există o poziție standard pentru electrodul de referință. De regulă se plasează pe zona mediană a capului, între emisferele cerebrale, sau pe urechi.

- Montajul referință – comună

Ieșirile tuturor amplificatoarelor sunt însumate și mediate, iar semnalul rezultat este folosit ca referință comună pentru fiecare canal.

- Montajul Laplacian

Fiecare canal reprezintă diferența dintre un electrod și media ponderată a semnalelor colectate de electrozii din jurul primului electrod.

Pentru a scoate mai bine în evidență caracteristicile semnalelor EEG se pot selecta diferite montaje, în timpul achiziției. Atâta timp cât montajele pot fi construite matematic din alte montaje, semnalul EEG poate fi vizualizat după cum se dorește. În cadrul acestei lucrări s-a utilizat montajul referință - comună.

Artefactele

- Artefactele biologice

Semnalele electrice detectate la nivelul scalpului, dar ale căror origini sunt non-cerebrale sunt denumite artefacte. Datele EEG sunt adesea contaminate cu artefacte. De regulă, amplitudinile artefactelor sunt mai mari față de cele ale semnalelor corticale. Câteva dintre cele mai comune tipuri de artefacte biologice sunt: mișcările ochilor, clipitul, activitatea cardiacă, contracția involuntară a mușchilor, etc. Cele mai proeminente artefacte induse de către ochi sunt cauzate de diferențele de potențial dintre corneea și retină, care sunt mai mari față de potențialele cerebrale.

- Artefacte provenite din mediul exterior

Pe lângă artefactele biologice, există multe alte tipuri de artefacte ale căror surse sunt regăsite în mediul exterior. Mișcările subiecților, sau deplasarea electrozilor din pozițiile inițiale, poate provoca salturi în semnalul înregistrat, cauzate de modificarea momentană a impedanței de contact. Slaba împănțare a electrozilor poate produce artefacte semnificative pe frecvența liniei de alimentare (50 Hz).

Corecția artefactelor

Una dintre metodele de corecție sau eliminare a artefactelor din semnalele EEG este Analiza pe Componente Independente (ICA). Această tehnică încearcă să descompună semnalele EEG într-un număr de componente independente statistic pentru a putea estima procesele biologice independente. Ținând seama de variațiile comportamentale ale semnalelor EEG, există mai mulți algoritmi de separație. Principiul care stă la baza fiecărei metode în parte: semnalul inițial este reconstruit doar din acele componente “curate” ale semnalului EEG, egalând cu zero toate

componentele nedorite. În prezent sunt implementate metode automate de rejecție a artefactelor, bazate pe ICA. În ultimii ani, comparând datele obținute pe persoane paralizate și persoane neparalizate s-a dovedit faptul că artefactele introduse de mușchi sunt mult mai pronunțate în domeniul gama de frecvențe (peste 30 Hz).

Activitatea electrică cerebrală este distribuită neuniform din punct de vedere topografic. De aceea este mult mai avantajos ca măsurarea să se facă în mai multe puncte pe scalp. Pentru diagnosticările neurologice, există mai multe sisteme de nomenclatură pentru poziționarea electrozilor. Până în prezent, cel mai utilizat și cel mai cunoscut, este sistemul internațional 10-20. În cadrul acestei lucrări de cercetare s-a utilizat o cască de electrozi cu 128 de canale (rezoluție spațială foarte bună, dar în același timp mare pentru nivelul cercetărilor realizate).

3.2. Sistemul de achiziție utilizat

Achiziții de semnale s-a făcut cu ajutorul aparaturii dezvoltate de Compumedics Neuroscan [39].



Fig. 3.2 Neuvo 128 – Amplificator 128 de canale [39]

Neuvo 128 – Amplificator cu 128 de canale (electrozi), care achiziționează semnale cu o frecvență maximă de eșantionare de 10 kHz. Frecvența ridicată de eșantionare permite înregistrarea semnalelor analogice cu un nivel de acuratețe ridicat. Acesta utilizează un convertor analog digital, pe 24 de biți pentru fiecare canal, asigurând măsurători cu un nivel de validitate crescut al datelor.

Neuvo este potrivit pentru necesitățile oricărui laborator de neuroștiință. Construit pe baza tehnologiei SynAmps RT, Neuvo este un amplificator de semnale EEG, ERP și EP, cu o densitate mare de specificații și preț competitiv. Neuvo setează un nou standard în tehnologia amplificatoarelor, asigurând un sistem potrivit pentru a înregistra orice semnale cu o frecvență de eșantionare de până la 10000 Hz. Acesta poate fi folosit împreună cu softul Curry, asigurând un sistem complet de achiziție și analiză. De asemenea poate fi utilizat împreună cu ACCESS SDK, permițând utilizatorilor să-și modeleze soft-ul pentru a controla și achiziționa datele. O altă caracteristică importantă a amplificatorului Neuvo este aceea că se pot conecta la acesta căști de electrozi QuikCap, care permit o mai rapidă și mai simplă plasare a electrozilor pe cap, regăsite sub forma diferitelor nomenclaturi. Sistemul Neuvo are certificare clasa IIB CE și aprobare FDA (Food and Drug Administration). FDA este o agenție a Statelor Unite din domeniul medical, responsabilă de reglementarea alimentației, suplimentelor, dispozitivelor medicale și a dispozitivelor radiante.

Modulele Neuvo pot fi conectate împreună permițând achiziția pe mai mult de 500 de canale în același timp. Acestea au individual 64 canale monopolare și 4 canale bipolare.

Un sistem EEG 128-channel Neuvo are două module cu 136 de canale în total.

Achiziția se poate face la o frecvență maximă de eșantionare este de 10000 Hz pe fiecare canal și toate canalele active.

Banda de frecvențe în care se pot face înregistrări este cuprinsă între DC și 3500 Hz. Multe potențiale de frecvență joasă (P300, MMN, CNV) au componente care pot fi măsurate precis folosind doar amplificatoare DC. Zgomotul poate fi eliminat chiar în timpul achiziției prin aplicarea unui semnal în antifază, rezultând nivele foarte bune al factorului de rejecție a modului comun. Această tehnologie asigură în același timp protecție crescută a pacientului.

Sistemul Neuvo este portabil și ușor de integrat. Amplificatoarele digitale sunt de regulă mici și portabile. Însă, trebuie luat în considerare faptul că portabilitatea poate implica mai multe surse de zgomot din mediul înconjurător.

Specificații amplificator Neuvo 128-canale:

- număr maxim de canale: 136
- canale EEG: 128
- canale bipolare: 8
- DC/AC: DC
- frecvența maximă de eșantionare: 10 kHz
- frecvențe eșantionare: 100, 200, 250, 500, 1000, 1250, 2000, 2500, 5000, 10000
- bandă frecvențe: DC-3500 Hz
- rezoluție: 24 biți
- valori tensiuni de intrare de până la 400mV (modul DC)
- sensibilitatea: 24nV (modul DC)
- impedanța de intrare: > 10 GOhm
- factorul de rejecție a modului comun: (CMRR) > 110 dB
- nivel zgomot (vârf la vârf): <0.5μV (modul DC)
- monitorizare impedanță: da
- trigger: 16 biți TTL
- conector casca electrozi: da

- sincronizare sistem: pot fi conectate maxim 4 module la o unitate a sistemului, care permit înregistrarea de semnale pe mai mulți subiecți, simultan

- interfața de achiziție: Ethernet

Amplificatorul Neuvo 128 este utilizat împreună cu STIM² pentru a face achiziții de semnale în cadrul unor experimente cu sarcini motorii.




Fig. 3.3 STIM² [39]

STIM² este alcătuit din 14 module dedicate unor experimente, un modul generic experimental programabil, un editor de fișiere audio și un convertor de fișiere de imagini. Modulele sunt împărțite în următoarele categorii de funcții: motorii, perceptuale, de atenție, de memorare și cognitive, multe dintre ele având experimente neuropsihologie (Tapping, Stroop, Categori, Sortare

cărți, etc.). Programul Gentask include o interfață pentru crearea și prezentarea aproape a orice tip de stimul vizual, auditiv, sau combinații a acestora și înregistrează răspunsurile comportamentale ale subiecților. Gentask a fost utilizat pentru o varietate de experimente auditorii - P300, N400, MMN, CNV, memorare de imagini și multe altele. Editorul de sunete este folosit pentru înregistrarea, editarea și prezentarea de segmente sonore digitale. Convertorul de imagini schimbă formatul mai puțin familiar al unor imagini într-unul de forma .bmp, .jpg sau .png.

STIM² se interfațează cu soft-urile Curry 7 și SCAN și cu toate amplificatoarele create de Compumedics Neuroscan: SynAmps RT, Neuvo, NuAmps și Grael.

Softul utilizat pentru achiziția de semnale EEG este Curry 7. În cadrul acestui program semnalele sunt prelucrate, prin aplicare de filtre trece bandă, filtru notch, analiză ICA, PCA, etc.

Curry 7 integrează mai multe modalități de prelucrare și afișare a imaginilor și a semnalelor mediale, precum cele atribuite EEG, ECoG, MEG, MRI, fMRI, CT. Combinând ultimile tehnici folosite în determinarea activității creierului și afișarea de imagini anatomice și funcționale, Curry asigură o acuratețe mare de localizare a activităților cerebrale. Folosind imagini anatomice obținute prin MR și CT, Curry asigură modele tridimensionale ale capului și creierului, iar pe acestea afișează regiunile corespunzătoare activității înregistrate. Este potrivit pentru crearea de hărți funcționale și diagnoză ale activității creierului. Astfel, mai multe metode de analiză a creierului sunt îmbinate într-un produs complet. Curry poate rula pe calculator sau laptop, cu sisteme de operare de la Windows XP, la alte versiuni mai noi și poate fi integrat în diverse aplicații.

Specificatii Curry 7:

- modul de achiziție a semnalelor EEG, cu posibilitatea procesării lor în timpul achiziției
- integrează date funcționale (EEG, MEG, ECoG, ECG) cu date imagistice (MRI, fMRI, CT)
- design modular: poate fi adaptat extragerii doar a caracteristicilor specifice aplicației
- detecție evenimente, prin setarea anumitor praguri
- mediere selectivă a semnalelor
- detecție și eliminare de artefacte
- filtrare, analiză a componentelor independente (ICA) și a componentelor principale (PCA)
- evaluare în domeniul timp și domeniul frecvență
- bloc de afișare a erorilor
- procesare automată și procesare pe loturi
- help senzitiv contextului de lucru
- exportă rezultatele în formate tipice programelor MATLAB, Excel și SPM

Pachetul Curry oferă toate uneltele necesare procesării datelor obținute prin metodele EEG sau MEG. Acesta oferă posibilitatea generării unei baze de date pentru a structura datele într-o formă mai intuitivă. După rereferențiere, filtrare, detecție și rejecție de artefacte, estimare a zgomotului, mediere selectivă, Curry poate aplica PCA sau ICA.

Casca de electrozi utilizată în cadrul experimentului este Quik – Cap 128-canale. Aceasta oferă o rezoluție suficient de mare pentru analiza regiunilor de interes. Datele înregistrate pe mai multe canale oferă informații în timp real despre intensitatea activității cerebrale, ale diferitelor regiuni ale capului. Casca de electrozi are avantajul că se montează rapid și ușor pe cap, iar plasamentul electrozilor rămâne constant pe parcursul mai multor achiziții.



Fig. 3.4 Casca electrozi Quik – Cap 128-canale

Specificații casca electorzi Quik – Cap 128-canale:

- canale EEG: 128
- canale bipolare: 4
- dimensiune: medie
- materialul din care este făcut electrodul: Ag/AgCl – sinterizate
- contact prin intermediul unui gel conductor
- electrodul de masă: Afz
- referință selectivă: între Cz și CPz, bărbie, frunte, umăr
- amplificator: SynAmps 2/RT, Neuvo
- tip conector: MDR80 (2x)
- adaptor cască: nu este necesar pentru Neuvo

3.3. Arie cortex motor și sensorimotor analizată

Zona analizată în cadrul experimentului este cea a cortexului motor și sezorimotor, prin activarea următoarelor canale de pe casca de electrozi: C3, FCC3h, C4, FCC4h, C1, C2, Cz, FCCz.




