

**Universitatea Națională de Știință și Tehnologie POLITEHNICA București**  
**Centrul Universitar Pitești**  
**Școala Doctorală Interdisciplinară**  
**Domeniul fundamental: Științe ingineresti**  
**Domeniul: Inginerie electronică, telecomunicații și tehnologii informaționale**

**Doctorand ing. Coman Daniela Andreea**

**- REZUMATUL TEZEI DE DOCTORAT -**

## **CONTRIBUȚII LA REALIZAREA SISTEMELOR DE ACHIZIȚIE ȘI PRELUCRARE A SEMNALELOR EEG**

Comisia de evaluare a tezei:

Președinte	prof. univ. dr. ing. <b>BIZON Nicu</b> , Universitatea Națională de Știință și Tehnologie POLITEHNICA București
Conducător de doctorat	prof. univ. dr. ing. <b>LITĂ Ioan</b> , Universitatea Națională de Știință și Tehnologie POLITEHNICA București – Centrul Universitar Pitești
Referenți oficiali	acad. prof. emerit dr. ing. <b>TEODORESCU Horia-Nicolai</b> , Universitatea Tehnica “Gheorghe Asachi” din Iași prof. univ. dr. ing. <b>GRIGORE Ovidiu</b> , Universitatea Națională de Știință și Tehnologie POLITEHNICA București prof. univ. dr. ing. <b>POP Ovidiu Aurel</b> , Technical University of Cluj-Napoca

Pitești  
2024

## Mulțumiri

Cu profundă recunoștință, doresc să mulțumesc tuturor celor care au contribuit la realizarea acestei teze de doctorat, un demers academic complex și provocator, care a marcat o etapă importantă în parcursul meu profesional și personal.

Îmi exprim aprecierea și adresez mulțumiri speciale coordonatorului de doctorat, domnului prof. univ. dr. ing. **Ioan Lița**, pentru îndrumarea și sprijinul continuu oferit în fiecare etapă a acestui demers academic, contribuind esențial la realizarea cercetării de față.

Le mulțumesc cu entuziasm membrilor comisiei de îndrumare pentru suportul constant și expertiza împărtășită pe parcursul acestei perioade.

Adresez recunoștință domnului prof. univ. dr. ing. **Silviu Ionița** pentru contribuția valoroasă prin sugestii, dedicare, răbdare și critici constructive, care au îmbogățit considerabil această lucrare. Viziunea sa științifică, spiritul neobosit, animat de o curiozitate profundă și o sete constantă de cunoaștere, mereu în căutarea unor noi orizonturi intelectuale, a fost o sursă de inspirație și un reper fundamental în dezvoltarea mea profesională.

Mulțumesc domnului conf. univ. dr. ing. **Gabriel Vasile Iana** pentru discuțiile constructive, sugestiile și feedback-ul valoros. De asemenea, îi mulțumesc domnului conf. univ. dr. ing. **Laurențiu Mihai Ionescu** pentru observațiile și recomandările utile oferite.

Nu pot uita contribuția valoroasă a colegilor și prietenilor de la Centrul CRC&D – Auto, sub conducerea domnului conf. univ. dr. fiz. **Marian Cătălin Ducu**. Discuțiile academice stimulative și atmosfera de colaborare m-au inclus într-un mediu propice dezvoltării intelectuale și unei mai bune înțelegeri a subiectului cercetat. Le mulțumesc pentru susținere și pentru încurajările care au făcut această călătorie mai plăcută.

Dedic această lucrare bunicii mele, Pompei, care, cu înțelepciunea sa blândă, și-a dorit să vadă această teză scrisă, a doua zi după ce am definit tema. Dar nu a fost să mai fie...

În final, mulțumesc fiului meu, Radu, de 9 ani, pentru concluzia profundă pe care a oferit-o acestei lucrări: „*Infinitul este ca plimbarea unei frunze în vânt*”... Doar noi o complicăm, măsurând – o!

# CUPRINS

INTRODUCERE.....	6
Capitolul 1 STUDIU ASUPRA ACTIVITĂȚII ELECTRICE A CREIERULUI .....	9
1.1 Formarea biosemnalelor în creier.....	9
1.2 Natura semnalelor EEG.....	10
1.3 Propagarea semnalului .....	10
1.4 Parametrii și clasificarea semnalelor EEG .....	11
1.5. Concluzii parțiale .....	11
1.6 Contribuții .....	12
Capitolul 2 PARTICULARITĂȚI ÎN ACHIZIȚIA ȘI PRELUCRAREA SEMNALELOR EEG	13
2.1 Structura hardware și software a sistemelor de achiziție pentru semnalele EEG .....	13
2.2. Obținerea și înregistrarea datelor EEG.....	14
2.2.1. Metodologia obținerii datelor EEG .....	14
2.2.2 Proiectarea experimentelor de achiziție EEG.....	15
2.2.3 Seturi de date experimentele .....	16
2.3 Tehnici de analiză și prelucrare a semnalelor EEG.....	18
2.4 Concluzii parțiale .....	18
2.5 Contribuții .....	19
Capitolul 3 CONTRIBUȚII LA ANALIZA ȘI PRELUCRAREA SEMNALELOR EEG .....	20
3.1 Prelucrare pentru separarea componentelor EEG prin filtrare .....	20
3.2 Metode de prelucrare pentru eliminarea zgomotului .....	21
3.2.1 Prezentarea algoritmului .....	21
3.2.2 Rezultate experimentale .....	22
3.3 Metode de prelucrare pentru eliminarea artefactelor .....	22
3.3.1 Prezentarea algoritmilor .....	22
3.3.2 Rezultate experimentale .....	23
3.4. Analiza în frecvență în benzi și sub-benzi specifice EEG.....	23
3.4.1. Prezentarea algoritmilor .....	23
3.4.2 Rezultate experimentale .....	23
3.4.3 Concluzii parțiale .....	26
3.4.4 Analiza în domeniile beta- alfa și teta-alfa.....	26
3.4.5 Prezentarea algoritmilor .....	26

3.4.6 Rezultate experimentale .....	27
3.4.7 Concluzii parțiale .....	29
3.5 Analiza semnalelor filtrate în benzi înguste .....	30
3.5.1 Prezentarea algoritmilor .....	31
3.5.2 Rezultate experimentale .....	33
3.5.3 Concluzii parțiale .....	34
3.6 Analiza prin metode statistice .....	35
3.6.1 Prezentarea algoritmilor .....	35
3.6.2 Rezultate experimentale .....	35
3.6.3 Concluzii parțiale .....	35
3.7 Contribuții .....	36
Capitolul 4 PROIECTAREA UNUI SISTEM DE ACHIZIȚIE EEG PENTRU SARCINI COGNITIVE .....	37
4.1. Problematika detectării în timp real a activității cognitive specifică efortului mental în sarcinile de calcul aritmetic .....	37
4.2 Proiectarea și implementarea modulelor de filtrare .....	37
4.3 Implementarea algoritmului de detecție în timp real a sarcinii mentale .....	38
4.3.1 Evaluarea algoritmului .....	41
4.3.2 Rezultate experimentale .....	42
4.4 Aplicație pentru maparea activității creierului cu 64 de canale EEG.....	46
4.5 Concluzii parțiale .....	47
Capitolul 5 CONCLUZII .....	49
5.1 Concluziile tezei .....	49
5.2. Contribuții .....	51
5.3 Perspective de cercetare .....	52
BIBLIOGRAFIE SELECTIVĂ .....	53

## LISTA ABREVIERILOR

AN	Adevărat Negativ
AP	Adevărat Pozitiv
ASR	Artifact Subspace Reconstruction (Reconstrucția subspațiului de artefacte)
BCI	Brain Computer Interface (Interfață Creier-Calculator)
BDF	Biosemi Data Format (Format de date Biosemi)
CAN	Convertor analog-numeric
CMRR	Common-Mode Rejection Ratio (Raportul de respingere a modului comun)
DT	Decision Tree (Arborele de Decizie)
EDF	European Data Format (Format european de date)
EEG	Electroencefalografie
EIT	Electrical Impedance Tomography (Tomografie cu impedanță electrică)
ERP	Event-Related Potential (Potențial evocat de eveniment)
Es	Energia semnalului
FFT	Fast Fourier Transform (Transformată Fourier Rapidă)
FIR	Finite Impulse Response (Filtru cu răspuns finit la impuls)
FN	Fals Negativ
FP	Fals Pozitiv
FTJ	Filtru Trece Jos
FTS	Filtru Trece Sus
Hz	Hertz
ICA	Independent Component Analysis (Analiza componentelor independente)
IIR	Infinite Impulse Response (Filtrul cu răspuns infinit la impuls)
KNN	K-Nearest Neighbors (K-Vecinii cei mai Aproiați)
LCR	Lichid cefalorahidian
LDA	Linear Discriminant Analysis (Analiza Discriminantă Liniară)
LFP	Local Field Potențial (Potencial de câmp local)
Lfp	Lungimea funcției de semnal
MARA	Multiple Artifact Rejection Algorithm (Algoritmul de Respingere a Artefactelor Multiple)
MAT	Mental Arithmetic Task (Sarcină aritmetică mentală)
MCC	Matthew Correlation Coefficient (Coeficientul de Corelație Matthew)
ML	Machine Learning (Învățare automată)
PA	Potențial de acțiune
PCA	Principal Component Analysis (Analiza componentelor principale)
RNN	Recurrent Neural Network (Rețea Neuronală Recursivă)
RSVP	Rapid Serial Visual Presentation (Prezentare vizuală rapidă în serie)
SD	Deviație standard
SDK	Software Development Kit (Set de dezvoltare software)
s	secunde
SNR	Signal-to-noise ratio (Raportul semnal-zgomot)
SVM	Support Vector Machine (Mașină cu Vectori de Suport)

# INTRODUCERE

În ultimele decenii, progresele în domeniul neuroștiinței și al inteligenței computaționale au dus la o expansiune semnificativă a cercetării în domeniul interfețelor creier-computer (BCI). Aceste tehnologii emergente se bazează în mare parte pe utilizarea electroencefalografiei (EEG), o tehnică consacrată în medicina clinică și un instrument esențial pentru cercetarea științifică. EEG permite monitorizarea neinvazivă a activității electrice a creierului, facilitând astfel o gamă variată de aplicații, de la monitorizarea stărilor cognitive în diverse contexte și a performanței cognitive până la diagnosticarea tulburărilor neurologice și controlul dispozitivelor externe.

**Domeniul tezei de doctorat** se situează la intersecția dintre neuroștiință și tehnologia informației, cu un accent special pe tehnicile de prelucrare a semnalelor EEG pentru detecția activității cerebrale în sarcini cognitive specifice. Electroencefalografia (EEG) a devenit un instrument fundamental nu doar în diagnosticul medical, ci și în dezvoltarea interfețelor creier-computer (BCI), care permit interacțiunea directă dintre creier și dispozitivele externe. Aceste sisteme, bazate pe EEG, au potențialul de a transforma monitorizarea și intervenția asupra stărilor cognitive și emoționale, cu aplicații extinse în asistența medicală și alte domenii.

**Motivația cercetării:** Metodele de învățare automată (ML), inteligența artificială (IA) în general, precum și modelele bayesiene sunt frecvent utilizate în cercetarea EEG, dar acestea prezintă limitări specifice în contextul sarcinilor cognitive de tip aritmetic. Astfel, am considerat că analiza semnalelor EEG pentru sarcinile mentale cognitive de acest tip, care antrenează mai multe procese neuronale și activează arii corticale distribuite, necesită utilizarea unor metode analitice mai rafinate.

Semnalul EEG din sarcinile aritmetice este puternic afectat de variabilitatea cognitivă, artefactele induse de mișcare și de schimbările fiziologice, ceea ce face dificilă obținerea unui set de date stabil și constant necesar pentru antrenarea modelelor ML sau IA. În plus, modelele bayesiene care depind de predictibilitatea bazată pe observații precedente se confruntă cu provocări din cauza naturii impredictibile și neliniare a activității cerebrale în aceste sarcini.

Abordarea propusă în această lucrare, care se bazează pe filtrarea și analiza spectrală a semnalelor EEG, oferă un răspuns mai potrivit pentru detectarea în timp real a efortului mental, fără a necesita seturi mari de date de antrenament și recalibrare continuă. Aceasta permite o discriminare eficientă a stărilor mentale prin metode directe și rapide, optimizând procesul pentru aplicații practice, precum interfețele creier-calculator.

Astfel, deși ML, IA și modelele bayesiene nu sunt inadecvate în mod absolut pentru analiza semnalelor EEG, în cazul specific al sarcinilor mentale aritmetice, metodele directe propuse în această lucrare se dovedesc a fi mai eficiente și adaptate cerințelor de procesare în timp real.

**Obiectivul principal al tezei** este de a detecta activitatea cerebrală în timpul unor sarcini cognitive intense, cum ar fi calculele aritmetice, comparativ cu o stare de referință și de a identifica electrozii cei mai sensibili în acest proces. Scopul este de a dezvolta metode eficiente de prelucrare și interpretare a semnalelor EEG pentru a detecta activitatea cerebrală asociată acestor sarcini în timp real.

Teza explorează noi modalități de investigare a semnalelor EEG, dezvoltând algoritmi care să distingă cu precizie activitatea cerebrală specifică calculului aritmetic, fără utilizarea metodelor de învățare automată și învățare profundă. Această abordare se concentrează pe calibrarea individuală, luând în considerare unicitatea fiecărui subiect și permite aplicarea metodei pe un nou subiect fără a compromite performanța, utilizând tehnici de analiză EEG bazate pe caracteristicile activității cerebrale individuale.

## **Conținutul tezei de doctorat**

**Capitolul 1** prezintă o scurtă incursiune în neurofiziologia activității electrice a creierului, stabilind baza teoretică pentru înțelegerea generării și captării semnalelor EEG. Sunt prezentate structura neuronilor și organizarea acestora la nivelul circuitelor cerebrale, evidențiindu-se modul în care activitatea electrică generată de aceste circuite contribuie la formarea semnalelor EEG. Se analizează mecanismele neuronale și diferențele dintre activitatea neuronală reală și cea distorsionată de mediile biologice prin care semnalele electrice se propagă, subliniind complexitatea ierarhică a interacțiunilor neuronale și modul în care acestea sunt reflectate în înregistrările EEG.

**Capitolul 2** descrie particularitățile și cerințele componentelor unui sistem EEG, subliniind provocările asociate cu obținerea unui semnal cu fidelitate ridicată. Sunt analizate aspectele esențiale ale întregului lanț de achiziție EEG, de la captarea semnalelor până la procesare, inclusiv interferențele și artefactele, precum și măsurile implementate pentru minimizarea acestora. Se prezintă diverse baze de date EEG, cu acces liber și acces restricționat, alături de importanța unui design experimental fiabil pentru asigurarea validității și reproductibilității datelor obținute. Sunt descrise experimentele alese pentru cercetare. Seturile de date utilizate în analiză au fost obținute atât din sursele de date existente – baza de date internațională Physionet, specializată în biosemnale, cât și prin realizarea experimentelor proprii. Domeniul principal de studiu selectat pentru analiză a fost stresul mental indus prin sarcini de calcul aritmetic.

**Capitolul 3** se concentrează pe contribuțiile aduse analizei și prelucrării semnalelor EEG. Sunt utilizate metode și algoritmi pentru a distinge între starea cognitivă indusă de calcul aritmetic și starea de relaxare prin tehnici avansate de filtrare și prelucrare, precum și aplicarea metodelor statistice pentru evaluarea conectivității funcționale în timpul diferitelor sarcini cognitive. Sunt investigate soluții pentru minimizarea artefactelor, comparate cu tehnici recente de eliminare a acestora. Accentul este pus pe analiza semnalelor EEG prin filtrare în benzi de frecvență corespunzătoare ritmurilor cerebrale (delta, teta, alfa, beta, gamma) și pe filtrarea în bandă îngustă. Se implementează trei metode de clasificare pentru discriminarea celor două stări mentale:

1. Metoda de comparare a limitelor de variație: diferențiază stările mentale prin compararea domeniilor de variație pentru două caracteristici ale semnalelor EEG, anume, mărimea vârfului spectral în benzile teta, alfa și beta și corelația statistică a perechilor de semnale.

2. Metoda de separare pe bază de distanță: utilizează algoritmi pentru identificarea tiparelor specifice stărilor cognitive comparând clusterelor în planurile frecvențelor beta-alfa și teta-alfa.

3. Metoda de filtrare în bandă îngustă simplifică procesul de analiză în domeniul temporal, eliminând necesitatea aplicării Transformatei Fourier. Această metodă facilitează calculul unor caracteristici relevante ale semnalului, cum ar fi energia și lungimea funcției acestuia. Metoda are ca efect o discriminare mai precisă între diferitele stări cognitive.

**Capitolul 4** este dedicat proiectării unui sistem de achiziție EEG pentru detectarea sarcinilor cognitive specifice unei interfețe BCI. A fost propus un algoritm original de detecție a sarcinii mentale care analizează semnalele EEG filtrate și le compară cu praguri de detecție predefinite, utilizând discriminatori logici pentru a determina prezența activității cognitive. Spre deosebire de abordările bazate pe învățarea automată, acest algoritm aplică o abordare analitică pentru analiza semnalelor în timp real, fără a necesita volume mari de date pentru antrenare.

Performanța sistemului a fost evaluată printr-o serie de experimente care au demonstrat că metoda propusă poate detecta cu acuratețe sarcinile cognitive, folosind praguri de detecție optimizate. Rezultatele au indicat că anumite canale EEG, în special cele din zonele frontale și parietale, sunt mai relevante pentru identificarea efortului mental. De asemenea, s-a dezvoltat un algoritm original pentru eliminarea automată a artefactelor, care facilitează o detecție și eliminare rapidă a perturbațiilor, îmbunătățind astfel calitatea semnalului și fiabilitatea sistemului.

**Capitolul 5** prezintă concluziile generale ale studiului, evidențiind contribuțiile aduse în domeniul de cercetare și subliniind aspectele inovatoare ale acestora. De asemenea, sunt discutate posibilele direcții de cercetare viitoare, care pot extinde sau aprofunda rezultatele obținute, oferind perspective pentru dezvoltările ulterioare.



# Capitolul 1 STUDIU ASUPRA ACTIVITĂȚII ELECTRICE A CREIERULUI

## 1.1 Formarea biosemnalelor în creier

Neuroștiința modernă se bazează în principal pe electroencefalografie (EEG) pentru a măsura direct și neinvaziv activitatea electrică a creierului. Având o înțelegere aprofundată a anatomiei și fiziologiei cerebrale, putem extrage și analiza informațiile din datele EEG prin metode computerizate (Electroencefalografie Computerizată).

În Fig. 1.1.1 este ilustrată o ierarhie a organizării biologice care necesită o examinare detaliată. Aceasta începe de la nivelul unei singure celule (a), continuă cu tipurile de conexiuni dintre celule (b), comportamentul lor colectiv în circuite mici (c), modul de propagare prin diferite medii (d), și se finalizează cu organizarea acestora în rețele funcționale complexe (e). Fiecare detaliu reprezintă o componentă unică în procesul de transmitere a semnalelor.