Fig. 3.5 Plasament electrozi.[39]

Canalele au fost alese astfel deoarece ritmurile sezorimotore sunt resimțite în ambele emisfere cerebrale. Electrodul de refetință este plasat pe frunte. În plus, softul de achiziție poate seta referința ca fiind media comuna a tuturor semnalelor înregistrate.

După plasarea electrozilor pe cap se încearcă obținerea unui contact mai bun dintre piele și electrod. În sensul asta, se folosește un gel conductor, care micșorează impedanța ariei de contact. Nu se începe imediat experimentul deoarece este nevoie de puțin timp ca acțiunea gelului să reducă impedanța de contact la valori acceptabile. În tot acest timp se prezintă subiectului informații despre sarcinile pe care va trebui să le îndeplinească în timpul paradigmei.

Achiziția semnalelor EEG a fost făcută pe un subiect, în cadrul unor experimente repetate. Subiectul este de sex masculin, cu vârsta 23 de ani și fără probleme medicale.

Achizițiile au fost efectuate în laboratorul de cercetare Campus, din cadrul facultății de Electronică, Telecomunicații și Tehnologia Informației, București.

3.4. Paradigma utilizată

Un aspect important al sistemelor BCI este acela că utilizatorul trebuie să execute diferite task-uri și strategii mentale, cu scopul de a genera trăsături specifice. Comunicarea creier-calculator are la bază aceste strategii mentale, care sunt definite și limitate de capabilitățile subiecților. Altfel spus, sistemele BCI sunt create în funcție de nevoile și aptitudinilor subiecților. Însă, și subiecții au datoria de a învăța diferite strategii și de a-și antrena creierul să genereze anumite modele pe care sistemele să le poată “înțelege”.

Strategiile mentale cele mai des utilizate sunt cele de imaginare motorie și cele de selecție (foculare pe diferite obiecte, concentrarea atenției).

În cadrul paradigmelor bazate pe metoda de atenție selectivă, sunt utilizați stimuli exteriori sub diverse forme: vizuali, auditivi sau somatosenzoriali. Cei mai utilizați stimuli sunt cei vizuali.

Paradigmele dezvoltate pe baza stimulilor vizuali sunt împărțite în două categorii, în funcție de caracteristicile cerebrale pe care le produc: paradigme bazate pe potențialul P300, paradigme bazate pe SSVEP (Steady State Visual Evoked Potential - potențialul evocat de regim permanent).

Paradigmele bazate pe ritmurile sezoimotore au cu totul altă abordare. Față de sistemele BCI bazate pe atenție selectivă, nu mai este nevoie de utilizarea unor stimuli externi. Mișcarea oricărui membru sau simpla contracție a unui mușchi este resimțită în activitatea electrică a creierului. Orice mișcare este rezultatul unui impuls generat de creier, ci nu invers. Astfel, putem afirma că mișcările există doar datorită sistemului nervos central – SNC, iar lipsa mișcărilor nu se datorează obligatoriu inactivității cerebrale, ci întreruperii căii de transmisie (sistemului nervos periferic) a impulsului. Putem afirma că există activitate cerebrală corelată cu mișcarea în sine, chiar înainte de producerea acesteia, fiind evidente modificările apărute în cadrul ritmurilor sezoimotore. Aceste ritmuri (SMR) fac referire la oscilațiile aparute în activitatea cerebrală din regiunile motorii sau somatosenzoriale ale creierului. Doar simpla imaginare a mișcării unor membre poate produce modificări ale ritmurilor sezoimotore.

Subiectul are de executat diferite mișcări ale brațelor, la momente de timp specificate în experimentul creat în programul STIM². Pe un monitor sunt afișate, din 4 în 4 secunde, imagini care sugerează stări succesive de repaus și mișcare ale brațelor. Subiectul trebuie să fie atent și să urmărească precis indicațiile din imagini, altfel experimentul nu mai este valid, pentru ceea ce se urmărește.

Fiecare complex de mișcări a fost repetat de mai multe ori, în cadrul unei achiziții. În etapa de prelucrare a semnalelor, vor fi extrase segmentele specifice claselor asociate, pentru fiecare achiziție efectuată.

STIM² transmite softului de achiziție momentele de timp la care trebuie plasați markerii, pe semnalele achiziționate. La fiecare tranziție de la un stimul la altul, pe semnalul achiziționat se plasează un marker cu numărul clasei din care face parte.




Fig. 3.6 Clasele de mișcări din cadrul paradigmei

Descriere bază de date

Baza de date cu semnalele EEG atribuite claselor de mișcări, a fost creată pentru a putea implementa analiza offline a sistemului BCI. Se vor parcurge următorii pași:

- Se importă înregistrările efectuate în cadrul experimentului cu sarcini motorii, utilizând toolbox-ul EEGLab[49].
- Se extrag segmente a câte 8010 eșantioane, corespunzătoare fiecărei clase de mișcări.
- Se creează două căi paralele pentru etapa de antrenare, respectiv de testare. Pentru calea de antrenare vom întâlni mai multe canale, pe care au fost achiziționate semnalele respective fiecărei clase, pentru a face analiza pe o regiune mai mare din aria cortexului motor și senzomotor. Calea de testare conține semnale achiziționate pe 8 canale.
- Pentru fiecare canal de achiziție semnalele sunt grupate pe clasele de apartenență.




Fig. 3.7 Structură bază de date

Necesitatea dezvoltării unei baze de date cu semnale EEG a survenit din faptul că pentru paradigma creată nu există o bază de semnale EEG în mediul web. Astfel a fost implementată o

structură tipică aplicației alese. Semnalele din cadrul bazei de date sunt etichetate tocmai prin denumirea căi de acces la acestea. Modalitatea de importare în mediul MATLAB se face pe baza căilor de acces și a denumirilor fișierelor. Algoritmul dezvoltat importă toate semnalele, pe rând și în ordinea întâlnită în baza de date, de pe toate canalele de achiziție, și respectiv pentru toate clasele. Astfel, matricea de semnale obținută, conține toate semnalele din baza de date, aranjate pe linii pornind de la clasa 1 și terminând cu clasa 4. Cunoșcând ordinea semnalelor din matrice, pot observa foarte ușor pentru care semnale algoritmul de clasificare returnează rezultate slabe respectiv ridicate. Evident, pentru a simula un experiment cu mișcări aleatoare ale brațelor, în care se face o achiziție de semnal EEG și se încearcă discriminarea lor, se poate realiza prin mixarea liniilor matricei de semnale atribuite claselor. Maparea dintre folderele de canale și canalele de achiziție este următoarea: CH1= FC3, CH2=FCC3h, CH3=C1, CH4=FCCz, CH5=Cz, CH6=FCC4h, CH7=C2, CH8=FC4, CH9=CCP3h, CH10=CCP4h, CH11=CPP3h, CH12=CPPz, CH13=CPP4h, CH14=C3, CH15=C4. Baza de semnale conține în prezent 300 de semnale pentru etapa de antrenare (75 pentru fiecare clasă) și 32 de semnale pentru etapa de testare (8 pentru fiecare clasă). Semnalele pot fi accesate doar pe un singur canal de achiziție, analiza făcându-se doar punctual, ci nu pe o regiune din aria motorie. Astfel, se pot scoate în evidență canalele pe care se obțin rezultate mai bune, în discriminarea sarcinilor motorii. Se urmărește extinderea bazei cu semnale de antrenare, pentru a obține rezultate mai bune în etapa de clasificare.

Capitolul 4. Brațul robotic JACO

4.1. Descriere braț robotic JACO



Fig. 4.1 Braț robotic JACO [44]

Kinova dezvoltă și fabrică platforme robotice simple, eficiente și sigure în cadrul a doua unități: cea de roboți asistivi, care oferă posibilități oamenilor cu dizabilități să-și depășească limitele impuse de propria condiție și cea de roboți de serviciu, care asigură oamenilor din industrie noi posibilități de a interacționa cu mediul de lucru, într-un mod mai eficient și sigur[44].

În cadrul acestui proiect am folosit modelul JACO 3. Lansat pe piață încă din anul 2010, este un braț robotic cu 6 grade de libertate, al cărui efector cuprinde 3 degete. Această capodoperă inginerească îmbunătățește semnificativ viața persoanelor cu dizabilități, ale căror mobilitate este restrânsă. În acest sens, orice persoană imobilizată complet sau parțial, poate beneficia de capabilitățile brațului robotic de a executa mișcări complexe.

Acest robot asistiv a fost adoptat rapid de persoanele cu dizabilități (în special de cele imobilizate în scaunul cu roțile), devenind renumit prin capabilitățile sale.

Caracteristici Jaco:

 Weight 5,2kg	 Payload 1,6kg (mid-range)	 Degrees of freedom 6	 Reach 900mm	 Power Consumption 25W average
--	---	--	--	---

- structură din fibră de carbon
- rezistent la apă
- este ușor (5.2 Kg)
- 6 grade de libertate
- poate atinge podeaua dacă este pe un scaun cu roțile standard
- efectorul poate avea 2 sau 3 degete flexibile
- plăcuțele de cauciuc de înaltă fricțiune ușurează apucarea obiectelor
- optimizat pentru activitățile de zi cu zi
- prezintă senzori de curent și limitări de protecție

Brațul poate fi controlat cu ajutorul unui joystick, însă poate fi și programat, folosind kitul de dezvoltare software pus la dispoziție de fabricant, pentru limbajul de programare C++. Acesta poate fi controlat în două moduri: control unghiular și control cartezian. Controlul unghiular implică mișcarea separată a fiecărui actuator. În schimb, controlul cartezian oferă posibilitatea mișcării mai multor actuatoare simultan, rezultând mișcări mult mai cursive și complexe. Pentru a obține mai ușor mișcări precise, am utilizat modul unghiular.

4.1.1. Brațul robotic




Fig. 4.2 Specificații braț robotic – Jaco

Greutate	4,4 Kg
Material	Fibră de carbon(segmente),Aluminiu (actuatori)
Încărcătură	2.6 Kg (atunci când brațul nu este extins la maxim) 2.2 Kg (atunci când brațul este extins la maxim/doar temporar poate sta în sarcina asta)
Întindere	90 cm
Număr rotiri articulații (Limitare softare)	±27.7 rotiri
Viteza maximă liniară	20 cm/s
Tensiune alimentare	18 - 29 VDC
Putere medie consumată	25 W (5W in repaus)
Puterea de vârf	100 W
Protocol de Comunicație	RS485
Cabluri de Comunicație	Cablu flat flex cu 20 de pini
2 pini de expansiune pe magistrala de comunicație	Da
Rezistent la apă	IPX2
Interval de temperatură de operare	-10 °C to 40 °C

Tabel 4.1 Specificații braț robotic – Jaco 3

Jaco permite utilizatorului să interacționeze cu mediul în condiții de siguranță, liber și eficient. Brațul se mișcă ușor, este silențios și oferă posibilitatea rotirii nelimitate a actuatorilor. Axele sunt reprezentate de discuri compacte de aluminiu (CADs), având un design unic. Fiecare braț robotic are în componența sa 2 seturi distincte de 3 identice, interschimbabile și ușor de înlocuit actuatore (CADs), conectate împreună printr-un cablu ZIF (forța de inserție zero).

Structura brațului din fibră de carbon asigură robustețe, durabilitate și deasemenea un aspect de ultimă oră. Brațul este montat pe un suport standard de aluminiu care poate fi fixat pe aproape orice suprafață.

4.1.2. Efectorul brațului robotic

Număr degete	3
Sistem actuator	Subacționate
Actuatori	Unul pentru fiecare deget
Senzori actuatori	Curent
	Temperatură
	Encoder rotațional
Deschidere maximă	175 mm
Diametrul minim al cilindrului apucat	45 mm
Diametrul maxim al cilindrului apucat	100 mm
Diametrul minim al obiectului apucat	8 mm
Greutate	727 g
Forța de strângere	3 degete - 40 N
	2 degete - 25 N
Timpul de închidere sau deschidere	1.2 Sec
Interval de temperatură de operare	-10 °C To 40 °C

Tabel 4.2 Specificații efector – Jaco 3

Efectorul are în componența sa 2 sau 3 degete subactuate, care pot fi controlate individual. Structura degetelor asigură o mare flexibilitate și o aderență de neegalat. Spre deosebire de versiunea anterioară, Jaco are un gripper mai subțire și un element de aderență care permite degetelor să se adapteze oricăror obiecte, indiferent de forma lor. Prin urmare, ele pot lua cu ușurință un ou sau pot prinde cu fermitate un borcan.

4.1.3. Controller-ul

Jaco poate fi controlat prin intermediul unui joystick (cu 7 butoane) sau programat direct din computer. Controlul este destul de intuitiv, punând la dispoziția utilizatorului 3 moduri diferite de navigare în spațiu: translație, rotație și prindere. Deasemenea, sistemul inteligent de evitare a obstacolelor menține brațul într-o arie de siguranță. Jaco prezintă o flexibilitate ridicată și se poate adapta tuturor nevoilor utilizatorului. Caracteristicile controller-ului sunt prezentate detaliat în Tabelul 4.3.




Fig. 4.3 Controller - Jaco

Porturi	
Joystick	1 Mbps CANBUS
Tensiune alimentare	18 - 29 VDC
Usb 2.0 (Api)	12 Mbps
Ethernet	Indisponibil
Frecvența sistemului	100 Hz (High Level Api) 500 Hz (Low Level API)
CPU	360 Mhz
SDK	
APIs	High And Low Level
Compatibilitate	Windows, Linux Ubuntu & ROS
Port	USB 2.0
Limbaj de programare	C++

Tabel 4.3 Specificații controller – Jaco 3

Capitolul 5. Metode de extragere a trăsăturilor din semnalele EEG

Etapele de prelucrare a semnalelor EEG sunt următoarele:




Fig. 5.1 Etapele de prelucrare a semnalelor EEG

5.1. Metode de extragere a trăsăturilor din semnalele EEG

Procesele creierului se regăsesc în semnalele EEG sub forma unui mix necunoscut de componente. Este foarte important să se găsească metode optime de prelucrare a semnalelor în vederea extragerii caracteristicilor definitorii ale unui anumit proces. Sistemele BCI, funcționează doar pe baza paradigmatelor de lucru proprii, iar caracteristicile utile extrase din semnal sunt specifice doar acestora. În recunoșterea de modele, extragerea de caracteristici este o formă specială de reducere a dimensionalității volumului de date. Când volumul de date de intrare într-un algoritm este prea mare pentru a fi procesat și ținând seama că informația este redundantă (multe date, puțină informație utilă), se recurge la aplicarea unor metode de extragere de caracteristici. Astfel se obține o reprezentare restrânsă a datelor, definite de caracteristicile atribuite acestora. Acest proces poartă numele de extragere de caracteristici (data mining). Alegerea metodei potrivite de extragere de caracteristici, este un pas important în dezvoltarea sistemelor BCI. Se urmărește reducerea setului de date fără a elimina informația utilă din acesta. Avantajele constau în viteza de prelucrare mai crescută și asigurarea unui nivel al acurateții mai ridicat, în cadrul etapei de clasificare.

Extragerea de caracteristici implică obținerea unui set de date restrâns care să descrie cu o acuratețe crescută datele inițiale. Atunci când se face analiza pe un volum mare de date, una din problemele existente este numărul mare de variabile implicate. În general, analiza cu un număr mare de variabile necesită spațiu de stocare/memorare mare și o putere computațională ridicată. Extragerea de caracteristici este un termen general care înglobează diferite metode de combinare a variabilelor pentru rezolvarea problemelor menționate mai sus, cu scopul obținerii unor rezultate mai bune.

În cadrul multor articole științifice se discută problema alegerii celei mai potrivite metode de analiză lineară a semnalelor unidimensionale din domeniul frecvență sau timp-frecvență.

Exemple de metode de extragere de caracteristici:

- metoda transformatei Fourier rapide (FFT)

Această metodă utilizează mijloace sau instrumente matematice pentru a analiza semnalele EEG. Caracteristicile extrase din semnalul analizat reies din calculul densității spectrale de putere (PSD) estimate. În spectrul EEG se regăsesc 4 benzi de frecvență care conțin caracteristici majore [41]. Densitatea spectrală de putere este calculată prin aplicarea transformatei Fourier funcției de autocorelație.

- metoda transformatei Wavelet (WT)

WT joacă un rol important în domeniile de recunoaștere și diagnosticare: aceasta comprimă semnalele biomedicale, care cuprind un volum mare de date, într-un mic set de date care reprezintă semnalul. Cum semnalele EEG sunt nestaționare, cea mai potrivită abordare de extragere a caracteristicilor din șirurile de date este de a folosi metoda transformatei wavelet, din domeniul

timp-frecvență, care reprezintă o tehnică de estimare spectrală în care orice funcție generală poate fi exprimată ca o serie infinită de wavelet-uri.

- metoda vectorilor proprii

Această metodă implică calculul frecvenței semnalului și calculul puterii artefactelor dominante. Esența acestei metode constă în potențialul descompunerii Eigen de a corela chiar și semnalele afectate de artefacte. Metoda vectorilor proprii înglobează următoarele metode: metoda Pisarenko's, metoda MUSIC, metoda norma - minimă

- distribuții timp – frecvență

Aceste metode necesită semnale mai puțin zgomotoase pentru a asigura performanțe bune. Prin urmare, este nevoie de parcurgerea a mai puține etape până când toate artefactele vor fi eliminate din setul de date. Fiind metode de tipul timp-frecvență, au de a face cu principiul staționarității. Procesul implică utilizarea de ferestre. Definiția transformatei Fourier discrete (TFD) pentru un semnal $x(n)$ a fost generalizată de Cohen astfel:

$$P(t, \omega) = \frac{1}{2\pi} \iint_{-\infty}^{+\infty} A(\theta, \tau) \Phi(\theta, \tau) e^{-j\theta t - j\omega \tau} d\theta d\tau$$

unde

$$A(\theta, \tau) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} x(u + \frac{\tau}{2}) x^*(u - \frac{\tau}{2}) e^{j\theta u} du$$

$A(\theta, \tau)$ este cunoscută popular ca funcția de ambiguitate și $\Phi(\theta, \tau)$ se referă la kernel-ul distribuției, în timp ce τ și ω sunt variabilele timpului respectiv frecvenței. [42]

- modele autoregresive

Metodele de tip autoregresiv (AR) estimează densitatea spectrală de putere a semnalelor EEG folosind o abordare parametrică. Prin urmare, metodele AR nu au probleme de scurgeri spectrale și oferă o mai bună rezoluție, în comparație cu abordarea neparametrică.

Performanțele metodelor

Scopul general a acestei treceri în revistă este de a scoate la lumină câteva modalități de extragere de caracteristici din semnalele EEG și de a arăta cât de rapide sunt metodele utilizate și cât de fiabile sunt caracteristicile extrase. Mai mult de atât, ne interesează cum aceste trăsături definesc stările creierului sau diferite sarcini mentale și cum anume le putem pune în evidență.

Viteza și acuratețea etapei de extragere de caracteristici din semnale EEG este de asemenea foarte importantă, în vederea de a obține rezultate rapide și de a păstra informații vitale. Atât de mult discutată în literatura de specialitate, metoda wavelet este introdusă ca soluție pentru semnalele instabile. Aceasta include reprezentarea prin undișoare care reprezintă un grup de funcții derivate din unda mamă prin procese de dilatare și translație. Utilizarea de ferestre de dimensiuni variabile reprezintă cea mai importantă trăsătură a acestei metode, deoarece asigură o rezoluție timp – frecvență adecvată, în tot domeniul de frecvențe. Metodele ce folosesc modele autoregresive nu sunt tocmai rapide și de aceea sunt mai puțin utilizate în aplicațiile de timp real. FFT apare ca fiind cea mai puțin eficientă metodă din cauza limitărilor care apar în analiza semnalele nestăționare.

Metodă	Rezoluție în frecvență	Scurgeri spectrale
FFT	Scăzută	Ridicate
AR	Ridicată	Scăzute
WT	Ridicată	Scăzute

Tabel 5.1 Comparație între FFT, AR și WT

Este recomandat să se utilizeze metodele AR în conjuncție cu mai multe metode conservative, precum cele de calcul al periodogramelor, pentru a obține modele optime și de a minimiza situațiile în care sunteți păcăliți de componente spectrale false.

Metoda TFD oferă posibilitatea de analiză a segmentelor continue lungi de date, chiar dacă dinamica semnalului EEG se schimbă rapid. În același timp o bună rezoluție în timp și frecvență este necesară, făcând ca această metodă să nu fie preferată în multe cazuri.

Numele metodei	Avantaje	Dezavantaje	Domeniu	Specifice
Transformata Fourier rapidă	(i) Utilă în procesarea semnalelor staționare (ii) Este potrivită pentru semnale de bandă îngustă, precum semnalele sinusoidale (iii) Are o viteză sporită față de aproape toate celelalte metode disponibile în aplicațiile de timp real	(i) Prezintă slăbiciuni în analiza semnalelor nestaționare, precum semnalele EEG (ii) Nu fac o estimare precisă a spectrului de putere și nu pot fi implicate în analiza de semnale EEG scurte (iii) FFT nu poate localiza spike-urile și complexe tipice crizelor epileptice în semnalele EEG (iv) FFT este foarte sensibil la prezența zgomotului și nu se aplică pe semnale de durată scurtă	Domeniul frecvență	Bandă îngustă Semnale staționare
Transformata Wavelet	(i) Utilizează fereastră cu dimensiune variabilă, fiind largă la frecvențe joase și îngustă la frecvențe înalte (ii) Este potrivită pentru analiza semnalelor tranzitorii și stocastice (iii) Este folosită pentru depistarea modelelor în semnalele neregulate, precum existența unor impulsuri la diferite instanțe de timp	(i) Este necesară alegerea familiei de undișoare, cea mai potrivită	Domeniul timp și domeniul frecvență	Semnale staționare și tranzitorii
Vecitori propii	Asigura rezoluții potrivite pentru a evalua sinusoidale din date	(i) În cazul metodei Pisarenko's, cele mai mici valori proprii pot genera zerouri false	Domeniul frecvență	Semnale îngropate în zgomot
Distribuții timp - frecvență	(i) Oferă posibilitatea să se examineze segmente mari continue din semnalul EEG (ii) Pentru a obține rezultate foarte bune, se face analiza TFD pe semnale fără zgomot	(i) Metodele timp - frecvență au de a face cu problema staționarității, iar de aceea în etapa de preprocesare este nevoie să se aplice ferestre pe semnal (ii) Este o metodă lentă (iii) Caracteristicile extrase pot depinde unele de celelalte	Domeniul timp și domeniul frecvență	Semnale staționare
Autoregresive	(i) AR limitează pierderile spectrale și îmbunătățește rezoluția în frecvență (ii) Analiza spectrală bazată pe modelele AR este avantajoasă când se aplică pe segmente scurte de semnal	(i) Ordinea modelului în estimarea spectrală AR este dificil de selectat (ii) Metodele AR va face o estimare spectrală slabă cât timp modelul estimatului nu este potrivit	Domeniul frecvență	Semnale cu caracteristici spectrale ascuțite

Tabel 5.2 Comparația performanțelor metodelor de analiză a semnalelor EEG

În concluzie, este dificil să setăm o ordine a priorităților în alegerea unei metode anume de extragere de caracteristici. Ce putem afirma este că fiecare metodă, prin avantajele și dezavantajele

sale, este mai mult sau mai puțin potrivită pentru analiza anumitor tipuri de semnale. Metodele specifice domeniului frecvență nu pot asigura performanțe ridicate pentru unele cazuri particulare ale semnalelor EEG. În contrast, metodele timp-frecvență, de exemplu, nu pot furniza informații detaliate despre semnalele EEG, atât de mult cum o fac metodele din domeniul frecvență.

Este crucial să se cunoască tipul semnalului analizat și ce se urmărește din acesta, pentru a alege metoda cea mai potrivită. Ori de câte ori se pune în discuție performanțele metodei de analiză, pentru orice aplicație metoda optimă poate fi diferită.