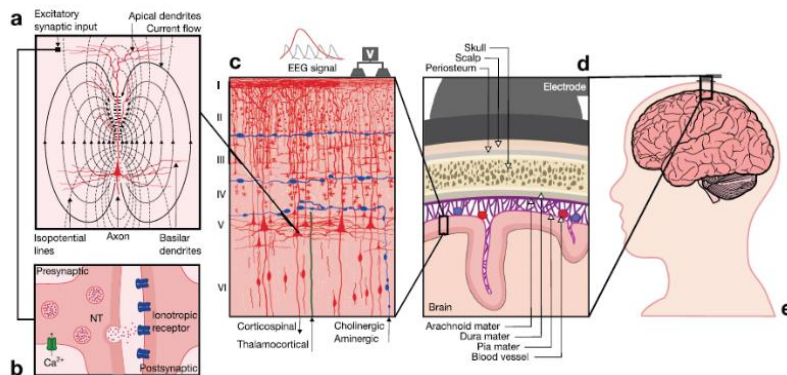


Fig.1.1.1 Bazele neurofiziologice ale EEG [1]

### De la structura cerebrală la semnalul EEG: înțelegerea influenței straturilor cerebrale

Activitatea cerebrală captată cu ajutorul electrozilor plasați pe scalp este generată în emisferile cerebrale la nivelul cortexului cerebral (neocortex) și se propagă la suprafața capului prin următoarele țesuturi de la interior la exterior: substanța albă, substanța cenușie, lichidul cefalorahidian (LCR), meningele și scalpul, Fig. 1.1.1 (d). Aceste medii biologice atenuează activitatea EEG de la vectorul sursă, acționând ca filtre naturale, distorsionând astfel semnalul EEG. Conform studiului realizat în [2] utilizarea unor modele simplificate ale țesuturilor poate genera erori de până la 20% în măsurători, afectând astfel precizia reconstrucției surselor neuronale. Această problemă devine critică atunci când modelele neglijează particularitățile izotrope ale țesuturilor cerebrale, influențând corectitudinea diagnosticelor bazate pe EEG.

*Neuronul*, ilustrat în Fig. 1.1.1a, reprezintă unitatea morfologică și funcțională de bază a țesutului nervos, fiind specializat în generarea și transmiterea semnalelor. Fiecare neuron primește și transmite impulsuri electrice către mii de alți neuroni prin conexiunile sinaptice Fig. 1.1.1b. Regimul activ al unui neuron, reprezentat de potențialul de acțiune (PA), constă într-o inversare temporară a potențialului electric membranar, care durează mai puțin de 1 ms. Modul de bază în care un neuron poate transmite informații este prin variația frecvenței potențialelor sale de acțiune


(numărul de PA transmite pe secundă, care se manifestă sub diferite tipare de semnal). Ceea ce măsoară EEG sunt potențialele de tensiune generate de populații mari de celule piramidale care acționează toate în mod sincron, adică în același timp și în același tipar [3].

### Coloanele neuronale și straturile corticale

Neocortexul, sau materia noastră cenușie este o structură complexă organizată în coloane celulare verticale care străbat șase straturi distincte, fiecare cu un tip specific de celule neuronale și o distribuție caracteristică pentru anumite regiuni corticale și subcorticale, Fig. 1.1c. Astfel, tiparele EEG reflectă indirect activitatea acestui circuit canonic al neocortexului, a cărui funcționare este esențială pentru mecanisme precum gândirea, percepția, memoria sau învățarea [4], [5], [6].

## 1.2 Natura semnalelor EEG

Ierarhia funcțională a creierului, organizată pe niveluri cu specializări distincte, se manifestă pe scări spatio-temporale multiple, de la cele microscopice la cele macroscopice [7]. În Figura 1.2.1, se ilustrează cum fiecare nivel contribuie la conținutul informațional al dinamicii neuronale în coordonate de spațiu și timp. Putem redefini astfel EEG ca o metodă care poate măsura activitatea electrică a creierului la aceeași viteză cu care se produce cogniția.



**Fig. 1.2.1** Scări spatio-temporale de analiză în EEG [7]

## 1.3 Propagarea semnalului

### Mecanisme de conducție electrică în creier

Modalitatea de baza (fundamentală) a propagării semnalului este conducția în volum.





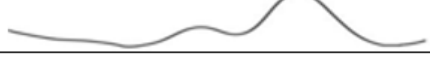
Fiecare tip de țesut străbătut are o conductivitate și permitivitate electrică specifică [8], care variază atât în funcție de frecvență, cât și de la un individ la altul, având caracteristici fizice și stări fiziologice diferite [9]. Parametrii dielectrici ai țesuturilor biologice joacă un rol esențial în propagarea semnalului EEG. În lucrarea [2] am propus formule aproximative de ordin întâi pentru calculul permitivității și conductivității, bazate pe aproximările Helmholtz și teoremele Gauss și Stokes. Aceste formule oferă o soluție îmbunătățită pentru estimarea precisă a parametrilor dielectrici în țesuturi izotrope.

### Modelul electric al capului uman: o abordare multi-strat

În majoritatea lucrărilor de cercetare sunt evaluate 3 sau 4 straturi tisulare [10], [11]. În lucrarea [12] am modelat, din punct de vedere electric, creierul uman, cu circuite pasive, prin evaluarea impedanțelor echivalente ale țesuturilor traversate de biocurenții electrici. Pentru o mai mare corectitudine în abordarea problemei inverse în EEG am evaluat un model detaliat implicând șapte straturi biologice tisulare cu conductibilitate și permitivitate specifică fiecăruia la frecvențe joase, în concordanță cu activitatea cerebrală.

## 1.4 Parametrii și clasificarea semnalelor EEG

Tensiunea măsurată la nivelul scalpului are o dinamică între valori pozitive și negative, la o rată care constituie frecvența semnalului. Reprezentată grafic, activitatea electrică a creierului, prezintă o succesiune de unde clasificate în cinci tipuri considerate ritmuri de bază: delta (0.5-4Hz), teta (4-8Hz), alfa (8-13Hz), beta (13-30Hz), gama (>30Hz), Fig. 1.4.1.

Denumire	Frecvență (Hz)	Amplitudine ( $\mu\text{V}$ )	
Gama	>30	5 – 10	
Beta	13 – 30	2 – 20	
Alfa	8 – 13	2 – 60	
Teta	4 – 8	2 – 100	
Delta	0.5 – 4	2 -200	

**Fig. 1.4.1** Tipurile principale de unde cerebrale și caracteristicile lor

## 1.5. Concluzii parțiale

- 1) Semnalul EEG este rezultatul activității electrice generate de excitațiile sinaptice ale neuronilor piramidali din cortexul cerebral, măsurat ca o sumă a curenților electrici captați la nivelul scalpului. Interacțiunile dintre miliarde de neuroni fac ca acest semnal să fie complex și dificil de interpretat.
- 2) Semnalul EEG este caracterizat de trinomul nestationar, neliniar și zgomotos.
  - Nestationaritatea: semnalul EEG este nestationar ca rezultat al schimbării configurațiilor funcționale ale diferitelor arhitecturi cerebrale (coloane/arii neuronale).
  - Neliniaritatea: povine din complexitatea proceselor cerebrale, suprapunerea efectelor, funcționarea creierului ca un întreg în care totul este interconectat.
  - Prezența zgomotului: semnalul EEG este afectat de zgomote interne (activitatea cardiacă, oculară, musculară) și externe (de mediu), ceea ce complică și mai mult interpretarea acestuia.
- 3) În ciuda caracterului nestationar și neliniar, creierul demonstrează o capacitate unică de organizare prin generarea de activități sincronizate, manifestate sub forma a cinci tipuri de unde cerebrale:  $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$ , și  $\gamma$ , fiecare având frecvențe și amplitudini specifice.

4) Banda de frecvență a semnalului EEG se extinde de la 0 la 100 Hz, majoritatea informațiilor utile se află în intervalul de 0-30 Hz, frecvențele mai mari fiind de obicei considerate zgomot.

## 1.6 Contribuții

- 1) Cu privire la suprapunerea și interacțiunea ritmurilor cerebrale (în EEG)
  - Am realizat o contribuție originală în domeniul captării semnalelor EEG prin modelarea activității cerebrale cu componente și circuite electronice, prezentată în lucrarea [12].
- 2) Cu privire la influența variabilității tisulare asupra propagării semnalului EEG:
  - Am adus o contribuție originală în lucrarea [2] obținând noi formule de calcul aproximativ pentru permitivitatea ( $\epsilon$ ) și conductivitatea ( $\sigma$ ) țesuturilor biologice.
  - Am dezvoltat un algoritm propriu, optimizat pentru a crește acuratețea rezultatelor prin estimări de ordin superior în dezvoltarea în serie a aproximațiilor parametrilor dielectrici.
- 3) Cu privire la problema inversă în EEG:
  - În lucrarea [12], am propus o abordare detaliată a problemei inverse în EEG, utilizând un model cu șapte straturi tisulare biologice, în contrast cu abordările existente în literatura de specialitate, care iau în considerare doar trei straturi.
  - În lucrarea [2], am identificat erori critice care împiedică acuratețea identificării surselor de semnal, contribuind astfel la îmbunătățirea metodelor de rezolvare a problemei inverse în EEG. Am demonstrat că precizia valorilor măsurate pentru parametrii dielectrici este esențială pentru reconstrucția corectă a surselor neuronale, iar erorile semnificative între 10%-20% pot duce la analize și diagnostice greșite.

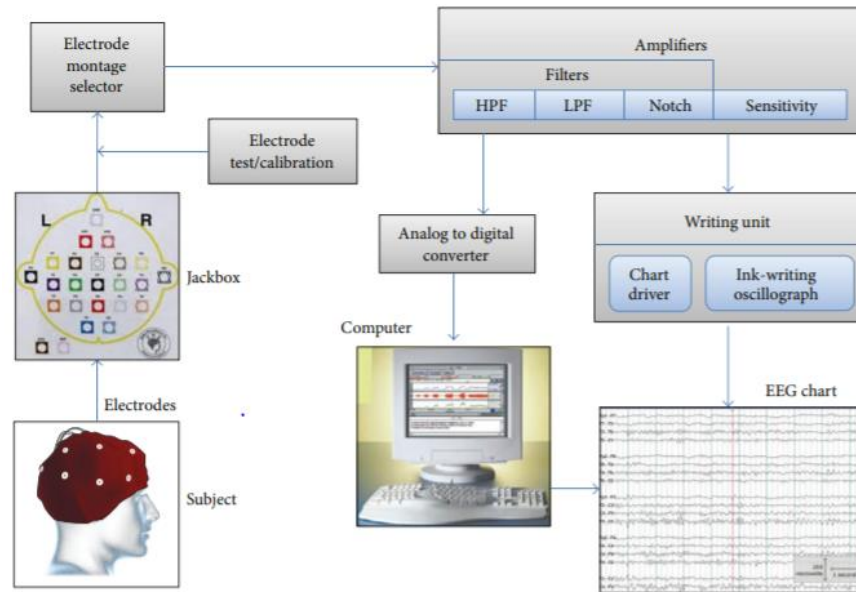
EEG ar fi un instrument la superlativ de măsurare a activității cerebrale dacă am putea stabili o corespondență directă de 1:1 între caracteristicile semnalelor și configurația microcircuitelor neuronale. Cognația, gândirea, memoria provin de fapt din procesul dinamic complex al interacțiunii celulare. Conexiunea dintre acestea și semnalul măsurat reprezintă de fapt **CONȚINUTUL EEG, O PROBLEMA DESCHISA!**

## **Capitolul 2 PARTICULARITĂȚI ÎN ACHIZIȚIA ȘI PRELUCRAREA SEMNALELOR EEG**

### **2.1 Structura hardware și software a sistemelor de achiziție pentru semnalele EEG**

Un sistem de monitorizare EEG, prezentat sugestiv în Fig. 2.1.1, include:

- A) Instrumentele pentru captarea/înregistrarea semnalului:
  - Electrozii
  - Casca preconfigurată cu localizarea electrozilor (la sistemele noi)
  - Gelul conductiv (la unele echipamente)
  - Bordul de electrozi (regasit în aplicațiile medicale)
  - Comutatorul electric al electrozilor
- B) Dispozitivele de achiziție a datelor:
  - Amplificatorul diferențial
  - Convertorul analogic digital
  - Camera video (opțional, în aplicații medicale)
- C) Dispozitivele de prelucrare:
  - Sistem pe bază de microprocesor/Calculator
- D) Interfața între sistemul de achiziție și sistemul de prelucrare
  - Interfața optică serială
  - Interfețe radio
- E) Sursa de alimentare a sistemului de achiziție
  - Acumulator DC
- F) Dispozitive de ieșire/conectica
  - Monitor
  - Tastatura
  - Cabluri și adaptoare, fibra optică



**Fig. 2.1.1** Schema de principiu a EEG-lui [13]

## 2.2. Obținerea și înregistrarea datelor EEG

Semnalele EEG captate prin intermediul electrozilor plasați pe scalpul subiectului trec prin lanțul de prelucrare la finalul căruia se obțin date numerice care se stochează și/sau fac obiectul unor prelucrări ulterioare. Din punct de vedere practice, datele stocate se regăsesc în baze de date internaționale în general cu acces liber (de ex. Physionet [14], <https://physionet.org/>).


Un neajuns al obținerii datelor din bazele de date EEG este că permit doar analiza datelor postprocesare, spre deosebire de experimentele proprii, care permit analiza în timp real.

### 2.2.1. Metodologia obținerii datelor EEG

#### A) Măsurarea biosemnalelor electrice

Federația Internațională de Electroencefalografie și Neurofiziologie Clinică (1958) a adoptat standardizarea pentru plasarea electrozilor, numită Sistemul Internațional 10-20, conform schemei ilustrate în Figura 2.2.1. Acest sistem permite o interpretare standardizată și reproductibilă a semnalelor EEG, facilitând compararea rezultatelor între diferiți subieți sau sesiuni de înregistrare.

Fiecare electrod este plasat în apropierea anumitor centre de activitate neuronală pe cortexul cerebral așa cum este descris în linii mari în Tabelul 2.2.1.



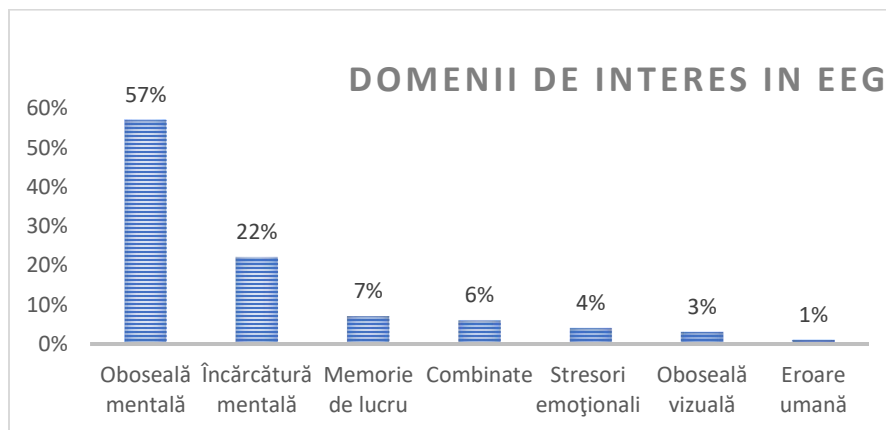
**Fig. 2.2.1** Sistemul Internațional 10-20 de plasare a electrozilor EEG [15]

**Tabelul 2.2.1** Corespondența dintre electrozi și centrii de activitate neuronală

Regiune	Electrozi	Funcțiile generale ale centrilor cerebrali
Prefrontal	Fp1, Fp2	procesele cognitive de nivel înalt cum ar fi deciziile, planificarea și inhibiția comportamentală
Frontal	F3, F4	memoria de lucru, atenția și abilitățile motorii
	Fz	activități de intenție și motivaționale
	F7	activități rationale
	F8	impulsuri emoționale
Central	C3, C4 și Cz	activități motorii și senzoriale
Temporal	T3, T4	procesarea auditivă a memoriei, procese emoționale
	T5, T6	anumite funcții de memorie
Parietal	P3, P4, Pz	procesarea senzorială și spațială (percepție și diferențiere)
Occipital	O1, O2	procesarea vizuală

## 2.2.2 Proiectarea experimentelor de achiziție EEG

Un studiu de meta-date din ultimii 20 de ani, a arătat un puternic interes în subiectele experimentelor EEG pentru: oboseală mentală, încărcătură mentală, memoria de lucru, recunoașterea erorii, oboseala vizuală, emoție și stres [15], a se vedea Figura 2.2.2. Stresul indus prin diverse metode ocupă un procent mic în EEG, însă studiile recente îi acordă din e în ce mai multă importanță.



**Fig. 2.2.2** Distribuția domeniilor de interes în cercetările EEG

### 2.2.3 Seturi de date experimentele

Seturile de date utilizate în analiză au provenit atât din baze de date cât și din experimente proprii. Domeniul principal de cercetare ales pentru analiză a fost stresul mental indus prin exerciții de calcul aritmetic.

#### A) Prezentarea seturilor de date din baza de date

Seturile de date au fost selectate din baza de date PhysiNet [14] (<https://physionet.org/>)

*Experimentul RSVP (rapid serial visual presentation)* (<https://physionet.org/content/ltrsvp/1.0.0/>) [16]. Acest set de date constă din înregistrări EEG, pentru un scenariu vizual special de detectare a țintei în scenele prezentate în serie rapidă. Un rezumat al experimentului RSVP este prezentat în Tabelul 2.2.2 .

**Tabelul 2.2.2** Sumarul experimentului RSVP

Indicator	Descriere		
	Instrumentatie	Cantitate	Detalii
Echipament	Biosemi Active Two cu 64 de canale (electrozi umezi Ag/AgCl)	8	Monopolar, cu 8 canale măsurate parietal - occipital (PO3, PO4, PO7, PO8) parietal (P7, P8) occipital (O1, O2)
	Rata de esantionare	2048 Hz	
	Filtru unic	0.15-28 Hz	
Subiecți	Persoane voluntare = 24,3 ani, deviație standard (SD) ± 3,7	11	vedere normală sau corectată spre normală
Teste	Prezentate vizual	3	1 test pentru fiecare apariție a țintei la 5Hz, 6Hz și 10Hz și pentru fiecare participant

#### *Experimentul MAT (Mental Arithmetic Task)*

Experimentul selectat din baza de date PhysiNet [14] pentru analiză implică sarcini de aritmetică mentală și a fost subiectul mai multor lucrări de cercetare în ultimii 4 ani. Acest experiment a avut ca obiectiv colectarea datelor cu scopul de a urmări modificările activității electrice cerebrale atunci când subiecții efectuează sarcini solicitante din punct de vedere cognitiv. Aceasta a constat în operații de scăderi succesive dintr-un număr cu patru cifre cu un număr de două cifre, de exemplu:  $3141 - 42 = 3099$ ,  $3099 - 42 = 3057$ , și așa mai departe.