În cadrul acestui proiect am utilizat următoarele metode de extragere de caracteristici:

- Metoda Welch
- Transformata Wavelet (WT)

5.1.1. Metoda Welch

[43]Semnalele aperiodice de energie finită sunt analizate în domeniul frecvență cu ajutorul transformatei Fourier. Pentru a estima caracteristicile spectrale ale semnalelor considerate a fi procese aleatoare, nu este posibilă aplicarea directă a analizei Fourier, ci se adoptă o tratare statistică a lor. Transformata Fourier a funcției de autocorelație a proceselor aleatoare staționare, care reprezintă densitatea spectrală de putere, face legătura dintre domeniul timp și frecvență. Pe baza unei mulțimi finite de observații se pot extrage componentele spectrale ale unui proces aleator. În lucrarea de față, procesul aleator este reprezentat de activitatea cerebrală (semnalul EEG), înregistrată în cadrul unor experimente cu sarcini motorii.

Pentru semnalele EEG nu se poate selecta o înregistrare de lungime finită pentru estimarea spectrului, lungimea acesteia fiind determinată de parametrii statistici ai semnalului. Pentru determinarea densității spectrale de putere estimate, se pot folosi următoarele metode neparametrice: metoda directă (periodograma), metoda Bartlett (periodograma mediată), metoda Welch (periodograma mediată modificată) și metoda Blackman – Tukey.

Pe datele obținute experimental am aplicat metoda neparametrică Welch. După ce am împărțit semnalul în clasele corespunzătoare și după etapa de filtrare, am utilizat funcția pwelch, din cadrul programului MATLAB [44], pentru a estima densitatea spectrală de putere. În continuare voi face o scurtă trecere în revistă a suportului matematic pe care este dezvoltat algoritmul funcției pwelch.

Segmentele ce se obțin din vectorul inițial se pot suprapune și pe fiecare segment se aplică o fereastră.

Fie $x[n]$ o secvență de N . Segmentele se vor obține astfel:

$$x_i[n] = x[n + iD] \quad \begin{matrix} n=0,1,2,\dots,M-1 \\ i=0,1,2,\dots,K-1 \end{matrix}$$

Rezultă K segment, fiecare de lungime M . Dacă $M=D$ segmentele nu se suprapun. Dacă $D = \frac{M}{2}$, există 50% suprapunere între segmentele succesive și $L = 2K$ segmente. Se pot obține K segmente de lungime $2M$ fiecare. Această suprapunere a segmentelor determină o reducere a dispersiei. Înainte de a calcula periodograma, segmentele de date sunt ponderate cu o fereastră, ceea ce conduce la o periodogramă modificată

$$\tilde{P}_{xx}^{(i)}(f) = \frac{1}{M \cdot U} \left| \sum_{n=0}^{M-1} x_i[n] w[n] e^{-j2\pi n f} \right|^2 \quad i = 0, 1 \dots L - 1$$

unde U este un factor de normalizare a puterii funcției fereastră și este ales ca

$$U = \frac{1}{M} \sum_{n=0}^{M-1} w^2[n]$$

Utilizarea funcției fereastră are drept efect reducerea lobilor laterali și, deci, a fenomenului de scurgere spectrală. Estimatul Welch al densității spectrale de putere este media aritmetică a acestor periodograme modificate, adică:

$$P_{xx}^w(f) = \frac{1}{L} \sum_{i=0}^{L-1} \tilde{P}_{xx}^{(i)}(f)$$

Desitatea spectrală de putere a fost estimată pe segmente de câte 8 secunde din semnalul inițial, fiecare reprezentând o clasă de mișcări. Pentru a obține reprezentarea din figurile de mai jos a semnalului înregistrat, au fost parcurse următoarele etape:

- achiziție: cu frecvența de eșantionare de 1 kHz (etapă în care semnalul real este amplificat, utilizând modulul Neuvo)

- filtrate: filtru Notch (rejecția frecvenței de 50 Hz), filtru trece banda (8- 12 Hz, ritmul alfa)

- fișierul cu semnalele achiziționate este salvat cu extensia .cnt pentru a fi importat în programul MATLAB, prin intermediul utilitarului EEGlab

- se aplică o funcție de extragere a semnalului corespunzător canalului vizat

- semnalul este afișat împreună cu markerii plasați pe acesta, încă din etapa de achiziție

Semnalele prezentate în Fig. 5.2 și Fig. 5.3 au fost achiziționate pe canalul 26 (C3), de pe casca de electrozi.




Fig. 5.2 Canalul C3, Semnalul inițial împărțit în segmente (clasele 1-2), cu durata 8 secunde.




Fig. 5.3 Canalul C3, Semnalul inițial împărțit în segmente (clasele 3-4), cu durata 8 secunde.

Se observă prezența activității oscilatorii la fiecare complex de mișcări executate. Fiecare segment extras surprinde o mișcare de abducție și o mișcare de adducție respectiv strângerea pumnului și relaxarea acestuia. Pentru mișcarea de adducție (revenirea brațului în starea de repaus) s-au înregistrat amplitudini mai mari, desemnând o activitate cerebrală mai intensă. Este de înțeles acest lucru deoarece revenirea brațului în poziția de repaus nu se face brusc, iar mișcarea în sine este solicitantă.

În Fig. 5.4 este prezentat spectrul densității de putere, pentru fiecare segment extras din semnalul inițial.




Fig. 5.4 C3, Densitatea spectrală de putere estimată, Clasele 1-2

Din grafic se poate observa că lobiile principale sunt centrați pe frecvențele 9, 10 Hz. Se poate afirma că cea mai mare parte a puterii semnalului este regăsită în intervalul 8-11 Hz, interval specific ritmului mu, înregistrat în zona cortexului motor. Există o relație direct proporțională între amplitudinile semnalului din domeniul timp și cele regăsite în spectrul de putere. Informația utilă nu se poate identifica atât de ușor urmărind variațiile în amplitudine ale semnalului.

Amplitudinile semnalului pot fi influențate de prezența artefactelor, variația intensității și a vitezei cu care subiecții execută mișcările brațelor. Este foarte dificil de urmărit particularitățile care apar în semnalul înregistrat, specifice fiecărei clase de mișcări în parte.




Fig. 5.5 C3, Densitatea spectrală de putere estimată, Clasele 3-4

5.1.2. Transformata Wavelet (WT)

Informația conținută în semnalele EEG este esențială pentru detecția diferitelor afecțiuni ale creierului, iar împreună cu analiza imaginilor obținute prin rezonanță magnetică formează cea mai complexă metodă de diagnosticare. Pe lângă importanța deosebită pe care o au semnalele EEG în cadrul domeniului medical, acestea primesc o atenție deosebită și din partea dezvoltatorilor de aplicații nonmedicale, precum cele de control a diverselor dispozitive. Pentru a extrage cele mai importante proprietăți ale semnalelor EEG, dintr-un set extins de date, este necesar a se utiliza cele mai eficiente unelte matematice.

Un exemplu foarte bun îl reprezintă transformata Wavelet discretă. Transformata wavelet multirezoluție realizează o reprezentare timp-scală a unui semnal discret, prin aplicarea mai multor bancuri de filtre digitale. Rezultă o descompunere a semnalului inițial în benzi de frecvență succesive.

Analiza de tip wavelet este, din punct de vedere teoretic, dezbătută în cadrul multor cărți și lucrări de specialitate, însă nu este prezentată într-o manieră tocmai intuitivă. Majoritatea resurselor bibliografice sunt elaborate de matematicieni, pentru matematicieni, iar gradul de descifrabilitate este redus chiar și pentru experții din domeniu, îndeosebi pentru cei interesați de implementarea lor în diverse aplicații practice.

Metoda wavelet permite reprezentarea semnalelor EEG luând în calcul atât informația temporală, cât și cea frecvențială. Aceasta reprezintă un progres față de celelalte metode de prelucrare a semnalelor nestaționare (STFT), deoarece permite ocolirea principiului de incertitudine stabilit de către Heisenberg, care afirmă că produsul dintre duratele de frecvență și timp ale unui semnal este limitat inferior de o valoare nenulă[45].

Avantajul major al transformatei Wavelet este acela că pune în evidență procesele nestaționare și localizează perturbațiile la scală temporală și frecvențială.

Una dintre diferențele majore dintre analiza de tip wavelet și analiza Fourier pe termen scurt constă în tipul ferestrelor de analiză utilizate: pentru analiza de tip Fourier ferestrele au durată fixă, indiferent de frecvența semnalului studiat, în timp ce pentru analiza wavelet se utilizează ferestre de durate variabile. Duratele ferestrelor depind de benzile de frecvențe în care este analizat semnalul astfel: pentru frecvențele joase se folosesc ferestre de lungă durată, iar pentru frecvențele înalte se utilizează ferestre de durată scurtă. Astfel, se poate afla precis poziționarea în timp a componentelor de înaltă frecvență (dar cu o acuratețe scăzută în specificarea valorii exacte a acestor frecvențe), respectiv se va cunoaște cu exactitate valoarea componentelor de frecvență joasă din semnalul analizat, dar fără a se specifica strict momentele de apariție a acestora.




Fig. 5.6 Împărțirea planului timp-frecvență în cazul: a) STFT; b) analizei wavelet[46]

Așa după cum se poate observa analiza wavelet nu folosește un domeniu variabil timp-frecvență ci unul scală-frecvență. Unul din avantajele majore ale transformatei Wavelet este capacitatea de a realiza analiza locală exactă a semnalului. Dacă considerăm o mică discontinuitate într-un semnal sinusoidal care nu este vizibilă (de exemplu fluctuația tensiunii de alimentare) și realizăm analiza Fourier, vom obține un spectru cu cele două vârfuri simetrice care reprezintă o singură frecvență, frecvența de 50Hz. Practic informația obținută din spectrul Fourier nu ne spune nimic despre discontinuitatea care a apărut în semnal. Dacă însă efectuăm analiza Wavelet, coeficienții obținuți ne arată cu exactitate locul în care s-a produs acea discontinuitate.

Transformata Wavelet continuă a unei sigmoide $x(t)$ este definită astfel:

$$WTX(T, a) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) h\left(\frac{t-T}{a}\right) e^{-j2\pi f t} dt$$

$$WTX(T, a) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(at) h\left(t - \frac{T}{a}\right) e^{-j2\pi f t} dt$$

În cadrul transformatei Wavelet continue, analiza unui semnal este efectuată prin utilizarea unei funcții speciale $h(t)$, numită undă “mamă”. Această funcție este translatată în timp pentru a selecta acea parte din semnal care se dorește a fi analizată. Porțiunea de semnal selectată este apoi dilatată sau contractată folosind un parametru de scală, a , care este analogul frecvenței. Pentru valori mici ale lui a , undișoara este o funcție “îngustă” a funcției originale, corespundândă frecvențelor înalte. Pentru valori mari ale lui a , undișoara este dilatată și corespunde frecvențelor joase. În cadrul WT, componentele de înaltă frecvență sunt analizate cu o rezoluție mai clară decât componentele de frecvență joasă. Acest lucru este de dorit în analiza formelor de undă tranzitorii rapide, precum semnalele EEG.

Definiția transformatei Wavelet continue mai poate fi întâlnită și sub forma,:

$$W(a, b) = \int_{-\infty}^{+\infty} f(t) \psi_{a,b}(t) dt$$

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right)$$

unde $f(t)$ este un semnal cu energie finită, iar a și b sunt constante reale.

Semnalele $\psi_{a,b}(t)$ sunt versiuni translate și scalate ale semnalului prototip $\psi(t)$, denumit și “mother wavelet”. [46]

- $a > 1$ implică dilatare
- $a < 1$ implică comprimare

Variabila “ b ” reprezintă translația de-a lungul axei x , în timp ce variabila “ a ” specifică scala (lărgimea) unei funcții bază particulare.