În funcție de performanța obținută privind numărul de operații corecte efectuate în timpul alocat (60 secunde), cei 36 de subiecți voluntari s-au separat în : Grupul “G” ( “Good”) care a efectuat cu ușurință mai multe operații corecte, respectiv Grupul “B” (Bad) cei care au efectuat corect un număr mai mic de operații.

În Tabelul 2.2.3 este prezentată o imagine generală a datelor experimentului.



**Tabelul 2.2.3** Sumarul experimentului MAT – baza de date Physionet

Indicator	Descriere		
	Instrumentatie	Cantitate	Detalii
Echipament	Neurocom (Ucraina, XAI-MEDICA) (electrozi umezi Ag/AgCl)	23 canale (19 EEG + 2 referință A1-A1, 1 ECG)	monopolar prefrontal (Fp1, Fp2) frontal (F3, F4, Fz, F7, F8) central (C3, C4, Cz) parietal (P3, P4, Pz) temporal (T3, T4, T5, T6) occipital (O1, O2)
	Rata de esantionare	500 Hz	
	Filtru unic	0.5-30 Hz	
Subiecți	studenți în domeniul biologie și medicină varsta medie = 18,6 ani, deviație standard (SD) = 0,87 ani)	36	26 subiecți - Grupul "G", numărul mediu de operații efectuate pe minut = $21 \pm 7,4$ 10 subiecți - Grup "B" numărul mediu de operații efectuate pe minut = $7 \pm 3,6$
Teste	Comunicate verbal	2	1 test – fără sarcina aritmetica, în stare de relaxare cu ochii închiși (180s) 1 test- cu sarcini aritmetice (60s)

### B) Prezentarea experimentelor proprii efectuate cu echipamentul Biosemi 64

Seturile de date proprii au fost obținute cu un echipamentul Biosemi Active Two în cadrul laboratorului de Automobile Inteligente din CENTRUL REGIONAL DE CERCETARE-DEZVOLTARE PENTRU MATERIALE, PROCESE ȘI PRODUSE INOVATIVE DESTINATE INDUSTRIEI DE AUTOMOBILE (CRC&D-AUTO), Pitești, <https://www.upit.ro/ro/cercetare-stiintifica/centrul-regional-crcd>.

#### *Experimentul 1 (propriu)*

În cadrul acestui experiment, s-au realizat înregistrări EEG utilizând sistemul Biosemi Active Two, configurat cu toate cele 64 de canale.

Testele au constat în exerciții de calcul aritmetic, afișate pe ecran cu un timp limită prestabilit. Pentru a menține atenția subiectului concentrată pe sarcina principală, expresiile de calcul au constat în scăderi succesive, începând de la 100, cu o rată de scădere de 3 (de exemplu:  $100 - 3 = 97$ ,  $97 - 3 = 94$ ,  $94 - 3 = 91$ ), continuând în același mod.

Tabelul 2.2.4 conține sintetic modul de proiectare a experimentului EEG cu sarcini mentale aritmetice.

**Tabelul 2.2.4** Sumarul Experimentului 1 – propriu

Indicator	Descriere		
	Instrumentatie	Cantitate	Detalii
Echipament	EEG Biosemi Active Two, electrozi umezi Ag/AgCl	64	Montaj monopolar (toti electrozii)
Subiecți	Adult, 58 ani, genul masculin, domeniul stiintelor ingineresti	1	Implicat în experiment în 10 ședințe succesive cu o durată de aproximativ 90 secunde, timpul experimentului o oră și jumătate
	Rata de esantionare	8192Hz	
	Filtru unic	0.16-30Hz	
Teste	Prezentare vizuală, cronometrată	10	1 test fără sarcină mentală cu ochii deschiși - (FS-OD) 3 teste fără sarcină mentală cu ochii închiși - (FS-OI) 3 teste cu sarcină continuă - (CSC) 3 teste cu sarcini intermitente - (CSI)
Tipul de teste	Sarcini de calcul aritmetic cu operații de scaderi succesive dintr-un număr initial	12	Seturi de scăderi începând de la cifra 100 cu o rată de scădere de 3

## 2.3 Tehnici de analiză și prelucrare a semnalelor EEG

Tehnicile consacrate pentru analiza și prelucrarea semnalelor EEG se bazează pe metodele de bază pentru studiul semnalelor în domeniul timp (Parametrii Hjorth, caracteristici statistice, dimensiunea fractală), frecvență (Trasformată Fourier Rapidă, Modelul Auto Regresiv, Vectori și valori proprii) sau timp-frecvență (Transformata Wavelet, Transformata Hilbert–Huang). Aceste tehnici sunt completate de o multitudine de metode specifice analizei datelor cu scopul de a obține performanțe cât mai bune în diverse aplicații pentru extragerea caracteristicilor și clasificarea semnalelor.

## 2.4 Concluzii parțiale

### Principalele concluzii în achiziția și prelucrarea semnalelor EEG

#### *Captarea semnalului EEG*

- calitatea datelor EEG înregistrate este direct influențată de impedanța de contact dintre electrod și țesut.

- captarea semnalului cu soluția de electrod activ rezolvă problema interferențelor preluate de cabluri prin adaptarea impedanței direct la nivelul electrodului. Acești electrozi amplifică semnalul înainte ca zgomotul să fie introdus de-a lungul cablurilor, prevenind astfel deteriorarea raportului semnal-zgomot (SNR) și asigurând o adaptare optimă a impedanței la nivelul scalpului.

#### *Amplificarea semnalului EEG*

- amplificatorul dintr-un sistem EEG trebuie să maximizeze raportul semnal-zgomot (SNR) al tensiunii măsurate, având un raport de respingere a modului comun (CMMR) de peste 100 dB și capacitatea de a amplifica semnalele de intensități mici, de 0,5-100  $\mu$ V, astfel încât acestea să

depășească zgomotul de fond. Acest lucru necesită un câștig de 10.000 până la 100.000. După amplificare, semnalul poate fi transmis în etapele următoare ale circuitului.

#### ***Eliminarea DC offset-ului***

- DC-offsetul în semnalul EEG este rezultatul mai multor factori: interfața electrod-țesut, tensiunea de decalaj a electrodului, nepotrivirea curentului de polarizare de intrare a amplificatorului, nepotriviri ale impedanței de intrare a amplificatorului și tensiunea de drift datorată temperaturii.

- DC offsetul în EEG este eliminat cu ajutorul amplificatorului diferențial și prin scheme de amplificare ce conțin FTS în primul etaj de preamplificare, pentru a elimina componentele de joasă frecvență.

#### ***Filtrarea semnalului EEG***

- filtrele analogice sunt integrate în unitatea amplificatorului pentru a reduce componentele de zgomot, Un filtru de trecere sus (FTS), cu o frecvență de tăiere de 0,5 Hz, este utilizat pentru a elimina zgomotul de joasă frecvență, iar un filtru de trecere jos (FTJ), cu o frecvență de tăiere mai mică decât jumătate din rata de eșantionare, reduce artefactele de înaltă frecvență.

- filtrele digitale sunt cele mai frecvent utilizate în construcția echipamentelor EEG, având frecvențe de tăiere similare cu filtrele analogice.

#### ***Frecvența de eșantionare***

-în general, se recomandă o frecvență de eșantionare cuprinsă între 128 și 1024 Hz, iar convertorul analog-numeric trebuie să aibă cel puțin 12 biți; cu cât numărul de electrozi este mai mare, cu atât frecvența de eșantionare este mai mică.

Pentru a certifica validitatea și reproductibilitatea rezultatelor colectate prin achiziția și prelucrarea semnalelor EEG este riguros să se adopte protocoale standardizate, să se proiecteze experimente eficient controlate și să se aplice tehnici de analiză a datelor pe măsura naturii și complexității acestora.

## **2.5 Contribuții**

Referitor la problematica captării semnalelor, în lucrarea [17] am conceput și evaluat prin simulare un sistem de preamplificare folosind tehnica electrozilor activi pentru captarea semnalelor EEG, care să ofere imunitate variațiilor de impedanță la interfața electrod-piele. Am implementat o soluție de electrod uscat utilizând pâslă conductivă, ca alternativă la electrozii tradiționali umezi, eliminând necesitatea de geluri conductive și pregătiri complexe ale pielii.

Am conceput teste specifice pentru sarcina mentală și am configurat Experimentul 1 pentru achiziția semnalelor EEG cu echipamentul Biosemi Active TWO, care dispune de 64 de canale. Testele de sarcină mentală au fost de tip aritmetic, incluzând diferite scenarii de aplicare a sarcinii: cu sarcină continuă, cu sarcină intermitentă (periodică), precum și teste de referință în stare de relaxare, atât cu ochii închiși, cât și cu ochii deschiși. Am realizat, de asemenea, un studiu bibliografic asupra metodelor și tehnicilor de prelucrare a semnalelor EEG.

# Capitolul 3 CONTRIBUȚII LA ANALIZA ȘI PRELUCRAREA SEMNALELOR EEG

## 3.1 Prelucrare pentru separarea componentelor EEG prin filtrare

Semnalul EEG înregistrat într-un punct specific reflectă o combinație de frecvențe provenite din diverse regiuni ale creierului, ca rezultat al interconectării proceselor cognitive sau stărilor mentale. O modificare utilă la nivelul sistemului de achiziție a semnalelor EEG este introducerea pe fiecare canal de măsurare a unui pachet de filtre programabile care să separe cele cinci benzi de trecere ale semnalelor de bază (delta, teta, alfa, beta și gama), așa cum este ilustrat în Fig. 3.1.1. Separarea semnalului original în aceste benzi de frecvență trebuie aplicată pe lanțul de prelucrare al datelor primare (brute), furnizate de convertorul analog-digital, conform exemplului pentru un canal prezentat în Fig. 3.1.2.




Fig. 3.1.1 Benzile EEG consacrate

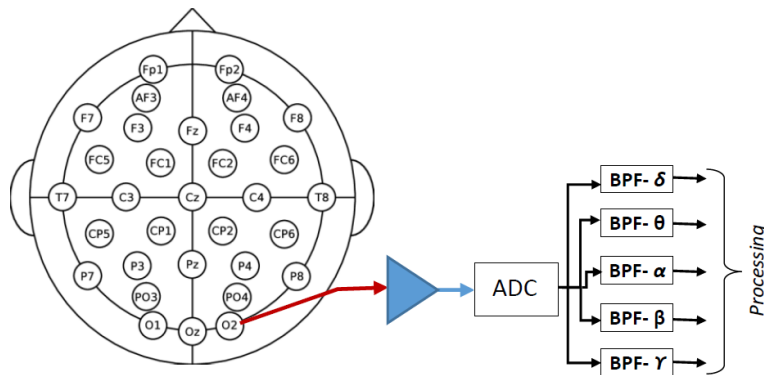



Fig. 3.1.2 Filtrarea selectivă pe sub-benzile EEG de bază

În cadrul Experimentului 1, s-a impus necesitatea unei analize mai detaliate, care a fost efectuată utilizând filtre digitale de tip trece-bandă pentru a izola intervale mai restrânse de frecvență. În faza preliminară, a fost aplicat un filtru trece-jos pentru a extrage componentele cu variație lentă. Au fost proiectate și implementate următoarele filtre:


i) un filtru trece-jos, cu frecvența de tăiere la 2 Hz, utilizat pentru eliminarea variațiilor lente ale semnalelor EEG. Practic, acest filtru extrage componenta lentă care este apoi scăzută din semnalul analizat, conform reprezentării din Figura 3.1.3.



**Fig. 3.1.3** Corecția semnalului prin eliminarea variațiilor lente

ii) o pereche de filtre FTS+FTJ pentru fiecare sub-bandă analizată (teta și beta în cazul Experimentului 1).

Filtrele proiectate sunt de tip FIR de ordin înalt, iar caracteristicile lor pentru banda teta sunt prezentate în Figura 3.1.4 (a) și (b). Pentru simplificare, se va denumi în continuare i) și ii) filtrare corectată.



**Fig. 3.1.4** Răspunsul în frecvență în banda teta pentru filtrul FTS (a) și pentru FTJ (b)

În cazul experimentului MAT (din baza de date), am proiectat trei filtre FTB de tip IIR pentru sub-benzile de interes teta, alfa și beta.

În experimentul RSVP s-au implementat patru filtre FIR de tip trece-bandă pentru patru sub-benzi (delta, teta, alfa, beta).

## 3.2 Metode de prelucrare pentru eliminarea zgomotului

### 3.2.1 Prezentarea algoritmului

#### Metoda medierii semnalului

Am propus o metodă de mediere prin segmentarea semnalului pe fiecare canal de măsurare în ferestre de timp mai mici de 1 secundă, pentru a surprinde cât mai precis dinamica potențialelor de acțiune neuronală. Împărțim semnalul EEG,  $x[N]$ , de lungime  $N$ , în  $m$  ferestre, fiecare având lungimea  $k$ , astfel încât  $N = m \times k$ . Ferestrele rezultate vor constitui coloanele unei matrice de dimensiuni  $m \times k$ .

### 3.2.2 Rezultate experimentale

Pentru exemplificare, a fost selectat un semnal din zona parietală stângă P7, obținut în cadrul experimentului RSVP, cu o durată de 250 de secunde și o rată de eșantionare de 2048 Hz. Numărul total de eșantioane ale semnalului,  $N$ , este  $250 \times 2048 = 512000$ . Am utilizat o fereastră de mediere cu durată de  $k = 0,5$  secunde, corespunzătoare la 1024 de eșantioane. Astfel, semnalul a fost divizat în 500 de segmente, care au fost ulterior mediate între ele. Rezultatul este un semnal generic în care zgomotul a fost redus, așa cum este ilustrat în Figura 3.2.1.

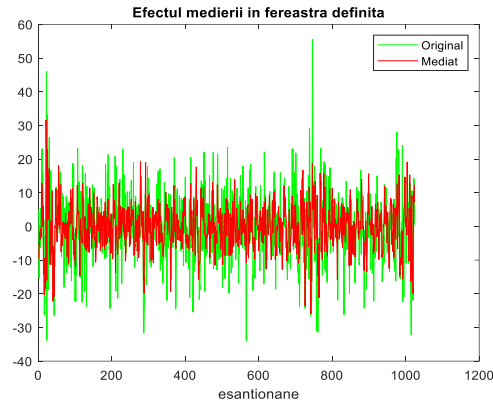


Fig.3.2.1 Semnal P7 mediat reprezentat în eșantioane (corespunzător ferestrei de timp - 0.5s)

### 3.3 Metode de prelucrare pentru eliminarea artefactelor

Metodele clasice de detectare a artefactelor în semnalele EEG sunt analiza componentelor principale (PCA- *Principal Component Analysis*) și analiza componentelor independente (ICA - *Independent Component Analysis*).

#### 3.3.1 Prezentarea algoritmilor

##### **Algoritmul ASR (*Artifact Subspace Reconstruction*)**

ASR este un algoritm dezvoltat recent pentru detectarea și eliminarea automată a artefactelor EEG. Acesta se bazează pe tehnica PCA, care reduce dimensiunea datelor prin menținerea doar a componentelor principale ce captează o proporție semnificativă din variabilitatea totală a acestora [18], [19]. ASR utilizează ferestrele glisante ale semnalului EEG. Pentru fiecare fereastră glisantă, metoda caută subspații principale care se abat semnificativ de la semnalul de bază.

##### **Algoritmul MARA (*Multiple Artifact Rejection Algorithm*)**

MARA este un algoritm ce poate fi aplicat datelor EEG după extragerea componentelor independente produse de tehnica ICA. Nucleul MARA se bazează pe tehnici de ML (*machine learning*). Este integrat ca modul în EEGLAB pentru a identifica și elimina automat artefactele

tranzitorii (mișcările oculare rapide, contracțiile musculare bruște, contacte imperfecte, mișcările capului sau ale corpului) din datele EEG.

### 3.3.2 Rezultate experimentale

Datele din Experimentul 1, prelucrate pentru eliminarea artefactelor folosind algoritmi ASR și MARA cu toolboxul EEGLAB din Matlab, sunt utilizate pentru analiză comparativă cu metoda de filtrare corectată propusă.

## 3.4. Analiza în frecvență în benzi și sub-benzi specifice EEG

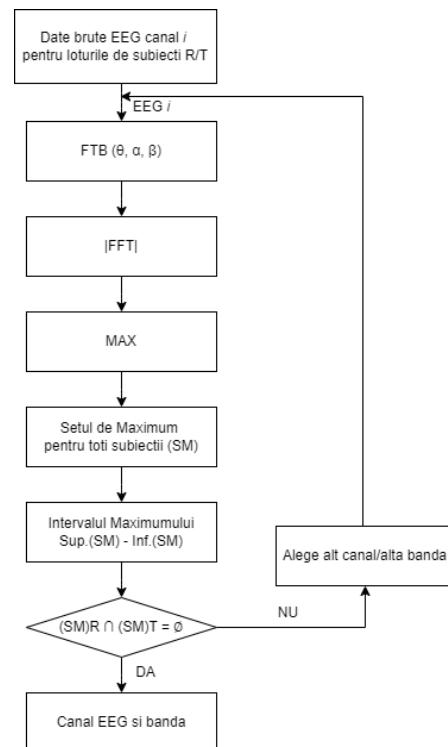
### 3.4.1. Prezentarea algoritmilor

O serie de experimente au fost analizate prin Transformata Fourier, pe semnale EEG filtrate, în benzile standard ( $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$ ,  $\gamma$ ). Algoritmul FFT este totuși destul de cronofag, iar utilizarea lui se pretează mai degrabă la analiza post-factum a experimentelor. O măsură utilizată în analiza semnalelor este maximul puterii spectrale, adică vârful spectral într-o anumită bandă de frecvență. De asemenea, poziția vârfului spectral oferă informații cu privire la frecvența dominantă în banda de interes.

### 3.4.2 Rezultate experimentale

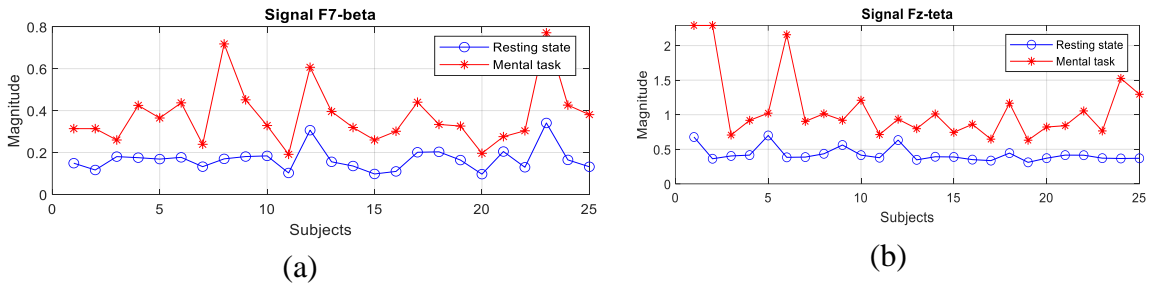
În experimentul MAT, procesul a implicat filtrarea tuturor semnalelor în benzile teta, alfa și beta, urmată de aplicarea transformatei Fourier pentru fiecare bandă și înregistrarea valorilor maxime spectrale. Această secvență de pași se aplică atât grupului de subiecți fără sarcină mentală (R), cât și celui cu sarcină mentală (T). Rezultatul constă în două seturi de maxime spectrale - pentru grupul fără sarcină ( $(SM)_R$ ) și pentru grupul cu sarcină ( $(SM)_T$ ). Intervalul maximelor este determinat prin evaluarea valorilor superioare și inferioare ale fiecărui set de maxime spectrale.

Discriminarea se realizează efectiv prin compararea limitelor celor două seturi de maxime (pentru starea R și starea T) pentru fiecare semnal EEG. Pentru o clasificare perfectă, cele două domenii trebuie să fie disjuncte, adică intersecția seturilor de maxime trebuie să fie mulțimea vidă. Acest lucru este de așteptat să se întâmple pentru anumite canale EEG în anumite benzi de semnale. Întregul principiu este structurat în Figura 3.4.1



**Fig.3.4.1** Schemă cu principiul evaluării prin maxime spectrale în experimentul MAT

In Fig. 3.4.2 subiecții de la 1 la 25 sunt ordonați în funcție de scorul de performanță obținut la test, se observă o suprapunere a limitelor globale, chiar și pentru semnalele cu cea mai bună separare a stărilor F7 și Fz în benzile teta și beta.



**Fig.3.4.2** Vârfurile spectrale în banda teta pentru subiecții grupului G ale semnalelor (a) F7 și (b) Fz

Următorul pas a fost să considerăm doar un grup selectat în funcție de scorul obținut la testul mental. Astfel, am decis să alegem doar subiecții care au obținut un scor mai mare decât scorul mediu al întregului grup „Good”, care este de 22,08, numit grup G\* (primii 11 subiecți).

Semnalele EEG găsite ca discriminatori între starea de relaxare (R) și starea implicată în sarcina aritmetică (T), în funcție de benzile specificate pentru fiecare grup, sunt prezentate în Tabelelele 3.4.1.

**Tabelul 3.4.1** Discriminatori stare de relaxare vs. sarcină mentală pentru subiecții cu scor  $\geq 26$  (grup Good, G\*)

Banda	Denumire semnal
$\theta$	F7
	Fz
$\alpha$	-
$\beta$	F7

Pentru a evalua performanța analizei am folosit un set de măsuri stabilite adecvat modelelor statistice precum acuratețea, precizia, sensibilitatea, scorul F1 și Coeficientul Matthew [7], [9].


Rezultatele lucrărilor care au abordat același experiment - MAT, din baza de date PhysioNet, sunt sintetizate în Tabelul 3.4.2. Constatăm că metodele utilizate au o acuratețe ridicată în clasificare, însă rezultatele privind identificarea electrozilor responsabili pentru sarcina aritmetică prezintă o variabilitate semnificativă.



**Tabelul 3.4.2.** Rezultate comparative cu privire la clasificarea semnalelor din baza de date PhysioNet


Metoda de clasificare	Caracteristici folosite	Acuratețe	Semnale	Referința
DT	Energie, entropie, medie, normă L2 în sub-benzi	>95	beta: F7, Cz alfa: Cz, O1 R vs. T.	[20]
SVM	Rezultate din analiza Fourier: energie, entropie, varianță	98,6 ÷ 90,3	C3, F4, Fp2, P3, O1, T3 (R vs. T)	[21]
KNN	Caracteristici hibride dintre momentele spectrale de putere, amplitudinea pătratică medie (RMS) și modelul autoregresiv.	99,74÷97,82	Fp1, Fp2, F3, F7, Fz, F8, F4, (R vs. T)	[22]
LDA		99,93 – 99,94	Fp1, Fp2	
RNN	Caracteristici timp-frecvență, putere spectrală în sub-benzi. ( $\delta$ , $\theta$ , $\alpha$ , $\beta$ , $\gamma$ )	93,59 ÷ 91,67 (LSTM)	Fp1, F7, Pz, P4 (R vs. T)	[23]
RNN	Entropii	99.63÷99.38LSTM, BLSTM, GRU	O2, Fz, Cz, Pz (R vs. T)	[24]
Metoda limitelor domeniilor	Vârful puterii spectrale în sub-benzi.	84% - 100%	F7, Fz, F3, F8, Fp1, Fp2 (R vs. T)	[25] Metoda propusa

Am extins analiza la Experimentul 1, care include un număr semnificativ mai mare de canale comparativ cu experimentul MAT (64 față de 19), folosind același principiu de evaluare a puterii vârfului spectral și concentrând atenția pe studiul benzilor de frecvență teta și beta. Sunt exemplificate în Fig. 3.4.3 rezultatele celor 6 teste (3 fără sarcină, în stare de relaxare și 3, cu sarcină aritmetică continuă) pe câte 32 de semnale ale fiecărei emisfere cerebrale. Rezultatele indică o grupare mai bună în starea de sarcină mentală în cele două benzi (beta și teta), comparativ cu starea de relaxare. Acest fapt sugerează natura activității cerebrale de a se organiza într-un mod mai structurat și mai coerent pentru a îndeplini sarcina.



**Fig.3.4.3** Vârfuluri spectrale în benzile (a) teta și (b) beta

În continuare, am evaluat și validat acuratețea datelor privind potențialele artefacte din Experimentul 1. Pentru aceasta, am comparat rezultatele datelor obținute prin combinarea celor trei filtre (denumită filtrare corectată) cu rezultatele generate de tehnicile ASR și ICA în EEGLAB din toolbox-ul Matlab. Se poate observa în Fig. 3.4.4 că nu sunt diferențe semnificative, în mod special între tehnica de filtrare corectată propusă și tehnica ASR.



**Fig.3.4.4.** Compararea rezultatelor procesării datelor prin filtrare corectată și utilizarea tehnicilor (a) ASR și (b) ICA pentru teste cu sarcină aritmetică continuă

### 3.4.3 Concluzii parțiale

- 1) Metoda propusă de filtrare a semnalelor EEG în sub-benzi de frecvență specifice ritmurilor cerebrale (delta, teta, alfa, beta, gamma) a facilitat analiza detaliată a activității cerebrale.
- 2) Metoda de filtrare cu filtru corector utilizată în Experimentul 1 a demonstrat o eficiență similară, în special cu tehnica ASR de eliminare automată a artefactelor, oferind o alternativă mai puțin consumatoare de timp.
- 3) Metoda de clasificare bazată pe praguri de acceptare pentru diferențierea stărilor mentale s-a dovedit eficientă, permițând ajustarea nivelului de încredere prin controlul gradului de suprapunere acceptabil al limitelor domeniilor de variație.
- 4) Studiul a confirmat că activitatea electrică a creierului, măsurată prin nivelul vârfului spectral, variază în funcție de intensitatea efortului cognitiv.
- 5) S-au observat diferențe semnificative între subiecți, sugerând că dinamica activității cerebrale este dependentă de particularitățile fiecărei persoane.
- 6) Studiul a confirmat importanța undelor teta și beta în sarcinile mentale de tip aritmetic și validitatea semnalelor discriminatorii utilizate pentru clasificarea stărilor mentale.
- 7) Instrumentele de analiză utilizate (FFT) au fost aplicate într-un mod original și eficient, fiind ușor de implementat cu un efort computațional minim.

### 3.4.4 Analiza în domeniile beta- alfa și teta-alfa

În cercetarea de față, am analizat comportarea semnalelor EEG în 64 de puncte de măsurare în două plane de frecvență:  $\beta - \alpha$ , respectiv  $\theta - \alpha$ , în cadrul testelor originale (Experimentul 1).

### 3.4.5 Prezentarea algoritmilor

Principiul algoritmului de lucru pentru realizarea analizei în domeniile beta- alfa și teta-alfa este prezentată în Fig.3.4.5.

Algoritmul de calcul este următorul:

- i) Calculează distanțele de la origine la fiecare punct al clusterului de referință – fără sarcină, în planul de frecvență analizat:

$$R_i = \sqrt{\overline{F_x}(i)^2 + \overline{F_y}(i)^2}$$

unde  $i=1, \dots, 64$  este numărul canalului EEG.

- ii) Determină valoarea maximă în vectorul distanțelor și poziția acesteia în vector:  $R_{\max} = \max(R_i)$ , respectiv  $i_m$  – numărul canalului cu distanța cea mai mare.

- iii) Calculează distanțele pentru clusterul corespunzător testului de comparat – cu sarcină  $D_i$ .

- iv) Compară cu relația condițională  $D_i > R_{\max}$  și rezultă un vector logic cu elementele 1 corespunzătoare canalelor EEG care sunt separate (disjuncte) în raport cu clusterul de referință, în planul de frecvență analizat.

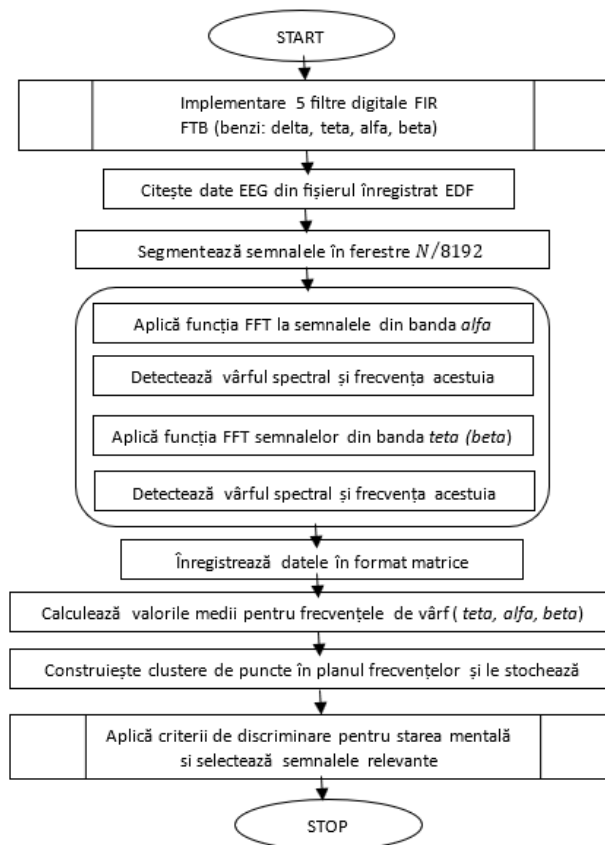


Fig.3.4.5 Principiul programului de aplicare

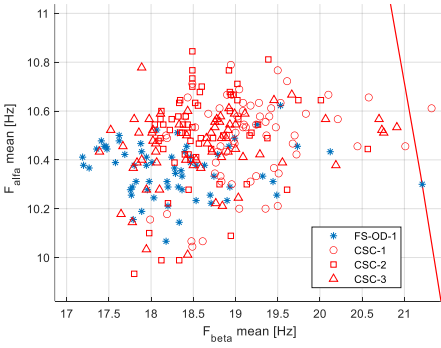
Se realizează analiza comparativă a separabilității clusterelor de puncte determinate de frecvențele dominante medii în planul beta-alfa, respectiv teta-alfa, pentru fiecare semnal EEG măsurat în cadrul testelor. Separabilitatea clusterelor se face la nivelul tuturor semnalelor utilizând frontiera determinată de cercul cu raza maximă care mărginește clusterul punctelor în planul de frecvență analizat pentru testul de referință.

### 3.4.6 Rezultate experimentale


Au fost analizate următoarele:

- **Comparația stărilor:** cu sarcină continuă (CSC) vs. Stare de referință ochi închiși (FS-OI)
- **Comparația stărilor de referință:** cu ochii închiși (FS-OI-x) vs. cu ochii deschiși (FS-OD)
- **Comparația stărilor:** cu sarcină continuă (CSC-x) vs. fără sarcină cu ochii deschiși (FS-OD-1)

Poziția punctelor de stare în planul frecvențelor medii alfa-beta, respectiv teta-alfa, pentru semnalele EEG în testele cu sarcină continuă, în raport cu testul de referință fără sarcină cu ochii deschiși, este investigată prin analiza clusterelor de puncte prezentate în Fig. 3.4.6.



(a) Planul beta-alfa



(b) Planul teta-alfa

**Fig.3.4.6** Clusterele de puncte pentru stări mentale în planul de frecvență

Metoda folosită pentru determinarea canalelor EEG cele mai sensibile la prezența sarcinii mentale de calcul matematic folosește algoritmul bazat pe compararea distanțelor dintre puncte în planul de frecvență analizat. În acest caz, criteriul de selecție a canalelor sensibile se bazează pe calculul unor raporturi de distanțe relative, de forma următoare:

$$\rho_i = \left( \frac{\text{Distanța dintre stare CSC} - n \text{ și stare FS} - OD - 1}{\text{Distanța dintre stare FS} - OD - 1 \text{ și stare FS} - OI - m} \right)_i \quad (3.4.1)$$

Unde  $n=1,2,3$  este indicele testelor cu sarcină continuă,  $m=0, 1, 2$  este indicele testelor de referință fără sarcină cu ochii închiși, iat  $i=1, \dots, 64$  este indicele (numărul) canalului EEG măsurat.

Selecția se aplică astfel:

- Dacă  $\rho_i > 1$  pentru semnalul  $i$  efectul sarcinii mentale specific este mai mare decât efectul ochilor deschiși, deci sarcina specifică are șanse să fie discriminate.
- Dacă  $\rho_i < 1$ , canalul EEG  $i$  nu va fi luat în considerare pentru discriminarea sarcinii.

În concluzie, canalele EEG care satisfac condiția de selecție pentru cele  $3 \times 3 = 9$  combinații de teste sunt luate în considerare ca fiind discriminatoare pentru sarcina mentală de calcul matematic, astfel:

- a) În planul de frecvență beta-alfa: CP5, CP3.
- b) În planul de frecvență teta-alfa: Oz, PO4, O2.

### 1. Analiza separabilității stărilor pentru testele cu sarcina intermitentă

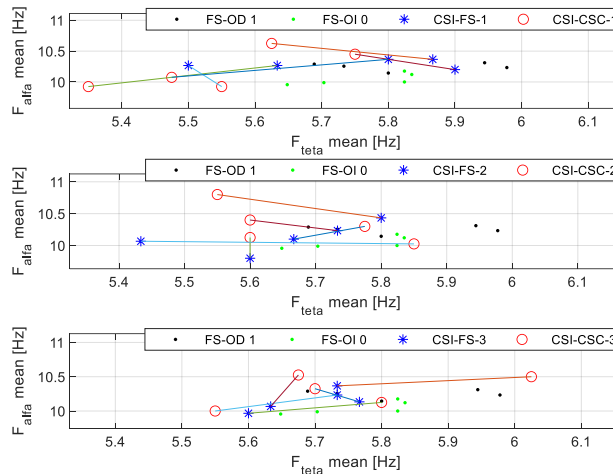
#### *Alegerea canalelor discriminatoare de sarcină mentală intermitentă*

Identificarea canalelor EEG cu potențial de discriminare a stării mentale în testele cu sarcină matematică intermitentă se face dintre cele care îndeplinesc condiția  $\rho_i > 1$  la toate cele trei teste. Astfel, în Tabelul. 3.4.3. sunt prezentate rezultatele extrase din grafice pentru analiza în cele două planuri de frecvență (beta-alfa și teta-alfa).

**Tabelul 3.4.3.** Canale EEG separate în toate cele trei teste cu sarcină intermitentă

Beta-alfa		Teta-alfa	
Emisfera stângă	Emisfera dreaptă	Emisfera stângă	Emisfera dreaptă
-	-	2- AF7 6- F5 31- Pz	52-T8 64-O2

În Fig.3.4.7 sunt reprezentate distanțele de deplasare a punctelor de stare pentru cele 5 canale sensibile în domeniul de frecvențe teta-alfa (vezi Tabelul 3.4.3) pentru testele cu sarcină intermitentă.



**Fig.3.4.7** Tranziția de poziție pentru 5 canale EEG în planul teta-alfa în cazul sarcinii mentale intermitente

### 3.4.7 Concluzii parțiale

- 1) Rezultatele obținute se bazează pe metode cantitative de evaluare a semnalelor în domeniul frecvență folosind două domenii: beta-alfa și teta-alfa.
- 2) Algoritmul metodei s-a aplicat pe experimente proprii și înregistrări (date) originale, în modul de postprocesare a datelor.
- 3) Stările de referință fără sarcină cu ochii închiși (FS-OI) au presupus că subiectul este complet relaxat într-un mediu lipsit de stimuli vizuali, sonori, tactili și kinestezici.
- 4) Starea fără sarcină cu ochii deschiși (FS-OD) reprezintă adevărata stare de referință pentru detectarea stării mentale specifice calculului matematic.
- 5) Separabilitatea stărilor mentale pentru canalele EEG măsurate se evaluează pe baza introducerii unui raport ce ține seama de distanțele dintre stările mentale considerate.
- 6) Semnalele EEG identificate ca fiind cele mai sensibile pentru discriminarea stării mentale cu sarcina de calcul matematic sunt în concordanță cu zonele creierului implicate în procesele de percepție vizuală, lucru cu memoria, gândire algoritmică și decizie.
- 7) S-a constatat că sarcinile mentale intermitente relevă stări diferite în planul frecvențelor analizate, față de sarcinile continue. Semnalele găsite relevante pentru discriminare sunt altele decât în cazul sarcinii continue.

- 8) Semnalele EEG relevante identificate în acest capitol sunt cele din zonele cheie ale creierului implicate în procesele neuronale specifice sarcinilor matematice. În sinteză:

Aria neuronală specializată [25]	Semnale EEG sensibile	
	Sarcina continuă	Sarcina intermitentă
DLPFC (dorso-lateral prefrontal cortex) zona cu rol în funcțiile executive precum memoria de lucru (stocare temporară și manipularea informațiilor), atenție selectivă (filtre, distrageri, lăsarea informațiilor importante să treacă [26] și flexibilitatea cognitivă, adică capacitatea de a comuta între diferite sarcini sau strategii mentale [27]		AF7, F5
AG (Angular Gyrus), care face parte din lobul parietal, este un nod cortical implicat în multiple funcții: memoria episodică, regăsirea faptelor în procesele de calcul, regăsirea faptelor numerice exprimate verbal, procesarea vizual-spațială și concepte abstracte. [28], [29], [30], [31], Zona este mai activă în emisfera stângă[103], efectiv în zona central-parietală de pe canalul CP5 canal [32].	CP5, CP3	Pz
În regiunea occipitală, zona vizuală primară (V1, zona Brodmann 17) și cortexul temporal-occipital ventral (VTOC, zona Brodmann 37) [33] sunt responsabile pentru procesarea numerelor și, în general, evaluarea cantităților exprimate numeric [34].	PO4, Oz, O2	O2
MLT este o regiune subcorticală în hipocamp-parahipocamp [35], care se reflectă în zonele temporale. MLT este asociată cu o serie de funcții cognitive precum memoria, reapelarea episodică, stocarea informațiilor spațiale și învățarea [36]. Primește informații vizuale și auditive pe care apoi le integrează și le transmite altor regiuni (rol de hub).		T8

### 3.5 Analiza semnalelor filtrate în benzi înguste

Filtrarea în benzi foarte înguste în general reduce complexitatea semnalelor EEG, ceea ce crează unele avantaje pentru analiza acestora, astfel:


- Se poate renunța la analiza în domeniul frecvenței, evitând astfel aplicarea transformatei Fourier;
- Analiza semnalului se poate face la nivel de perioadă – o perioadă de referință, considerând o bandă de trecere la filtrare suficient de îngustă în jurul unei frecvențe mediane.
- Pot fi utilizate măsuri mai simple pentru caracterizarea semnalelor, cum sunt cele în domeniul timp: amplitudinea (vârful de semnal), energia, dinamica semnalului.
- Pot fi evaluate *lungimea funcției de semnal pe o perioadă* – care este o măsură independentă de nivelul (componenta de offset) a semnalului care a fost implementată în acest subcapitol.