Proprietățile funcției mamă Wavelet:

- să fie atât ea cât și transformata ei Fourier de pătrat integrabil;
- să fie mărginită și de valoare medie nulă
- să respecte condiția de admisibilitate

$$C_{\psi} = \int_{-\infty}^{+\infty} \frac{|\psi(s)|^2}{|s|} ds < \infty$$

Coeficienții transformatei wavelet rezultă din produsul intern al funcției de transfer cu fiecare dintre funcțiile bază.

Transformata continuă inversă Wavelet are următoarea relație:

$$f(t) = \frac{1}{C_\Psi} \int_0^{+\infty} \int_{-\infty}^{+\infty} W(a, b) \Psi_{a,b}(t) db \frac{da}{a^2}$$

Există mai multe familii de semnale prototip: Haar, Daubechies, Coiflet, Symmlet, Battle-Lemarie, Morlet




Fig. 5.7 (a) Coif1; (b) db2; (c) Meyer; (d) Sym3; (e) Morlet; (f) Mexican

Scalarea unei funcții wavelet înseamnă alungirea sau comprimarea acesteia. Gradul scalării se măsoară cu ajutorul factorului de scală notat cu „a”.




Fig. 5.8 Scalarea funcțiilor mamă Wavelet [47]

Factor de scală “a” mic implică funcție wavelet alungită, detalii modificate rapid și frecvență mare.

Factor de scală “a” mare implică funcție wavelet comprimată, modificări lente în semnal și frecvență mică.

Translația funcțiilor wavelet reprezintă, de fapt, o întârziere cu care funcția wavelet originală se “amorsează”.




Fig. 5.9 Efectul translației asupra funcției de bază $\Psi(t)$ [47]

Transformata Wavelet Discretă

Calcularea coeficienților transformatei Wavelet pentru orice scală ar însemna un proces mult prea costisitor din punct de vedere al operațiilor efectuate. Pentru a calcula transformata Wavelet discretă – DWT Discrete Wavelet Transform – se alege un set de scale și poziții pentru care se vor realiza calculele. Una din modalități este alegerea factorului de scală și poziție ca fiind putere a lui 2. O astfel de transformare, numită și diadică, permite realizarea unei analize mult mai eficiente și mai corecte decât pentru alte variante de alegere a factorilor de scală și poziție. Odată ales setul ce cuprinde factorii de scală și poziție, putem implementa DWT folosind filtrele. Practic este vorba de o implementare a algoritmului de descompunere în subbenzi folosind două canale. O primă implementare a DWT folosind o astfel de arhitectură a fost realizată de Mallat în 1988. În general, conținutul de joasă frecvență este cea mai importantă componentă a unui semnal. Aceasta definește „identitatea” semnalului. Dacă luăm ca exemplu vocea umană și eliminăm frecvențele înalte, aceasta se va auzi diferit dar va fi inteligibilă. În cazul în care eliminăm frecvențele înalte, vocea este posibil să fie distorsionată. [47]

Dacă luăm în considerare reprezentarea cu filtre a DWT atunci avem două componente: %o aproximări – sunt componente cu factor de scală mare, adică componente de frecvență joasă, %o detalii – componente cu factor de scală mic, adică componente de frecvență înaltă.

Procesul de implementare a DWT cu filtre este reprezentat în figura 4.8. [47]




Fig. 5.10 Reprezentarea cu filtre a DWT[47]

Semnalul original este trecut prin două filtre complementare rezultând două componente A – aproximări, D – detalii.

Funcția de dilatație a transformatei wavelet discrete poate fi reprezentată ca un arbore de filtre trece jos și filtre trece sus. Semnalul original este descompus succesiv în componente de rezoluție scăzută, în timp ce componentele de înaltă frecvență nu sunt analizate. Numărul maxim de dilatații care poate fi efectuat depinde de dimensiunea datelor semnalului analizat. De exemplu, un semnal format din $2N$ eșantioane, poate fi descompus în N nivele discrete, folosind transformata wavelet discretă.




Fig. 5.11 Descompunere pe trei nivele

Dacă descompunerea se face până la nivelul L , se va obține o descompunere trece jos de rezoluție $1/L$ și o sumă de detalii de rezoluții din ce în ce mai fine. Această descompunere reprezintă descompunerea wavelet multirezoluție sau piramidală.

Caracteristicile extrase din semnalele EEG achiziționate sunt energiile calculate pentru fiecare coeficient în parte, obținute prin descompunerea pe 8 nivele a semnalelor, utilizând transformata wavelet multirezoluție.

Semnalele EEG au fost achiziționate cu frecvența de 1 kHz. Astfel, coeficienții rezultați din descompunere cuprind următoarele benzi de frecvențe: D1(500-1000 Hz), D2(255-500 Hz), D3(128-255 Hz), D4(64-128 Hz), D5(32-64 Hz - Gama), D6(16-32 Hz - Beta), D7(8-16 Hz - Alfa), D8(4-8 Hz - Teta), A8(0-4 Hz Delta)

Algoritmul de extragere de caracteristici presupune parcurgerea următoarelor etape:

- se importă segmentele corespunzătoare fiecărei clase de mișcări din baza de date
- se aplică descompunerea wavelet multirezoluție (pe 8 nivele) pentru fiecare segment
- se calculează energiile pentru fiecare coeficient rezultat din descompunerea unui segment
- matricea de caracteristici rezultată va conține pe linii valorile energiilor atribuite segmentelor, iar pe coloane valorile energiilor atribuite coeficienților
- se normalizează coloanele matricei de caracteristici

În figura de mai jos sunt reprezentate semnalele reconstruite cu ajutorul coeficienților obținuți prin descompunerea unui segment achiziționat pe canalul C3, atribuit clasei 1 de mișcări.




Fig. 5.12 Descompunerea unui segment în benzile de frecvențe cerebrale

Descompunerea multirezoluție a fost realizată utilizând familia de undișoare Daubechies de ordinul 8. Prin mai multe teste efectuate în programul MATLAB am dedus faptul că familia de wavelet-uri, “Daubechies8”, aproximează ce la bine semnalele EEG achiziționate.




Fig. 5.13 Aproximare semnal EEG prin undișoare din familia Daubechies8

Cea mai mare parte a energiei semnalului EEG este regăsită pe coeficienții de detaliu D6 și D7, corespunzători ritmurilor alfa și beta. Acest lucru confirmă existența unei activități oscilatorii mai intense în banda de frecvențe 8-30 Hz a semnalelor EEG, achiziționate în cadrul unor experimente cu sarcini motorii.




Fig. 5.14 Reprezentarea grafică procentuală a energiilor calculate pentru fiecare coeficient.

Prin această reprezentare putem pune în evidență contribuția infimă a coeficienților D1, D2, D3 și D4, în analiza semnalelor electroencefalografice. Însă, metoda utilizată ulterior, de discriminare a semnalelor EEG, presupune utilizarea și acestor coeficienți.

Prin normalizarea coloanelor matricei de caracteristici se pune în evidență relația dintre valorile energiilor (în procente), a fiecărui coeficient din descompunere, pentru toate cele 4 clase. Astfel, se obține o repartiere pe clase, mult mai intuitivă, a procentelor energiilor întâlnite pe fiecare coeficient.

Coeficientul D6 prezintă cel mai mare procent din energia semnalului descompus, indiferent de clasa din care face parte semnalul (Fig. 4.14). Acest lucru face mai dificilă discriminarea semnalelor din clase diferite. Faptul că procentele energiilor întâlnite pe coeficientul D6 sunt cele mai mari, indiferent de clasa de apartenență a semnalelor analizate, implică mai mult o asemănare între semnale decât o deosebire. Deoarece dorim să punem în evidență deosebirile existente între semnalele din diferite clase s-a recurs la eliminarea coeficientului D6 (considerat a fi valoarea medie a semnalului), în etapa de clasificare.

5.2. Clasificare

Cum a fost menționat și în capitolul 1, există mai multe modalități de a clasifica semnalele EEG, fie prin utilizarea de clasificatori liniari sau neliniari (bayesieni), utilizarea de rețele neuronale sau clasificatori combinați. Deși fiecare metodă prezintă avantaje, oferind diferite grade de acuratețe, în lucrarea de față am utilizat rețeaua neuronală cu funcții de bază radiale (RBF).

5.2.1. Rețea neuronală cu funcții de bază radiale (RBF)

Rețelele neuronale bazate pe funcții radiale (RBF) se bucură în ultimul timp de o atenție tot mai mare, datorită avantajelor pe care le prezintă. Comparativ cu rețeaua MLP, în care se încearcă determinarea minimului gradientului funcției de eroare, procesul rețelei RBF presupune aproximarea unei suprafețe într-un spațiu multidimensional care să se asemene cu cea descrisă de datele de intrare. Astfel spus, performanțele rețelelor neuronale bazate pe funcții radiale sunt în strânsă legătură cu capacitatea de interpolare a datelor de test cu datele învățate în etapa de antrenare. O rețea neuronală artificială RBF va răspunde mai bine la un set de date de test, dacă aceasta a dispus inițial de mai mulți vectori de antrenament. [48]

Rețeaua neuronală RBF prezintă următoarea arhitectură:

- un strat de intrare (strat senzorial) compus din L neuroni virtuali ($i=0\dots L-1$), care nu realizează o prelucrare de semnal, ci doar o multiplexare, prelucrarea propriu-zisă având loc doar în stratul intermediar și în cel de ieșire.

- un strat intermediar cu M neuroni ($j=0\dots M-1$), care implementează funcția Gaussiană de activare:

$$z_j = e^{-\frac{\|X-m_j\|^2}{2\sigma_j^2}}$$

- un strat de ieșire cu N neuroni ($k=0\dots N-1$), care realizează suma ponderată a ieșirilor de pe stratul intermediar.

$$y_k = \sum_{j=0}^{M-1} w_{kj} z_j + \theta_k$$

unde:

- σ_j (dispersia) și m_j (media) descriu centroizii (prototipurile intrărilor)
- $X = [x_0, x_1, \dots, x_i, \dots, x_{L-1}]$, vectorul de intrare
- x_i este valoarea atribuită neuronului i din stratul de intrare, $i=0\dots L-1$

- z_j este ieșirea neuronului j din stratul ascuns (intermediar), $j=0...M-1$
- y_k este ieșirea neuronului k din stratul de ieșire, $k=0...N-1$
- w_{kj} este ponderea legăturii dintre neuronul k din stratul de ieșire și neuronul j din stratul ascuns (intermediar)

În stratul ascuns are loc partiționarea spațiului de intrare în grupări descrise prin dispersie și medie, în timp ce în stratul de ieșire se ia decizia de apartenență a vectorului de intrare la una din clase.

Numărul neuronilor din stratul de intrare este egal cu dimensiunea vectorului de intrare. Numărul neuronilor din stratul acuns poate fi mai mic sau egal cu numărul vectorilor din setul de antrenare. Numărul optim de centroizi (neuroni din stratul ascuns) se determină experimental. Numărul de clase în care se face clasificarea setează numărul de neuroni din stratul de ieșire. De exemplu, pentru clasificarea a 4 clase de semnale EEG am nevoie de 4 neuroni în stratul de ieșire.

Vectorii din setul de antrenare vor desemna mediile. Este de dorit ca eroarea de pe lotul de antrenare să fie zero. Astfel, se va obține un sistem de $M \times N$ ecuații cu $M \times N$ ponderi necunoscute, din care se vor determina ponderile. [48]




Fig. 5.15 Arhitectura rețelei neuronale utilizate pentru clasificarea semnalelor EEG

Descriere algoritm de implementare a rețelei neuronale

Pentru antrenarea rețelei neuronale RBF se folosește metoda centrilor ficși (aleși aletor). Presupune utilizarea de funcții radiale fixe, care reprezintă funcțiile de activare a stratului ascuns. Pozițiile centrilor funcțiilor sunt alese aleator din setul de vectori din etapa de antrenare.