Astfel, au fost proiectate și implementate Filtre Trece Bandă pentru benzi înguste:  $fd1=[3\ 4]$ ;  $fd2=[4\ 5]$ ;  $fd3=[5\ 6]$ , cu următoarele caracteristici parametrice:

Tip filtru: FIR,  
 Ordinul filtrului: 4000,  
 Frecvența de tăiere jos=3Hz, respective 4Hz și 5Hz  
 Frecvența de tăiere sus=4Hz, respectiv 5Hz și 6 Hz  
 Ripplu în banda de trecere=0.1,  
 Atenuarea în banda de oprire=80dB,  
 Frecvența de eșantionare=500 Hz sau 8192Hz  
 (frecvența de eșantionare a semnalelor EEG)\*.

\*În funcție de experimentul care furnizează datele

De exemplu, caracteristica de frecvență pentru primul filtru este redată în Fig.3.5.1.



Banda de trecere a filtrului ideal corespunzător este puțin peste 0,7Hz și e dispusă simetric în jurul frecvenței mediane a filtrului egală cu 3,5Hz.

Calculul arată că perioada semnalului va putea să difere în plus sau în minus cu cca 10% față de perioada se referință  $T_{med}=1/F_{med\_FTB}$ .

**Fig.3.5.1** Caracteristica filtrului de bandă îngustă fd1: 3 – 4 Hz

### 3.5.1 Prezentarea algoritmilor

Algoritmul de analiză a semnalului filtrat în bandă îngustă consă în următorii pași:

- i) Calculul perioadei medii a semnalului filtrat pe baza frecvenței medii a benzii de trecere a FTB:  $T_{med}=1/F_{med\_FTB}$ .
- ii) Calculul numărului de eșantioane de semnal dintr-o perioadă medie:  $n=T_{med} F_e$ , unde  $F_e$  este frecvența de eșantionare a semnalelor EEG (500Hz sau 8192Hz).
- iii) Se calculează caracteristici ale semnalului  $s(t_k)$  discretizat pe perioada  $T_{med}$ ,  $k=1, \dots, n$ , astfel:

- Media  $\mu = \frac{1}{n} \sum_{k=1}^n s(t_k)$ , deviația standard  $\sqrt{\frac{1}{n-1} \sum_{k=1}^n (s(t_k) - \mu)^2}$ , energia semnalului  $Es = \sum_{k=1}^n (s(t_k))^2$ .
- Se determină vârful semnalului pe perioadă cu pașii următori:

- Se calculează succesiv diferențele de ordinul 1 pentru semnalul  $s(t_k)$ :  
 $\Delta_k^{(1)} = s(t_{k+1}) - s(t_k)$ , pentru  $k=1, \dots, n-1$ ,

- Apoi se calculează diferențele de ordinul 2:  $\Delta_k^{(2)} = \Delta_{k+1}^{(1)} - \Delta_k^{(1)}$ , pentru  $k=1, \dots, n-2$ , și se verifică *condiția de vârf*, adică creștere urmată de descreștere a semnalului  $s(t_k)$ :

$$\Delta_k^{(1)} > 0 \ \& \ \Delta_k^{(2)} < 0 \quad (3.5.1)$$

- Se reține valoarea lui  $k$  pentru care condiția este adevărată. Dacă se detectează vârfuri pentru  $m$ -valori ale lui  $k$ , vârful absolut al semnalului pe porțiunea analizată  $p$  (perioada) se extrage cu funcția:

$$Svarf(p) = \max_{\{k_m\}} (s(t_{k_m})) \quad (3.5.2)$$

- Mulțimea punctelor  $\{Svarf(p)\}$  pentru  $p=1, \dots, N_p$  reprezintă *anvelopa vârfurilor* pe întreg semnalul format din  $N_p$  perioade.

- Lungimea funcției semnal pe porțiunea corespunzătoare unei perioade ( $Lfp$ ) se calculează ca sumă a distanțelor discrete dintre punctele de eșantionare pe funcția de semnal, astfel:

$$Lfp(p) = \sum_{k=1}^n \sqrt{(\Delta_k s)^2 + (1/F_e)^2} \quad (3.5.3)$$

Unde  $n = \frac{F_e}{F_{med\_FTB}}$  numărul de eșantioane pe o perioadă (medie) de semnal.

Notă: Din punct de vedere matematic  $Lfp$  este lungimea unui drum parametrizat în  $R^2$  care se poate evalua cu integrala curbilinie. Astfel, prin parametrizare se rezolvă problema dimensionalității în relația (3.5.1), iar lungimea funcției se calculează în format discret:

$$Lfp(p) = \sum_{k=1}^n \sqrt{1 + \left(\frac{\Delta S_k}{\Delta t}\right)^2} \quad (3.5.4)$$

Energia semnalului pentru o perioadă cu  $n$  eșantioane este:

$$Es(p) = \sum_{k=1}^n (s(t_k))^2 \quad (3.5.5)$$

Spre deosebire de  $Lfp$ , energia depinde și de nivelul semnalului în perioada  $p$  și va fi luată în considerare ca și criteriu adițional pentru discriminarea sarcinilor mentale strict în banda îngustă de lucru.

- iv) Formarea criteriului de discriminare a sarcinii mentale ia în considerare măsurile de semnal discutate mai sus pentru calculul pragurilor de detecție și se alcătuiesc condițiile de discriminare pentru fiecare canal EEG măsurat  $i$ .
  - Pragurile de detecție se definesc pe baza medierii caracteristicilor pe un anumit număr de perioade  $p=1, \dots, w$ , astfel:



$$\circ \text{Prag1}(i) = \max(\overline{Lfp(p)})_{p=1,w}, \quad (3.5.6)$$

unde  $w$  este lățimea ferestrei de mediere cu un anumit număr de perioade, pentru lungimea funcției de semnal.

$$\circ \text{Prag2}(i) = \max(\overline{Es(p)})_{p=1,w}, \quad (3.5.7)$$

unde  $w$  este lățimea ferestrei de mediere cu un anumit număr de perioade, pentru energia semnalului.

- Condițiile de detecție a sarcinii mentale (SM) se pot impune prin conjuncție (ȘI logic) ori prin disjuncție (SAU logic) în formele următoare:

$$SMC(p)^{(i)} = \left( \overline{Lfp(p)}_{p=1,w} > \text{Prag1}(i) \right) \& \left( \overline{Es(p)}_{p=1,w} > \text{Prag2}(i) \right), \quad (3.5.8)$$

respectiv


$$SMD(p)^{(i)} = \left( \overline{Lfp(p)}_{p=1,w} > \text{Prag1}(i) \right) \mid \left( \overline{Es(p)}_{p=1,w} > \text{Prag2}(i) \right). \quad (3.5.9)$$

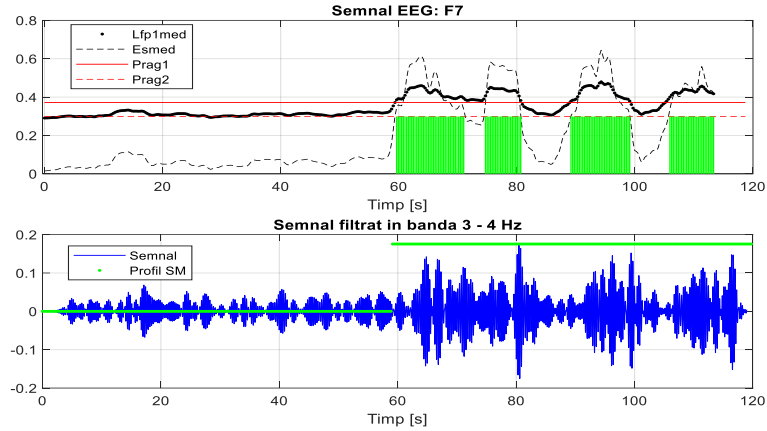
### 3.5.2 Rezultate experimentale

Subiectul ales a fost cel cu nr. 1 situat în grupul G (good) pe locul 6, cu un punctaj de performanță de 30,53. Valorile medii ale discriminatorilor  $Lfp$  și  $Es$  au fost calculate pe o fereastră ce conține 20 de perioade succesive.

Perioada de calibrare pentru stabilirea pragurilor reprezintă primele 60 de secunde corespunzătoare porțiunii fără sarcină. În Fig.3.5.2 sunt ilustrate graficele cu funcțiile de discriminare, pragurile calculate cu relațiile (3.5.6) și (3.5.7) și, marcate cu bare de culoare verde - porțiunile în care s-a detectat sarcina mentală potrivit condițiilor de discriminare conjugate (3.5.8).

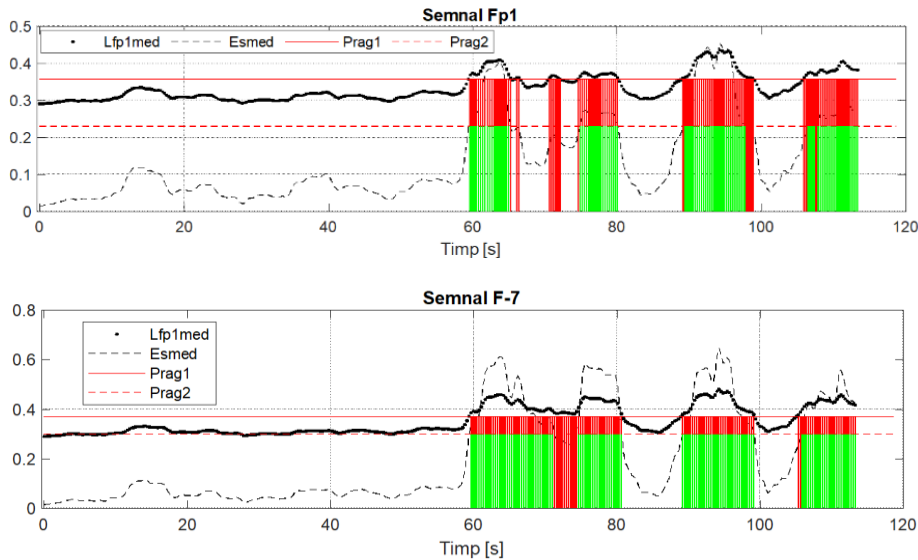
Pe fiecare figură, în partea de jos este reprezentat și semnalul EEG filtrat în banda de interes - în cazul de față 3-4 Hz. Sunt prezentate pentru exemplificare două semnale Fp1 și F7.





**Fig.3.5.2** Discriminarea sarcinii mentale cu  $SMC(p)^{(i)}$  relația (3.5.8)

În Fig.3.5.2 sunt ilustrate rezultatele detecției pentru condiția de discriminare a sarcinii mentale disjunctivă (3.5.9). Porțiunile marcate cu bare de culoare roșie semnifică detecția sarcinii mentale după condiția  $\left(\overline{(Lfp(p))}_{p=1,w}\right) > Prag1(i)$ . Porțiunile disjuncte arată efectul creșterii lungimii medii a funcției de semnal pe o perioadă din alte cauze decât energetice, cum ar fi o creștere sensibilă a frecvenței semnalului față de  $F_{med\_FTB}$ . Deci, criteriul de discriminare disjunctiv surprinde mai complet modificările semnalului.



**Fig.3.5.2** Rezultatul comparativ al discriminării cu condiția  $SMD(p)^{(i)}$  relația (3.5.9) -bare cu roșu și cu condiția  $SMC(p)^{(i)}$  relația (3.5.8) -bare cu verde

### 3.5.3 Concluzii parțiale

- 1) Rezultatele obținute în urma aplicării criteriilor de discriminare propuse, pe semnale filtrate în bandă îngustă – porțiuni din banda teta 3-4 Hz, relevă detecția sarcinii mentale în intervalul de timp când aceasta este indusă de experiment (intre 60 și 120 s).

- 2) Pentru semnalul F7 proporția detecției este cea mai mare, fapt în concordanță cu rezultatul analizei din secțiunea 3.4.2. Alte semnale relevante sunt Fp1, F8, O1 și O2.
- 3) Detecția nu este continuă: proporția zonelor de detecție, distribuția lor și nivelul pragurilor de discriminare depind în principiu de subiect, de semnalul EEG măsurat.
- 4) Pentru anumite semnale se remarcă o simetrie/similitudine relativă între emisferele capului. Astfel: Profilul de sarcină mentală detectat în semnalul F7 este asemănător cu F8 , T3 cu T4, C3 cu C4.
- 5) Evaluările din această secțiune constituie o bază pentru dezvoltarea metodei de detecție a sarcinii mentale în timp real cu aplicarea algoritmului în mod dinamic.

## **3.6 Analiza prin metode statistice**

### **3.6.1 Prezentarea algoritmilor**

Principiul constă în includerea pe fiecare canal de măsurare a pachetului de filtre programabile. Fiecare canal de măsurare EEG generează cinci benzi de semnale filtrate care îmbogățesc de cinci ori cantitatea de date,

Tipurile de corelații utilizate în analiza EEG raportate în literatură sunt corelația Pearson, corelația rangul Spearman și corelația rangul Kendal. Corelația Pearson este mai potrivită pentru analiza datelor EEG [37], fiind folosită ca metodă de investigare a conectivității funcționale. În EEG acesta este expresia interacțiunilor liniare între diferite regiuni ale creierului [38].

### **3.6.2 Rezultate experimentale**

Sunt analizate exerimentele MAT și RSVP din baza de date PhisyoNet. Analiza, dezbateră rezultatorilor și avantajele obținute prin această metodă au fost prezentate în lucrările [25] și [39].

### **3.6.3 Concluzii parțiale**

- 1) Analiza corelațională pe benzi selectate de frecvență a oferit o diversitate numerică extinsă, relevând trăsături particulare ale activității electrice cerebrale și permițând o interpretare mai nuanțată a stărilor mentale
- 2) Matricile de corelație între semnalele brute și cele filtrate în benzi specifice ritmurilor cerebrale au arătat o creștere a corelației în majoritatea cazurilor, indicând o mai bună conectivitate funcțională după filtrare.
- 3) Corelația semnalelor EEG scade în timpul sarcinilor mentale aritmetice, reflectând reorganizarea funcțională a rețelelor neuronale în creier, pe măsură ce activitățile devin mai focalizate și specifice pentru a răspunde cerințelor cognitive.
- 4) Coeficientul de corelație Pearson a fost utilizat pentru a identifica perechile de semnale corelate, cu un prag de 0,5, demonstrând utilitate în studiile cu un număr limitat de electrozi, crescând puterea de decizie a sistemului.
- 5) Importanța undelor teta și beta a fost evidențiată și prin acest criteriu. Undele teta sunt fundamentale pentru funcții cognitive superioare precum atenția și memoria de lucru, iar undele beta sunt asociate cu gândirea analitică și manipularea numerică, ambele având un rol esențial în sarcinile mentale aritmetice.

### 3.7 Contribuții

Principalele contribuții aduse în Capitolului 3 pot fi sintetizate după cum urmează:

- 1) Proiectarea unui set de filtre digitale pentru filtrarea selectivă a semnalelor EEG în sub-benzile de interes consacrate:  $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$  și  $\gamma$ . Aplicarea filtrelor la setul de semnale din experimentul cu stimuli vizuali RSVP.
- 2) Efectuarea unui studiu pe baza analizei spectrale în benzile  $\theta$ ,  $\alpha$  și  $\beta$  pentru răspunsul canalelor EEG monitorizate în cadrul experimentului MAT, pentru a evalua capacitatea celor mai relevante canale pentru detecția sarcinii mentale.
- 3) Aplicarea soluției de eliminare a variației lente a semnalelor EEG prin scăderea din semnalul brut a componentelor extrase cu un filtru Trece Jos de 2Hz.
- 4) Aplicarea metodei ASR de eliminare a artefactelor pe semnalele din experimentul propriu (Experimentul 1).
- 5) Proiectarea unor filtre de bandă îngustă (1Hz) și aplicarea unui astfel de filtru în domeniul undelor  $\theta$  pentru investigarea prezenței sarcinii mentale de natură matematică pe semnalele din experimentul MAT.
- 6) Introducerea într-o manieră originală a unei măsuri pentru semnalele filtrate în bandă îngustă – denumită lungimea funcției (semnal) pe o perioadă (Lfp) pentru discriminarea apariției sarcinii mentale.
- 7) Elaborarea unui algoritm de detecție pentru sarcina mentală folosind indicatorul Lfp împreună cu energia semnalului  $E_s$  și, exemplificarea acestuia pe date din experimentul MAT.
- 8) Investigarea corelației între semnalele EEG prin comparație între testele cu sarcină mentală și cele în stare de relaxare în cadrul experimentului MAT.

# Capitolul 4 PROIECTAREA UNUI SISTEM DE ACHIZIȚIE EEG PENTRU SARCINI COGNITIVE

Scopul acestui capitol este de a stabili configurația potrivită și parametrii unui sistem neinvaziv bazat pe captarea și interpretarea automată a semnalelor EEG – având rol de interfață creier-computer (Brain Computer Interface) pentru detectarea unor sarcini cognitive specifice.

## 4.1. Problematika detectării în timp real a activității cognitive specifică efortului mental în sarcinile de calcul aritmetic


În contextul actual, marcat de dezvoltarea mai multor tehnologii de scanare neinvazivă a creierului, investigarea activității cerebrale prin tehnica EEG are avantaje dar ridică și o problemă specifică. Aceasta derivă tocmai din complexitatea biosemnalelor și din problemele legate de achiziția lor (zgomot, artefacte, contact electrod-scalp deficitar, etc.). Prin urmare, detectarea în timp real a activității mentale depinde de decodificarea biosemnalelor complexe prin metode cât mai imune la problema achiziției de semnal.

## 4.2 Proiectarea și implementarea modulelor de filtrare

Filtrele personalizate, se regăsesc ca module software generate prin programul de aplicație și salvate apoi ca fișiere/structuri de date distinct. Următoarele filtre au fost proiectate și implementate cu funcția Matlab designfilt:

1) Un Filtru Trece Jos de tip FIR cu rol de eliminare a componentelor lente din semnalele EEG brute, având caracteristica de frecvență în Fig.4.2.1.


Ordinul filtrului: 4000,  
frecvența de tăiere =2Hz,  
Ripplu în banda de trecere=0.1,  
Atenuarea în banda de oprire=80dB,  
Frecvența de eșantionare=8192Hz  
(frecvența de eșantionare a  
semnalelor EEG)



**Fig.4.2.1** Parametrii și caracteristica filtrului de corecție pentru variația lentă

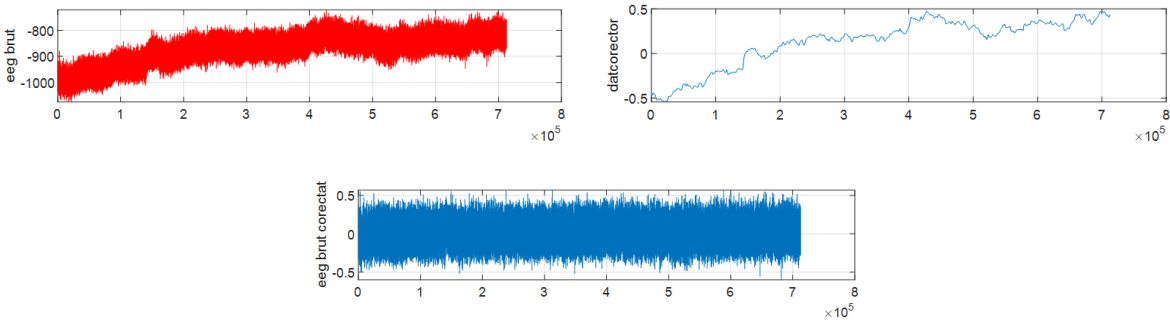
2) Trei Filtre Trece Bandă de bandă îngustă, [3-4Hz], [4-5Hz] și [5-6Hz], caracteristica pentru [3-4Hz] este prezentată în Fig.4.2.2.

- Ordinul filtrului: 4000,
- frecvența de tăiere jos = 3Hz,
- frecvența de tăiere sus = 4Hz
- Ripplu în banda de trecere=0.1,
- Atenuarea în banda de oprire=80dB,
- Frecvența de eșantionare=8192Hz  
(frecvența de eșantionare a semnalelor EEG).



**Fig.4.2.2** Caracteristicile filtrelor de bandă îngustă

Efectul filtrului corector este exemplificat în Fig.4.2.3.



**Fig. 4.2.3** Efectul corecției prin scădere

### 4.3 Implementarea algoritmului de detecție în timp real a sarcinii mentale

Ideea de bază a algoritmului de detecție a sarcinii mentale este prelucrarea dinamică a datelor achiziționate și compararea caracteristicilor de discriminare cu praguri de detecție precalculate pe o porțiune de început a semnalelor într-un interval de timp alocat pentru calibrare.

Această soluție, nu folosește tehnici de învățare automată care să necesite volume mari de date de antrenare și efectuarea multor experimente de achiziție de semnale EEG.

Algoritmul se bazează pe aplicarea aparatului matematic formal descris în secțiunea 3.5. Analiza semnalelor filtrate în benzi înguste. Pașii algoritmului sunt următorii:

- (1) Pornirea achiziției de date EEG brute pe 64 de canale (în sistemul 20-10);
- (2) Pornește prelucrarea datelor după un interval de timp de stabilizare ( $t_{start}=0\dots2$  secunde);
- (3) Normalizarea datelor (echivalentul condiționării semnalelor);
- (4) Aplicarea filtrului de corecție pentru diminuarea variației lente a semnalelor (sub 2Hz);
- (5) Filtrarea în bandă îngustă (Aplicare FTB) și reținere date după 1 secundă;
- (6) Calculul perioadei medii a semnalului filtrat pe baza frecvenței medii a benzii de trecere a FTB:  
 $T_{med}=1/F_{med\_FTB}$ .

- (7) Calculul numărului de eşantioane de semnal dintr-o perioadă medie:  $n = T_{\text{med}} F_e$ , unde  $F_e$  este frecvența de eşantionare a semnalelor EEG (8192Hz).
- (8) Semnalul curent este segmentat dinamic în cadre egale cu perioada medie – cu conținut de  $n = T_{\text{med}} F_e$  eşantioane:  $Ssp(p) = (S_k)_p$ , pentru  $k=1, \dots, n$  și  $p=1, \dots, N_p$ .
- (9) Aplicarea unui algoritm de eliminare automata a artefactelor.
- (10) Se calculează două măsuri specifice în fiecare cadru de perioadă medie care se pot evalua în mod dinamic cu efort de calcul redus și caracterizează semnalul ca energie, dar și ca formă:
- Lungimea funcției (curbei) semnalului pe perioada medie  $Lfp(p) = \sum_{k=1}^n \sqrt{(\Delta_k S)^2 + (1/F_e)^2}$  calculată cu  $Lfp(p) = \sum_{k=1}^n \sqrt{1 + \left(\frac{dS_k}{dt}\right)^2}$  și ponderată cu  $n$ .
  - Energia semnalului pe perioada medie, este tot o măsură integrală care se calculează discretizat cu relația  $Es(p) = \sum_{k=1}^n (S_k)^2$ .
- (11) Se mediază caracteristicile calculate pe o fereastră  $w$  ce conține un număr stabilit de perioade de semnal  $\overline{Lfp(p)}_{p=1,w}$ , respectiv  $\overline{Es(p)}_{p=1,w}$ . Fereastra de semnal pentru mediere se alege  $w=3 \dots 20$  perioade.
- (12) Se calculează pragurile de detecție ca valoare maximă a mediei caracteristicii pe durata de calibrare stabilită  $t_{\text{calib}}$ , pentru fiecare canal EEG măsurat, astfel:

$$Prag1(i) = \max_{t_{\text{calib}}} (\overline{Lfp(p)})_{p=1,w}$$

$$Prag2(i) = \max_{t_{\text{calib}}} (\overline{Es(p)})_{p=1,w},$$

Durata de calibrare este de cel puțin 10 secunde, la începutul sesiunii de achiziție a semnalelor EEG, obligatoriu într-o stare de repaus mental impus, de regulă cu ochii deschiși.

- (13) După scurgerea perioadei de calibrare se evaluează pe ferestre succesive de semnal cu lățimea  $w$ , condițiile de discriminare a sarcinii mentale sub forma criteriilor exprimate prin următoarele expresii logice:

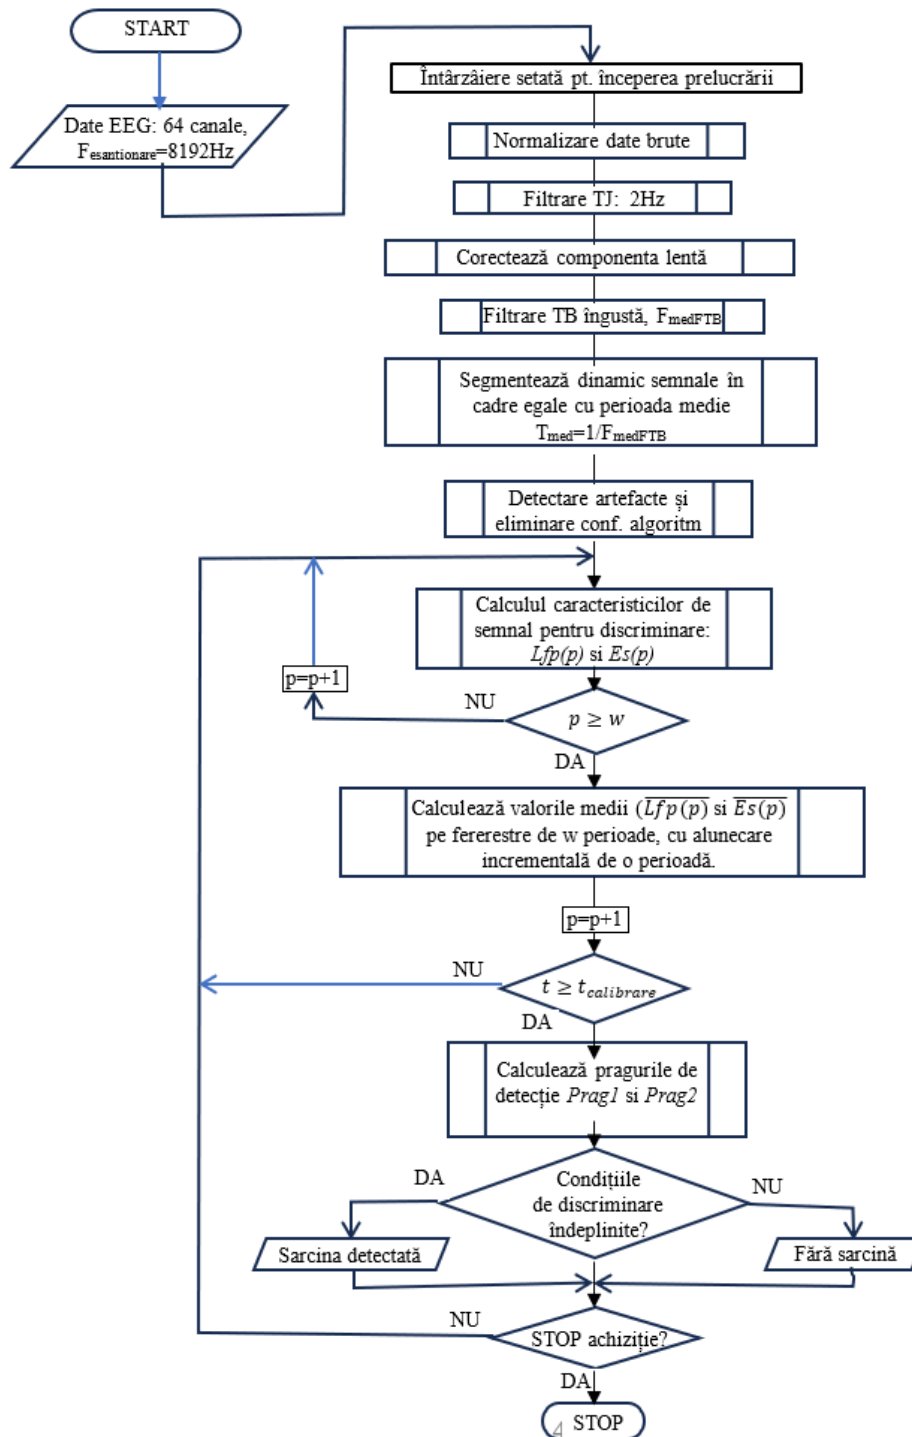
$$SMC(p)^{(i)} = \left( (\overline{Lfp(p)})_{p=1,w} > Prag1(i) \right) \& \left( (\overline{Es(p)})_{p=1,w} > Prag2(i) \right), \quad \text{cu}$$

conjuncția condițiilor parțiale, respectiv

$$SMD(p)^{(i)} = \left( (\overline{Lfp(p)})_{p=1,w} > Prag1(i) \right) | \left( (\overline{Es(p)})_{p=1,w} > Prag2(i) \right) \text{ cu disjuncția}$$

condițiilor parțiale.

Principiul de funcționare al sistemului de detecție în timp real este prezentat în Fig. 4.3.1.



**Fig.4.3.1** Algoritm de detecție



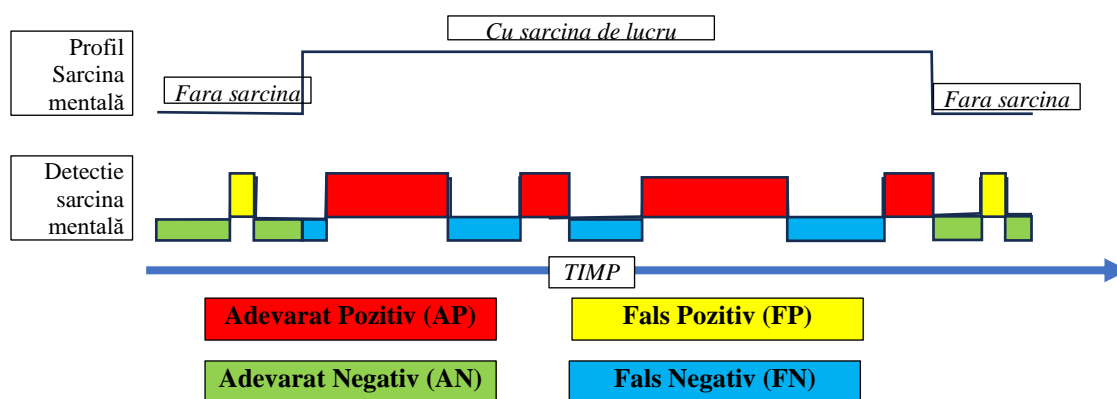
### 4.3.1 Evaluarea algoritmului

Răspunsul fiecărui semnal EEG la prezența sau non-prezența sarcinii mentale, precum și la manifestarea intermitentă a acesteia poate fi clasificat din punct de vedere al probabilității de detecție a evenimentului în patru tipuri, definite în Tabelul 4.3.1.

**Tabelul 4.3.1** Categoria de răspunsuri

Tip de răspuns (probabilist)	Definiție
Adevărat Pozitiv (AP)	Răspunsul apare în prezența sarcinii mentale
Adevărat Negativ (AN)	Răspunsul nu apare când sarcina mentală nu e prezentă
Fals Pozitiv (FP)	Răspunsul apare când sarcina mentală nu e prezentă
Fals Negativ (FN)	Răspunsul nu apare când sarcina mentală e prezentă

În Fig.4.3.2 este ilustrat modul în care algoritmul de detecție a sarcinii mentale poate să furnizeze răspunsuri. Cantitativ, în termeni probabilști sunt valabile relațiile  $FP+AN=1$  și  $FN+AP=1$ .



**Fig.4.3.2** Răspunsuri posibile la detecția sarcinii mentale

Compoziția răspunsului sistemului de detecție din punct de vedere al probabilităților de apariție a celor patru situații prezentate, determină încrederea în capacitatea sistemului de a discrimina sarcina mentală. În acest scop, am folosit un set de criterii cunoscute, definite astfel:

$Acuratetea = \frac{AP + AN}{AP + FP + AN + FN}$	$Precizia = \frac{AP}{AP + FP}$
$Senzitivitatea = \frac{AP}{AP + FN}$	$Specificitatea = \frac{AN}{AN + FP}$

## 4.3.2 Rezultate experimentale


### i. Experimente cu sarcină mentală intermitentă

În această secțiune sunt prezentate rezultatele evaluării sistemului de detecție a sarcinii mentale pentru trei teste în care sarcina mentală este aplicată intermitent. Așa cum au fost descrise în subcapitolul 2.2.3.

Parametrii algoritmului au fost prestabiliți astfel:

- Timpul de așteptare până la procesarea datelor 1 secundă,
- Banda de trecere a FTB 3 – 4 Hz (în domeniul undelor  $\theta$ ),
- Pragul raportului condiției de detecție a artefactelor 2.5,
- Fereastra de analiză pentru artefacte conține 5 perioade de semnal,
- Eliminarea artefactului: înlocuirea a 4 perioade vecine artefactului cu semnalul mediat pe 3 perioade precedente artefactului,
- Fereastra de mediere a caracteristicilor de detecție:  $w=10$  perioade,
- Durata de calibrare: 9 secunde de la începerea procesării datelor,
- Detecția s-a făcut cu ambele condiții de discriminare: cu operatorul SI, respectiv SAU.

Rezultatul cu răspunsurile Adevărat Pozitiv (AP) pentru testul CSI-3 este reprezentat în Fig.4.3.3



**Fig.4.3.3** Procentul de răspunsuri AP pentru canalele EEG pentru testul CSI-3

Valorile numerice obținute sunt sintetizate în Tabelul 4.3.2 pentru cele trei teste:

**Tabelul 4.3.2** Canale EEG care satisfac criteriile de performanță la detecția sarcinii mentale intermitente

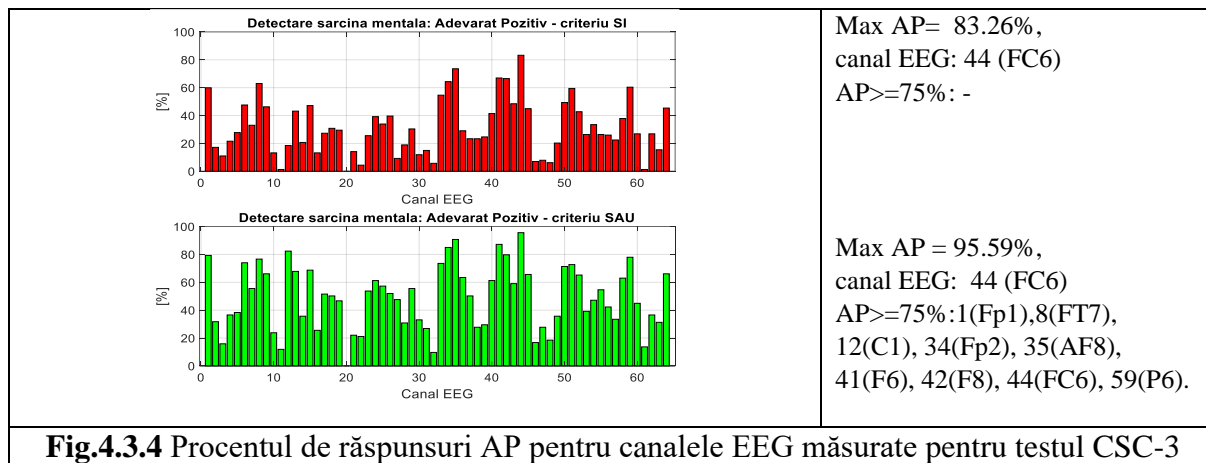
Testul CSI-1		
Criteriu	Cu discriminatorul Si	Cu discriminatorul SAU
Acuratețea	max = 0.729, canal EEG 63 (PO4)	max = 0.760, canal EEG 63 (PO4)

	-	$\geq 0.75$ : 52(T8), 63(PO4)
<b>Precizia</b>	max = 1, canale EEG: 22, 25, 27, 29, 31, 32, 51, 52, 60-64.	max = 1, canale EEG: 16, 23, 24, 29, 51, 56, 61.
<b>Senzitivitatea</b>	max = 0.46, canal EEG: 63 (PO4) -	max = 0.68, canal EEG: 13 (C3) -
<b>Specificitatea</b>	max =1, canale EEG: 15, 16, 21-25, 27-29, 31, 32, 51, 52, 55, 56, 60-64	max =1, canale EEG: 16, 21, 23, 24, 28, 29, 51, 55, 56, 61
<b>Testul CSI-2</b>		
	<b>Cu discriminatorul SI</b>	<b>Cu discriminatorul SAU</b>
<b>Acuratețea</b>	max = 0.793, canal EEG 7 (F7) $\geq 0.75$ : 7 (F7), 9(FC5), 15(T7)	max = 0.808, canal EEG 53 (TP8) $\geq 0.75$ : 2(AF7), 7(F7), 15(T7), 23(P7), 28(Iz), 53(TP8)
<b>Precizia</b>	max = 1, canale EEG: 13, 19, 29, 31, 32, 38, 45, 47, 54, 55, 58, 60, 61, 64.	max = 1, canale EEG: 10, 27, 47, 58, 60, 64
<b>Senzitivitatea</b>	max = 0.789, canal EEG: 7 (F7) $\geq 0.75$ : 7(F7), 8(FT7)	max = 0.866, canal EEG: 6(F5) $\geq 0.75$ : 2(AF7), 6(F5), 7(F7), 8(FT7), 9(FC5), 15(T7),
<b>Specificitatea</b>	max =1, canale EEG: 10, 13, 18-22, 26, 27, 29, 31, 32, 38, 45, 47, 54, 55, 58, 60, 61, 64	max =1, canale EEG: 10, 20-22, 26, 27, 47, 68, 60, 61, 64.
<b>Testul CSI-3</b>		
	<b>Cu discriminatorul SI</b>	<b>Cu discriminatorul SAU</b>
<b>Acuratețea</b>	max = 0.69, canal EEG 43 (FT8) $\geq 0.75$ : -	max = 0.753, canal EEG: 49 (C2) $\geq 0.75$ : 49 (C2)
<b>Precizia</b>	max = 1, canale EEG: 5, 11, 13, 18, 20, 38, 39, 45, 46, 48, 56.	max = 1, canale EEG: 11, 13, 18, 20, 34, 36, 37, 38, 46, 48.
<b>Senzitivitatea</b>	max = 0.69, canal EEG: 51 (C6) $\geq 0.75$ : -	max = 0.87, canal EEG: 49(C2) $\geq 0.75$ : 43(FT8), 49(C2), 51(C6), 52(T8), 60(P8), 63(PO4)
<b>Specificitatea</b>	max =1, canale EEG: 3-5, 11, 13, 18, 20, 21, 27, 32, 34, 35-38, 44, 45, 47, 56	max = 1, canal EEG: 4, 11, 13, 18, 20, 21, 27, 34, 36-38, 46, 48

## ii. Experimente cu sarcina mentală continuă

Conform Experimentului 1 au fost efectuate trei teste cu aplicarea sarcinii mentale continue, timp de 75 de secunde precedate de 10 secunde în stare de așteptare cu ochii deschiși, perioadă folosită pentru calibrarea sistemului. După aplicarea sarcinii înregistrările continua cel puțin 5 secunde, fără sarcină.