În prima etapă se stabilește numărul de centroizi pentru fiecare din cele 4 clase și apoi sunt inițializați. Numărul optim de centroizi este determinat experimental, în cadrul mai multor încercări. Pe datele existente am constatat ca rețeaua răspunde cel mai bine pentru un număr de 29 de centroizi, pentru fiecare clasă în parte. Cei 29 de centroizi sunt inițializați cu primii vectori de intrare din setul de date de antrenare. Am optat pentru această variantă pentru a avea un control asupra rezultatelor obținute. De exemplu, dacă centroizii sunt inițializați aleator, la fiecare rulare a codului de antrenare a rețelei, vom obține rezultate diferite ale acurateței, astfel nemaiputându-se observa evoluția pentru diferite modificări. În setul vectorilor de antrenare se urmărește ca datele din fiecare clasă să fie suficient de similare, iar cele din clase diferite să fie suficient de diferite.

Fiecare clasă va avea un reprezentant (media datelor din clasă), care va fi considerat centrul clasei. Pentru a determina reprezentanții claselor se aplică algoritmul K-means de partiționare a spațiului de intrare în grupări descrise prin dispersie și medie. K-means presupune inițializarea aleatoare a centrilor claselor (numărul de clase este cunoscut-4), după care se vor itera următoarele etape:

- se asignează datele la centrul cel mai apropiat
- se actualizează centrii ca valori medii ale elementelor aparținând clasei respective

Deoarece algoritmul nu va găsi întotdeauna configurația optimă, corespunzătoare minimului global al funcției de minimizare și fiind sensibil la alegerea inițială a centroizilor, se va rula de mai multe ori algoritmul pentru a reduce aceste inconveniente.

Algoritmul “k-means” va rula maxim o mie de iterații în care își va recalcula centroizii pe baza mediei valorilor vectorilor de intrare care aparțin centroidului respectiv sau se va opri în momentul în care asupra centroizilor nu se mai face nici o modificare.

Se poate considera că centrul final al unei clase reflectă caracteristicile unui element tipic al clasei, prin valorile variabilelor din acel centru (procente de energie în aplicația de față).

Capitol 6. Rezultate

Pe baza semnalelor înregistrate am obținut următoarele reprezentări grafice ale activității electrice cerebrale.




Fig. 6.1 Activitatea cerebrală înregistrată în zona cortexului motor, în timpul mișcărilor brațelor

Utilizând caracteristicile extrase prin analiza wavelet multirezoluție (folosind familia de waveleturi Daubechies, de ordin 8) au fost obținute următoarele rezultate de clasificare a semnalelor EEG, în etapa de testare. Clasificare a fost făcută pe fiecare canal de achiziție, iar valorile din tabel reprezintă răspunsurile rețelei neuronale.

	C3	FCC3h	C1	FCCz	Cz	FCC4h	C2	C4
Sgn_Clasa1	4	1	1	2	4	1	3	1
Sgn_Clasa2	2	4	4	2	1	1	2	1
Sgn_Clasa3	3	3	3	3	3	3	4	3
Sgn_Clasa4	2	4	4	3	4	3	4	1
Acuratețe	50%	75%	75%	50%	50%	50%	50%	50%
75%								

Tabel 6.1 Răspunsurile furnizate de clasificator, folosind DWT(db8)

Rezultatele din Tabelul 6.1 sunt obținute în condițiile în care rețeaua neuronală este antrenată doar pe 20 de semnale (5 din fiecare clasă), pe canale de achiziție independente. Rezultatele cele mai bune în etapa de antrenare au fost obținute alegând un număr de 4 centroizi, pe clasă.

În continuare, voi testa clasificatorul pentru mai multe seturi de caracteristici, obținute prin modificarea familiilor de waveleturi, utilizate în descompunerea multirezoluție.

	C3	FCC3h	C1	FCCz	Cz	FCC4h	C2	C4
Sgn_Clasa1	4	2	2	2	4	2	3	3
Sgn_Clasa2	2	2	2	2	3	1	4	3
Sgn_Clasa3	3	3	3	3	4	4	3	4
Sgn_Clasa4	3	3	3	3	1	4	2	4
Acuratețe	50%	50%	50%	50%	0%	25%	25%	25%
34%								

Tabel 6.2 Răspunsurile furnizate de clasificator, folosind DWT(coif5)

	C3	FCC3h	C1	FCCz	Cz	FCC4h	C2	C4
Sgn_Clasa1	4	1	1	1	3	2	3	4
Sgn_Clasa2	2	1	1	2	1	1	4	3
Sgn_Clasa3	2	1	1	2	3	2	3	4
Sgn_Clasa4	1	1	4	2	4	3	2	4
Acuratețe	25%	25%	50%	50%	50%	0%	25%	25%
31%								

Tabel 6.3 Răspunsurile furnizate de clasificator, folosind DWT(sym7)

	C3	FCC3h	C1	FCCz	Cz	FCC4h	C2	C4
Sgn_Clasa1	1	1	1	1	3	1	3	4
Sgn_Clasa2	1	3	3	4	3	1	3	2
Sgn_Clasa3	3	3	3	3	3	4	4	3
Sgn_Clasa4	1	4	4	4	3	4	2	4
Acuratețe	50%	75%	75%	75%	25%	50%	0%	75%
53%								

Tabel 6.4 Răspunsurile furnizate de clasificator, folosind DWT(db6)

În literatura de specialitate, familia de waveleturi Daubechies este considerată cea mai potrivită pentru punerea în evidență a desincronizării ritmurilor sensorimotoare. Pentru analiza semnalelor EEG achiziționate, se observă că cele mai bune rezultate se obțin utilizând familia de waveleturi Daubechies.

Pentru a crește gradul de generalizare și de a obține rezultate mult mai bune în clasificarea semnalelor EEG, prin utilizarea de rețele neuronale, este nevoie de o baza de date cu semnale mult mai mare, pentru a asigura suficiente date în antrenarea rețelei. Altfel spus, rețeaua neuronală oferă răspunsuri mai bune dacă este suficient de bine antrenată și dacă datele de învățare respectă un anumit model, pentru fiecare clasa implicată.

În tabelul 5.6, sunt afișate răspunsurile rețelei neuronale RBF antrenate pe baza a 300 de semnale (75 pentru fiecare clasă), folosind 29 de centroizi pentru fiecare clasă, fiind inițializați cu primii vectori din setul de antrenare. Sunt testate 32 de semnale (câte 8 din fiecare clasă), achiziționate din aria cortexului motor, fiind aparte de semnalele din lotul de antrenare.

	C3	FCC3h	C1	FCCz	Cz	FCC4h	C2	C4
Sgn_Clasa1	4	2	2	2	1	1	4	1
Sgn_Clasa2	2	1	1	1	1	2	2	2
Sgn_Clasa3	3	3	3	3	3	3	3	3
Sgn_Clasa4	4	4	4	4	4	4	1	4
Acuratețe	75%	50%	50%	50%	75%	100%	50%	100%
68.8%								

Tabel 6.5 Răspunsurile furnizate de clasificator după extinderea bazei de date, DWT(db8)

Controlul brațului robotic JACO 3 prin intermediul semnalelor EEG clasificate

Controlul unui braț robotic prin intermediul biopotențialelor reprezintă un punct important în dezvoltarea de sisteme robotice asistive. În cadrul roboticii, interacțiunea om – robot este văzută cu maxim interes, în special în aplicațiilor medicale, dedicate persoanelor cu dizabilități.

Maparea directă dintre semnalele EEG și mișcările brațului robotic este destul de intuitivă. Fiecărei clase de semnale îi este atribuită mișcarea unui actuator al brațului robotic. Semnalele fiind discriminate în patru clase, puteam avea controlul asupra a 4 tipuri de mișcări efectuate de către brațul robotic. Fiecare actuator este caracterizat de 3 stări: repaus, rotație în sens orar și rotație în sens trigonometric. Starea de repaus este desemnată de inactivitatea cerebrală din zona ariei de interes. Astfel, fiecărei clase de semnale EEG îi este asociată o mișcare de rotație a unui actuator. Brațul robotic prezintă 6 actuatoare care desemnează articulațiile și 3 actuatoare pentru degetele efectorului. Toate cele 9 actuatoare pot fi controlate independent. Pentru a realiza comanda independentă a tuturor actuatorelor și pentru a efectua toate mișcările posibile este nevoie de 18 elemente distincte de comandă. Acest lucru nu este tocmai dorit și nici practic, în vederea realizării unor mișcări cursive și complexe. De aceea, pentru roboții care prezintă multe grade de libertate este nevoie de o abordare diferită pentru a realiza comanda lor.



Fig. 6.2 Numerotare actuatori – Jaco 3

În vederea programării mișcărilor brațului robotic, numerotarea actuatorelor pornește de la baza acestuia. În cadrul acestei aplicații, beneficiind doar de patru elemente distincte de comandă (clasele 1, 2, 3 și 4) se pot acționa un număr restrâns de actuatoare. Pentru o exemplificare practică vor fi asociate actuatorelor 6, f1, f2 și f3 clasele de semnale, de comandă. Astfel, pentru a acționa actuatorul 6 în ambele sensuri, voi utiliza drept comenzi clasele 1 și 2, iar pentru a închide și deschide degetele efectorului voi folosi clasele 3 și 4. Gripper-ul brațului robotic se va mișca întocmai seriei de răspunsuri furnizate de clasificatorul semnalelor EEG achiziționate.




Fig. 6.3 Comanda gripper-ului, prin intermediul semnalelor EEG

Concluzii și contribuții

În cadrul acestei lucrări sunt investigate sistemele bazate pe interfețe creier-calculator, îndeosebi cele care utilizează electroencefalograma (EEG), ca metodă de achiziție. Scopul acestor sisteme este de a permite utilizatorilor să manipuleze structuri robotice, doar prin simpla activitate cerebrală, corelată anumitor sarcini mentale. În urma testelor efectuate, se poate afirma că utilizarea biopotențialelor în interfețele om - calculator este o metodă viabilă pentru aplicații în domeniul roboticii. Pentru a susține această afirmație, au fost parcurse toate cele trei etape din realizarea unei interfețe creier - calculator: achiziția de semnale EEG, prelucrarea acestora și controlul brațului robotic Jaco 3.

Contribuțiile personale aduse prin această lucrare pot fi rezumate astfel:

- realizarea unui studiu asupra stadiului actual al cercetărilor în domeniul BCI;
- crearea unei paradigme, pe baza căreia se fac achiziții de semnale EEG
- crearea unei baze de date cu semnale EEG ce au la bază sarcini motorii, înregistrate atât în perioada de antrenare cât și în cea de testare;
- implementarea unui cod de extragere de caracteristici din semnalele EEG, aplicând analiza wavelet multirezoluție, pe segmentele extrase din semnalele achiziționate
- implementarea unui cod de clasificare ce utilizează rețeaua neuronală cu funcții de bază radială și obținerea unei rate de clasificare maxime de 68.8%;
- realizarea legăturii dintre semnalele clasificate și comanda gripper-ului brațului robotic Jaco 3

Achiziția semnalelor EEG, prelucrarea și clasificarea acestora prin metoda aleasă, reprezintă un suport adecvat pentru continuarea studiilor și încercarea de a obține rezultate cât mai bune, caracterizate prin execuția unor mișcări mai complexe ale brațului robotic.