Parametrii algoritmului sunt cei aplicați la experimentele cu sarcină intermitentă (vezi punctul precedent). Un exemplu de răspunsul algoritmului de detecție pentru sarcina mentală continua pentru testul CSC-3 este prezentat în Fig. 4.3.4.



Valorile numerice obținute sunt sintetizate în Tabelul 4.3.3 pentru cele trei teste:

**Tabelul 4.3.3** Canale EEG care satisfac criteriile de performanță la detecția sarcinii mentale continue

<b>Testul CSC-1</b>		
Criteriu	Cu discriminatorul SI	Cu discriminatorul SAU
Acuratețea	max = 0.711, canal EEG 35 (AF8) -	max = 0.745, canal EEG 54(CP6) -
Precizia	max = 1, canale EEG: 1(Fp1), 30 (POz), 31 (Pz), 35 (AF8)	max = 1, canal EEG: 30 (POz)
Senzitivitatea	max = 0.61, canal EEG: 13 (C3) -	max = 0.82, canal EEG: 18 (CP3) ≥0.75: 22(P5)
Specificitatea	max = 1, canal EEG: 1(Fp1), 30 (POz), 31 (Pz), 35 (AF8)	max = 1, canal EEG: 30 (POz)
<b>Testul CSC-2</b>		
	Cu discriminatorul SI	Cu discriminatorul SAU
Acuratețea	max = 0.633, canal EEG 3 (AF3) -	max = 0.679, canal EEG 3 (AF3) -
Precizia	max = 1, canale EEG: 5, 9,12, 15, 18, 20, 25, 27-31, 39, 49, 50, 55, 58, 60.	max = 1, canale EEG: 15, 18, 22, 26, 27, 29, 31, 57
Senzitivitatea	max = 0.432, canal EEG: 3(AF3) -	max = 0.625, canal EEG: 3(AF3) -
Specificitatea	max = 1, canale EEG: 5, 9,12, 15, 18, 20, 25, 27-31, 39, 49, 50, 55, 58, 60.	max = 1, canale EEG: 15, 18, 22, 26, 27, 29, 31, 57
<b>Testul CSC-3</b>		
	Cu discriminatorul SI	Cu discriminatorul SAU
Acuratețea	max = 0.735, canal EEG 59 (P6) -	max = 0.729, canal EEG: 12 (C1) -
Precizia	max = 1, canale EEG: 11, 22, 26, 28, 30, 31,32, 61,62, 63.	max = 1, canal EEG: 30 (POz)

Senzitivitatea	max = 0.83, canal EEG: 44(FC6) ≥0.75: 44(FC6)	max = 0.95, canal EEG: 44(FC6) ≥0.75: 1(Fp1), 8(FT7), 12(C1), 34(Fp2), 35(AF8), 41(F6), 42(F8), 44(FC6), 59(P6). ≥75%: 43(FT8), 49(C2), 51(C6), 52(T8), 60(P8), 63(PO4)
Specificitatea	max =1, canale EEG: 11, 20, 22, 26, 28, 30, 31,32, 61,62, 63.	max = 1, canale EEG: 20, 30 (POz)

Pentru testele cu sarcina mentală continuă, se remarcă două canale EEG comune tuturor testelor care au relevat Precizia maximă: 30 (POz) și 31 (Pz) amplasate în zona convențională posterioară. Aceste canale corespund zonelor funcționale ale cortexului recunoscute pentru funcții cognitive: aria 39 (Girusul Angular - nodul de integrare a mai multe funcții) precum și arii parieto-occipitale responsabile cu vederea (mișcări reflexe ale ochilor, integrarea optică și recunoașterea formelor, etc.).

În aria convențională frontală au răspuns cu precizie maximă canalele 1(Fp1), 5(F3), 9(FC5) și 11(FC1) care corespund ariei funcționale DLPFC (dorso-lateral prefrontal cortex) zona cu rol în funcțiile executive precum memoria de lucru (stocare temporară și manipularea informațiilor), atenție selectivă: filtrare, distrageri, lăsarea informațiilor importante să treacă [26] și flexibilitatea cognitivă, adică capacitatea de a comuta între diferite sarcini sau strategii mentale [27].

Pentru testele cu sarcina mentală intermitentă, canale comune cu precizia maximă: 27 (O1), 32 (CPz) din zona posterioara, respectiv centrală, iar din aceeași zona funcțională se regasesc și canalele EEG 22 (P5), 23 (P7), 25 (PO7), 29 (Oz), 31 (Pz), 60 (P8), 61 (P10), 64 (O2). În zona frontală se regănesc 3 (AF3), 4 (F1), 5 (F3), 10 (FC3), 11 (FC1). În zona centrală canalele de precizie maximă detectate sunt: 13 (C3), 18 (CP3) și 19 (CP1). Acestea corespund ariilor neuronale cu responsabilități în procesele cognitive și asociate acestora.

Utilizarea informației de detecție cumulative de la mai multe canale cu precizie maximă are ca efect creșterea acurateții modelului pe seama reducerii ratei de răspunsuri Fals Negativ (FN), detectorul devenind astfel mai sensibil.

Un astfel de model a fost testat pentru datele din *Experimentul 1* cu următoarele precizări privind procedura de lucru și setarea parametrilor:

- i) S-a introdus un parametru *la* (latență acceptată) prin care se admit răspunsuri Fals Pozitive pentru o anumită perioadă de timp de la încetarea aplicării sarcinii mentale. În testul prezentat *la* este setat la 3 secunde.
- ii) Cu setul de canale selectate având răspunsurile cu FP=0, obținut în condițiile de la punctul precedent, se cumulează răspunsurile AP de la toate canalele selectate.
- iii) Testarea metodei a fost făcută atât pentru discriminatorul cu ȘI cât și pentru discriminatorul cu SAU.

Un exemplu de implementare a metodei este prezent în Fig. 4.3.5, pentru testele cu sarcină continuă.

Discriminatorul ȘI


26 canale EEG precise: 1 11 14 19 23 25 29 30 31 35 36 38 39 40 41 45 49 50 51 53 56 58 59 60 61 62

Nr raspunsuri AP: 31 52 64 42 95 65 54 10 8 96 61 75 42 61 48 70 57 72 69 93 76 74 31 25 75 50

Discriminator SAU

8 canale EEG precise: 11 30 31 45 49 56 60 61

Nr raspunsuri AP: 75 31 12 136 74 108 83 136



**Fig. 4.3.5** Testul CSC-1 și răspunsul detectorului în raport cu sarcina continuă (sus pentru discriminator ȘI, jos pentru discriminator SAU, cu linie continua ciclul de aplicare al sarcinii mentale)

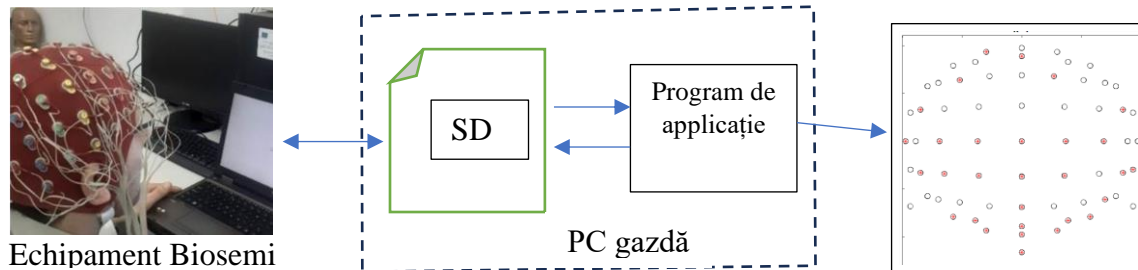
### Comentarii asupra rezultatelor

- Aplicarea algoritmului de detecție pe datele de la mai multe canale considerate precise crește rata răspunsurilor Adevărat Pozitive cu peste 50%, astfel că acuratețea poate ajunge la peste 0.9.
- O posibilă optimizare (minimizare) a numărului de canale necesar a fi grupate pentru cumulare este alegerea acelor care dau răspunsuri AP disjuncte.
- Am considerat modelul sarcinii mentale ca o aplicație liniară în trepte și cu paliere constante, raportându-ne la aceasta pentru calificarea răspunsurilor detectorului. Răspunsul creierului este însă diferit de acest model formal de aplicare a sarcinii, cu siguranță este neliniar și posibil nestaționar. Astfel, ceea ce noi detectăm în banda de frecvență de interes, cu ajutorul unor măsuri de semnal cantitative și aplicând discriminatorii definiți surprinde chiar modul de răspuns real al creierului.


## 4.4 Aplicație pentru maparea activității creierului cu 64 de canale EEG

Algoritmul de detecție a sarcinii mentale a fost completat cu o aplicație de vizualizare a canalelor activate de sarcina mentală și clasificate ca atare. Aplicația realizată folosește echipamentul Biosemi cu 64 de canale EEG, împreună cu un program de citire a datelor EEG brute elaborat cu resurse software SDK de la Biosemi.

Schema bloc a aplicației este prezentată în Fig.4.4.1. În Fig.4.4.2 se prezintă trei stări ale interfeței din timpul testelor.



**Fig.4.4.1** Schema de principiu a aplicației Interfața grafică prezintă în mod dinamic activarea canalelor EEG în raport cu sarcina mentală practică de subiect.



**Fig.4.4.2** Aspectul interfeței de mapare a activității creierului cu 64 de puncte

## 4.5 Concluzii parțiale

- 1) Procesele neuronale care se manifestă în timpul sarcinii mentale nu sunt continue. Altfel spus, creierul nu lucrează în regim de comutație pornit-oprit. Din acest motiv, detecția sarcinii mentale se confruntă cu stări tranzitorii, care se manifestă prin intermitența și latența răspunsului algoritmului de detecție. În acest mod se explică atât răspunsurile Fals Negative cât și o parte din răspunsurile Fals Pozitive. Acestea din urmă pot să aibă și alte cauze independente de starea mentală monitorizată.
- 2) Alegerea canalelor EEG potrivite pentru detectarea sarcinii mentale a avut în vedere două condiții dificil de îndeplinit simultan: Acuratețea maximă și Precizia maximă. Canalele EEG găsite relevante în timpul testelor se regăsesc printre cele utilizate și în alte cercetări și chiar în construcția celor mai recente interfețe BCI.
- 3) Pentru detecția sarcinilor mentale în timp real am propus un algoritm de discriminare fără un model de referință învățat preliminar, ci bazat pe o filtrare specifică într-o bandă îngustă a semnalelor și evaluarea unor caracteristici care depind de forma și mărimea semnalului: Lfp – lungimea funcției (curbei) de semnal pe o perioadă, respectiv Es – energia semnalului. Aceste caracteristici, mediate pe o fereastră sunt folosite la început pentru calibrarea sistemului pe o perioadă de relaxare impusă subiectului, construind astfel referința pentru discriminare în sesiunea curentă de lucru. Această referință are avantajul că este foarte specifică subiectului chiar la momentul achiziției de date și nu depinde de modele preantrenate cu seturi uriașe de date.

- 4) Setarea parametrilor de lucru ai algoritmului de detecție începând cu banda specifică (îngustă) de filtrare, lungimea ferestrelor de mediere, construcția criteriilor de detecție și alcătuirea expresiilor logice de discriminare precum și stabilirea pragurilor de detecție s-au făcut prin cercetare experimentală susținută cu date din teste proprii, originale cât și din baze de date internaționale.
- 5) Prin conceperea și aplicarea unui algoritm original de detecție și eliminare a artefactelor am încercat să rezolv o problemă în general dificilă mai ales pentru tratarea în timp real a semnalelor.
- 6) Algoritmul elaborat oferă răspunsuri pertinente cu acuratețe de peste 75% în unele experimente. Precizia nu este însă foarte bună pentru canalele care răspund bine la sarcină în sensul că există răspunsuri Fals Pozitive. Totuși se pot considera de încredere canalele EEG la care s-a constatat că nu dau răspunsuri Fals Pozitive înainte de apariția sarcinii, cele de după dispariția sarcinii având ca posibilă justificare latența proceselor neuronale cognitive și/sau prelungiri ale stării determinate chiar de subiect (voluntare sau involuntare).



## Capitolul 5 CONCLUZII

### 5.1 Concluziile tezei

Sarcina mentală aritmetică este utilizată în EEG pentru a înțelege procesarea informației și răspunsul creierului la efortul cognitiv, permițând identificarea tiparelor de activitate neuronală, evaluarea performanței cognitive, monitorizarea nivelului de concentrare și detectarea potențialelor disfuncții.

Obiectivul a fost inducerea unor stări mentale care activează procese cognitive precum atenția, concentrarea, gândirea algoritmică, memoria de lucru și activitatea cognitivă. Au fost alese sarcinile mentale matematice pentru investigarea activității cerebrale în condiții de stres cognitiv indus de raționamentul logic. Scopul principal al studiului a fost analiza sistematică a semnalelor EEG pentru discriminarea între stările cu și fără efort mental, validând rezultatele cu informațiile existente în literatura de specialitate. S-au dezvoltat metode originale de investigare, contribuind astfel la descifrarea mecanismelor complexe ale gândirii, percepției și învățării.

Studiul a analizat experimentele MAT cu 19 canale EEG (din baza de date), Experimentul 1 cu 64 de canale EEG (original), ambele implicând calcule aritmetice prin scăderi succesive dintr-un număr inițial, precum și un experiment RSVP cu stimuli vizuali cu 8 canale EEG (din baza de date).

Identificarea și eliminarea artefactelor constituie o primă provocare în interpretarea precisă a datelor EEG. Am propus o soluție pentru implementarea unor filtre digitale programabile pe fiecare canal EEG, care permite descompunerea semnalului brut în componente de frecvență specifice ritmurilor cerebrale (delta, teta, alfa, beta, gamma). Această abordare elimină diferențele dintre oscilațiile de frecvențe diferite și oferă posibilitatea de a explora caracteristicile individuale ale oscilațiilor neuronale și interdependențele acestora, fără a pierde informații esențiale din semnalul compozit.

Pentru experimentul propriu, am utilizat preliminar un filtru trece-jos cu o frecvență de tăiere la 2 Hz pentru a extrage componenta lentă, urmat de filtrarea în sub-benzi. Eficiența metodei de filtrare cu filtrul corector a fost demonstrată prin compararea semnalelor procesate cu algoritmi recenți, precum ASR și ICA (metoda MARA). Tehnica de filtrare propusă a generat rezultate similare cu ASR, evidențiind performanța sa în raport cu tehnicile actuale de eliminare a artefactelor.

Am dezvoltat o metodă și pentru reducerea zgomotului din semnalul EEG prin segmentarea acestuia și calculul mediilor aritmetice pentru fiecare coloană de semnal, utilizând o modalitate diferită de împărțire și „amestecare” a eşantioanelor de timp în ferestre. Această abordare, spre deosebire de o fereastră obișnuită care analizează segmente individuale de timp, evidențiază tiparele dominante și componentele stabile ale semnalului de-a lungul diferitelor ferestre.

O provocare majoră a fost dezvoltarea mecanismelor de discriminare a stărilor mentale la nivelul fiecărui canal EEG. Am acordat atenție identificării și adaptării metodelor de lucru atât în domeniul timp, cât și în domeniul frecvență. Instrumentele de analiză inițială, precum transformata Fourier Rapidă (FFT), au fost aplicate prin programe originale, pentru datele experimentale disponibile. Astfel, am implementat o metodă de clasificare cu ajutorul limitelor domeniilor de variație a vârfurilor spectrale pentru experimentul MAT și Experimentul 1. Rezultatele au indicat domenii clar disjuncte pentru semnalele F7 și Fz în benzile teta și beta. Experimentul 1 a confirmat mai multe canale discriminatoare, punând aceasta pe seama faptului că în acest experiment componenta auditivă și verbală nu au existat.

Pentru studiul comportării canalelor EEG la sarcina mentală, am analizat gruparea acestora în clustere de puncte în planurile de frecvență beta-alfa și teta-alfa și am evaluat distanțele dintre punctele ce reprezintă stările. Coordonatele punctelor de stare sunt frecvențele dominante medii calculate pentru fiecare semnal, iar separabilitatea canalelor se face printr-o condiție asupra unei funcții care depinde de distanțele euclidiene dintre stări. În acest scop, am propus pentru comparație o măsură egală cu raportul distanțelor relative dintre stări în subcapitolul 3.4. Metoda clusterelor a demonstrat că există canale EEG specifice, sensibile la diferențele dintre stările mentale cu sarcina de calcul matematic. S-a constatat că sarcinile mentale intermitente manifestă stări diferite în planul frecvențelor analizate, comparativ cu sarcinile continue, iar canalele EEG relevante pentru discriminare sunt diferite în cele două cazuri. Analiza cantitativă a identificat semnale specifice pentru sarcina continuă (CP5, CP3, PO4, Oz, O2) și pentru sarcina intermitentă (AF7, F5, Pz, O2, T8).

Metoda spectrală, urmată de evaluarea vârfurilor spectrale în sub-benzi de frecvență, a fost utilizată pentru testele efectuate atât în starea de relaxare, cât și în timpul calculului continuu. Aplicarea acestei metode a relevat diferențierea clară a stărilor mentale în prezența sarcinii, față de cele fără sarcină mentală, pentru durate lungi ale semnalelor. Pentru porțiuni scurte de semnal, comparative cu lungimea ferestrei de analiză pentru detecția în timp real, rezultatele acestei metode nu sunt relevante. În consecință, studiul a fost orientat către evaluarea semnalelor în domeniul timp-frecvență pe benzi de frecvență înguste. Astfel, în domeniul frecvență, prelucrarea efectuată este filtrarea de tip trece-bandă (fără a necesita calculul Transformatei Fourier), iar în domeniul timp se calculează două măsuri integrale ale semnalului: energia semnalului ( $E_s$ ) și lungimea funcției semnalului ( $L_{fp}$ ) strict pentru porțiunea de semnal egală cu perioada medie a semnalului filtrat.

Detectarea sarcinii mentale în timp real reprezintă provocarea care a impus filtrarea în bandă îngustă și utilizarea măsurilor integrale menționate, pentru a evita analiza semnalelor pe durată mare și cu un efort de calcul ridicat. Astfel, am implementat algoritmul de detecție bazat pe un cadru de semnal de ordinul secundelor (sub 3 secunde), care este evaluat cu măsurile propuse  $E_s$  și  $L_{fp}$ . Discriminarea sarcinii se face prin comparație cu praguri obținute prin calibrare chiar în timpul sesiunii de lucru, folosind condiții logice ce diferențiază conjunctiv și disjunctiv.

Concluzia studiului arată că aplicarea criteriilor de discriminare în această formă, pe semnale EEG filtrate în banda îngustă (teta 3-4 Hz), permite detectarea eficientă a sarcinii mentale, semnalul F7 oferind cea mai mare proporție de detecție, ceea ce vine în concordanță cu analiza

spectrală a domeniilor de variație a vârfurilor spectrale (3.4.2). Profilul de sarcină mentală detectat în semnalul F7 este asemănător cu cel din semnalele F8, T3 cu T4, și C3 cu C4, sugerând o integrare și cooperare eficientă între regiunile cerebrale. Alte semnale relevante identificate includ Fp1, F8, și O1, O2. Această metodă a constituit baza pentru implementarea algoritmului în timp real, oferind răspunsuri pertinente cu o acuratețe de peste 75% în unele experimente, pentru discriminatorul cu operatorul SI, respectiv peste 85% pentru discriminatorul cu operatorul SAU.

Am efectuat o evaluare a canalelor EEG care prezintă cea mai mare încredere pentru detectarea sarcinii mentale, folosind algoritmul de detecție în timp real propus. Condiția de bază a fost selectarea canalelor cele mai precise și selective pentru sarcină, adică cele care nu răspund fals pozitiv. Se remarcă astfel canalele EEG POz și Pz, situate în zona centrului de intersecție a funcțiilor cognitive (Girusul Angular). Pentru creșterea sensibilității și acurateții metodei, am arătat că aplicarea algoritmului de detecție pe datele de la mai multe canale considerate precise crește rata răspunsurilor Adevărat Pozitive cu peste 50%, astfel că acuratețea poate ajunge la peste 0.9. Discriminatorul SAU poate să genereze rate de răspunsuri AP cumulate mai mici deoarece este mai restrictiv cu detectarea canalelor EEG de precizie, admițând un număr mai mic de canale care dau răspunsuri FP=0. În general, discriminatorul ȘI admite mai multe canale cu precizie maximă, deci și șansa de a avea mai multe răspunsuri AP cumulate de la mai multe canale este mai mare.

Variabilitatea individuală, expresia unică a dinamicii cerebrale a fiecărui subiect, adaugă o provocare suplimentară pentru această cercetare. Metodele alese, împreună cu sensibilitatea discriminatorilor, au permis o reflectare mai precisă a variabilității individuale, captând nuanțele subtile ale diferențelor în activitatea neuronală specifice fiecărui subiect.

Studiul nu utilizează tehnicile de învățare automată care se bazează pe volume mari de date de antrenament și numeroase experimente EEG. În locul recunoașterii formelor prin modele preantrenate din multiple exemple, metoda propusă prelucrează inițial o porțiune scurtă de semnal EEG în stare de relaxare impusă. Această prelucrare permite stabilirea unor valori prag de referință pentru fiecare canal EEG, la care se raportează ulterior caracteristicile secvențelor de semnale captate în mod dinamic.

## 5.2. Contribuții

- Simplificarea analizei EEG prin implementarea metodei de filtrare în benzi înguste, care a permis o evaluare eficientă fără a necesita Transformata Fourier, utilizând măsuri directe, cum ar fi lungimea funcției semnalului ( $L_{fp}$ ) și energia semnalului ( $E_s$ ).
- Dezvoltarea de mecanisme de discriminare a stărilor mentale prin construcția criteriilor de detecție, formularea expresiilor logice de discriminare și stabilirea pragurilor de detecție.
- Introducerea unui filtru corector preliminar pentru eliminarea artefactelor care demonstrează eficiența în eliminarea artefactelor prin compararea semnalelor procesate cu algoritmi precum ASR.
- Dezvoltarea unei metode de reducere a zgomotului printr-o metodă de segmentare a semnalului EEG și calculul mediilor aritmetice pentru fiecare coloană de semnal.

- Dezvoltarea unui algoritm care detectează artefactele pe baza amplitudinilor atipice în timpul procesării semnalului și înlocuiește secvențele suspecte fără a întrerupe continuitatea semnalului.
- Evitarea dependenței de metodele de învățare automată printr-o abordare alternativă care nu necesită volume mari de date de antrenament, stabilind valori de prag de calibrare la nivel de individ.
- Am realizat o contribuție în domeniul separării semnalelor EEG prin modelarea activității cerebrale cu componente și circuite electronice.
- Am propus un model al conexiunilor electrice pentru șapte structurile tisulare ale capului uman, utilizând circuite pasive și evaluând impedanțele echivalente ale țesuturilor traversate de biocurenți electrici.
- Am adus o contribuție pentru obținerea unor formule de calcul aproximativ pentru proprietățile dielectrice ale țesuturilor biologice.

### 5.3 Perspective de cercetare

Complexitatea semnalelor EEG în ceea ce privește forma și dinamica formei lor precum și de insuficiența cunoașterii a mecanismelor neuronale profunde și asociative la nivelul creierului aflat în diferite stări de lucru, lasă deschis drumul către experiment și testare pentru găsirea de instrumente matematice potrivite pentru analiza și prelucrarea semnalelor, precum și pentru conceperea unor sisteme logice potrivite detecției și discriminării stărilor mentale.

Pornind de la cercetarea doctorală prezentată în această teză, întrevăd și îmi propun să continui studiul asupra următoarelor perspective de cercetare:

1. Conceperea unor experimente sistematice adecvate pentru obținerea de date în condiții de sarcini mentale variate pentru scenarii diverse.
2. Testarea detectorului într-o multitudine de benzi înguste pentru a găsi eventuale domenii de răspuns mai bun de-a lungul benzilor consacrate delta, teta, alfa, beta și gama.
3. Îmbunătățirea algoritmului de detecție a sarcinii mentale prin optimizarea unor parametrii cum ar fi dimensiunea ferestrei de analiză și prelucrare a semnalului, precum și parametrii algoritmului pentru tratarea artefactelor.
4. Perfecționarea algoritmului de detecție a sarcinii mentale, cât și pe cel de tratare a artefactelor prin dezvoltarea și implementarea unor modele de decizie bazate pe inteligență artificială.
5. Investigarea unor soluții de implementare hardware la nivelul algoritmului de detecție, cum ar fi filtrele digitale, paralelizarea unor operații asupra mulțimii de semnale.
6. Efectuarea de experimente pentru achiziția de date cu interfețe combinate cum ar fi EEG și detectorul pentru mișcarea ochilor, pentru aplicații de comandă și control în general, inclusiv pentru persoanele cu dizabilități.

## BIBLIOGRAFIE SELECTIVĂ

1. Portillo-Lara, R.; Tahirbegi, B.; Chapman, C.A.R.; Goding, J.A.; Green, R.A. *Mind the Gap: State-of-the-Art Technologies and Applications for EEG-Based Brain–Computer Interfaces*. APL Bioengineering 2021, 5, 031507, doi:10.1063/5.0047237.
2. **Coman, D.A.**; Amuzescu, B.; Nistor, G. *Theoretical Assumptions in Conductivity and Dielectric Properties Assessment of Biological Tissues - Errors and Resulting Consequences*. In Proceedings of the 2023 13th International Symposium on Advanced Topics in Electrical Engineering (ATEE); IEEE: Bucharest, Romania, March 23 2023; 1–6, DOI: 10.1109/ATEE58038.2023.10108270
3. Cohen, M.X. *Where Does EEG Come From and What Does It Mean?*, Trends in Neurosciences 2017, 40, 208–218, doi:10.1016/j.tins.2017.02.004.
4. Wang, X.-J. *Theory of the Multiregional Neocortex: Large-Scale Neural Dynamics and Distributed Cognition*, Annu. Rev. Neurosci. 2022, 45, 533–560, doi:10.1146/annurev-neuro-110920-035434.
5. Molnár, Z.; Rockland, K.S. Chapter 5 - Cortical Columns. In *Neural Circuit and Cognitive Development (Second Edition)*; Rubenstein, J., Rakic, P., Chen, B., Kwan, K.Y., Eds.; Academic Press, 2020; pp. 103–126 ISBN 978-0-12-814411-4.
6. Hawkins, J.; Ahmad, S.; Cui, Y. *A Theory of How Columns in the Neocortex Enable Learning the Structure of the World*, Front. Neural Circuits, 2017, 11, 81, doi:10.3389/fncir.2017.00081.
7. Le Van Quyen, M. *The Brainweb of Cross-Scale Interactions*. New Ideas in Psychology 2011, 29, 57–63, doi:10.1016/j.newideapsych.2010.11.001
8. Gabriel, C.; Gabriel, S.; Corthout, E. *The Dielectric Properties of Biological Tissues: I. Literature Survey*, Phys. Med. Biol. 1996, 41, 2231–2249, doi:10.1088/0031-9155/41/11/001.
9. Mahinda, H.A.M.; Murty, O. *Variability in Thickness of Human Skull Bones and Sternum - An Autopsy Experience*, Journal of Forensic Medicine and Toxicology, 2009, 26, 26–31.
10. Akhtari, M.; Bryant, H.C.; Mamelak, A.N.; Flynn, E.R.; Heller, L.; Shih, J.J.; Mandelkern, M.; Matlachov, A.; Ranken, D.M.; Best, E.D.; et al. *Conductivities of Three-Layer Live Human Skull*, Brain Topogr. 2002, 14, 151–167, doi:10.1023/a:1014590923185..
11. Næss, S.; Halnes, G.; Hagen, E.; Hagler, D.J.; Dale, A.M.; Einevoll, G.T.; Ness, T.V. *Biophysically Detailed Forward Modeling of the Neural Origin of EEG and MEG Signals*, NeuroImage, 2021, 225, 117467, doi:10.1016/j.neuroimage.2020.117467
12. **Coman, D.A.**; Ionita, S.; Lita, I. *Electrical Model of the Human Head-Circuit Parameters*, In Proceedings of the 2020 43rd International Spring Seminar on Electronics Technology (ISSE); IEEE: Demanovska Valley, Slovakia, May 2020; pp. 1–7
13. Al-Qazzaz, N.K.; Ali, S.H.B.M.; Ahmad, S.A.; Chellappan, K.; Islam, M.S.; Escudero, J. *Role of EEG as Biomarker in the Early Detection and Classification of Dementia*. ScientificWorldJournal 2014, 2014, 906038, doi:10.1155/2014/906038.
14. <https://physionet.org/about/database/> , PhysioNet Databases, accesat 2021.

15. Lina Elsherif Ismail, Waldemar Karwowski, *Applications of EEG Indices for the Quantification of Human Cognitive Performance: A Systematic Review and Bibliometric Analysis*, PLOS ONE, 2020 Dec 4;15(12):e0242857. doi: 10.1371/journal.pone.0242857)..
16. Matran-Fernandez, A.; Poli, R. *Brain-Computer Interfaces for Detection and Localization of Targets in Aerial Images*. IEEE Trans Biomed Eng 2017, 64, 959–969, doi:10.1109/TBME.2016.2583200.
17. **Coman, D.A.**; Ionita, S.; Lita, I. *Theoretical and Practical Aspects in the Design and Construction of Active Electrodes for EEG*. In Proceedings of the 2020 IEEE 26th International Symposium for Design and Technology in Electronic Packaging (SIITME); IEEE: Pitesti, Romania, October 21 2020; pp. 81–83..
18. Bloniasz, P. *Artifact Subspace Reconstruction (ASR) for Electroencephalography Artifact Removal Must Be Optimized for Each Unique Dataset*, 2022, doi:10.32388/SMEI50..
19. Plechawska-Wojcik, M.; Kaczorowska, M.; Zapala, D. The Artifact Subspace Reconstruction (ASR) for EEG Signal Correction. A Comparative Study. In *Information Systems Architecture and Technology: Proceedings of 39th International Conference on Information Systems Architecture and Technology – ISAT 2018*.
20. Fatimah, B.; Pramanick, D.; Shivashankaran, P. Automatic Detection of Mental Arithmetic Task and Its Difficulty Level Using EEG Signals. In Proceedings of the 2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT); IEEE: Kharagpur, India, July 2020; pp. 1–6.
21. Fatimah, B.; Pramanick, D.; Shivashankaran, P. *Automatic Detection of Mental Arithmetic Task and Its Difficulty Level Using EEG Signals*. In Proceedings of the 2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT); IEEE: Kharagpur, India, July 2020; pp. 1–6.
22. Attallah, O. *An Effective Mental Stress State Detection and Evaluation System Using Minimum Number of Frontal Brain Electrodes*. Diagnostics 2020, 10, 292, doi:10.3390/diagnostics10050292.
23. Ganguly, B.; Chatterjee, A.; Mehdi, W.; Sharma, S.; Garai, S. *EEG Based Mental Arithmetic Task Classification Using a Stacked Long Short Term Memory Network for Brain-Computer Interfacing*. In Proceedings of the 2020 IEEE VLSI DEVICE CIRCUIT AND SYSTEM (VLSI DCS); IEEE: Kolkata, India, July 2020; pp. 89–94.
24. Varshney, A.; Ghosh, S.K.; Padhy, S.; Tripathy, R.K.; Acharya, U.R. *Automated Classification of Mental Arithmetic Tasks Using Recurrent Neural Network and Entropy Features Obtained from Multi-Channel EEG Signals*. Electronics 2021, 10, 1079, doi:10.3390/electronics10091079.
25. **Coman, D.A.**; Ionita, S.; Lita, I. *Evaluation of EEG Signals by Spectral Peak Methods and Statistical Correlation for Mental State Discrimination Induced by Arithmetic Tasks*. Sensors 2024, 24, 3316, doi:10.3390/s24113316.
26. *Genomics, Circuits, and Pathways in Clinical Neuropsychiatry*; Elsevier, 2016; ISBN 978-0-12-800105-9.
27. Yang, X.; Gao, M.; Shi, J.; Ye, H.; Chen, S. *Modulating the Activity of the DLPFC and OFC Has Distinct Effects on Risk and Ambiguity Decision-Making: A tDCS Study*. Front. Psychol. 2017, 8, 1417, doi:10.3389/fpsyg.2017.01417

28. Arsalidou, M.; Taylor, M.J. *Is 2+2=4? Meta-Analyses of Brain Areas Needed for Numbers and Calculations.* *NeuroImage* 2011, 54, 2382–2393, doi:10.1016/j.neuroimage.2010.10.009.
29. Seghier, M.L. *The Angular Gyrus: Multiple Functions and Multiple Subdivisions.* *Neuroscientist* 2013, 19, 43–61, doi:10.1177/1073858412440596.
30. Grabner, R.H.; Ansari, D.; Koschutnig, K.; Reishofer, G.; Ebner, F.; Neuper, C. *To Retrieve or to Calculate? Left Angular Gyrus Mediates the Retrieval of Arithmetic Facts during Problem Solving.* *Neuropsychologia* 2009, 47, 604–608, doi:10.1016/j.neuropsychologia.2008.10.013.
31. Dehaene, S.; Piazza, M.; Pinel, P.; Cohen, L. *THREE PARIETAL CIRCUITS FOR NUMBER PROCESSING.* *Cognitive Neuropsychology* 2003, 20, 487–506, doi:10.1080/02643290244000239.
32. Sulcova, D.; Salman, Y.; Ivanoiu, A.; Mouraux, A. *Exploring the Properties of the Left Angular Gyrus Using TMS-Evoked Potentials; Neuroscience, 2022*
33. Evans, T.M.; Kochalka, J.; Ngoon, T.J.; Wu, S.S.; Qin, S.; Battista, C.; Menon, V. *Brain Structural Integrity and Intrinsic Functional Connectivity Forecast 6 Year Longitudinal Growth in Children's Numerical Abilities.* *J. Neurosci.* 2015, 35, 11743–11750, doi:10.1523/JNEUROSCI.0216-15.2015.
34. Iuculano, T.; Rosenberg-Lee, M.; Supekar, K.; Lynch, C.J.; Khouzam, A.; Phillips, J.; Uddin, L.Q.; Menon, V. *Brain Organization Underlying Superior Mathematical Abilities in Children with Autism.* *Biological Psychiatry* 2014, 75, 223–230, doi:10.1016/j.biopsych.2013.06.018.
35. Insausti, R.; Córcoles-Parada, M.; Ubero, M.M.; Rodado, A.; Insausti, A.M.; Muñoz-López, M. *Cytoarchitectonic Areas of the Gyrus Ambiens in the Human Brain.* *Front. Neuroanat.* 2019, 13, 21, doi:10.3389/fnana.2019.00021.
36. Gage, N.M.; Baars, B.J.; *Chapter 7 - Learning and Remembering.* In *Fundamentals of Cognitive Neuroscience - A Beginner's Guide*; Academic Press, 2018; Second Edition, pp. 215–246, doi.org/10.1016/B978-0-12-803813-0.00007-6..
37. Mukaka, M.M. *Statistics Corner: A Guide to Appropriate Use of Correlation Coefficient in Medical Research.* *Malawi Med J* 2012, 24, 69–71.
38. Cao, J.; Zhao, Y.; Shan, X.; Wei, H.; Guo, Y.; Chen, L.; Erkoyuncu, J.A.; Sarrigiannis, P.G. *Brain Functional and Effective Connectivity Based on Electroencephalography Recordings: A Review.* *Human Brain Mapping* 2022, 43, 860–879, doi:10.1002/hbm.25683
39. **Coman, D.A.**; Ionita, S.; Lita, I. *Using Multiple Frequency Selection at Each Measurement Channel to Analyze Brain Electrical Activity.* In *Proceedings of the 2022 14th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)*; IEEE: Ploiesti, Romania, June 30 2022;1–6, DOI: 10.1109/ECAI54874.2022.9847429