Bibliografie

- [1] - SAEID SANEI, J. A. CHAMBERS, EEG Signal Processing, John Wiley & Sons, Chapter 1.1 History, 2013. Opens overlay Babak A. Taheri, Opens overlay Robert T. Knight, Opens overlay Rosemary L. Smith, A dry electrode for EEG recording
- [2] - Interfața creier-calculator: utilizarea semnalului electric al creierului în aplicații practice, Catalin CTEFAN, Cristian BOBOC, December, 04, 2015
- [3] - J.R. Wolpaw, N. Birbaumer, D.J. McFarland, G. Pfurtscheller, and T.M. Vaughan. Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, 113(6):767–791, 2002.
- [4] - G. Pfurtscheller, C. Neuper, and N. Birbaumer. Motor cortex in voluntary movements, chapter Human brain-computer interface, pages 367–401. CRC Press, riehle a, vaadia e. edition, 2005.
- [5] - N. Birbaumer. Breaking the silence: Brain-computer interfaces (BCI) for communication and motor control. *Psychophysiology*, 43(6):517–532, 2006.
- [6] - U. Hoffmann, J. Vesin, and T. Ebrahimi. Recent advances in brain-computer interfaces. In *IEEE International Workshop on Multimedia Signal Processing*, 2007.
- [7] - F. Cabestaing and A. Rakotomamonjy. Introduction aux interfaces cerveau machine (BCI). In *21ème Colloque sur le Traitement du Signal et des Images, GRETSI, 07*, pages 617–620, 2007.
- [8] - Millán, J. d. R. (2002). “Brain–computer interfaces,” in *Handbook of Brain Theory and Neural Networks*, 2nd Edn, ed. M. A. Arbib (Cambridge, MA: The MIT Press), 178–181.
- [9] - Nicolelis, M. A. L. (2001). Actions from thoughts. *Nature* 409, 403–407.
- [10] - Dornhege, G. Millán, J. d. R. Hinterberger, T. McFarland, D. J. and Müller, K. -R. (eds). (2007). *Towards Brain– Computer Interfacing*. Cambridge, MA: MIT Press.
- [11] - Allison, B. Z., Wolpaw, E. W., and Wolpaw, J. R. (2007). Brain–computer interface systems: progress and prospects. *Expert Rev. Med. Devices* 4, 463–474.
- [12] - Williamson, J., Murray-Smith, R., Blankertz, B., Krauledat, M., and Müller, K.-R. (2009). Designing for uncertain, asymmetric control: interaction design for brain–computer interfaces. *Int. J. Hum. Comput. Stud.* 67, 827–841.
- [13] - Carlson T., Robert Leeb, Ricardo Chavarriaga, and José del R. Millán, The birth of the brain-controlled wheelchair, *IROS*, page 5444-5445. IEEE, (2012)
- [14] - Millán, J. d. R., Renkens, F., Mouriño, J., and Gerstner, W. (2004b). Noninvasive brain-actuated control of a mobile robot by human EEG. *IEEE Trans. Biomed. Eng.* 51, 1026–1033.
- [15] - Millán, J. d. R., Renkens, F. Mouriño, J., and Gerstner, W. (2004a). Brainactuated interaction. *Artif. Intell.* 159, 241–259.
- [16] - Karim, A. A., Hinterberger, T. Richter, J., Mellinger, J. Neumann, N., Flor, H., Kübler, A., and Birbaumer, N. (2006). Neural internet: web surfing with brain potentials for the completely paralyzed. *Neurorehabil. Neural Repair* 20, 508–515.
- [17] - Computational Intelligence and Neuroscience Volume 2016 (2016), Article ID 3861425, 15 pages
- [18] - Contribuții la implementarea unei interfețe creier - calculator, R.Aldea, http://www.tuiasi.ro/uploads/files/Rezumat_Roxana_Aldea.pdf , accesat la data: 03.02.2017
- [19] - Lambda communications, <http://lambda.ro/research/index.php?id=36>, accesat la data: 14.02.2017

- [20] - H. Ramoser, J. Muller-Gerking, and G. Pfurtscheller. Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE Transactions on Rehabilitation Engineering*, 8(4):441–446, 2000.
- [21] - G. Dornhege, B. Blankertz, G. Curio, and K.-R. Müller. Increase information transfer rates in BCI by CSP extension to multi-class. In *Advances in Neural Information Processing Systems*, pages 733–740, 2004.
- [22] - W. Wu, X. Gao, and S. Gao. One-versus-the-rest (OVR) algorithm: An extension of common spatial patterns(CSP) algorithm to multi-class case. In *27th Annual International Conference of the Engineering in Medicine and Biology Society*, 2005. *IEEE-EMBS 2005*, pages 2387– 2390, 2005.
- [23] - Fabien Lotte, Phd. Thesis, 2008
- [24]- C.M.Michel,M.M.Murray, G. Lantz, S. Gonzalez, L. Spinelli, and R. Grave de Peralta. EEG source imaging. *Clin Neurophysiol.*, 115(10):2195–2222, 2004.
- [25]- S. Baillet, J.C. Mosher, and R.M. Leahy. Electromagnetic brain mapping. *IEEE Signal Processing Magazine*, 18(6):14–30, 2001.
- [26] - Tarik Al-ani^{1,2} and Dalila Trad^{1,3}, 1LISV-UVSQ, 10-12 Av de l'Europe, 78140 Velizy , 2Department of Informatics, ESIEE-Paris, Cité Descartes-BP 99 93162 Noisy-Le-Grand , Signal Processing and Classification Approaches for Brain-Computer Interface
- [27] - Ali Bashashati, Mehrdad Fatourehchi, Rabab K Ward and Gary E Birch. A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals, *Journ. Of Neural Engineering*, 2007
- [28] - Di D, Zhihua C, Ruifang F, Guangyu L, Tian L. Study on human brain after consuming alcohol based on eeg signal. In: *Computer Science and Information Technology (ICCSIT)*, 2010 3rd IEEE International Conference on, vol. 5. IEEE; 2010. p. 406–09.
- [29] - Hanafiah ZM, Taib MN, Hamid N. Eeg pattern of smokers for theta, alpha and beta band frequencies. In: *Research and Development (SCOREd)*, 2010 IEEE Student Conference on. IEEE; 2010. p. 320–23.
- [30] - E. Malar, A novel approach for the detection of drunken driving using the power spectral density analysis of EEG *Int J Comput Appl*, 21 (2011)
- [31] - M. Sharanreddy, P. Kulkarni, Automated eeg signal analysis for identification of epilepsy seizures and brain tumour, *J Med Eng Technol*, 37 (8) (2013), pp. 511–519
- [32] - Hansen IH, Marcussen M, Christensen JA, Jennum P, Sorensen HB. Detection of a sleep disorder predicting parkinson's disease. In: *Engineering in Medicine and Biology Society (EMBC)*, 2013 35th Annual International Conference of the IEEE. IEEE; 2013. p. 5793–96
- [33] - C.S. Ang, M. Sakel, M. Pepper, M. Phillips, Use of brain computer interfaces in neurological rehabilitation, *Brit J Neurosci Nurs*, 7 (3) (2011), pp. 523–528
- [34] - Y. Höller, J. Bergmann, M. Kronbichler, J.S. Crone, E.V. Schmid, A. Thomschewski, K. Butz, V. Schütze, P. Höller, E. Trinka, Real movement vs. motor imagery in healthy subjects, *Int J Psychophysiol*, 87 (1) (2013), pp. 35–41
- [35] - Manifestări electrice ale celulei vii, <http://www.scribub.com/medicina/MANIFESTARI-ELECTRICE-ALE-CELU43197.php>, accesat la data: 23.03.2017
- [36] - Loo C. K, A. Samraj, and G. C. Lee, “Evaluation of Methods for Estimating Fractal Dimension in Motor Imagery-Based Brain Computer Interface,” *Discrete Dynamics in Nature and Society*, vol. 2011, pp. 1–8, 2011.
- [37] - Durka P. J., J. Zygierevicz, H. Klekowicz, J. Ginter, and K. J. Blinowska, “On the statistical

- significance of event-related EEG desynchronization and synchronization in the time-frequency plane.,” IEEE, transactions on bio-medical engineering, vol. 51, no. 7, pp. 1167–75, Jul. 2004.
- [38] - Cortex motor și somatosenzorial, <https://au.pinterest.com/explore/homunculus-brain/?lp=true>, accesat la data: 10.02.2017
- [39] - Compumedics Neuroscan, <http://compumedicsneuroscan.com/>, accesat la data: 27.03.2017
- [40] - Transformări timp - frecvență utilizate în telecomunicații: transformata Fourier pe termen scurt și transformata wavelet, Conf. dr. ing. Mircea RĂDUCANU*, Prof. dr. ing. Lucian STANCIU*, Prof. dr. ing. Adelaida MATEESCU*, pag.54-63
- [41] - A. Subasi, M. K. Kiymik, A. Alkan, and E. Koklukaya, “Neural network classification of EEG signals by using AR with MLE preprocessing for epileptic seizure detection,” Mathematical and Computational Applications, vol. 10, no. 1, pp. 57–70, 2005.
- [42] - Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains, <https://www.hindawi.com/journals/isrn/2014/730218/>, accesat la data 10.04.2017
- [43] - ESTIMAREA SPECTRULUI DE PUTERE, pag 285-361, http://telecom.etc.tuiasi.ro/pns/curs/cap_13.pdf, accesat la data: 10.04.2017
- [44] - <http://www.kinovarobotics.com/>, accesat la data: 12.02.2017
- [45] - Răducanu, M., Mateescu, M. L. (2002). ECG signals compression and analysis using Wavelet analysis. Telecomunicații Revue, 2, 47-52.
- [46] - Analiza de tip wavelet, <http://scs.etc.tuiasi.ro/iciocoiu/courses/CIPS/course7/Capitolul2.pdf>, accesat la data 12.04.2017
- [47] - Viziunea computerizată în exemple și aplicații practice, http://users.utcluj.ro/~elupu/Curs/upload/Cursuri/Univ.Nord_BM1/Curs_14/c1/1/proc/self/cwd/home/bel/mihag/master.pdf, accesat la data: 24.04.2017
- [48] - Reteaua neurala cu functii de baza radiale (RBF), <http://www.victorneagoe.com/university/prai/lab4b.pdf>, accesat la data: 28.04.2017
- [49] - EEGLab, <https://www.mathworks.com/matlabcentral/linkexchange/links/748-eeqlab>, accesat la data: 03.02.2017


```

% Semnalele sunt importate in Workspace utilizand toolbox-ul EEGLab.
% Din cadrul structurii create voi extrage doar semnalele de pe canalele de
% interes si timpii la care sunt plasate pe semnal diferitele tipuri de markeri

%% Vizualizare semnalelor de pe diferite canale de achizitie

% Extrag semnalul de pe canalul 26 (C3), din structura EEG, pentru a fi
% vizualizat
Ch26=EEG.data(26,:);

% Memorez in vectori momentele de timp la care sunt plasate diferite
% tipuri de markeri pe semnalul achizitionat. Fiecare tip de marker este
% atribuit unei actiuni executate de subiect, in timpul achizitiilor
% Tip marker - actiune:
%           1 - Abductie mana dreapta
%           2 - Adductie mana dreapta
%           3 - Abductie mana stanga
%           4 - Adductie mana stanga
%           5 - Strange pumn drept
%           6 - Relaxeaza pumn drept
%           7 - Strange pumn stang
%           8 - Relaxeaza pumn stang

for i=1:length(EEG.event)
    if EEG.event(1,i).type==1
        AbductieD(i)=EEG.event(1,i).latency;
    else if EEG.event(1,i).type==2
        AdductieD(i)=EEG.event(1,i).latency;
    else if EEG.event(1,i).type==3
        AbductieS(i)=EEG.event(1,i).latency;
    else if EEG.event(1,i).type==4
        AdductieS(i)=EEG.event(1,i).latency;
    else if EEG.event(1,i).type==5
        GraspD(i)=EEG.event(1,i).latency;
    else if EEG.event(1,i).type==6
        ReleaseD(i)=EEG.event(1,i).latency;
    else if EEG.event(1,i).type==7
        GraspS(i)=EEG.event(1,i).latency;
    else if EEG.event(1,i).type==8
        ReleaseS(i)=EEG.event(1,i).latency;
    end
end
end
end
end
end
end
end

% Elimin din vectori toate elementele egale cu 0

AbductieD=AbductieD(AbductieD~=0);
AdductieD=AdductieD(AdductieD~=0);
AbductieS=AbductieS(AbductieS~=0);
AdductieS=AdductieS(AdductieS~=0);
GraspD=GraspD(GraspD~=0);
ReleaseD=ReleaseD(ReleaseD~=0);

```

```

GraspS=GraspS(GraspS~=0);
ReleaseS=ReleaseS(ReleaseS~=0);

% Afisez semnalul impreuna cu markerii plasati pe acesta (reprezentati
% prin bare verticale de culori si denumiri diferite), la momentele de timp
% specificate in vectorii creati mai sus
figure
plot(EEG.times,Ch26)
xlabel('[s]')
ylabel('[uV]')
vline(AbductieD,'g','AbductieD');
vline(AdductieD,'r','AdductieD');
vline(AbductieS,'k','AbductieS');
vline(AdductieS,'m','AdductieS');
vline(GraspD,'g','GraspD');
vline(ReleaseD,'r','ReleaseD');
vline(GraspS,'k','GraspS');
vline(ReleaseS,'m','ReleaseS');

% calcul densitate spectrala de putere estimata, pentru fiecare segment din
% semnal asociat unei clase, utilizand metoda neparametrica Welch

Fs = 1000; % Frecventa de esantionare
Nfft = 8192;

segment_window = ones(1,ceil(7000/8));
%segment_window = hamming(ceil(7507/8));
%segment_window = blackman(ceil(7000/8));
Chx=EEG.data(26,:);
latency_vect = zeros(1,14);
latency_vect(14) = length(Chx);
for i = 2:13
    latency_vect(i) = EEG.event(1,i-1).latency;
end
Chx_windows = zeros(13,8000);
for i = 1:13
    aux = Chx((1+latency_vect(i)):latency_vect(i+1));
    Chx_windows(i,:) = [aux zeros(1,8000-length(aux))];
end
Chx_windows_psd = zeros(13,Nfft/2+1);
for i = 1:13
    [Chx_windows_psd(i,:),f_vect] =
    pwelch(Chx_windows(i,:),segment_window,[],Nfft,Fs);
End

figure
for i = 1:13
    hold on;
    plot(f_vect,abs(Chx_windows_psd(i,:)))
    axis([5 15 0 max(abs(Chx_windows_psd(i,:)))])
end

% figure
% for i = 1:13
%     hold on;
%     plot(f_vect,20*log10(abs(Chx_windows_psd(i,:))))
%     axis([0 20 -80 max(20*log10(abs(Chx_windows_psd(i,:))))])
% end

```

```

Chx = EEG.data(26,:);
latency_vect = zeros(1,14);
latency_vect(14) = length(Chx);
for i = 2:13
    latency_vect(i) = EEG.event(1,i-1).latency;
end
Chx_windows = zeros(6,8010);
for i = 1:6
    aux = Chx((latency_vect(2*i)):latency_vect(2*i+2));
    Chx_windows(i,:) = [aux zeros(1,8010-length(aux))];
end
% Creare baza de date:
% segmentele din semnal, asociate claselor vor fi salvate intr-o baza de date
% prorie, sub forma unor fisiere .mat
Antrenare1 = Chx_windows(1,:);
% .....
% din alta achizitie se extrag si semnalele de testare
Testare1 = Chx_windows(1,:);
% .....

% Determinarea distributiei energiilor pe coeficienti
function result = Calcul_Energii_Coefwv(C, L)
nr_coef = size(L,2)-1;
offset = 0;
energy=0;
for i = 1:nr_coef
    if(i == 1)
        energy(i) = sum(C(1:L(1)).^2);
        offset = offset + L(1);
    else
        energy(i) = sum(C(offset + 1 : offset + L(i)).^2);
        offset = offset + L(i);
    end
end
energy = (energy / sum(energy))*100; % energiile exprimate in procente
energy(energy == max(energy)) = []; % elimin energia calculata pe coeficientul
D6
result = energy;

end

% Cod antrenare RBF
clear all;
addpath('kMeans');
addpath('ReteaNeuronalRBF');

cale_folder = 'C:/Users/Raducanu Emanuel/Desktop/Database/CH/Antrenare/';
user_folder_canale = dir(sprintf('%s', cale_folder));%numele folderelor de
canale
lista_dir_canale = {user_folder_canale.name}; %lista folderelor de canale

Semnale = [ ];
aux_contorl = 1;
contorl = 1;

for i = 3: size(user_folder_canale,1)

```

```

    cale_canale = fullfile(sprintf('%s', cale_folder), sprintf('%s',
lista_dir_canale{i}));

user_folder_clase = dir(sprintf('%s', cale_canale)); %numele folderelor de clase
lista_dir_clase = {user_folder_clase.name};

contor2 = 1;
contor1 = aux_contor1;

for j = 3: size(user_folder_clase,1)
    director = fullfile(sprintf('%s', cale_canale), sprintf('%s',
lista_dir_clase{j}));
    lista_semnale = dir([director, '/*.mat']);
    for k = 1: size (lista_semnale,1)
        Semnale{contor1, contor2} = load([cale_canale '/Clasa_' num2str(contor2)
'/Antrenare' num2str(k) '.mat']);
        contor1 = contor1 + 1;
    end;
    contor1 = aux_contor1;
    contor2 = contor2 + 1;
end
aux_contor1 = aux_contor1+size (lista_semnale,1);
end
%Redenumesc vectorii cu semnale. Toate vor primi numele "Antrenare", pentru
% a putea parcurge toata structura cu bucle for.
for k=1:size (Semnale,2)
    for l=1:size (Semnale,1)
        F = fieldnames(Semnale{l,k});
        Semnale{l,k} = rnfield(Semnale{l,k}, F, 'Antrenare');
    end
end

%Creez matricea cu semnale
Matrice_semnale = zeros( size (Semnale,1)*size (Semnale,2), 8010);
contor_linii_matrice = 1;
for i=1:size (Semnale,2)
    for j=1:size (Semnale,1)
        Matrice_semnale(contor_linii_matrice,:)= Semnale{j,i}.Antrenare;
        contor_linii_matrice = contor_linii_matrice + 1;
    end
end

m = size(Matrice_semnale,1);
Nr = 8;
Valori_Energii = zeros(m,Nr);

for i=1:m
    [C,L] = wavedec(Matrice_semnale(i,:),Nr,'db8');
    Valori_Energii(i,:) = Calcul_Energii_Coefwv(C, L);
end

% Normalizez colonele matricei Valori_Energii
minim = min(Valori_Energii, [], 1);
maxim = max(Valori_Energii, [], 1);
Valori_Energii = (Valori_Energii - repmat(minim, m, 1))./(repmat(maxim, m, 1) -
repmat(minim, m, 1));
Valori_Energii = Valori_Energii';

% Incarc coloana de indecsi pentru semnale
Id1 = ones(1,(size(Valori_Energii,2)/4));
Id2 = 2*Id1;
Id3 = 3*Id1;

```

```

Id4 = 4*Id1;
ID = [Id1 Id2 Id3 Id4];
Valori_Energii = [Valori_Energii;ID];
Valori_Energii = Valori_Energii';

%% X intrari Y iesi
X = Valori_Energii(:,1:(end-1));

%Se vor elimina valorile maxime ale energiilor, care apar intotdeauna pe
%coeficientul de detaliu corespunzator benzii de frecventa beta(13-30 Hz)
%Vom memora in X valorile energiilor ramase.
% for i=1:size(X_Initial,1)
%
%     aux = X_Initial(i,:);
%     aux = aux(aux~=max(aux));
%     X(i,:)=aux;
% end

Y = Valori_Energii(:,end);
% 'm' - numarul de semnale
m = size(X, 1);

% =====
% Antrenare retea neuronală RBF
% =====

% Antrenez retea neuronală folosind n centroizi pentru fiecare clasă
[Centroizi, betas, Theta] = AntrenareReteaRBF(X, Y, 29, true);

% =====
% Etapa de antrenare - Calcul acuratete retea
% =====

disp('Calculeaza acuratetea...');
Contor_raspCorect = 0;
raspGresit = [];

%Pentru fiecare ciclu...

for (i = 1 : m)
    % Calculeaza scorul pentru fiecare categorie
    scor = EvaluareReteaRBF(Centroizi, betas, Theta, X(i, :));
    [scorMaxim, Clasa(i,1)] = max(scor);

%validare raspuns
    if (Clasa(i,1) == Y(i))
        Contor_raspCorect = Contor_raspCorect + 1;
    else
        raspGresit = [raspGresit; X(i, :)];
    end
end

acuratete = Contor_raspCorect / m * 100;
fprintf('Acuratete etapa antrenare: %d ghicite din %d, %.1f%%\n',
Contor_raspCorect, m, acuratete);

```

```

% Cod testare RBF

clearvars -except Centroizi betas Theta minim maxim
addpath('kMeans');
addpath('ReteaNeuronalRBf');

cale_folder = 'C:/Users/Raducanu Emanuel/Desktop/Database/CH/Testare/';
user_folder_canale = dir(sprintf('%s', cale_folder)); %numele folderelor de
canale
lista_dir_canale = {user_folder_canale.name}; %lista

Semnale = [ ];
aux_contorl = 1;
contorl = 1;

for i = 3: size(user_folder_canale,1)
    cale_canale = fullfile(sprintf('%s', cale_folder), sprintf('%s',
lista_dir_canale{i}));

    user_folder_clase = dir(sprintf('%s', cale_canale)); %numele folderelor de clase
    lista_dir_clase = {user_folder_clase.name};

    contor2 = 1; % contorizeaza folderele claselor
    contorl = aux_contorl; % contorizeaza fisierele din folderele claselor

    for j = 3: size(user_folder_clase,1)
        director = fullfile(sprintf('%s', cale_canale), sprintf('%s',
lista_dir_clase{j}));
        lista_semnale = dir([director, '/*.mat']);
        for k = 1: size (lista_semnale,1)
            Semnale{contorl, contor2} = load([cale_canale '/Clasa_' num2str(contor2)
            '/Testare' num2str(k) '.mat']);
            contorl = contorl + 1;
        end;
        contorl = aux_contorl;
        contor2 = contor2 + 1;
    end
    aux_contorl = aux_contorl+size (lista_semnale,1);
end

%Redenumesc vectorii cu semnale. Toate vor primi numele "Testare", pentru
% a putea parcurge toata structura cu bucle for.
for k=1:size (Semnale,2)
    for l=1:size (Semnale,1)
        F = fieldnames(Semnale{l,k});
        Semnale{l,k} = rnfield(Semnale{l,k}, F, 'Testare');
    end
end

%Creez matricea cu semnale
Matrice_semnale = zeros( size (Semnale,1)*size (Semnale,2), 8010);
contor_linii_matrice = 1;
for i=1:size (Semnale,2)
    for j=1:size (Semnale,1)
        Matrice_semnale(contor_linii_matrice,:)= Semnale{j,i}.Testare;
        contor_linii_matrice = contor_linii_matrice + 1;
    end
end
end

```

```

m = size(Matrice_semnale,1);
Nr = 8;
Valori_Energii = zeros(m,Nr);

for i=1:m
    [C,L] = wavedec(Matrice_semnale(i,:),Nr,'db8');
    Valori_Energii(i,:) = Calcul_Energii_Coefwv(C, L);
end

Valori_Energii = (Valori_Energii - repmat(minim, size(Valori_Energii,1),
1))./(repmat(maxim, size(Valori_Energii,1), 1) - repmat(minim, m, 1));
Valori_Energii = Valori_Energii';

% Incarc coloana de indecsi pentru semnale
Id1 = ones(1, (size(Valori_Energii,2)/4));
Id2 = 2*Id1;
Id3 = 3*Id1;
Id4 = 4*Id1;
ID = [Id1 Id2 Id3 Id4];
Valori_Energii = [Valori_Energii;ID];
Valori_Energii = Valori_Energii';

%% X intrari Y iesiri dorite
X = Valori_Energii(:,1:(end-1));
Y = Valori_Energii(:,end);
% 'm' - numarul de semnale
m = size(X, 1);
disp('Calculeaza acuratetea...');
Contor_raspCorect = 0;
raspGresit = [];

%Pentru fiecare ciclu...
for (i = 1 : m)
    % Calculeaza scorul pentru fiecare semnal
    scor = EvaluareReteaRBF(Centroizi, betas, Theta, X(i, :));
    [scorMaxim, Clasa(i,1)] = max(scor);

%validare raspuns
    if (Clasa(i,1) == Y(i))
        Contor_raspCorect = Contor_raspCorect + 1;
    else
        raspGresit = [raspGresit; X(i, :)];
    end
end

acuratete = Contor_raspCorect / m * 100;
fprintf('Acuratete etapa testare: %d ghicite din %d, %.1f%%\n',
Contor_raspCorect, m, acuratete);
% Scriu in fisier .txt raspunsurile retelei
Clasa=Clasa';
y=fopen('Comenzi_Clase.txt','wt');
fprintf(y,'%d ',Clasa);
fclose(y);

```